

# **UTILIZAREA REȚELELOR NEURONALE BAYESIENE LA PROGNOZA CONSUMULUI DE ENERGIE ELECTRICĂ**

Teză destinată obținerii  
titlului științific de doctor inginer  
la  
Universitatea Politehnica Timișoara  
în domeniul INGINERIE ENERGETICĂ  
de către

**Mihaela Daciana MIC (CRĂCIUN)**

Președinte:	Prof.univ.dr.ing. Sorin MUȘUROI
Conducător științific:	Prof.univ.dr.ing. Ștefan KILYENI
Referenți științifici:	Prof.univ.em.dr.ing. Mircea EREMIA Prof.univ.dr.fiz. Adrian PALCU Conf.univ.dr.ing. Constantin BĂRBULESCU

Data susținerii tezei: 01.10.2021

Seriile Teze de doctorat ale UPT sunt:

- |   |   |
|---|---|
| 1. Automatică                               | 11. Știința și Ingineria Materialelor                                   |
| 2. Chimie                                   | 12. Ingineria Sistemelor  |
| 3. Energetică                               | 13. Inginerie Energetică  |
| 4. Inginerie Chimică                        | 14. Calculatoare și Tehnologia Informației                              |
| 5. Inginerie Civilă                         | 15. Ingineria materialelor  |
| 6. Inginerie Electrică                      | 16. Inginerie și Management   |
| 7. Inginerie Electronică și Telecomunicații | 17. Arhitectură   |
| 8. Inginerie Industrială                    | 18. Inginerie Civilă și Instalații                                      |
| 9. Inginerie Mecanică                       | 19. Inginerie Electronică, Telecomunicații și Tehnologii Informaționale |
| 10. Știința Calculatoarelor                 |   |

Universitatea Politehnică Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnică – Timișoara, 2021

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității Politehnică Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300223 Timișoara, Bd. Vasile Pârvan 2B  
Tel./fax 0256 404677  
e-mail: editura@upt.ro

## PREFAȚĂ

Teza de doctorat este rodul activității de mai mulți ani sub îndrumarea permanentă, generoasă și plină de înțelegere a conducătorului științific, Prof.dr.ing. Ștefan Kilyeni, căruia îi adresez cele mai respectuoase și prețioase mulțumiri și pe această cale, atât pentru cultul rigurozității științifice imprimat, cât și pentru modul în care a știut să mă ghideze.

Lucrarea reprezintă o sinteză a rezultatelor de cercetare ale autorului, în perioada octombrie 2016 – iulie 2021, în cadrul studiilor doctorale în domeniul *Inginerie Energetică* la *Universitatea Politehnica Timișoara*.

În acești ani, am avut șansa să particip la soluționarea unor contracte de cercetare încheiate cu societăți de distribuție a energiei electrice și o serie de agenți economici, strâns legate de tema tezei de doctorat, în cadrul *Centrului de Cercetare pentru Analiza și Optimizarea Regimurilor Sistemelor Electroenergetice*, condus de Prof.dr.ing. Ștefan Kilyeni. Aceste activități de cercetare au avut o puternică influență asupra formării și orientării mele profesionale. În acest context, adresez alese mulțumiri Conf.dr.ing. Constantin Bărbulescu, pentru ajutorul acordat, pentru observațiile și sfaturile primite, mereu constructive, pentru îndrumarea și colaborarea permanentă.

Pentru sprijinul acordat în vederea finalizării tezei, doresc să adresez mulțumiri călduroase conducerii Departamentului de Electroenergetică. Îmi exprim gratitudinea față de cadrele didactice din Departamentul de Electroenergetică – m-au încurajat și mi-au oferit un real ajutor. În mod special membrilor comisiei de îndrumare, care în toți acești ani i-am simțit alături de mine, cu sfaturi și critici binevenite, de un real folos pentru finalizarea tezei: Conf.dr.ing. Gheorghe Vuc, Conf.dr.ing. Florin Molnar, Șef lucr.dr.ing. Ioan Borlea (și Șef lucr.dr.ing. Dan Jigoria-Oprea în prima perioadă).

Pe parcursul elaborării tezei am avut o conlucrare deosebit de constructivă cu Asist.dr.ing. Antheia Deacu și Șef lucr.dr.ing. Violeta Chiș, materializată și prin lucrări publicate împreună. Mi-au pus la dispoziție rezultatele obținute în tezele lor de doctorat, care au tratat tot problema prognozei consumului, abordată cu metode alternative.

Doresc să remarc, alăturând recunoștința mea, ajutorul de care am beneficiat din partea unor specialiști din cadrul Enel Distribuție Banat, prin asigurarea suportului pentru partea aplicativă a tezei.

Mulțumiri și colegilor din cadrul Departamentului de Matematică – Informatică, Universitatea "Aurel Vlaicu" din Arad, unde îmi desfășor activitatea, pentru atmosfera de reală prietenie și colegialitate, fără de care elaborarea tezei ar fi fost mai dificilă.

Mulțumesc în mod deosebit, și pe această cale, membrilor comisiei de analiză a tezei de doctorat, Prof.univ.em.dr.ing. Mircea Eremia (Universitatea Politehnica din București), Prof.univ.dr. Adrian Palcu (Universitatea "Aurel Vlaicu" din Arad, Universitatea de Vest din Timișoara) și Conf.dr.ing. Constantin Bărbulescu (Universitatea Politehnica Timișoara), pentru atenția cu care au parcurs teza de doctorat, pentru observațiile și aprecierile formulate, pentru sfaturile primite.

Nu în ultimul rând, doresc să adresez cele mai sincere mulțumiri familiei, pentru sprijinul și înțelegerea acordate în toți acești ani.

Timișoara, iulie 2021

*Michaela Crăciun*

Mic (Crăciun), Mihaela Daciana

## **UTILIZAREA REȚELELOR NEURONALE BAYESIENE LA PROGNOZA CONSUMULUI DE ENERGIE ELECTRICĂ**

Cuvinte cheie: sisteme electroenergetice, consum de energie electrică, curbe de sarcină, prognoză, rețele neuronale bayesiene

Rezumat: tematica tezei de doctorat se încadrează în preocupările actuale din domeniul managementului transportului, distribuției și consumului energiei electrice. La modul general, s-au avut în vedere două obiective esențiale: activitatea de prognoză (a consumului de energie electrică și de putere, a curbelor de sarcină) și utilizarea unor tehnici moderne, eficiente, bazate pe inteligența artificială (în principal rețele neuronale artificiale bayesiene) pentru obținerea prognozelor.

Metodologiile elaborate în cadrul tezei au la bază o abordare teoretică riguroasă, materializată prin realizarea și implementarea unor instrumente soft de aplicabilitate generală, utile atât operatorilor de distribuție și de transport din România cât și agenților economici cu preocupări în domeniul implementării surselor regenerabile distribuite de energie. Programele de calcul au fost realizate în mediul de programare Matlab. Ele utilizează cu eficiență posibilitățile oferite de mediile de programare avansate și de sistemele de calcul actuale.

Aplicațiile concrete se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea componente: Timișoara, Arad, Deva și Reșița. Au fost efectuate o serie de studii de prognoză dedicate stațiilor de transformare de 110 kV / m.t. din cadrul UTR Timișoara. Dintre aceste stații au fost selectate pentru prezentare în detaliu în cadrul tezei 5 stații semnificative de 110 / 20 kV (3 din municipiul Timișoara, una dintr-o localitate importantă a jud. Timiș și una care alimentează o exploatare petrolieră): Bucovina, IMT, Musicescu, Deta și Satchinez.

# CUPRINS

<b>CUPRINS</b> .....	5
<b>ACRONIME</b> .....	9
<b>LISTA DE FIGURI</b> .....	11
<b>LISTA DE TABELE</b> .....	17
<b>1. INTRODUCERE</b> .....	27
<b>2. TEORIA REȚELELOR NEURONALE BAYESIENE</b> .....	33
2.1. Elemente de probabilități și statistică.....	33
2.1.1. Independență. Probabilități condiționate. Teorema lui Bayes .....	33
2.1.2. Probabilități – interpretare frecventistă vs. subiectivistă .....	36
2.1.2.1. Interpretare frecventistă (obiectivistă) .....	36
2.1.2.2. Interpretare subiectivistă (bayesiană) .....	36
2.1.3. Legi de probabilitate .....	37
2.1.3.1. Considerații preliminare .....	37
2.1.3.2. Legea de probabilitate normală (Gauss-Laplace) .....	37
2.1.3.3. Legea de probabilitate log-normală .....	39
2.2. Modelare probabilistică și învățare automată .....	39
2.2.1. Considerații preliminare.....	39
2.2.2. Învățare automată bayesiană (BML – Bayesian Machine Learning)....	40
2.2.3. Metode de aproximare a posteriorului și a probabilităților marginale ...	43
2.2.3.1. Considerații preliminare .....	43
2.2.3.2. Estimarea probabilității MLE .....	43
2.2.3.3. Estimarea probabilității MAP .....	44
2.2.3.4. Minimum Description Length (MDL) .....	44
2.3. Rețele neuronale bayesiene.....	46
2.3.1. RNA "clasică" vs. RNA bayesiană .....	46
2.3.2. Principiile învățării RNA bayesiană .....	48
2.3.2.1. Considerații preliminare .....	48
2.3.2.2. Priorul .....	48
2.3.2.3. Funcția de probabilitate sau modelul cu zgomot .....	49
2.3.2.4. Distribuția posterioară .....	50
2.3.2.5. Aproximarea Gaussiană a distribuției posterioare .....	51
2.3.3. Optimizarea bayesiană a parametrilor de control – <i>cadru evidentă</i> ....	51
2.3.4. Interpretarea numerică a <i>cadrelor evidente</i> .....	53
2.3.5. Selecția variabilelor de intrare prin tehnica bayesiană ARD .....	54
2.3.6. Determinarea barelor de eroare asupra ieșirii RNA.....	54
2.3.7. Selecția modelului bayesian .....	55
2.4. Concluzii .....	56

---

<b>3. APLICAȚII ALE REȚELOR BAYESIENE ÎN DOMENIUL INGINERIEI SISTEMELOR ELECTROENERGETICE</b> .....	57
3.1. Considerații preliminare .....	57
3.2. Aplicații în domeniul fiabilității rețelelor și sistemelor electroenergetice .....	58
3.3. Aplicații în domeniul estimării stării sistemelor electroenergetice.....	60
3.4. Aplicații în domeniul analizei stabilității sistemelor electroenergetice.....	62
3.5. Aplicații în domeniul diagnozei și localizării defectelor .....	62
3.6. Alte aplicații ale rețelelor bayesiene.....	64
3.7. Concluzii .....	66
<b>4. PROGNOZA CONSUMULUI DE ENERGIE ELECTRICĂ</b> .....	67
4.1. Clasificarea metodelor de prognoză .....	67
4.2. Metode pentru prognoze pe termen mediu și lung .....	69
4.3. Metode pentru prognoze pe termen scurt.....	70
4.4. Utilizare rețelelor neuronale bayesiene în studiile de prognoză .....	76
4.5. Concluzii .....	81
<b>5. REȚELE NEURONALE ARTIFICIALE (RNA)</b> .....	83
5.1. Prezentarea generală a RNA .....	83
5.1.1. Considerații preliminare .....	83
5.1.2. Clasificarea RNA.....	84
5.2. Modelul RNA.....	85
5.2.1. Modelul neuronului artificial .....	85
5.2.2. Structura RNA .....	87
5.2.3. Învățarea RNA .....	87
5.2.3.1. Considerații preliminare .....	87
5.2.3.2. Învățarea supervizată .....	88
5.2.3.3. Învățarea nesupervizată .....	91
5.3. Rețele neuronale de tip perceptron.....	92
5.3.1. RNA de tip perceptron cu un singur strat .....	92
5.3.2. RNA de tip perceptron cu mai multe straturi .....	93
5.4. Concluzii .....	97
<b>6. MODEL MATEMATIC ȘI INSTRUMENT SOFT PENTRU PROGNOZA CONSUMULUI DE ENERGIE ELECTRICĂ ȘI DE PUTERE</b> .....	99
6.1. Tehnica bayesiană .....	99
6.1.1. Considerații preliminare .....	99
6.1.2. Principiile inferenței bayesiene.....	100
6.1.3. Priorul în RNA.....	101
6.1.4. Calculul funcției erorii și funcției gradientului.....	102
6.1.5. Procedura Cadru Evidență.....	103
6.1.6. Predicția pentru regresie și barele de eroare .....	106
6.2. Metoda de optimizare – Gradient Conjugat Scalat .....	107
6.3. Instrumentul software RNA bayesiană .....	110
6.3.1. Considerații preliminare.....	110
6.3.2. Funcțiile Netlab utilizate .....	110
6.3.3. Implementarea modelului matematic în instrumentul soft.....	114
6.4. Concluzii .....	118

---

<b>7. STUDII DE CAZ ȘI REZULTATE</b> .....	119
7.1. Validarea prin comparații a metodelor elaborate.....	119
7.1.1. Considerații preliminare.....	119
7.1.2. Comparații pentru UTR Reșița și ansamblul Enel Banat .....	120
7.1.2.1. Considerații preliminare .....	120
7.1.2.2. UTR Reșița .....	121
7.1.2.3. Enel Banat .....	126
7.1.3. Comparații stația de 110 / 20 kV Victoria.....	131
7.1.3.1. Considerații preliminare .....	131
7.1.3.2. Stația Victoria.....	132
7.1.4. Concluzii privind studiile comparative.....	150
7.2. Enel Distribuție Banat și UTR componente .....	151
7.2.1. Considerații preliminare.....	151
7.2.2. UTR Arad .....	151
7.2.3. UTR Deva .....	156
7.2.4. UTR Reșița.....	158
7.2.5. UTR Timișoara .....	160
7.2.6. Enel Banat .....	163
7.2.7. Analiza comparativă a rezultatelor .....	165
7.2.8. Previzionarea calității prognozelor pentru UTR .....	167
7.3. Stații din cadrul Enel Distribuție Banat .....	171
7.3.1. Considerații preliminare.....	171
7.3.2. Stația Bucovina .....	171
7.3.2.1. Prima zi de miercuri a fiecărei luni, ora 9 .....	171
7.3.2.2. Prima zi de miercuri a fiecărei luni, ora 21.....	173
7.3.2.3. A doua zi de joi a fiecărei luni, ora 9.....	175
7.3.2.4. A doua zi de joi a fiecărei luni, ora 21 .....	176
7.3.2.5. Ultima zi de marți a fiecărei luni, ora 9 .....	178
7.3.2.6. Ultima zi de marți a fiecărei luni, ora 21.....	179
7.3.3. Stația IMT.....	181
7.3.3.1. Prima zi de miercuri a fiecărei luni, ora 9 .....	181
7.3.3.2. Prima zi de miercuri a fiecărei luni, ora 21.....	182
7.3.3.3. A doua zi de joi a fiecărei luni, ora 9.....	183
7.3.3.4. A doua zi de joi a fiecărei luni, ora 21 .....	184
7.3.3.5. Ultima zi de marți a fiecărei luni, ora 9 .....	185
7.3.3.6. Ultima zi de marți a fiecărei luni, ora 21.....	185
7.3.4. Stația Musicescu.....	186
7.3.4.1. Prima zi de miercuri a fiecărei luni, ora 9 .....	186
7.3.4.2. Prima zi de miercuri a fiecărei luni, ora 21.....	188
7.3.4.3. A doua zi de joi a fiecărei luni, ora 9.....	189
7.3.4.4. A doua zi de joi a fiecărei luni, ora 21 .....	190
7.3.4.5. Ultima zi de marți a fiecărei luni, ora 9 .....	190
7.3.4.6. Ultima zi de marți a fiecărei luni, ora 21.....	191
7.3.5. Stația Deta .....	192
7.3.5.1. Prima zi de miercuri a fiecărei luni, ora 9 .....	192
7.3.5.2. Prima zi de miercuri a fiecărei luni, ora 21.....	193
7.3.5.3. A doua zi de joi a fiecărei luni, ora 9.....	194
7.3.5.4. A doua zi de joi a fiecărei luni, ora 21 .....	195
7.3.5.5. Ultima zi de marți a fiecărei luni, ora 9 .....	196
7.3.5.6. Ultima zi de marți a fiecărei luni, ora 21.....	197

---

7.3.6. Stația Satchinez .....	198
7.3.6.1. Prima zi de miercuri a fiecărei luni, ora 9 .....	198
7.3.6.2. Prima zi de miercuri a fiecărei luni, ora 21.....	199
7.3.6.3. A doua zi de joi a fiecărei luni, ora 9.....	200
7.3.6.4. A doua zi de joi a fiecărei luni, ora 21 .....	201
7.3.6.5. Ultima zi de marți a fiecărei luni, ora 9 .....	202
7.3.6.6. Ultima zi de marți a fiecărei luni, ora 21.....	202
7.3.7. Analiza comparativă a rezultatelor .....	203
7.3.8. Previzionarea calității prognozelor pentru stații.....	206
7.4. Concluzii .....	215
<b>8. CONCLUZII GENERALE. CONTRIBUȚII PERSONALE .....</b>	<b>217</b>
<b>BIBLIOGRAFIE .....</b>	<b>221</b>
<b>SINTEZA PRIVIND LUCRĂRILE PROPRII .....</b>	<b>233</b>
<b>ANEXA 7.1. COMPARAȚII PROGNOZE (CD).....</b>	<b>235</b>
A7.1.2.2. UTR Reșița.....	235
A7.1.2.3. Enel Banat.....	237
A7.1.3.2. Stația Victoria .....	240
<b>ANEXA 7.2. PROGNOZE UNITĂȚI TERITORIALE REȚEA (CD) .....</b>	<b>247</b>
A7.2.2. UTR Arad .....	247
A7.2.3. UTR Deva .....	249
A7.2.4. UTR Reșița .....	251
A7.2.5. UTR Timișoara .....	254
A7.2.6. Enel Banat.....	256
<b>ANEXA 7.3. PROGNOZE STAȚII (CD) .....</b>	<b>259</b>
A7.3.2. Stația Bucovina.....	259
A7.3.3. Stația IMT .....	267
A7.3.4. Stația Musicescu .....	277
A7.3.5. Stația Deta .....	289
A7.3.6. Stația Satchinez .....	301
A7.3.7. Analiza comparativă a rezultatelor.....	313



## ACRONIME

AE	- Algoritm Evolutiv
AG	- Algoritm Genetic
AMI	- Advanced Metering Infrastructure
AMM	- Advanced Metering Management
AMR	- Automated Meter Reading
ANFIS	- Adaptive Neuro-Fuzzy Inference System
ANN	- Artificial Neural Network
ARD	- Automatic Relevance Determination
ARIMA	- Autoregressive Integrated Moving Average
ARIMAX	- Autoregressive Integrated Moving Average with Exogenous Variables
ARMA	- Autoregressive Moving Average
ARMAX	- Autoregressive Moving Average with Exogenous Variables
BAM	- Bidirectional Associative Memory
BIC	- Bayesian Information Criterion
BL	- Bayesian Learning
BML	- Bayesian Machine Learning
BNN	- Bayesian Neural Network
BNP	- Bayesian Non-Parametric
CG	- Conditional Gaussian
CMMP	- Cele Mai Mici Pătrate
c.p.t	- Consum Propriu Tehnologic
CPT	- Conditional Probability Table
DAEM	- Day-Ahead Energy Market
EM	- Expectation Maximization
EP	- Expectation Propagation
EUNITE	- European Network on Intelligent TEchnologies for Smart Adaptive Systems
EXAA	- Energy Exchange Austria
FOB	- Funcție Obiectiv
GP	- Gaussian Process
IA	- Inteligență Artificială
LASSO	- Least Absolute Shrinkage and Selection Operator
MAE	- Mean Absolute Error
MAP	- Maximum A Posterior
MAPE	- Mean Absolute Percent Error
MCMC	- Markov Chain Monte Carlo

## 10 Acronime

---

MCP	- McCulloch-Pitts
MDL	- Minimum Description Length
ML	- Machine Learning
MLE	- Maxim Likelihood Estimation
MLK	- Marginal Likelihood
MLP	- Multilayer Perceptron
MP	- Most Probable
MSE	- Mean Squared Error
m.t.	- medie tensiune
NA	- Neuron Artificial
OPCOM	- Operatorul Pieței de Energie Electrică
PCA	- Principal Component Analysis
PCCB	- Piața Centralizată a Contractelor Bilaterale
PDF	- Probability Density Function
PI	- Piața Intra-zilnică
PPC	- Problemă de Programare Convexă
PPN	- Probleme de Programare Neliniară
PPP	- Problemă de Programare Pătratică
PSO	- Particular Swarm Optimization
PTSC	- Prognoză pe Termen Scurt a Consumului
PZU	- Piața pentru Ziua Următoare
RB	- Rețea Bayesiană
RBD	- Rețea Bayesiană Dinamică
RBH	- Rețea Bayesiană Hibridă
RMSE	- Root Mean Square Error
RNA	- Rețea Neuronală Artificială
RR	- Relație de Restricție
SA	- Simulated Annealing
SCADA	- Supervisory Control and Data Acquisition
SCG	- Scaled Conjugate Gradient
SEE	- Sistem ElectroEnergetic
SEN	- Sistemul Electroenergetic Național al României
SSM	- State-Space Models
SVM	- Support Vector Machine
TS	- Tabu Search
UE	- Uniunea Europeană
UTR	- Unități Teritoriale Rețea
VBL	- Variational Bayesian Learning
VLSI	- Very Large Scale Integration

## LISTA DE FIGURI

Nr. crt.	Numărul figurii	Titlul figurii
1.	Fig. 2.1.1.	Graficul funcției de densitate de probabilitate, $m = 0, \sigma = 1$
2.	Fig. 2.1.2.	Graficul funcției de repartiție $\Phi$
3.	Fig. 2.1.3.	Graficele densităților variabilelor normale pentru $\sigma = \overline{1,4}$
4.	Fig. 2.2.1.	Fluxul de actualizare a distribuției de probabilitate prior și posterioară generat de datele observate (evidence)
5.	Fig. 2.2.2.	Alegea claselor de modele bazată pe Lama lui Occam
6.	Fig. 5.1.1.	Arhitectura generală a unei rețele neuronale
7.	Fig. 5.2.1.	Neuronul artificial (NA)
8.	Fig. 5.2.2.	Arhitectura unui sistem cu învățare supervizată
9.	Fig. 5.3.1.	Arhitectura perceptronului simplu
10.	Fig. 5.3.2.	Structura unei rețele neuronale organizată pe mai multe straturi
11.	Fig. 7.1.1.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
12.	Fig. 7.1.2.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
13.	Fig. 7.1.3.	Analiza comparativă a rezultatelor pentru anul 2011
14.	Fig. 7.1.4.	Analiza comparativă a rezultatelor pentru anul 2012
15.	Fig. 7.1.5.	Analiza comparativă a rezultatelor pentru anul 2013
16.	Fig. 7.1.6.	Analiza comparativă a rezultatelor pentru anul 2011
17.	Fig. 7.1.7.	Analiza comparativă a rezultatelor pentru anul 2012
18.	Fig. 7.1.8.	Analiza comparativă a rezultatelor pentru anul 2013
19.	Fig. 7.1.9.	Analiza comparativă a rezultatelor pentru anul 2011
20.	Fig. 7.1.10.	Analiza comparativă a rezultatelor pentru anul 2012
21.	Fig. 7.1.11.	Analiza comparativă a rezultatelor pentru anul 2013
22.	Fig. 7.1.12.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
23.	Fig. 7.1.13.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
24.	Fig. 7.1.14.	Analiza comparativă a rezultatelor pentru anul 2011
25.	Fig. 7.1.15.	Analiza comparativă a rezultatelor pentru anul 2012
26.	Fig. 7.1.16.	Analiza comparativă a rezultatelor pentru anul 2013
27.	Fig. 7.1.17.	Analiza comparativă a rezultatelor pentru anul 2011
28.	Fig. 7.1.18.	Analiza comparativă a rezultatelor pentru anul 2012
29.	Fig. 7.1.19.	Analiza comparativă a rezultatelor pentru anul 2013
30.	Fig. 7.1.20.	Analiza comparativă a rezultatelor pentru anul 2011
31.	Fig. 7.1.21.	Analiza comparativă a rezultatelor pentru anul 2012
32.	Fig. 7.1.22.	Analiza comparativă a rezultatelor pentru anul 2013
33.	Fig. 7.1.23.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)
34.	Fig. 7.1.24.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)
35.	Fig. 7.1.25.	Analiza comparativă a rezultatelor pentru anul 2012
36.	Fig. 7.1.26.	Analiza comparativă a rezultatelor pentru anul 2013
37.	Fig. 7.1.27.	Analiza comparativă a rezultatelor pentru anul 2012
38.	Fig. 7.1.28.	Analiza comparativă a rezultatelor pentru anul 2013

<b>Nr. crt.</b>	<b>Numărul figurii</b>	<b>Titlul figurii</b>
39.	Fig. 7.1.29.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)
40.	Fig. 7.1.30.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)
41.	Fig. 7.1.31.	Analiza comparativă a rezultatelor pentru anul 2012
42.	Fig. 7.1.32.	Analiza comparativă a rezultatelor pentru anul 2013
43.	Fig. 7.1.33.	Analiza comparativă a rezultatelor pentru anul 2012
44.	Fig. 7.1.34.	Analiza comparativă a rezultatelor pentru anul 2013
45.	Fig. 7.1.35.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)
46.	Fig. 7.1.36.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)
47.	Fig. 7.1.37.	Analiza comparativă a rezultatelor pentru anul 2012
48.	Fig. 7.1.38.	Analiza comparativă a rezultatelor pentru anul 2013
49.	Fig. 7.1.39.	Analiza comparativă a rezultatelor pentru anul 2012
50.	Fig. 7.1.40.	Analiza comparativă a rezultatelor pentru anul 2013
51.	Fig. 7.1.41.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)
52.	Fig. 7.1.42.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)
53.	Fig. 7.1.43.	Analiza comparativă a rezultatelor pentru anul 2012
54.	Fig. 7.1.44.	Analiza comparativă a rezultatelor pentru anul 2013
55.	Fig. 7.1.45.	Analiza comparativă a rezultatelor pentru anul 2012
56.	Fig. 7.1.46.	Analiza comparativă a rezultatelor pentru anul 2013
57.	Fig. 7.1.47.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)
58.	Fig. 7.1.48.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)
59.	Fig. 7.1.49.	Analiza comparativă a rezultatelor pentru anul 2012
60.	Fig. 7.1.50.	Analiza comparativă a rezultatelor pentru anul 2013
61.	Fig. 7.1.51.	Analiza comparativă a rezultatelor pentru anul 2012
62.	Fig. 7.1.52.	Analiza comparativă a rezultatelor pentru anul 2013
63.	Fig. 7.1.53.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)
64.	Fig. 7.1.54.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)
65.	Fig. 7.1.55.	Analiza comparativă a rezultatelor pentru anul 2012
66.	Fig. 7.1.56.	Analiza comparativă a rezultatelor pentru anul 2013
67.	Fig. 7.1.57.	Analiza comparativă a rezultatelor pentru anul 2012
68.	Fig. 7.1.58.	Analiza comparativă a rezultatelor pentru anul 2013
69.	Fig. 7.2.1.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)
70.	Fig. 7.2.2.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)
71.	Fig. 7.2.3.	Analiza comparativă a rezultatelor pentru anul 2016
72.	Fig. 7.2.4.	Analiza comparativă a rezultatelor pentru anul 2017
73.	Fig. 7.2.5.	Analiza comparativă a rezultatelor pentru anul 2018
74.	Fig. 7.2.6.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)
75.	Fig. 7.2.7.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)
76.	Fig. 7.2.8.	Analiza comparativă a rezultatelor pentru anul 2016
77.	Fig. 7.2.9.	Analiza comparativă a rezultatelor pentru anul 2017
78.	Fig. 7.2.10.	Analiza comparativă a rezultatelor pentru anul 2018
79.	Fig. 7.2.11.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)
80.	Fig. 7.2.12.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)
81.	Fig. 7.2.13.	Analiza comparativă a rezultatelor pentru anul 2016
82.	Fig. 7.2.14.	Analiza comparativă a rezultatelor pentru anul 2017
83.	Fig. 7.2.15.	Analiza comparativă a rezultatelor pentru anul 2018
84.	Fig. 7.2.16.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)
85.	Fig. 7.2.17.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

<b>Nr. crt.</b>	<b>Numărul figurii</b>	<b>Titlul figurii</b>
86.	Fig. 7.2.18.	Analiza comparativă a rezultatelor pentru anul 2016
87.	Fig. 7.2.19.	Analiza comparativă a rezultatelor pentru anul 2017
88.	Fig. 7.2.20.	Analiza comparativă a rezultatelor pentru anul 2018
89.	Fig. 7.2.21.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)
90.	Fig. 7.2.22.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)
91.	Fig. 7.2.23.	Analiza comparativă a rezultatelor pentru anul 2016
92.	Fig. 7.2.24.	Analiza comparativă a rezultatelor pentru anul 2017
93.	Fig. 7.2.25.	Analiza comparativă a rezultatelor pentru anul 2018
94.	Fig. 7.3.1.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)
95.	Fig. 7.3.2.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)
96.	Fig. 7.3.3.	Analiza comparativă a rezultatelor pentru anul 2017
97.	Fig. 7.3.4.	Analiza comparativă a rezultatelor pentru anul 2018
98.	Fig. 7.3.5.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)
99.	Fig. 7.3.6.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)
100.	Fig. 7.3.7.	Analiza comparativă a rezultatelor pentru anul 2017
101.	Fig. 7.3.8.	Analiza comparativă a rezultatelor pentru anul 2018
102.	Fig. 7.3.9.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)
103.	Fig. 7.3.10.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)
104.	Fig. 7.3.11.	Analiza comparativă a rezultatelor pentru anul 2017
105.	Fig. 7.3.12.	Analiza comparativă a rezultatelor pentru anul 2018
106.	Fig. 7.3.13.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)
107.	Fig. 7.3.14.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)
108.	Fig. 7.3.15.	Analiza comparativă a rezultatelor pentru anul 2017
109.	Fig. 7.3.16.	Analiza comparativă a rezultatelor pentru anul 2018
110.	Fig. 7.3.17.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)
111.	Fig. 7.3.18.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)
112.	Fig. 7.3.19.	Analiza comparativă a rezultatelor pentru anul 2017
113.	Fig. 7.3.20.	Analiza comparativă a rezultatelor pentru anul 2018
114.	Fig. 7.3.21.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)
115.	Fig. 7.3.22.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)
116.	Fig. 7.3.23.	Analiza comparativă a rezultatelor pentru anul 2017
117.	Fig. 7.3.24.	Analiza comparativă a rezultatelor pentru anul 2018
118.	Fig. 7.3.25.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
119.	Fig. 7.3.26.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
120.	Fig. 7.3.27.	Analiza comparativă a rezultatelor pentru anul 2017
121.	Fig. 7.3.28.	Analiza comparativă a rezultatelor pentru anul 2018
122.	Fig. 7.3.29.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
123.	Fig. 7.3.30.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
124.	Fig. 7.3.31.	Analiza comparativă a rezultatelor pentru anul 2017
125.	Fig. 7.3.32.	Analiza comparativă a rezultatelor pentru anul 2018
126.	Fig. 7.3.33.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)

<b>Nr. crt.</b>	<b>Numărul figurii</b>	<b>Titlul figurii</b>
127.	Fig. 7.3.34.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
128.	Fig. 7.3.35.	Analiza comparativă a rezultatelor pentru anul 2017
129.	Fig. 7.3.36.	Analiza comparativă a rezultatelor pentru anul 2018
130.	Fig. 7.3.37.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
131.	Fig. 7.3.38.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
132.	Fig. 7.3.39.	Analiza comparativă a rezultatelor pentru anul 2017
133.	Fig. 7.3.40.	Analiza comparativă a rezultatelor pentru anul 2018
134.	Fig. 7.3.41.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
135.	Fig. 7.3.42.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
136.	Fig. 7.3.43.	Analiza comparativă a rezultatelor pentru anul 2017
137.	Fig. 7.3.44.	Analiza comparativă a rezultatelor pentru anul 2018
138.	Fig. 7.3.45.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
139.	Fig. 7.3.46.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
140.	Fig. 7.3.47.	Analiza comparativă a rezultatelor pentru anul 2017
141.	Fig. 7.3.48.	Analiza comparativă a rezultatelor pentru anul 2018
142.	Fig. 7.3.49.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
143.	Fig. 7.3.50.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
144.	Fig. 7.3.51.	Analiza comparativă a rezultatelor pentru anul 2017
145.	Fig. 7.3.52.	Analiza comparativă a rezultatelor pentru anul 2018
146.	Fig. 7.3.53.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
147.	Fig. 7.3.54.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
148.	Fig. 7.3.55.	Analiza comparativă a rezultatelor pentru anul 2017
149.	Fig. 7.3.56.	Analiza comparativă a rezultatelor pentru anul 2018
150.	Fig. 7.3.57.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
151.	Fig. 7.3.58.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
152.	Fig. 7.3.59.	Analiza comparativă a rezultatelor pentru anul 2017
153.	Fig. 7.3.60.	Analiza comparativă a rezultatelor pentru anul 2018
154.	Fig. 7.3.61.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
155.	Fig. 7.3.62.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
156.	Fig. 7.3.63.	Analiza comparativă a rezultatelor pentru anul 2017
157.	Fig. 7.3.64.	Analiza comparativă a rezultatelor pentru anul 2018

<b>Nr. crt.</b>	<b>Numărul figurii</b>	<b>Titlul figurii</b>
158.	Fig. 7.3.65.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
159.	Fig. 7.3.66.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
160.	Fig. 7.3.67.	Analiza comparativă a rezultatelor pentru anul 2017
161.	Fig. 7.3.68.	Analiza comparativă a rezultatelor pentru anul 2018
162.	Fig. 7.3.69.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
163.	Fig. 7.3.70.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
164.	Fig. 7.3.71.	Analiza comparativă a rezultatelor pentru anul 2017
165.	Fig. 7.3.72.	Analiza comparativă a rezultatelor pentru anul 2018
166.	Fig. 7.3.73.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
167.	Fig. 7.3.74.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
168.	Fig. 7.3.75.	Analiza comparativă a rezultatelor pentru anul 2017
169.	Fig. 7.3.76.	Analiza comparativă a rezultatelor pentru anul 2018
170.	Fig. 7.3.77.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
171.	Fig. 7.3.78.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
172.	Fig. 7.3.79.	Analiza comparativă a rezultatelor pentru anul 2017
173.	Fig. 7.3.80.	Analiza comparativă a rezultatelor pentru anul 2018
174.	Fig. 7.3.81.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
175.	Fig. 7.3.82.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
176.	Fig. 7.3.83.	Analiza comparativă a rezultatelor pentru anul 2017
177.	Fig. 7.3.84.	Analiza comparativă a rezultatelor pentru anul 2018
178.	Fig. 7.3.85.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
179.	Fig. 7.3.86.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
180.	Fig. 7.3.87.	Analiza comparativă a rezultatelor pentru anul 2017
181.	Fig. 7.3.88.	Analiza comparativă a rezultatelor pentru anul 2018
182.	Fig. 7.3.89.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
183.	Fig. 7.3.90.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
184.	Fig. 7.3.91.	Analiza comparativă a rezultatelor pentru anul 2017
185.	Fig. 7.3.92.	Analiza comparativă a rezultatelor pentru anul 2018
186.	Fig. 7.3.93.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
187.	Fig. 7.3.94.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
188.	Fig. 7.3.95.	Analiza comparativă a rezultatelor pentru anul 2017

---

<b>Nr. crt.</b>	<b>Numărul figurii</b>	<b>Titlul figurii</b>
189.	Fig. 7.3.96.	Analiza comparativă a rezultatelor pentru anul 2018
190.	Fig. 7.3.97.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
191.	Fig. 7.3.98.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
192.	Fig. 7.3.99.	Analiza comparativă a rezultatelor pentru anul 2017
193.	Fig. 7.3.100.	Analiza comparativă a rezultatelor pentru anul 2018
194.	Fig. 7.3.101.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
195.	Fig. 7.3.102.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
196.	Fig. 7.3.103.	Analiza comparativă a rezultatelor pentru anul 2017
197.	Fig. 7.3.104.	Analiza comparativă a rezultatelor pentru anul 2018
198.	Fig. 7.3.105.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
199.	Fig. 7.3.106.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
200.	Fig. 7.3.107.	Analiza comparativă a rezultatelor pentru anul 2017
201.	Fig. 7.3.108.	Analiza comparativă a rezultatelor pentru anul 2018
202.	Fig. 7.3.109.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
203.	Fig. 7.3.110.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
204.	Fig. 7.3.111.	Analiza comparativă a rezultatelor pentru anul 2017
205.	Fig. 7.3.112.	Analiza comparativă a rezultatelor pentru anul 2018
206.	Fig. 7.3.113.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
207.	Fig. 7.3.114.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
208.	Fig. 7.3.115.	Analiza comparativă a rezultatelor pentru anul 2017
209.	Fig. 7.3.116.	Analiza comparativă a rezultatelor pentru anul 2018
210.	Fig. 7.3.117.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
211.	Fig. 7.3.118.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
212.	Fig. 7.3.119.	Analiza comparativă a rezultatelor pentru anul 2017
213.	Fig. 7.3.120.	Analiza comparativă a rezultatelor pentru anul 2018



## LISTA DE TABELE

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
1.	Tabelul 2.1.1.	Calculul probabilității posteroare aplicând formula lui Bayes
2.	Tabelul 6.3.1.	Funcțiile Netlab utilizate în instrumentul soft RNA bayesiană
3.	Tabelul 7.1.1.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW) (Anexa 7.1)
4.	Tabelul 7.1.2.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
5.	Tabelul 7.1.3.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
6.	Tabelul 7.1.4.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
7.	Tabelul 7.1.5.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
8.	Tabelul 7.1.6.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)
9.	Tabelul 7.1.7.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)
10.	Tabelul 7.1.8.	Valoarea comparativă a indicilor de performanță
11.	Tabelul 7.1.9.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW) (Anexa 7.1)
12.	Tabelul 7.1.10.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
13.	Tabelul 7.1.11.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
14.	Tabelul 7.1.12.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
15.	Tabelul 7.1.13.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW) (Anexa 7.1)
16.	Tabelul 7.2.14.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)
17.	Tabelul 7.1.15.	Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)
18.	Tabelul 7.1.16.	Valoarea comparativă a indicilor de performanță
19.	Tabelul 7.1.17.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW) (Anexa 7.1)
20.	Tabelul 7.1.18.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
21.	Tabelul 7.1.19.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
22.	Tabelul 7.1.20.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
23.	Tabelul 7.1.21.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
24.	Tabelul 7.1.22.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
25.	Tabelul 7.1.23.	Valoarea comparativă a indicilor de performanță
26.	Tabelul 7.1.24.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW) (Anexa 7.1)
27.	Tabelul 7.1.25.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
28.	Tabelul 7.1.26.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
29.	Tabelul 7.1.27.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
30.	Tabelul 7.1.28.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
31.	Tabelul 7.1.29.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
32.	Tabelul 7.1.30.	Valoarea comparativă a indicilor de performanță
33.	Tabelul 7.1.31.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW) (Anexa 7.1)
34.	Tabelul 7.1.32.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
35.	Tabelul 7.1.33.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
36.	Tabelul 7.1.34.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
37.	Tabelul 7.1.35.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
38.	Tabelul 7.1.36.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
39.	Tabelul 7.1.37.	Valoarea comparativă a indicilor de performanță
40.	Tabelul 7.1.38.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW) (Anexa 7.1)
41.	Tabelul 7.1.39.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
42.	Tabelul 7.1.40.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
43.	Tabelul 7.1.41.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
44.	Tabelul 7.1.42.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
45.	Tabelul 7.1.43.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
46.	Tabelul 7.1.44.	Valoarea comparativă a indicilor de performanță
47.	Tabelul 7.1.45.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW) (Anexa 7.1)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
48.	Tabelul 7.1.46.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
49.	Tabelul 7.1.47.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
50.	Tabelul 7.1.48.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
51.	Tabelul 7.1.49.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
52.	Tabelul 7.1.50.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
53.	Tabelul 7.1.51.	Valoarea comparativă a indicilor de performanță
54.	Tabelul 7.1.52.	Curbele de sarcină pentru perioada 2006-2011 (puterile în MW) (Anexa 7.1)
55.	Tabelul 7.1.53.	Curbele de sarcină pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
56.	Tabelul 7.1.54.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
57.	Tabelul 7.1.55.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW) (Anexa 7.1)
58.	Tabelul 7.1.56.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
59.	Tabelul 7.1.57.	Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)
60.	Tabelul 7.1.58.	Valoarea comparativă a indicilor de performanță
61.	Tabelul 7.2.1.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)
62.	Tabelul 7.2.2.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)
63.	Tabelul 7.2.3.	Curbele de sarcină prognozate (puterile în MW) pentru perioada 2016-2018 (RNA bayesiană, curba de sarcină)
64.	Tabelul 7.2.4.	Curbele de sarcină prognozate (puterile în MW) pentru perioada 2016-2018 (RNA bayesiană, orar)
65.	Tabelul 7.2.5.	Valoarea comparativă a indicilor de performanță
66.	Tabelul 7.2.6.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW) (Anexa 7.2)
67.	Tabelul 7.2.7.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
68.	Tabelul 7.2.8.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
69.	Tabelul 7.2.9.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
70.	Tabelul 7.2.10.	Valoarea comparativă a indicilor de performanță
71.	Tabelul 7.2.11.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW) (Anexa 7.2)
72.	Tabelul 7.2.12.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
73.	Tabelul 7.2.13.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
74.	Tabelul 7.2.14.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
75.	Tabelul 7.2.15.	Valoarea comparativă a indicilor de performanță
76.	Tabelul 7.2.16.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW) (Anexa 7.2)
77.	Tabelul 7.2.17.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
78.	Tabelul 7.2.18.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
79.	Tabelul 7.2.19.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
80.	Tabelul 7.2.20.	Valoarea comparativă a indicilor de performanță
81.	Tabelul 7.2.21.	Curbele de sarcină pentru perioada 2006-2015 (puterile în MW) (Anexa 7.2)
82.	Tabelul 7.2.22.	Curbele de sarcină pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
83.	Tabelul 7.2.23.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
84.	Tabelul 7.2.24.	Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW) (Anexa 7.2)
85.	Tabelul 7.2.25.	Valoarea comparativă a indicilor de performanță
86.	Tabelul 7.2.26.	Indicii specifici globali de performanță
87.	Tabelul 7.2.27.	Indicii specifici anuali de performanță (2016)
88.	Tabelul 7.2.28.	Indicii specifici anuali de performanță (2017)
89.	Tabelul 7.2.29.	Indicii specifici anuali de performanță (2018)
90.	Tabelul 7.2.30.	Valorile indicilor pătratici globali caracteristici
91.	Tabelul 7.2.31.	Clasamente pe baza indicilor caracteristici
92.	Tabelul 7.2.32.	Clasamente pe baza indicilor specifici (echivalenți) de performanță
93.	Tabelul 7.2.33.	Comparație clasamente
94.	Tabelul 7.2.34.	Comparație note
95.	Tabelul 7.3.1.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
96.	Tabelul 7.3.2.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
97.	Tabelul 7.3.3.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
98.	Tabelul 7.3.4.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
99.	Tabelul 7.3.5.	Valoarea comparativă a indicilor de performanță
100.	Tabelul 7.3.6.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
101.	Tabelul 7.3.7.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
102.	Tabelul 7.3.8.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
103.	Tabelul 7.3.9.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
104.	Tabelul 7.3.10.	Valoarea comparativă a indicilor de performanță
105.	Tabelul 7.3.11.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
106.	Tabelul 7.3.12.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
107.	Tabelul 7.3.13.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
108.	Tabelul 7.3.14.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
109.	Tabelul 7.3.15.	Valoarea comparativă a indicilor de performanță
110.	Tabelul 7.3.16.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
111.	Tabelul 7.3.17.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
112.	Tabelul 7.3.18.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
113.	Tabelul 7.3.19.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
114.	Tabelul 7.3.20.	Valoarea comparativă a indicilor de performanță
115.	Tabelul 7.3.21.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
116.	Tabelul 7.3.22.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
117.	Tabelul 7.3.23.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
118.	Tabelul 7.3.24.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
119.	Tabelul 7.3.25.	Valoarea comparativă a indicilor de performanță
120.	Tabelul 7.3.26.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
121.	Tabelul 7.3.27.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
122.	Tabelul 7.3.28.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
123.	Tabelul 7.3.29.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
124.	Tabelul 7.3.30.	Valoarea comparativă a indicilor de performanță
125.	Tabelul 7.3.31.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
126.	Tabelul 7.3.32.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
127.	Tabelul 7.3.33.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
128.	Tabelul 7.3.34.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
129.	Tabelul 7.3.35.	Valoarea comparativă a indicilor de performanță
130.	Tabelul 7.3.36.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
131.	Tabelul 7.3.37.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
132.	Tabelul 7.3.38.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
133.	Tabelul 7.3.39.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
134.	Tabelul 7.3.40.	Valoarea comparativă a indicilor de performanță
135.	Tabelul 7.3.41.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
136.	Tabelul 7.3.42.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
137.	Tabelul 7.3.43.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
138.	Tabelul 7.3.44.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
139.	Tabelul 7.3.45.	Valoarea comparativă a indicilor de performanță
140.	Tabelul 7.3.46.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
141.	Tabelul 7.3.47.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
142.	Tabelul 7.3.48.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
143.	Tabelul 7.3.49.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
144.	Tabelul 7.3.50.	Valoarea comparativă a indicilor de performanță
145.	Tabelul 7.3.51.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
146.	Tabelul 7.3.52.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
147.	Tabelul 7.3.53.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
148.	Tabelul 7.3.54.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
149.	Tabelul 7.3.55.	Valoarea comparativă a indicilor de performanță
150.	Tabelul 7.3.56.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
151.	Tabelul 7.3.57.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
152.	Tabelul 7.3.58.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
153.	Tabelul 7.3.59.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
154.	Tabelul 7.3.60.	Valoarea comparativă a indicilor de performanță

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
155.	Tabelul 7.3.61.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
156.	Tabelul 7.3.62.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
157.	Tabelul 7.3.63.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
158.	Tabelul 7.3.64.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
159.	Tabelul 7.3.65.	Valoarea comparativă a indicilor de performanță
160.	Tabelul 7.3.66.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
161.	Tabelul 7.3.67.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
162.	Tabelul 7.3.68.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
163.	Tabelul 7.3.69.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
164.	Tabelul 7.3.70.	Valoarea comparativă a indicilor de performanță
165.	Tabelul 7.3.71.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
166.	Tabelul 7.3.72.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
167.	Tabelul 7.3.73.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
168.	Tabelul 7.3.74.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
169.	Tabelul 7.3.75.	Valoarea comparativă a indicilor de performanță
170.	Tabelul 7.3.76.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
171.	Tabelul 7.3.77.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
172.	Tabelul 7.3.78.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
173.	Tabelul 7.3.79.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
174.	Tabelul 7.3.80.	Valoarea comparativă a indicilor de performanță
175.	Tabelul 7.3.81.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
176.	Tabelul 7.3.82.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
177.	Tabelul 7.3.83.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
178.	Tabelul 7.3.84.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
179.	Tabelul 7.3.85.	Valoarea comparativă a indicilor de performanță
180.	Tabelul 7.3.86.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
181.	Tabelul 7.3.87.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
182.	Tabelul 7.3.88.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
183.	Tabelul 7.3.89.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
184.	Tabelul 7.3.90.	Valoarea comparativă a indicilor de performanță
185.	Tabelul 7.3.91.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
186.	Tabelul 7.3.92.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
187.	Tabelul 7.3.93.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
188.	Tabelul 7.3.94.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
189.	Tabelul 7.3.95.	Valoarea comparativă a indicilor de performanță
190.	Tabelul 7.3.96.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
191.	Tabelul 7.3.97.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
192.	Tabelul 7.3.98.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
193.	Tabelul 7.3.99.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
194.	Tabelul 7.3.100.	Valoarea comparativă a indicilor de performanță
195.	Tabelul 7.3.101.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
196.	Tabelul 7.3.102.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
197.	Tabelul 7.3.103.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
198.	Tabelul 7.3.104.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
199.	Tabelul 7.3.105.	Valoarea comparativă a indicilor de performanță
200.	Tabelul 7.3.106.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
201.	Tabelul 7.3.107.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
202.	Tabelul 7.3.108.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
203.	Tabelul 7.3.109.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
204.	Tabelul 7.3.110.	Valoarea comparativă a indicilor de performanță
205.	Tabelul 7.3.111.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
206.	Tabelul 7.3.112.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)



<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
207.	Tabelul 7.3.113.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
208.	Tabelul 7.3.114.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
209.	Tabelul 7.3.115.	Valoarea comparativă a indicilor de performanță
210.	Tabelul 7.3.116.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
211.	Tabelul 7.3.117.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
212.	Tabelul 7.3.118.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
213.	Tabelul 7.3.119.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
214.	Tabelul 7.3.120.	Valoarea comparativă a indicilor de performanță
215.	Tabelul 7.3.121.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
216.	Tabelul 7.3.122.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
217.	Tabelul 7.3.123.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
218.	Tabelul 7.3.124.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
219.	Tabelul 7.3.125.	Valoarea comparativă a indicilor de performanță
220.	Tabelul 7.3.126.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
221.	Tabelul 7.3.127.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
222.	Tabelul 7.3.128.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
223.	Tabelul 7.3.129.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
224.	Tabelul 7.3.130.	Valoarea comparativă a indicilor de performanță
225.	Tabelul 7.3.131.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
226.	Tabelul 7.3.132.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
227.	Tabelul 7.3.133.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
228.	Tabelul 7.3.134.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
229.	Tabelul 7.3.135.	Valoarea comparativă a indicilor de performanță
230.	Tabelul 7.3.136.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
231.	Tabelul 7.3.137.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
232.	Tabelul 7.3.138.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)

<b>Nr. crt.</b>	<b>Numărul tabelului</b>	<b>Titlul tabelului</b>
233.	Tabelul 7.3.139.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
234.	Tabelul 7.3.140.	Valoarea comparativă a indicilor de performanță
235.	Tabelul 7.3.141.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
236.	Tabelul 7.3.142.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
237.	Tabelul 7.3.143.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
238.	Tabelul 7.3.144.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
239.	Tabelul 7.3.145.	Valoarea comparativă a indicilor de performanță
240.	Tabelul 7.3.146.	Curbele de sarcină pentru perioada 2009-2016 (puterile în MW) (Anexa 7.3)
241.	Tabelul 7.3.147.	Curbele de sarcină pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
242.	Tabelul 7.3.148.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
243.	Tabelul 7.3.149.	Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW) (Anexa 7.3)
244.	Tabelul 7.3.150.	Valoarea comparativă a indicilor de performanță
245.	Tabelul 7.3.151.	Indicii specifici de performanță – analiză exhaustivă
246.	Tabelul 7.3.152.	Indicii specifici de performanță – stația Bucovina (Anexa 7.3)
247.	Tabelul 7.3.153.	Indicii specifici de performanță – stația IMT (Anexa 7.3)
248.	Tabelul 7.3.154.	Indicii specifici de performanță – stația Musicescu (Anexa 7.3)
249.	Tabelul 7.3.155.	Indicii specifici de performanță – stația Deta (Anexa 7.3)
250.	Tabelul 7.3.156.	Indicii specifici de performanță – stația Satchinez (Anexa 7.3)
251.	Tabelul 7.3.157.	Clasament stații
252.	Tabelul 7.3.158.	Clasament zile – marți (Anexa 7.3)
253.	Tabelul 7.3.159.	Clasament zile – miercuri (Anexa 7.3)
254.	Tabelul 7.3.160.	Clasament zile – joi (Anexa 7.3)
255.	Tabelul 7.3.161.	Clasament zile
256.	Tabelul 7.3.162.	Clasament ore – ora 9 (Anexa 7.3)
257.	Tabelul 7.3.163.	Clasament ore – ora 21 (Anexa 7.3)
258.	Tabelul 7.3.164.	Clasament ore
259.	Tabelul 7.3.165.	Valorile indicilor pătratici globali caracteristici
260.	Tabelul 7.3.166.	Clasamente pe baza indicilor specifici (echivalenți) de performanță
261.	Tabelul 7.3.167.	Comparație clasamente
262.	Tabelul 7.3.168.	Comparație note
263.	Tabelul 7.3.169.	Analiza corelării calității prognozei cu indicii de caracteristici (anual, lunar)
264.	Tabelul 7.3.170.	Analiza corelării calității prognozei cu indicii de caracteristici (anual, lunar)

# 1. INTRODUCERE

Creșterea permanentă a consumului de energie, în general, și de energie electrică în special, rămâne în continuare o caracteristică a țărilor dezvoltate și a celor în curs de dezvoltare. Există și perioade temporare de recesiune, trendul general crescător rămâne. În zilele noastre se cercetează noi tehnologii de conversie și de utilizare eficientă a energiei. Sursele neconvenționale de energie (eoliene, fotovoltaice, biomasă și biogaz, micro-hidrocentrale) au o pondere din ce în ce mai accentuată în balanța energetică generală.

Pentru planificarea corectă a dezvoltării instalațiilor de producere, transport și distribuție a energiei electrice se impune ca o necesitate cunoașterea valorii consumului. Evident că nu se poate vorbi despre o anumită valoare fixă, cunoscută, ci despre o valoare prognozată, pe baza istoricului evoluției anterioare. În asemenea situații este vorba de o prognoză pe termen mediu sau lung.

Din punctul de vedere al funcționării eficiente a instalațiilor menționate mai sus și al satisfacerii în condiții cât mai bune a cerințelor utilizatorilor de energie, prezintă interes și prognoza pe termen scurt sau foarte scurt a consumului. În această categorie se înscrie și prognoza puterii maxime zilnice sau cea a curbelor de sarcină (variația puterii consumate pe durata unei zile).

Liberalizarea pieței de energie electrică și procesul de dereglementare au avut ca efect utilizarea și integrarea unor noi modalități, mai eficiente, de producere și de management al consumului. Ca urmare, atât companiile de producere, de transport și distribuție a energiei electrice cât și consumatorii caută căi de creștere a eficienței. Aceasta în condițiile instabilității prețului energiei, îmbătrânirii infrastructurii energetice și noilor reglementări referitoare la protecția mediului. În acest context, prezintă interes și prognoza pe termen scurt a consumului (pentru ziua următoare sau pentru ora următoare).

În România piața de energie s-a liberalizat relativ complet, element care a determinat apariția unei competiții acerbe în domeniu. Tendința de a oferi consumatorului final posibilitatea de alegere a furnizorului de energie electrică a prins viață. Astfel, furnizorii și distribuitorii de energie electrică devin tot mai mult interesați de dezvoltarea de noi strategii orientate către implementarea de soluții de control și asistență a deciziilor.

În concluzie, atât pentru sistemele electroenergetice (SEE) "clasice", reglementate, cât și pentru cele moderne actuale, "dereglementate", caracterizate de integrarea pe scară din ce în ce mai largă a surselor regenerabile de energie, cunoașterea evoluției consumului de energie electrică reprezintă un element important în activitatea decizională.

Indiferent de orizontul de timp pentru care se efectuează prognoza, abordarea problemei se poate face atât prin metode "clasice", bazate pe modelarea matematică și tehnicile de optimizare liniară sau neliniară cunoscute [Kilyeni2015], cât și prin metode care utilizează tehnici moderne, bazate pe inteligența artificială, în special rețelele neuronale artificiale [Kumar 2016], [Singh2017], [Hsu2018], [Jarndal2020]. În toate

situațiile este extrem de importantă cunoașterea istoricului evoluției consumului și a altor elemente care influențează consumul, pentru o perioadă de câteva ori mai mare decât cea pentru care se efectuează prognoza.

În ultimii ani se remarcă utilizarea teoriei bayesiene, rețelelor bayesiene și rețelelor neuronale bayesiene [Nabney2002], [Mackay2003], [Bolstad2004], [Koch 2007], [Russell2010] la soluționarea unor aplicații din domeniul electroenergeticii. Cele mai multe aplicații vizează fiabilitatea rețelelor și sistemelor electroenergetice [Borges 2016], [Sykora2016], [Lorencin2017] și prognoza consumului [Izudheen2019], [Lopez2019], [Sun2019], [Bessani2020], [Sarajcev2020]. Alte domenii de interes: estimarea stării SEE [Angioni2016], [Pegoraro2017], [Petra2017], analiza stabilității SEE [Seppanen2016], [Chevalier2019], diagnoza și localizarea defectelor [WangT2015], [XuB2019] etc.

În acest context, tematica tezei de doctorat se încadrează în preocupările actuale din domeniul managementului transportului, distribuției și consumului energiei electrice. La modul general, s-au avut în vedere două obiective esențiale: activitatea de prognoză (a consumului de energie electrică și de putere, a curbelor de sarcină) și utilizarea unor tehnici de inteligență artificială (în principal rețele neuronale artificiale bayesiene) pentru obținerea prognozelor.

Analizele teoretice sunt finalizate prin tehnici originale de soluționare a modelelor matematice elaborate, implementate în instrumente soft proprii, care utilizează eficient posibilitățile oferite de diversele medii de programare și de sistemele informatice actuale.

S-a pornit de la cazuri relativ simple și de la baze de date test, în scopul validării metodelor propuse și "calibrării" instrumentelor soft. În același scop au fost realizate o serie de studii comparative cu rezultatele obținute în alte teze de doctorat [Deacu2015], [Chiș2015]. În continuare s-au analizat situații reale, vizând operatori de distribuție din România: Enel, Electrica, Delgaz Grid etc.

Din motive de spațiu, pentru partea aplicativă propriu-zisă a tezei s-au selectat o parte dintre studiile de caz privind Enel Distribuție Banat. Ele se referă atât la ansamblul societății de distribuție cât și la principalele unități teritoriale rețea (UTR) componente: UTR Arad, UTR Deva, UTR Reșița și UTR Timișoara. Se prezintă și o serie de rezultate referitoare la stații de transformare de 110 kV / m.t. din cadrul UTR Timișoara. Au fost selectate 5 stații semnificative de 110 / 20 kV (3 din municipiul Timișoara, una dintr-o localitate importantă a jud. Timiș și una care alimentează o exploatare petrolieră): Bucovina, IMT, Musicescu, Deta și Satchinez.

Teza de doctorat se extinde pe 234 de pagini, fiind structurată pe 8 capitole, prefață, 3 anexe (pe suport de informație electronic, 82 pagini) și o amplă listă bibliografică. Ea conține un număr de 213 figuri, scheme și histograme, respectiv 264 tabele. Lista bibliografică cuprinde 207 titluri, remarcându-se prezența unor lucrări semnificative, atât din categoria celor considerate deja "clasice" cât și a celor de dată recentă, apărute în țară sau în publicații de prestigiu din străinătate.

Capitolul 1 are un caracter introductiv. Prima parte cuprinde încadrarea și justificarea tematicii tezei de doctorat, în contextul stadiului actual de evoluție a electroenergeticii, al preocupărilor existente pe plan mondial și în România. Partea a doua realizează o prezentare succintă a conținutului fiecărui capitol al tezei. Ultima parte a capitolului evidențiază atât modul de valorificare a cercetărilor efectuate în cadrul tezei de doctorat (lucrări publicate în reviste de specialitate sau în volumele

unor conferințe internaționale, contracte de cercetare științifică sau asistență tehnică, programe de calcul) cât și utilitatea rezultatelor obținute pentru operatorii de distribuție a energiei electrice (din România, dar nu numai) și pentru alți agenți economici (cu precădere cei care se ocupă de implementarea surselor regenerabile de energie). În final se subliniază perspectivele deschise de această teză de doctorat privind direcțiile posibile de continuare și extindere a investigațiilor.

Se menționează faptul că fiecare dintre capitolele tezei cuprinde un subcapitol final, care, alături de evidențierea concluziilor și a contribuțiilor originale, deschide calea pentru capitolul (capitolele) următoare.

Obiectivul capitolului 2 constă în prezentarea noțiunilor teoretice legate de abordarea bayesiană, de rețelele bayesiene, de rețelele neuronale bayesiene și a unor elemente conexe. Noțiunile respective sunt necesare atât pentru înțelegerea aspectelor prezentate în capitolele următoare, legate de utilizarea conceptelor și modelelor bayesiene în domeniul electroenergeticii cât și a modelului matematic al prognozei consumului de energie și al instrumentului soft aferent.

Prima parte a capitolului trece în revistă o serie de elemente de probabilități și de statistică: probabilități condiționate, interpretare frecventistă vs. subiectivistă a probabilităților, teorema lui Bayes, legile de probabilitate etc. A doua parte se referă la învățarea automată (Machine Learning – ML) în contextul modelării probabiliste: învățarea automată bayesiană (BML), metodele de aproximare a posteriorului și a probabilităților marginale, inferența bayesiană etc. Ultima parte este consacrată exclusiv RNA bayesiene: compararea RNA "clasice" cu cele bayesiene, principiile învățării (antrenării) la RNA bayesiene, optimizarea bayesiană a parametrilor de control (noțiunea de *cadru evidență*, inclusiv abordarea sa numerică).

În capitolul 3 se efectuează o prezentare sistematizată a unor aplicații ale rețelelor bayesiene (RB) în domeniul ingineriei sistemelor electroenergetice. Se trec în revistă o gamă largă de exemple, începând cu fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a sistemului electroenergetic (SEE) în ansamblu, continuând cu estimarea stării SEE, cu analiza stabilității SEE, cu diagnoza și localizarea defectelor în rețelele electrice, diagnoza defectelor legate de transformatoare și generatoare, cu estimarea valorii parametrilor elementelor de rețea (linii electrice, transformatoare) etc. Cele mai numeroase aplicații se regăsesc în domeniul prognozei consumului de energie electrică și putere. Ele vor fi tratate separat, în Capitolul 4, având în vedere că prognoza utilizând rețelele neuronale bayesiene constituie și obiectul acestei teze de doctorat.

Capitolul 4 este destinat prezentării problemelor legate de prognoza consumului de energie electrică (putere de vârf, putere orară, energie consumată, curbe de sarcină etc.) și a metodelor utilizate pentru obținerea prognozei.

Prima parte a capitolului cuprinde aspecte generale legate de prognoză, clasificarea metodelor utilizate după diverse criterii, insistându-se asupra orizontului de timp la care se referă prognoza. Urmează prezentarea propriu-zisă a metodelor, în funcție de orizontul de timp la care se referă, pe baza unui studiu bibliografic consistent. Sunt urmărite atât metodele "clasice", bazate pe modelarea matematică, cât și cele "moderne", de dată mai recentă, utilizând tehnici de inteligență artificială, logică fuzzy, sisteme expert, "support vector machine" (SVM) etc. Un subcapitol aparte, consistent, este dedicat metodelor care utilizează rețele neuronale bayesiene, care constituie obiectul acestei teze de doctorat.

Capitolul 5 are ca obiectiv prezentarea rețelelor neuronale artificiale (RNA). El oferă baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică și putere (capitolul 6).

Prima parte a capitolului trece în revistă o gamă largă de aspecte generale privind RNA: terminologia de bază, structura RNA, clasificarea RNA etc. A doua parte are ca obiect prezentarea modelului RNA. Se pornește de la neuronul artificial și se ajunge la structura RNA. Un paragraf aparte este dedicat tehnicilor de învățare (antrenare) utilizate de RNA – învățarea supravegheată, respectiv cea nesupravegheată. Ultima parte a capitolului este consacrată prezentării rețelelor neuronale artificiale de tip perceptron, cu un singur strat și cu mai multe straturi, cu o atenție specială pentru cele de tip backpropagation.

În capitolul 6 se prezintă atât modelul matematic al prognozei consumului de energie electrică și putere (inclusiv curbe de sarcină) cât și instrumentul soft realizat pe baza modelului respectiv (care va fi utilizat în capitolul următor, care constituie principala parte aplicativă a tezei de doctorat). Au fost folosite elementele teoretice prezentate în capitolele anterioare (2 și 5) ale tezei.

Prima parte a capitolului detaliază tehnica bayesiană în contextul aplicației de prognoză, trecându-se în revistă principiile inferenței bayesiene, priorul RNA, calculul funcțiilor de eroare și al gradientului, procedura *evidență*, predicția și barele de eroare. A doua parte prezintă tehnica de optimizare utilizată în cadrul aplicației – metoda gradientului conjugat scalat (SCG). Ultima parte oferă o serie de detalii despre instrumentul soft care înglobează toate modelele matematice prezentate în acest capitol. A fost conceput în mediul Matlab, utilizând toate facilitățile (de interfață și portabilitate) specifice sistemelor de operare și mediilor informatice actuale. În cadrul aplicației soft au fost implementate și o serie de proceduri din toolbox-ul Netlab al Matlab [Nabney2002], care constituie instrumente utile pentru simularea algoritmilor specifici rețelelor neuronale artificiale.

Capitolul 7 constituie principala partea aplicativă a tezei de doctorat. Se prezintă rezultatele obținute privind prognoza puterii consumate și a curbelor de sarcină utilizând tehnici de inteligență artificială – RNA bayesiene.

Aspectele teoretice, modelele și metodele de calcul elaborate și instrumentele soft prezentate în capitolele anterioare au fost folosite pentru obținerea prognozelor menționate, abordând o gamă largă de studii de caz. S-a pornit de la cazuri relativ simple și de la baze de date test, în scopul validării metodelor propuse și "calibrării" instrumentelor soft.

În același scop au fost realizate o serie de studii comparative cu rezultatele obținute în alte două teze de doctorat [Deacu2015], [Chiș2015]. În continuare s-au analizat situații reale, referitoare la operatori de distribuție din România: Enel, Electrica, Delgaz Grid etc. Din motive de spațiu, pentru acest capitol s-au selectat doar o serie de studii de caz vizând Enel Distribuție Banat. O parte a rezultatelor sunt prezentate în extenso, restul doar în sinteză, detaliile fiind oferite în Anexele 7.1, 7.2 și 7.3 (sub formă electronică).

Primul subcapitol are rolul de a valida modelele de calcul și instrumentele soft elaborate în cadrul acestei teze de doctorat, prin realizarea unor comparații cu rezultatele obținute în [Deacu2015] și [Chiș2015], în scopul demonstrării calităților superioare ale metodelor utilizând RNA bayesiene.

Al doilea subcapitol prezintă o serie de studii de prognoză realizate atât pentru ansamblul rețelei de distribuție din cadrul Enel Distribuție Banat cât și pentru

unitățile teritoriale rețea (UTR) componente: UTR Arad, UTR Deva, UTR Reșița și UTR Timișoara.

Al treilea subcapitol este dedicat stațiilor de transformare de 110 kV / m.t. din cadrul UTR Timișoara. Pentru prezentarea rezultatelor în detaliu au fost selectate 5 stații semnificative de 110 / 20 kV (3 din municipiul Timișoara, una dintr-o localitate importantă a jud. Timiș și una care alimentează o exploatare petrolieră): Bucovina, IMT, Musicescu, Deta și Satchinez.

La finele fiecărui subcapitol în parte și al întregului capitol se prezintă o serie de comentarii și concluzii, cu caracter particular sau vizând aspecte mai generale, atât legat de rezultatele prognozelor cât și de metodele și modelele utilizate. Ele prezintă interes atât operatorilor de distribuție cât și tuturor celor interesați de evoluția viitoare a consumului de energie electrică.

Capitolul 8 cuprinde concluziile generale ale tezei și prezentarea sistematizată a contribuțiilor originale, precum și relieful direcțiilor și perspectivele oferite de teza de doctorat pentru continuarea și extinderea cercetărilor și aplicarea rezultatelor obținute și a experienței acumulate. Metodologiile și programele de calcul elaborate sunt de aplicabilitate generală, constituind un instrument eficient de lucru pentru operatorii de distribuție și de transport, pentru agenții economici cu preocupări în domeniul consumului și producerii de energie electrică.

Anexele cuprind o serie de elemente și de rezultate de detaliu referitoare la studiile de caz prezentate în teza de doctorat.

Rezultatele obținute au fost și vor fi valorificate în cadrul unor contracte de cercetare științifică și asistență tehnică derulate prin Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor de Funcționare a Sistemelor Electroenergetice din cadrul Universității Politehnica Timișoara (director prof.dr.ing. Ștefan Kilyeni), beneficiarii fiind Enel Distribuție Banat și Dobrogea, Electrica Muntenia Nord, Delgaz Grid Iași (operatori importanți de distribuție a energiei electrice în România) și entități economice cu preocupări în domeniul implementării resurselor regenerabile de energie [UPT2017], [UPT2018], [UPT2019], [UPT2020a], [UPT 2020b].

Așa cum rezultă din lista lucrărilor proprii de la finele tezei, activitatea de pregătire prealabilă a doctorandei și rezultatele obținute în perioada de elaborare a lucrării au fost valorificate prin 5 lucrări indexate ISI (2 în reviste, 3 în volumele unor conferințe) [Bucerzan2010], [Crăciun2013], [Bărbulescu2018], [Crăciun2018a], [Csorba2018], 2 lucrări indexate în alte baze de date internaționale (BDI) (1 în revistă, 1 într-un volum de conferință, în curs de indexare ISI) [Crăciun2017], [Bărbulescu 2021] și 2 rapoarte științifice.

Analizele teoretice realizate în cadrul tezei de doctorat, precum și rezultatele practice obținute, deschid o serie de perspective clare de continuare și aprofundare a cercetărilor atât în domeniul prognozei consumului de energie electrică (putere) și a curbelor de sarcină cât și în ceea ce privește utilizarea RB la soluționarea unor alte probleme din domeniul electroenergeticii:

- rafinarea metodelor de soluționare bazate pe utilizarea RNB, în scopul creșterii eficienței și ameliorării performanțelor acestora;
- corelarea istoricului evoluției consumului cu o serie de alți factori (climatici, economici, gradul de implementare a producătorilor neconvenționali), în măsura disponibilității acestora;

- utilizarea RNB în studii de prognoză legate de sursele de energie regenerabilă (puterea sau energia generată, viteza vântului pentru centralele eoliene, iradianța pentru cele fotovoltaice etc.);
- elaborarea unor metode care să elimine sau să corecteze unele date evident eronate în istoricul consumului;
- utilizarea RB în studii legate de fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a SEE în ansamblu, estimarea stării SEE, analiza stabilității SEE, diagnoza și localizarea defectelor în rețelele electrice, diagnoza defectelor legate de transformatoare și generatoare etc.



## 2. TEORIA REȚELELOR NEURONALE BAYESIENE

Obiectivul capitolului 2 constă în prezentarea noțiunilor teoretice legate de abordarea bayesiană, de rețelele bayesiene, de rețelele neuronale bayesiene și a unor elemente conexe. Noțiunile respective sunt necesare atât pentru înțelegerea aspectelor prezentate în capitolele următoare, legate de utilizarea conceptelor și modelelor bayesiene în domeniul electroenergeticii cât și a modelului matematic al prognozei consumului de energie și al instrumentului soft aferent (capitolul 6).

Prima parte a capitolului trece în revistă o serie de elemente de probabilități și de statistică: probabilități condiționate, interpretare frecventistă vs. subiectivistă a probabilităților, teorema lui Bayes, legile de probabilitate etc.

A doua parte se referă la învățarea automată (Machine Learning – ML) în contextul modelării probabiliste: învățarea automată bayesiană (BML), metodele de aproximare a posteriorului și a probabilităților marginale, inferența bayesiană etc.

Ultima parte este consacrată exclusiv RNA bayesiene: compararea RNA "clasice" cu cele bayesiene, principiile învățării (antrenării) la RNA bayesiene, optimizarea bayesiană a parametrilor de control (noțiunea de *cadru evidență*, inclusiv abordarea sa numerică).

### 2.1. Elemente de probabilități și statistică

#### 2.1.1. Independență. Probabilități condiționate. Teorema lui Bayes

Pentru început se consideră utilă prezentarea succintă a unor elemente cu caracter axiomatic despre probabilități, în contextul utilizării rețelelor neuronale bayesiene [Balint2006], [Bolstad2004], [Hajek2019], [Leon2012], [Petrehus2005], [Căbulea2013].

*Definiție:* Un spațiu  $S$  al unei experiențe (probe) este o mulțime de rezultate elementare cu proprietatea că orice rezultat elementar al experienței (probei) aparține mulțimii.

*Axiomele probabilității:* O funcție  $P$  ce asociază fiecărui eveniment  $X \in P(S)$  un număr  $P(X)$ , numit probabilitatea lui  $X$ , astfel încât să fie satisfăcute următoarele axiome:

- $P(X) \geq 0, \forall X \in P(S)$
- $P(S) = 1$
- $X \cap Y = \emptyset \Rightarrow P(X \cup Y) = P(X) + P(Y), \forall X, Y \in P(S)$ , adică  $X$  și  $Y$  – evenimente disjuncte se numește *probabilitate pe spațiul*  $S = \{e_1; e_2; \dots; e_n\}$  [Balint2006].

*Măsură de probabilitate* este funcția  $f : P(S) \rightarrow \mathbb{R}_+^1$ .

Se numește *spațiu de probabilitate* spațiul  $S$  împreună cu măsura probabilistă  $P$ , cu alte cuvinte perechea  $(S; P)$ .

*Propoziție:* Fie  $X \in P(S)$ . Dacă  $X = \emptyset$ ; atunci  $P(X) = 0$ , iar dacă  $X = \{e_1, e_2, \dots, e_k\}$

atunci  $P(X) = \sum_{i=1}^k P(\{e_i\})$ .

*Consecință:* Relația  $P(\{e_i\}) = P(\{e_j\}), \forall i, j = \overline{1, n} \Rightarrow P(\{e_i\}) = \frac{1}{n}, \forall i = \overline{1, n}$  are

loc dacă cele  $n$  evenimente elementare  $e_1, e_2, \dots, e_n$  din spațiul  $S$ , au aceeași probabilitate (adică sunt *egal probabile*).

*Propoziții:*

- Pentru orice  $X \in P(S)$  avem  $P(\overline{X}) = 1 - P(X)$ , unde  $\overline{X}$  este evenimentul complementar lui  $X$ ;
- $\forall X, Y \in P(S)$  are loc egalitatea:  $P(X \cup Y) = P(X) + P(Y) - P(X \cap Y)$  (*regula adunării*);
- $P(\emptyset) = 0$ .

Legat de *evenimente independente* sunt valide următoarele considerații teoretice [Bolstad2004].

În primul rând se definește noțiunea de *probabilitate de uniune*. Se consideră evenimentele  $X$  și  $Y$  din spațiul  $S$ . *Probabilitatea de uniune* a celor două evenimente reprezintă probabilitatea în care ambele evenimente au loc simultan, la aceeași repetiție a experimentului aleator. Cu alte cuvinte probabilitatea de uniune a evenimentelor  $X$  și  $Y$  este probabilitatea intersecției celor două evenimente ale spațiului  $S$ , adică  $P(X \cap Y)$ .

*Definiții:*

- Evenimentele  $X$  și  $Y$  din  $P(S)$  sunt *independente* dacă  $P(X \cap Y) = P(X) \cdot P(Y)$ . Se spune că evenimentele  $X_1; X_2; \dots; X_n$  sunt *independente în totalitate* dacă pentru orice  $1 \leq i_1 < i_2 < \dots < i_s \leq n$ , avem  $P(X_{i_1} \cap X_{i_2} \cap \dots \cap X_{i_s}) = P(X_{i_1}) \cdot P(X_{i_2}) \cdot \dots \cdot P(X_{i_s})$ .
- Se consideră  $X_1; X_2; \dots; X_n$  și  $Y_1; Y_2; \dots; Y_k$  două partiții ale spațiului  $S$ . Dacă  $P(X_i \cap Y_j) = P(X_i) \cdot P(Y_j), \forall i, j; i = \overline{1, n}, j = \overline{1, k}$  se poate spune că *partițiile* sunt *independente*.

*Teoremă:* În cazul în care  $X$  și  $Y$  sunt două evenimente independente, atunci evenimentele  $X$  și  $\overline{Y}$ ,  $\overline{X}$  și  $Y$ ,  $\overline{X}$  și  $\overline{Y}$  sunt de asemenea independente.

*Definiție:* Probabilitatea unui eveniment  $X$ , stabilit în uniunea evenimentelor se numește *probabilitatea marginală*. Acesta se determină prin însumarea lui  $P(X \cap Y)$  și  $P(X \cap \overline{Y})$  folosind axiomele probabilității.

Având definite noțiunile de mai sus, se poate introduce noțiunea de *probabilitate condiționată*.

*Definiție:* Dacă două evenimente  $X$  și  $Y$  nu se pot realiza simultan în cazul efectuării experienței (probei), atunci evenimentele  $X$  și  $Y$  asociate experienței (probei) aleatoare sunt *incompatibile*.

*Probabilitatea evenimentului  $X$  condiționată de  $Y$*  se notează  $P(X|Y)$  sau  $P_Y(X)$

și este definită prin  $P(X|Y) = \frac{P(X \cap Y)}{P(Y)}$ , dacă  $P(Y) \neq 0$ . Această egalitate, scrisă sub

forma  $P(X \cap Y) = P(X|Y) \cdot P(Y)$  este cunoscută sub denumirea de *regula produsului*. Dacă se notează cu  $S_r$  *universul redus* în care apare evenimentul  $X$ , atunci  $S_r = X$  [Balint2006], [Bolstad2004].

*Propoziție:* Pentru  $Y \in P(S)$  fixat, cu  $P(Y) \neq 0$ , oricare ar fi  $X_1, X_2 \in P(S)$ , avem:

- $0 \leq P(X_1|Y) \leq 1$ ;
- $P(S|Y) = 1$ ;
- $X_1, X_2$  – *incompatibile*  $\Rightarrow P((X_1 \cup X_2)|Y) = P(X_1|Y) + P(X_2|Y)$ .

*Teoreme:*

- Dacă  $X$  și  $Y$  sunt evenimente independente având probabilitățile nenule, atunci  $P(X|Y) = P(X)$  și  $P(Y|X) = P(Y)$ ;
- Dacă  $X_1; X_2; \dots; X_n$  sunt niște evenimente care se pot realiza simultan, adică  $P(X_1 \cap X_2 \cap \dots \cap X_n) \neq 0$ , atunci are loc regula produsului generalizată, adică  $P(X_1 \cap X_2 \cap \dots \cap X_n) = P(X_1) \cdot P(X_2|X_1) \cdot P(X_3|(X_1 \cap X_2)) \cdot \dots \cdot P(X_n|(X_1 \cap X_2 \cap \dots \cap X_{n-1}))$ .

*Consecință:* Dacă  $X_1; X_2; \dots; X_n$  sunt niște evenimente independente, atunci  $P(X_1 \cap X_2 \cap \dots \cap X_n) = P(X_1) \cdot P(X_2) \cdot P(X_3) \cdot \dots \cdot P(X_n)$ .

*Teoremă (Formula probabilității totale):* Dacă evenimentele  $X_1; X_2; \dots; X_n$  constituie o partiție a spațiului  $S$  și  $Y \in P(S)$ , atunci  $P(Y) = \sum_{i=1}^n P(X_i) \cdot P(Y|X_i)$ .

*Teoremă (Formula lui Bayes):* Dacă evenimentele  $X_1; X_2; \dots; X_n$  constituie o partiție a spațiului  $S$  și sunt cauza producerii unui eveniment  $Y$ , atunci:

$$P(X_k|Y) = \frac{P(Y|X_k) \cdot P(X_k)}{\sum_{i=1}^n P(Y|X_i) \cdot P(X_i)} \quad (2.1.1)$$

*Definiție:* Probabilitățile  $P(X_i), P(Y|X_i), i = \overline{1, n}$  se numesc *probabilități apriori* și  $P(X_i|Y)$  se numesc *probabilități aposteriori*.

*Observație:* Formula lui Bayes modifică probabilitățile apriori prin incorporarea informației furnizate de realizarea evenimentului  $Y$  [Balint2006].

Pentru a înțelege mai bine teorema lui Bayes universul  $S$  se poate privi ca având două dimensiuni: una observabilă și una neobservabilă. În universul bayesian evenimentele neobservabile  $X_1; X_2; \dots; X_n$  partiționează universul pe fâșii orizontale în timp ce evenimentul observabil  $Y$  este reprezentat de o fâșie verticală. Probabilitatea  $P(Y)$  se determină însumând pe coloană probabilitățile  $P(Y \cap X_i)$ . Fiecare  $P(Y \cap X_i)$  se calculează înmulțind probabilitatea apriori  $P(X_i)$  cu  $P(Y|X_i)$ .

În tabelul 2.1.1 se prezintă calculul probabilității aposteriori. Se poate enunța teorema lui Bayes astfel: probabilitatea posterioară se calculează împărțind produsul dintre probabilitățile apriori la suma produsului probabilităților apriori.

Tabelul 2.1.1. Calculul probabilității posterioare aplicând formula lui Bayes

S	$S_r = X$			
	Apriori			Aposteriori
$X_1$	$P(X_1)$	$P(Y X_1)$	$P(X_1 \cap Y) = P(X_1) \cdot P(Y X_1)$	$P(X_1 Y) = \frac{P(X_1 \cap Y)}{P(Y)}$
$X_2$	$P(X_2)$	$P(Y X_2)$	$P(X_2 \cap Y) = P(X_2) \cdot P(Y X_2)$	$P(X_2 Y) = \frac{P(X_2 \cap Y)}{P(Y)}$
...	...	...	...	...
$X_n$	$P(X_n)$	$P(Y X_n)$	$P(X_n \cap Y) = P(X_n) \cdot P(Y X_n)$	$P(X_n Y) = \frac{P(X_n \cap Y)}{P(Y)}$
			$P(Y) = \sum (P(X_i \cap Y))$	

Utilizarea teoremei lui Bayes se poate rezuma parcurgând următoarele trei etape [Bolstad2004]:

1. se înmulțește probabilitatea apriori pentru fiecare  $X_i$  – aceasta își găsește probabilitatea  $X_i \cap Y$  prin regula de înmulțire;
2. apoi probabilitățile de la pasul 1 se însumează pentru fiecare  $i = \overline{1, n}$  – astfel se determină probabilitatea lui  $Y$  prin legea probabilității totale;
3. se împarte fiecare dintre valorile probabilităților aprior prin suma lor – astfel se determină probabilitatea condiționată a lui  $X_i$  dat de  $Y$ .

## 2.1.2. Probabilități – interpretare frecventistă vs. subiectivistă

### 2.1.2.1. Interpretare frecventistă (obiectivă)

Tematica probabilităților frecventiste este abordată doar în contextul unor experimente aleatorii bine definite. În acest caz interpretarea frecventistă mai poartă denumirea de interpretare "obiectivă", datorită faptului că interpretarea presupune probabilitățile ca fiind componente ale universului fizic.

*Definiție:* Probabilitatea unui eveniment  $X$ , notată  $P(X)$ , reprezintă fracțiunea de universuri posibile în care evenimentul  $X$  este adevărat.

Definiția este corelată cu *interpretarea frecventistă*, care presupune organizarea unui experiment și numărarea în cadrul său a cazurilor în care evenimentul este adevărat.

Dacă se notează numărul de apariții ale unui eveniment  $X$  după  $n$  încercări cu  $n_X$ , atunci  $P(X)$  se calculează astfel:

$$P(X) = \lim_{n \rightarrow \infty} \frac{n_X}{n} \quad (2.1.2)$$

În definiția frecventistă a probabilităților, una din problemele fundamentale constă în faptul că limita unui șir infinit de încercări este independentă de segmentele sale inițiale finite. În cazul în care numărul de încercări efectuate este finit, va apărea o frecvență relativă diferită corespunzătoare fiecărei serii de încercări, chiar dacă probabilitatea reală ar trebui să fie întotdeauna aceeași. Conform [Hajek2011] definiția frecvenței relative devine circulară deoarece în cazul în care probabilitatea poate fi măsurată doar cu o anumită eroare, această eroare de măsurare poate fi la rândul ei exprimată tot doar ca o probabilitate.

În interpretarea obiectivistă rezultatul unui eveniment se bazează fie pe procesul care generează evenimentul fie pe proprietățile fizice obiective ale obiectului.

Definirea probabilităților ca predispoziții este greu de făcut deoarece pentru moment nu se știe ce sunt ele ci doar se presupune ce fac ele. Faptul că frecvențele relative stabile sunt o manifestare a predispozițiilor, adică a probabilităților invariante singulare (ce fac referire la evenimentul considerat în sine, nu la seria de încercări repetate) se reflectă în legea numerelor mari.

În acest tip de abordare, pentru a putea măsura probabilitatea unui proces, este necesar ca acesta să aibă o natură repetitivă.

### 2.1.2.2. Interpretare subiectivistă (bayesiană)

În abordarea subiectivistă, probabilitatea măsoară o certitudine personală, atribuindu-se o probabilitate unei ipoteze, pe când în abordarea frecventistă, testarea ipotezei se face fără a i se atribui o probabilitate inițială.

*Interpretarea subiectivistă* poartă și denumirea de *interpretare bayesiană*. Acest tip de interpretare consideră că probabilitatea unui eveniment este o măsură a convingerii personale respectiv subiective, că evenimentul va avea loc.

Raționamentul cu propoziții a căror valoare de adevăr este incertă este permis în cadrul interpretării subiectiviste. Specificarea unor *probabilități a priori* este necesară pentru evaluarea probabilității unei ipoteze. Probabilitățile a priori sunt apoi actualizate prin datele relevante noi ce apar.

În acest tip de interpretare se aplică *principiul cauzelor insuficiente* (denumirea Laplace) sau *principiul indiferenței* (denumirea Keynes)[Bolstad2004]. Acest principiu afirmă că atunci când există un număr supraunitar  $n$  de posibilități ce îndeplinesc condițiile: mutual exclusive (sau distincte), exhaustive colectiv (ce acoperă toate posibilitățile), distinctibile doar prin denumirilor lor, atunci fiecărei posibilități trebuie să i se atribuie o probabilitate egală cu  $1/n$  ([Bolstad2004]).

Abordarea bayesiană permite îmbinarea naturală a frecvențelor cu raționamentul experților. Probabilitățile numerice pot fi preluate din baze de date, pot fi evaluate de către experți sau pot fi o combinație între cele două variante [Leon2012].

### 2.1.3. Legi de probabilitate

#### 2.1.3.1. Considerații preliminare

Legile de probabilitate urmate de diferite fenomene aleatoare din diverse domenii sunt foarte variate. Aceste legi se aplică în funcție de tipul de variabile aleatoare: discrete sau continue. În cele ce urmează se vor prezenta cele mai semnificative legi de probabilitate.

Variabilele aleatoare continue au asociate următoarele legi de probabilitate sugestive: normală, uniformă, log-normală, Gamma,  $\chi^2$ , Student (Cauchy), Snedecor (Fischer), Weibull. Din lista legilor de probabilitate enumerate mai sus, se prezintă cele care prezintă interes în contextul tezei de doctorat: legea de probabilitate normală și cea log-normală.

#### 2.1.3.2. Legea de probabilitate normală (Gauss-Laplace) – $N(m, \sigma^2)$

Variabila aleatoare  $X$  urmează legea normală (Gauss-Laplace) sau, altfel spus,  $X$  are repartiție normală cu parametrii  $m$  (media) și  $\sigma$  (dispersia),  $m \in \mathbb{R}, \sigma > 0$ , dacă densitatea sa de probabilitate (repartiție) este funcția:



$$f(x; m, \sigma) = \frac{1}{\sigma \cdot \sqrt{2 \cdot \pi}} \cdot e^{-\frac{(x-m)^2}{2 \cdot \sigma^2}} \quad (2.1.3)$$

Se notează cu  $N(m, \sigma^2)$  o variabilă aleatoare cu repartiție normală, având parametrii  $m$  și  $\sigma$ .  $f$  se numește funcția de *densitate de repartiție normală sau gaussiană* [Căbulea2013].

În cazul în care  $m = 0$  și  $\sigma = 1$  funcția  $f$  devine:

$$f(x; 0, 1) = \frac{1}{\sqrt{2 \cdot \pi}} \cdot e^{-\frac{x^2}{2}}, x \in \mathbb{R} \quad (2.1.4)$$

Graficul acestei funcții se regăsește în figura 2.1.1. În acest caz se spune că *variabila aleatoare  $X$  urmează legea normală standard sau legea normală centrată redusă*.

Fig. 2.1.1. Graficul funcției de densitate de probabilitate,  $m = 0$ ,  $\sigma = 1$ Fig. 2.1.2. Graficul funcției de repartiție  $\Phi$ 

Funcția de repartiție a variabilei normale standard se numește funcția lui Laplace (fig. 2.1.2):

$$\Phi(X) = \frac{1}{\sqrt{2 \cdot \pi}} \cdot \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \quad (2.1.5)$$

*Proprietăți* [Căbulea2013], [Petrehus2005]:

- dacă variabila aleatoare  $X$  are repartiție normală cu parametrii  $m$  și  $\sigma$ , atunci valoarea medie și dispersia sa sunt  $M(X) = m$  iar  $D^2(X) = \sigma^2$ ;
- dacă variabilele aleatoare independente  $X$  și  $Y$  au repartiții normale cu parametrii  $m_1$  și  $\sigma_1$ , respectiv  $m_2$  și  $\sigma_2$ , atunci variabilele  $X+Y$  și  $X-Y$  au repartiții normale, cu parametrii  $m_1 \pm m_2$  și  $\sigma = \sqrt{\sigma_1^2 + \sigma_2^2}$ ;
- dacă variabila aleatoare  $X$  are repartiție normală cu parametrii  $m$  și  $\sigma$ , iar  $a, b, k \in \mathbb{R}, k > 0$ , atunci:
  - $P(a < X < b) = \Phi\left(\frac{b-m}{\sigma}\right) - \Phi\left(\frac{a-m}{\sigma}\right)$ ;
  - $P(|X - m| < k \cdot \sigma) = 2 \cdot \Phi(k)$ ;

- dacă  $f_1, f_2, \dots, f_n$  sunt variabile aleatoare independente și normale de tip  $N(m, \sigma)$ , atunci  $\frac{f_1 + f_2 + \dots + f_n}{n}$  este variabilă aleatoare de tip  $N\left(m, \frac{\sigma}{\sqrt{n}}\right)$ .
- pentru  $\sigma$  mare, graficul este mai aplatizat în jurul mediei  $m = 0$  (figura 2.1.3).




Fig. 2.1.3. Graficele densităților variabilelor normale pentru  $\sigma = \overline{1,4}$  [Petrehus2005]

### 2.1.3.3. Legea de probabilitate log-normală – $\log N(m, \sigma)$

Variabila aleatoare  $X$  urmează legea *log-normală* (logaritmică normală) sau altfel spus  $X$  are repartiție *log-normală* cu parametrii  $m$  și  $\sigma$  ( $m \in \mathbb{R}, \sigma > 0$ ), dacă densitatea sa de probabilitate este funcția [Căbulea2013]:

$$f(x; m, \sigma) = \begin{cases} \frac{1}{\sigma \cdot x \cdot \sqrt{2 \cdot \pi}} \cdot e^{-\frac{(\ln x - m)^2}{2\sigma^2}} & , x > 0 \\ 0 & , x \leq 0 \end{cases} \quad (2.1.6)$$

Altfel spus, dacă notăm variabila aleatoare nenegativă  $Y = e^X$ , variabila  $Y$  urmează o repartiție log-normală  $Y \sim \log N(m, \sigma)$  dacă variabila  $\ln Y$  urmează o repartiție normală, adică  $\ln Y \sim N(m, \sigma)$ .

*Proprietăți* ale variabilei aleatoare  $X$ :

- media este  $M(X) = e^{m + \frac{\sigma^2}{2}}$ ;
- dispersia este  $D^2(X) = e^{2m + \sigma^2} \cdot (e^{\sigma^2} - 1)$ .

## 2.2. Modelare probabilistică și învățare automată

### 2.2.1. Considerații preliminare

O definiție a învățării automate (Machine Learning – ML) poate fi următoarea: învățarea automată este un domeniu interdisciplinar axat atât pe fundamentele matematice cât și pe aplicațiile practice ale sistemelor care învață, raționează și acționează.

Învățarea automată poate fi aplicată în diverse domenii, cum ar fi: ingineria, știința calculatoarelor, statistica, științele cognitive și psihologia, neuroștiințele computaționale și, nu în ultimul rând, în economie. În domeniul ingineriei învățarea automată se poate aplica în subdomenii precum: procesarea de semnale, identificarea sistemelor, controlul adaptiv și optimal, teoria informațională respectiv robotică etc.

Dintr-un alt punct de vedere învățarea automată poate fi privit astfel:

- un instrument de metode pentru procesarea datelor (selectează datele într-una dintre multiplele metode posibile; alege metodele care au performanțe teoretice sau empirice bune; face predicții și ia decizii);
- știința învățării modelelor din date (definește un spațiu de modele posibile; învață parametrii și structura modelelor din date; face predicții și ia decizii).

Instrumentele de modelare trebuie să îndeplinească o serie de condiții: să reprezinte fidel incertitudinea în structura modelului și a parametrilor și, de asemenea, zgomotul din datele selectate; să fie automatizată și adaptivă; să fie robustă; să scaleze bine seturi de date de dimensiuni mari.

În cadrul modelării probabilistice sunt descrise date care pot fi observate din sistem. În cazul în care se utilizează teoria probabilității pentru a exprima toate formele de incertitudine și zgomot asociate modelului atunci *probabilitatea inversă* va permite deducerea valorilor necunoscute, adaptate modelului, efectuarea predicțiilor și învățarea din date. Probabilitatea inversă se referă la regula lui Bayes, care precizează cum se fac deducții despre ipoteze din date. Predicția și învățarea pot fi privite ca aplicații ale formulei lui Bayes [Bolstad2004]:

$$P(\text{ipoteza}|\text{date}) = \frac{P(\text{date}|\text{ipoteza}) \cdot P(\text{ipoteza})}{P(\text{date})} \quad (2.2.1)$$

Pe de o parte ML încearcă să învețe modele din date, iar pe de altă parte ea poate fi privită ca un set de instrumente de metode de prelucrare a datelor.

Elementele fundamentale în ML sunt [Mitchell1997], [Barber2012]:

- problemele canonice de tipul clasificare, regresie, estimare a densității;
- reprezentarea încrederii și axioma lui Cox;
- teorema "The Dutch Book" – certitudine asimptotică și consens;
- Lama lui Occam și probabilitatea marginală (Marginal Likelihood – MLK) sau modelul evidenței;
- alegerea priorilor: priori obiectivi, subiectivi, ierarhici, empirici și conjugați.

### 2.2.2. Învățare automată bayesiană (BML – Bayesian Machine Learning)

În cadrul ML totul se bazează pe două reguli simple: regula sumei și cea a produsului [Ghahramani2013].

Regula sumei:

$$P(x) = \sum_y P(x, y) \quad (2.2.2)$$

Regula produsului:

$$P(x, y) = P(x, y) \cdot P(y|x) \quad (2.2.3)$$

Aplicând cele două reguli (sumă și produs) putem rezolva orice problema din domeniul modelării bayesiene, implicit învățarea bayesiană (BL – Bayesian Learning). Când  $y$  este variabilă continuă se înlocuiește suma cu integrala.  $P(x, y)$  reprezintă probabilitatea de uniune.



Din regula sumei și a produsului obținem regula lui Bayes.

$$P(\theta|D, m) = \frac{P(D|\theta, m) \cdot P(\theta|m)}{P(D|m)} \quad (2.2.4)$$

unde:

- $P(D|\theta, m)$  – ipoteza (likelihood) lui  $\theta$  în modelul  $m$ ;
- $P(\theta|m)$  – probabilitatea prior a lui  $\theta$ ;
- $P(\theta|D, m)$  – probabilitatea posterioară a lui  $\theta$  dată de  $D$ ;
- $P(D|m)$  – evidența, factor de normalizare ce asigură faptul că posteriorul integrează la 1, sau probabilitatea marginală sau distribuția normală de probabilitate;
- $m$  – modelul.

Relația de mai sus ne dă răspuns la întrebarea "Ce se poate afirma (cunoaște) despre distribuția parametrului  $\theta$ , după ce s-a observat setul de date  $D$  și s-au folosit cunoștințele pe care le avem despre mecanismul implicit de generare a datelor?"

Inferența se realizează prin perceperea și considerarea evidenței care fixează variabilele în stări cunoscute calculând, în subsidiar, probabilitățile care interesează, condiționate de această evidență.

Evidența se mai numește și probabilitate marginală sau distribuție marginală de probabilitate. Termenul  $P(D|\theta, m)$ , indică probabilitatea ca un model să genereze datele observate.

Teorema lui Bayes arată cum se pot actualiza cunoștințele priori folosind modelul de generare a datelor. Distribuția de probabilitate priori  $P(\theta|m)$  descrie informația care există despre variabilă înainte de a observa datele. După ce setul de date  $D$  este cunoscut, se actualizează distribuția priori la cea posterioară [Ciobanu2019].

O imagine de ansamblu a actualizării ipotezelor din dovezi empirice (*evidence*) este reprezentată în figura 2.2.1.

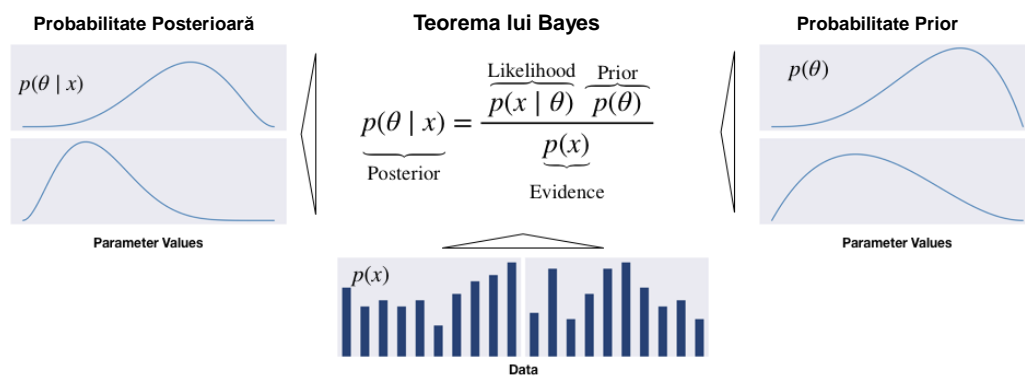


Fig. 2.2.1. Fluxul de actualizare a distribuției de probabilitate prior și posterioară generat de datele observate (*evidence*) [Gutierrez2020]

Predicția se rezumă la egalitatea:

$$P(x|D, m) = \int P(x|\theta, D, m) \cdot P(\theta|D, m) \cdot d\theta \quad (2.2.5)$$

în timp ce, ca și model de comparație, avem relația:

$$P(m|D) = \frac{P(D|m) \cdot P(m)}{P(D)} \quad (2.2.6)$$

unde:

$$P(D|m) = \int P(D|\theta, m) \cdot P(\theta|m) \cdot d\theta \quad (2.2.7)$$

În egalitățile de mai sus  $m$  reprezintă modelul. Modelul este complet când avem toate datele bine definite. Normalizarea  $1/P(D|m)$  este echivalentul probabilității marginale. Normalizarea este importantă când comparăm diferite modele de clase. Învățarea înseamnă a obține probabilități posterioare din date a priori. Pentru predicție nu avem nevoie de algoritmi deoarece putem reveni la cele două reguli (sumă și produs).

În modelare bayesiană nu există regulă de maximizare, ea se folosește în teoria optimizării. Pentru parametrii datelor se aplică suma / integrala. Ultima integrală se numește și probabilitate marginală. În practică trebuie să știm cum calculăm cele două integrale.

În cazul în care avem de comparat mai multe modele se poate aplica *Lama lui Occam* (*Bayesian Occam's Razor*) [Mackay2003].

Se consideră două clase de modele  $m$  și  $m'$ . Utilizând probabilități posterioare date de setul de date  $D$ , avem:

$$p(m|D) = \frac{p(D|m) \cdot p(m)}{p(D)} \quad (2.2.8)$$

unde

$$p(D|m) = \int p(D|\theta, m) \cdot p(\theta|m) \cdot d\theta \quad (2.2.9)$$

În acest caz se poate interpreta probabilitatea marginală (evidența modelului)  $p(D)$ , astfel:

- probabilitatea ca parametrii selectați aleator din prior ar genera setul de date  $D$ ;
- probabilitatea datelor din model integrează la 1 asupra tuturor valorilor posibile ale parametrilor;
- expresia  $\log_2 \left( \frac{1}{P(D|m)} \right)$  reprezintă numărul de biți necesari la observarea datelor

$D$  din modelul  $m$ .

Clase de modele prea simple sunt nepotrivite pentru generarea setului de date. Clasele de modelele prea complexe pot genera multiple seturi de date posibile, astfel încât ele sunt nepotrivite pentru a genera acel set de date particular în mod aleator. Concluzia lui Ockham [Ghahramani2013] – "nu explica lucruri într-un mod mai complex decât este necesar". Interpretarea se regăsește în figura 3.2.2.




Fig. 2.2.2. Alegerea claselor de modele bazată pe Lama lui Occam [Ghahramani2013]

Alegerea priorilor în cadrul ML reprezintă un element fundamental. Priorii în cadrul ML pot fi: obiectivi, subiectivi, ierarhici și empirici.

Revenind la modelul bayesian, calculul ipotezei marginale (marginal likelihood) poate fi greu de gestionat din punctul de vedere al operației calcul. Se utilizează notațiile:  $y$  – date observate,  $x$  – variabilele ascunse,  $\theta$  – parametri,  $m$  – clasa modelului:

$$p(y|m) = \int p(y|\theta, m) \cdot p(\theta|m) \cdot d\theta \quad (2.2.10)$$

Integrala de mai sus poate atinge dimensiuni mari. Prezența variabilelor latente conduce la dimensiuni suplimentare, care trebuie să fie marginalizate în exterior.

$$p(y|m) = \int \int p(y, x|\theta, m) \cdot p(\theta|m) \cdot dx \cdot d\theta \quad (2.2.11)$$

Termenul ipotezei (likelihood) poate fi complicat, singura cale de calcul fiind cea numerică. Situația este similară cu optimizarea.

### 2.2.3. Metode de aproximare a posteriorului și a probabilităților marginale

#### 2.2.3.1. Considerații preliminare

Se utilizează următoarele metode de aproximare a posteriorului și a probabilităților marginale (Marginal Likelihood – MLK): aproximarea Laplace, BIC (Bayesian Information Criterion), aproximarea variațională, propagarea așteptată (EP), metode bazate pe lanțuri Markov (Markov Chain Monte Carlo – MCMC), eșantionare exactă etc.

Înainte de a prezenta metodele concrete, se impune un preambul despre noțiunile MLE (Maximum Likelihood Estimation) și estimarea MAP (Maximum A Posterior), legate de estimarea probabilităților [Mitchell1997], urmat de prezentarea MDL (Minimum Description Length) într-un context care leagă concepte din statistică, teoria informației și filozofie care stau la baza ML.

Pentru a aborda cu succes învățarea parametrilor din setul de date de antrenare disponibil, trebuie să se țină cont de două aspecte:

- acordarea atenției cuvenite modului în care se estimează parametrii de probabilitate din datele disponibile;
- la fel și pentru modul în care se reprezintă distribuțiile probabilităților de uniune.

Două din cele mai utilizate abordări ML legate de modele probabilistice bazate pe datele de antrenare provin din două principii de bază diferite [Mitchell1997]:

- Maximum Likelihood Estimation (MLE) – se caută o estimare a parametrului care maximizează probabilitatea datelor observate;
- Maximum a Posterior (MAP) Estimation – se caută estimarea cea mai probabilă a parametrului, având în vedere datele observate (evidence), și, în plus, se ia în considerare bază de presupuneri despre valoarea parametrului (prior).

MAP diferă de MLE prin faptul că presupune un fundament de cunoștințe disponibil. Ambele principii sunt utilizate pe scară largă pentru a deriva și pentru a justifica o gamă largă de algoritmi ML, de la rețelele bayesiene (RB) până la regresia liniară și la învățarea RNA.

#### 2.2.3.2. Estimarea probabilității MLE

MLE estimează unul sau mai mulți parametri de probabilitate  $\theta$  pe baza principiului că, dacă observăm datele de antrenare  $D$ , ar trebui să alegem valoarea lui  $\theta$  care conduce la  $D$  cel mai probabil.

Definiția MLE este dată de relația:

$$\theta^{MLE} = \underset{\theta}{\operatorname{argmax}} P(D|\theta) \quad (2.2.12)$$

$P(D|\theta)$  se numește adesea probabilitatea datelor (funcție de probabilitate) a datelor, deoarece exprimă probabilitatea datelor observate  $D$  ca și funcție de  $\theta$ .

Maximizarea lui  $P(D|\theta)$  este echivalentă cu maximizarea logaritmului  $\ln P(D|\theta)$  datorită proprietății de monotonie crescătoare a funcției logaritmice. Rezultă:

$$\theta^{MLE} = \underset{\theta}{\operatorname{argmax}} [P(D|\theta)] = \underset{\theta}{\operatorname{argmax}} [\ln P(D|\theta)] \quad (2.2.13)$$

### 2.2.3.3. Estimarea probabilității MAP

MAP estimează unul sau mai mulți parametri de probabilitate  $\theta$  pe baza principiului că ar trebui să alegem cea mai probabilă valoare a lui  $\theta$ , fiind cunoscute datele observate  $D$  și ipotezele noastre anterioare date (rezumate) de  $P(\theta)$ .

MAP este definită de relația:

$$\theta^{MAP} = \underset{\theta}{\operatorname{argmax}} P(\theta|D) \quad (2.2.14)$$

Utilizând teorema lui Bayes principiul MAP se poate rescrie sub forma:

$$\theta^{MAP} = \underset{\theta}{\operatorname{argmax}} P(\theta|D) = \underset{\theta}{\operatorname{argmax}} \frac{P(D|\theta) \cdot P(\theta)}{P(D)} \quad (2.2.15)$$

Având în vedere faptul că  $P(D)$  nu depinde de  $\theta$  și ignorând numitorul, relația de mai sus se poate rescrie sub forma:

$$\theta^{MAP} = \underset{\theta}{\operatorname{argmax}} P(\theta|D) = \underset{\theta}{\operatorname{argmax}} P(D|\theta) \cdot P(\theta) \quad (2.2.16)$$

Comparând expresia de mai sus cu principiul MLE, se observă că în MLE se alege  $\theta$  pentru a maximiza  $P(D|\theta)$ , în schimb principiul MAP maximizează  $P(D|\theta) \cdot P(\theta)$ . Diferența constă în prezența lui  $P(\theta)$ .

### 2.2.3.4. Minimum Description Length (MDL)

Pornind de la teorema lui Bayes:

$$P(h|D) = \frac{P(D|h) \cdot P(h)}{P(D)} \quad (2.2.17)$$

unde  $D$  reprezintă datele iar  $h$  – ipotezele, dorim să determinăm "din ce ipoteză provin datele, cunoscând datele" [Mackay2003].

*Esența inferenței bayesiene este dată de examinarea datelor pentru a maximiza probabilitatea unei ipoteze care este cel mai probabil să dea naștere datelor observate.* Practic vrem să determinăm  $\operatorname{argmax} P(h|D)$ , adică dorim să știm pentru ce  $h$ ,  $D$  observat este cel mai probabil. Eliminând numitorul în teorema lui Bayes, deoarece el nu depinde de ipoteză, ajungem de fapt la MAP. Se face uz în continuare de câteva observații:

- maximizarea lucrează de fapt similar pentru logaritm și pentru funcția originală (lucrând cu funcția logaritmică, nu se schimbă problema de maximizare);

- logaritmul produsului este suma logaritmilor individuali;
- maximizarea unei mărimi este echivalentă cu minimizarea acelei mărimi, luată cu semn schimbat).

Rezultă următorul șir de egalități:

$$\begin{aligned} h_{MAP} &= \operatorname{argmax} P(D|h) \cdot P(h) = \operatorname{argmax} \{\log_2 [P(D|h) \cdot P(h)]\} = \\ &= \operatorname{argmax} [\log_2 P(D|h) + \log_2 P(h)] = \operatorname{argmin} [-\log_2 P(D|h) - \log_2 P(h)] \end{aligned} \quad (2.2.18)$$

Pentru un mesaj sau eveniment cu probabilitate  $P$ , cea mai eficientă (cea mai compactă) codificare a aceluși mesaj va necesita  $-\log_2 P$  biți [Mackay2003]. Aceasta este tocmai natura acelor termeni care apar în expresia MAP derivată din teorema lui Bayes. Se poate afirma că în cadrul inferenței bayesiene, cea mai probabilă ipoteză depinde de doi termeni care evocă sensul lungimii - mai degrabă lungimea minimă. Acest fapt poate fi transcris matematic astfel:

$$\operatorname{argmin} [lungime(D|h) + lungime(h)] \quad (2.2.19)$$

Termenul *lungime* din expresia de mai sus ne conduce la Lama lui Occam (Occam's Razor) [Mackay2003]. Ockham face următoarea afirmație: "Trebuie să ne străduim să lucrăm cu cea mai simplă ipoteză care poate explica toate datele în mod satisfăcător!". *lungime(D|h)* este lungimea datelor, dată fiind ipoteza. Dacă ipoteza generează datele foarte bine și putem măsura datele fără erori, atunci nu avem nevoie deloc de date observate. Prin urmare, *lungime(D|h)* surprinde succint noțiunea de "cât de bine se potrivesc datele cu ipoteza dată". În esență, este vorba de noțiunea de clasificare greșită sau rata de eroare. O ipoteză perfectă este "scurtă", poate fi chiar zero la limită. O ipoteză care nu se potrivește perfect cu datele, tinde să fie "lungă". Trebuie găsită soluția de compromis. Dacă se ajustează ipoteza cu o lamă Occam mare, va rezulta un model simplu, care nu se potrivește cu toate datele. În consecință, trebuie furnizate mai multe date, pentru a avea un grad de încredere mai mare. Pe de altă parte, dacă se lucrează cu o ipoteză complexă (și totodată lungă), s-ar putea să se potrivească foarte bine datele de antrenare, dar aceasta poate să nu fie ipoteza corectă, întrucât se opune principiului MAP de a avea o ipoteză cu entropie mică.

Reunind toate informațiile legate de definirea ML, se poate formula următoarea concluzie: *inferența bayesiană statuează că cea mai bună ipoteză este cea care minimizează suma celor doi termeni – lungimea ipotezei și rata de eroare.*

Aceasta conduce la următoarele întrebări:

- Complexitatea modelului asupra unui model liniar – ce grad polinomial să alegem, cum să reducem suma pătratelor reziduale ?
- Alegerea arhitecturii RNA – cum să nu producem overfit datelor de antrenare și să obținem o precizie bună a validării, dar să reducem eroarea de clasificare ?
- Regularizarea SVM și alegerea Kernel-ului – cum să stabilim un echilibru între aspecte soft vs. hard, cu alte cuvinte cum să realizăm un compromis între acuratețe și neliniaritatea limitei deciziei ?

MDL arată că dacă se alege o reprezentare a ipotezelor astfel încât dimensiunea ipotezei  $h$  să fie  $-\log_2 P(h)$  și o reprezentare pentru excepții (erori) astfel încât lungimea de codificare a lui  $D$  (dată fiind ipoteza  $h$ ), să fie egală cu  $-\log_2 P(D|h)$ , atunci principiul MDL produce ipoteză MAP.

În practica ML, ar putea fi uneori mai ușor să se specifice o reprezentare care să capteze cunoștințe despre probabilitățile relative ale ipotezelor decât să se precizeze pe deplin probabilitatea fiecărei ipoteze. În această situație devine extrem de importantă problema reprezentării cunoștințelor și a expertizei în domeniu.

## 2.3. Rețele neuronale bayesiene

### 2.3.1. RNA "clasică" vs. RNA bayesiană

Cele mai populare rețele neuronale artificiale (RNA) sunt cele de tip perceptron multi-strat (MultiLayer Perceptron – MLP). MLP-ul constă dintr-o structură formată dintr-un strat de intrare, unul sau mai multe straturi ascunse și un strat de ieșire. Stratul de intrare este colectorul datelor de intrare sub forma unui vector  $x$ , în timp ce stratul de ieșire produce rezultatul sub forma unui vector  $y$ . Straturile ascunse cuprind un număr variabil de neuroni.

Funcția de activare, neliniară, este de obicei funcția tangentă hiperbolică, fiind de forma:

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3.1)$$

Astfel o RNA cu  $d$  intrări,  $h$  straturi ascunse și o singură ieșire definește un model neliniar parametrizat, de la intrarea  $x$  spre ieșirea  $y$ , de forma:

$$y = y(x; w) = \sum_{j=0}^h \left[ w_{jf} \left( \sum_{i=0}^d w_{ji} \cdot x_i \right) \right] \quad (2.3.2)$$

Parametrii modelului RNA sunt ponderile și pragurile de activare care conectează straturile rețelei între ele. Ponderile  $w$  sunt estimate în procesul de antrenare (învățare). RNA se antrenează cu ajutorul unui set de date de antrenare cu  $N$  probe, reprezentate de perechile  $D = \{x_i, t_i\}_{i=1}^N$ . Variabila  $t$  denotă ieșirea cunoscută. Faza de antrenare constă în ajustarea ponderilor în așa fel încât să se minimizeze funcția de eroare  $E_D$ . De regulă, funcția de eroare este egală cu suma pătratelor erorilor dintre ieșirea cunoscută  $t_i$  și ieșirea reală a RNA  $y_i = y(x_i; w)$ , fiind definită de relația:

$$E_D(w) = \frac{1}{2} \cdot \sum_{i=1}^N (y_i - t_i)^2 = \frac{1}{2} \cdot \sum_{i=1}^N e_i^2 \quad (2.3.3)$$

Procesul de antrenare este urmat de un proces de generalizare, care constă în evaluarea abilității RNA de a generaliza, adică de a furniza rezultate corecte atunci când se confruntă cu date de intrare noi, care nu au fost utilizate în procesul de antrenare. Acest set de date poartă denumirea de set de date de testare. Performanța de măsurare (numită și generalizarea erorii) este dată fie de media pătratelor erorilor (MSE – Mean Square Error), fie de radicalul mediei pătratelor erorilor (RMSE – Root Mean Square Error). MSE și RMSE sunt definite de relațiile:

$$MSE = \sum_{i=1}^N \frac{e_i^2}{N} \quad (2.3.4)$$

$$RMSE = \sqrt{MSE} \quad (2.3.5)$$

În problemele de prognoză a consumului de energie se utilizează și media erorii procentuale absolute (MAPE – Mean Absolute Percent Error):

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|e_i|}{t_i} \quad (2.3.6)$$

O generalizare de calitate, adică obținerea de predicții bune pentru intrări noi, se poate obține controlând complexitatea RNA, prin tehnici de reducere (pruning) sau regularizare. Regularizarea nu șterge explicit ponderile nerelevante, nefiind o metodă de selecție a arhitecturii RNA ca și pruning-ul. În regularizare parametrii care nu influențează modelul sunt "împinși" spre zero sau aproape de zero.

Conform [Bishop2006] în modelarea predictivă, semnalul poate fi gândit ca un adevărat model de bază, pe care dorim să îl învățăm din date. Pe de altă parte, zgomotul se referă la informațiile irelevante sau aleatoare dintr-un set de date. Scopul ML este surprinderea adevăratului model și ignorarea zgomotului. Overfitting-ul apare atunci când modelul învață semnalul, precum și zgomotul, din datele de antrenare și nu va funcționa bine pe noile date pe care modelul nu a fost antrenat (datele de testare).

Regularizarea înseamnă a schimba o situație sau un sistem astfel încât să respecte legile sau să se bazeze pe rațiune. Regularizarea adaugă o penalizare parametrilor modelului, pentru a reduce libertatea lui. Ca urmare modelul va fi mai puțin probabil să se potrivească cu zgomotul datelor de antrenare, dar se vor ameliora abilitățile de generalizare.

Există două categorii de metode de regularizare: LASSO (Least Absolute Shrinkage and Selection Operator) sau regularizare de tip L1, respectiv Ridge sau regularizarea de tip L2.

LASSO este o tehnică de selectare a caracteristicilor, foarte utilă pentru problemele de regresie. Se adaugă o penalizare pentru coeficienții diferiți de zero:

$$\sum_{i=1}^N (Y_i - \sum_j x_{ij} \cdot w_j)^2 + \lambda \cdot \sum_{j=1}^m |w_j| \quad (2.3.7)$$

Ca rezultat, pentru valori ridicate ale lui  $\lambda$ , mulți coeficienți sunt reduși exact la zero sub LASSO, ceea ce nu este niciodată cazul în regularizarea Ridge.

Regularizarea Ridge conduce ponderile mai aproape de originea 1 prin adăugarea unui termen de regularizare pătratic funcției obiectiv:

$$\sum_{i=1}^N (Y_i - \sum_j x_{ij} \cdot w_j)^2 + \lambda \cdot \sum_{j=1}^m w_j^2 \quad (2.3.8)$$

În ceea ce privește optimizarea bayesiană a coeficienților de regularizare, se realizează prin adăugarea unui termen de penalitate numit "weight decay" la funcția obiectiv  $E_D$ . Ca urmare rezultă o nouă funcție obiectiv de forma:

$$S(w) = E_D(w) + \mu \cdot E_W(w) = E_D(w) + \mu \cdot \frac{1}{2} \cdot \sum_{j=1}^m w_j^2 \quad (2.3.9)$$

care penalizează valorile mari ale ponderilor, care determină eventuala "curbură" excesivă a modelului.  $\mu$  este coeficientul de regularizare, el controlând libertatea regularizării. Dacă valoarea lui  $\mu$  este prea mare, atunci modelul nu se potrivește bine cu datele. În caz contrar, dacă  $\mu$  este prea mic, atunci apare overfitting-ul (modelul se comportă bine pe setul de antrenare, dar pe setul de testare eroarea crește). Există o valoare optimă a lui  $\mu$ , care oferă cel mai bun compromis între over- și underfitting. Valoarea optimă a lui  $\mu$  se va determina prin tehnici de cross-validare.

În cele ce urmează se prezintă o interpretare probabilistică a învățării RNA, care permite controlul automat al complexității RNA. Acest tip de RNA se numește *RNA bayesiană*.

Abordarea parcurge următorii pași:

- principiile învățării RNA bayesiană – o abordare probabilistică a învățării RNA;
- aproximarea Gaussiană a distribuției posterioare;
- optimizarea bayesiană a parametrilor de control – cadrul evidență;

- interpretarea numerică a cadrului evidenț;ă;
- selecția variabilelor de intrare prin tehnica bayesiană ARD (Automatic Relevance Determination);
- determinarea barelor de eroare asupra ieșirii RNA;
- selecția modelului bayesian.

### 2.3.2. Principiile învățării RNA bayesiană

#### 2.3.2.1. Considerații preliminare

Principiile raționamentului bayesian sunt conturate și aplicate la estimarea parametrilor RNA. Abordarea din acest capitol se bazează pe cea prezentată în [Mackay 2003]. Abordarea bayesiană consideră o funcție de densitate de probabilitate – PDF (Probability Density Function) asupra ponderilor RNA. PDF-ul reprezintă gradele de încredere, de diferitele valori, ale vectorului pondere  $w$ . PDF este setat inițial la o anumită distribuție apriori și apoi este transformat într-o distribuție posterioară, odată ce datele au fost observate prin utilizarea teoremei lui Bayes.

În acest context, în loc de un singur și "cel mai bun" set de ponderi calculate prin abordarea clasică a probabilității maxime (cu minimizarea unei funcții de eroare), metodele bayesiene produc o distribuție completă pentru parametrul RNA. Distribuția posterioară poate fi apoi utilizată pentru a deduce predicții ale RNA pentru noi valori ale variabilelor de intrare, cu alte cuvinte pentru a face prognoza cu RNA.

#### 2.3.2.2. Priorul

Deoarece la început nu se cunosc valorile pe care ar trebui să le ia ponderile, priorul va fi ales ca o distribuție destul de largă. Acest lucru se obține alegând PDF-ul priorului ca fiind o distribuție gaussiană cu varianță mare, de forma:

$$p(w|\alpha) = \frac{1}{Z_W(\alpha)} \cdot e^{(-\alpha \cdot E_W)} \quad (2.3.10)$$

În care  $\alpha$  reprezintă varianța inversă asupra seturilor de ponderi și de praguri de activare, iar  $Z_W(\alpha)$  reprezintă constanta de normalizare a PDF-ului. În cadrul abordării bayesiene  $\alpha$  se numește hiperparametru deoarece el controlează distribuția altor parametri (ponderi).

Alegerea unei distribuții gaussiene simplifică analiza în cadrul RNA și permite aplicarea unei proceduri analitice. Mai mult de atât, alegerea unui prior gaussian pentru ponderi conduce la o interpretare probabilistică a regularizatorului  $E_W$ . Într-adevăr,  $E_W$  poate fi interpretat ca fiind logaritmul cu semn schimbat al distribuției probabilității apriori asupra parametrilor. Este important faptul că în ipoteza de lucru, distribuția asupra ponderilor se definește pentru hiperparametrul  $\alpha$  fixat. În acest moment al modelării se presupune valoarea lui  $\alpha$  cunoscută. Deoarece s-a ales un prior gaussian, factorul de normalizare  $Z_W(\alpha)$  este dat de relația [Bishop2006]:

$$Z_W(\alpha) = \int e^{(-\alpha \cdot E_W)} = \left( \frac{2 \cdot \pi}{\alpha} \right)^{\frac{m}{2}} \quad (2.3.11)$$

Explicația este următoarea: pentru variabile continue funcția de distribuție de probabilitate devine funcție de densitate de probabilitate iar suma probabilităților se transformă în integrală [Bishop2006]. În plus se ține cont că se lucrează cu distribuție gaussiană. În relația de mai sus  $m$  reprezintă numărul total de parametri ai RNA.



### 2.3.2.3. Funcția de probabilitate sau modelul cu zgomot

Setul de date de intrare în model conține informații nerelevante sau aleatoare, ceea ce conduce la așa numitul *noise* (zgomotul care interferează cu semnalul și astfel apar distorsiuni în date). Proveniența funcției de probabilitate este legată de definirea modelului cu zgomot.

Fiind dat un set de date de antrenare cu  $N$  probe de forma  $D = \{x_i, t_i\}_{i=1}^N$ , scopul învățării RNA este de a găsi o relație  $\Re$  între intrările  $x_i$  și ieșirile cunoscute  $t_i$ . Datorită faptului că există incertitudini în această relație, cum ar fi zgomotul din date sau fenomene care nu sunt luate în considerare, relația devine  $t_i = \Re(x_i) + \varepsilon_i$ , unde zgomotul  $\varepsilon_i$  este expresia diferitelor incertitudini. Se dorește aproximarea lui  $\Re(x)$  cu  $y(x; w)$ , adică un model de regresie non-liniar dat de MLP. Se lucrează în ipoteza în care a  $i$ -a ieșire cunoscută  $t_i$  este dată de o funcție deterministă cu argument vectorul de intrare  $x$ , la care se adaugă un zgomot gaussian independent.

Următoarea ipoteză este aceea că eroarea are o distribuție normală cu media zero și varianța  $\sigma^2 = 1/\beta$ . În acest context, distribuția zgomotului este dată de relația:

$$p(\varepsilon_i | \beta) = \sqrt{\frac{\beta}{2 \cdot \pi}} \cdot \exp\left(-\frac{\beta}{2} \cdot \varepsilon_i^2\right) \quad (2.3.12)$$

Continuând scenariul în ipoteza zgomotelor independente, probabilitatea de uniune a unui set de  $N$  valori ale zgomotului se exprimă sub forma:

$$p(\varepsilon | \beta) = p(\varepsilon_1, \dots, \varepsilon_N | \beta) = \prod_{i=1}^N p(\varepsilon_i | \beta) = \left(\frac{\beta}{2 \cdot \pi}\right)^{\frac{N}{2}} \cdot \exp\left(-\frac{\beta}{2} \cdot \sum_{i=1}^N \varepsilon_i^2\right) \quad (2.3.13)$$

Considerând diferența dintre ieșirea cunoscută și cea reală a modelului  $\varepsilon_i = t_i - y_i$  și înlocuind-o în relația (2.3.13), rezultă funcția de probabilitate (likelihood):

$$p(D | w, \beta) = \frac{1}{Z_D(\beta)} \cdot e^{(-\beta \cdot E_D)} \quad (2.3.14)$$

$\beta$  se numește de asemenea hiperparametru și el reprezintă inversul varianței zgomotului din ieșirea cunoscută. La fel ca și hiperparametrul  $\alpha$ , și pentru  $\beta$  se presupune că, în acest moment al modelării, valoarea sa este cunoscută.

Modelul zgomotului gaussian permite calculul analitic al factorului de normalizare  $Z_D(\beta)$ , el fiind dat de relația:

$$Z_D(\beta) = \left(\frac{2 \cdot \pi}{\beta}\right)^{\frac{N}{2}} \quad (2.3.15)$$

Alegând funcția de probabilitate gaussiană, se obține o interpretare probabilistică a funcției de eroare  $E_D$ . Într-adevăr, funcția de eroare standard, poate fi interpretată ca fiind minus logaritmul probabilității modelului cu zgomot, dat de relația (2.3.16):

$$E_D = -\log p(D | w, \beta) \quad (2.3.16)$$

### 2.3.2.4. Distribuția posterioară

Odată ce s-a calculat PDF-ul priorului și s-a definit funcția de probabilitate, devine posibilă deducerea PDF-ului posterior, prin aplicarea teoremei lui Bayes:

$$p(w|\alpha, \beta, D) = \frac{p(D|w, \beta) \cdot p(w|\alpha)}{p(D|\alpha, \beta)} \quad (2.3.17)$$

În relația (2.3.17) s-a ținut cont de faptul că priorul nu depinde de hiperparametrul  $\beta$  iar funcția de probabilitate (likelihood-ul) nu depinde de hiperparametrul  $\alpha$ .

Înlocuind relațiile (2.3.10) și (2.3.14) în relația (2.3.17), se obține:

$$\begin{aligned} p(w|\alpha, \beta, D) &= \frac{\frac{1}{Z_D(\beta)} \cdot e^{(-\beta \cdot E_D)} \cdot \frac{1}{Z_W(\alpha)} \cdot e^{(-\alpha \cdot E_W)}}{p(D|\alpha, \beta)} = \\ &= \frac{\exp[-\beta \cdot E_D - \alpha \cdot E_W]}{Z_D(\beta) \cdot Z_W(\alpha) \cdot p(D|\alpha, \beta)} = \frac{\exp\{-S(w)\}}{Z_S(\alpha, \beta)} \end{aligned} \quad (2.3.18)$$

unde s-a utilizat notația  $S(w) = \beta \cdot E_D + \alpha \cdot E_W$ .

Distribuția posterioară va fi dată de relația (2.3.19):

$$p(w|\alpha, \beta, D) = \frac{1}{Z_S(\alpha, \beta)} \cdot \exp\{-S(w)\} \quad (2.3.19)$$

Constanta de normalizare este dată de relația (2.3.20):

$$Z_S(\alpha, \beta) = \int e^{-S(w)} \cdot dw \quad (2.3.20)$$

Se menționează faptul că în practică, într-un context multiparametric, cum se întâlnește în învățarea RNA-urilor,  $m$  (numărul tuturor parametrilor RNA) are valori relativ mari ( $m \gg 10$ ), evaluarea factorului de normalizare  $Z_S(\alpha, \beta)$  nu poate fi realizată analitic. Pentru a surmonta acest aspect, în [Mackay2003] se propune o *aproximare gaussiană asupra distribuției posterioare a ponderilor*.

Valorile optime ale ponderilor RNA corespund valorii maxime a PDF-ului posterior. Cum factorul de normalizare este independent de ponderi, poate fi ignorat în acest context. Astfel valoarea maximă a posteriorului se obține minimizând  $S(w)$ , adică a logaritmului negativ  $S(w) = -\log p(w|\alpha, \beta, D)$  din relația (2.3.19).

Conform notației de mai sus:

$$S(w) = \beta \cdot E_D(w) + \alpha \cdot E_W(w) = \frac{\beta}{2} \cdot \sum_{i=1}^N [y(x_i; w) - t_i]^2 + \frac{\alpha}{2} \cdot \sum_{i=1}^m w_i^2 \quad (2.3.21)$$

apoi rezultă

$$S(w) = \frac{\beta}{2} \cdot \sum_{i=1}^N [y(x_i; w) - t_i]^2 + \frac{\alpha}{2} \cdot \sum_{i=1}^m w_i^2 \quad (2.3.22)$$

Conform [Bishop2006],  $S(w)$  este suma pătratelor funcției de eroare la care se adaugă termenul de regularizare, ce depinde numai de coeficientul de regularizare  $\mu = \alpha/\beta$ . După cum se poate observa, abordarea bayesiană conduce în mod automat și natural la minimizarea unei funcții regularizate. Deci, se pare că interpretarea lui  $S(w)$  ca logaritm al unei probabilități aduce puține noutăți. Cu toate acestea, o interpretare

probabilistică va furniza noi instrumente (în special teorema lui Bayes) capabile să deducă din date valorile optime ale lui  $\alpha$  și  $\beta$ , adică acele valori care ajustează cel mai bine complexitatea modelului. Mai mult, modelarea probabilistică tratează incertitudinea într-un mod natural, astfel va fi posibilă atribuirea unor bare de eroare pentru predicțiile modelului.

### 2.3.2.5. Aproximarea Gaussiană a distribuției posterioare

Inferențele de mai sus, mai precis optimizarea bayesiană a hiperparametrilor de control  $\alpha$  și  $\beta$ , respectiv evaluarea barelor de eroare asupra predicțiilor RNA, necesită integrări peste spațiul ponderilor. Cum factorul de normalizare exprimat în ecuația (2.3.20) nu poate fi evaluat analitic, este necesară o aproximare gaussiană a distribuției posterioare. Această aproximare este obținută prin dezvoltarea în serie Taylor (cu reținerea termenilor până la ordinul 2 inclusiv) asupra lui  $S(w)$  în jurul valorii sale minime sau a celui mai probabil set al ponderilor, notat  $w_{MP}$  (indicele  $MP$  provine de la "most probable") [Bishop2006]. Prin aproximarea gaussiană, factorul de normalizare  $S(w)$  poate fi evaluat analitic, obținând următorul rezultat:

$$Z_S^*(\alpha, \beta) = (2 \cdot \pi)^{\frac{m}{2}} \cdot |A|^{-\frac{1}{2}} \cdot \exp[-S(w_{MP})] \quad (2.3.23)$$

În relația (2.3.23),  $|A|$  este determinantul matricei hessiene a funcției de eroare totale (ce include și regularizarea)  $S(w)$ .

### 2.3.3. Optimizarea bayesiană a parametrilor de control – cadru evidentă

Așa cum s-a menționat, hiperparametrii  $\alpha$  și  $\beta$  controlează complexitatea modelului RNA. Până în acest moment al modelării s-au presupus cunoscute valorile celor doi hiperparametri, dar în practică în majoritatea aplicațiilor, avem o idee vagă asupra valorilor hiperparametrilor [Bishop2006]. O modalitate de rezolvare a acestei probleme este includerea varianței zgomotului și a coeficientului de regularizare în lista parametrilor modelului. Astfel, vectorul parametrilor  $\theta$  devine  $\theta = \{w, \alpha, \beta\}$ . Regulile teoriei probabilității, incluse în cadrul bayesian, oferă un răspuns la problema enunțată, prin conceptul de marginalizare. Acest concept implică necesitatea integrării asupra hiperparametrilor. Astfel se obține următorul rezultat:

$$p(w|D) = \iint p(w, \alpha, \beta | D) \cdot d\alpha \cdot d\beta = \iint p(w | \alpha, \beta, D) \cdot p(\alpha, \beta | D) \cdot d\alpha \cdot d\beta \quad (2.3.24)$$

Deși această marginalizare poate fi realizată analitic, [Mackay2003] recomandă soluționarea numerică, rezultând valorile optime ale hiperparametrilor  $\alpha$  și  $\beta$ , notate cu  $\alpha_{MP}$  și  $\beta_{MP}$ . Restul calculelor se efectuează cu hiperparametrii setați pe aceste valori optime. Această abordare poartă denumirea de *cadru evidentă*.

Aplicarea teoremei lui Bayes permite deducerea valorilor hiperparametrilor din date. Astfel se obține relația:

The diagram shows a central equation:  $p(\alpha, \beta | D) = \frac{p(D | \alpha, \beta) \cdot p(\alpha, \beta)}{p(D)}$ . Arrows indicate the flow of information: 'Evidență' (Evidence) points to  $p(D | \alpha, \beta)$ ; 'Prior' points to  $p(\alpha, \beta)$ ; and 'Factor de normalizare' (Normalization factor) points to  $p(D)$ . A box labeled 'Posterior' points to the left side of the equation,  $p(\alpha, \beta | D)$ .

$$p(\alpha, \beta | D) = \frac{p(D | \alpha, \beta) \cdot p(\alpha, \beta)}{p(D)} \quad (2.3.25)$$

În relația (2.3.25)  $p(\alpha, \beta)$  este *priorul* peste hiperparametrii numit și hiperprior, iar  $p(D|\alpha, \beta)$  este termenul probabilității numit *evidența* lui  $\alpha$  și  $\beta$ . Cum valorile hiperparametrilor nu se cunosc, priorul  $p(\alpha, \beta)$  se preia dintr-o distribuție uniformă. Factorul de normalizare  $p(D)$  nefiind dependent de  $\alpha$  și  $\beta$ , maximizarea posteriorului  $p(\alpha, \beta|D)$  este dată de maximizarea termenului  $p(D|\alpha, \beta)$ , numit *termen evidență pentru*  $\alpha$  și  $\beta$ . Acest termen poate fi obținut integrând probabilitatea datelor peste toate valorile posibile ale ponderilor  $w$ :

$$p(D|\alpha, \beta) = \int p(D|w, \alpha, \beta) \cdot p(w|\alpha, \beta) \cdot dw = \int p(D|w, \alpha, \beta) \cdot p(w|\alpha) \cdot dw \quad (2.3.26)$$

În relația (2.3.26) a doua egalitate se datorează faptului că ponderile sunt independente de varianța zgomotului.

Utilizând aproximarea gaussiană pentru posteriorul ponderilor, termenul evidență poate fi scris sub următoarea formă [Bishop2006]:

$$p(D|\alpha, \beta) = \frac{Z_S^*(\alpha, \beta)}{Z_D(\beta) \cdot Z_W(\alpha)} = \frac{(2 \cdot \pi)^{\frac{m}{2}} \cdot |A|^{\frac{1}{2}} \cdot \exp[-S(w_{MP})]}{\left(\frac{2 \cdot \pi}{\beta}\right)^{\frac{N}{2}} \cdot \left(\frac{2 \cdot \pi}{\alpha}\right)^{\frac{m}{2}}} \quad (2.3.27)$$

unde  $S(w_{MP}) = \beta \cdot E_D^{MP} + \alpha \cdot E_W^{MP}$ .

Valorile optime  $\alpha_{MP}$  și  $\beta_{MP}$  corespund maximului termenului *evidență* pentru  $\alpha$  și  $\beta$ . Așa cum s-a precizat, acest PDF poate fi, de asemenea, interpretat ca o funcție de eroare pentru a minimiza aplicând logaritmul relației (2.3.27):

$$\begin{aligned} \log p(D|\alpha, \beta) &= \log \frac{(2 \cdot \pi)^{\frac{m}{2}} \cdot |A|^{\frac{1}{2}} \cdot \exp(-\beta \cdot E_D^{MP} - \alpha \cdot E_W^{MP})}{(2\pi)^{\frac{N}{2}} \cdot \left(\frac{1}{\beta}\right)^{\frac{N}{2}} \cdot (2 \cdot \pi)^{\frac{m}{2}} \cdot \left(\frac{1}{\alpha}\right)^{\frac{m}{2}}} = \\ &= -\frac{1}{2} \cdot \log |A| - \beta \cdot E_D^{MP} - \alpha \cdot E_W^{MP} - \frac{N}{2} \cdot \log(2 \cdot \pi) + \frac{N}{2} \cdot \log(\beta) + \frac{m}{2} \cdot \log(\alpha) \end{aligned} \quad (2.3.28)$$

obținând în final relația:

$$\log p(D|\alpha, \beta) = -\alpha \cdot E_W^{MP} - \beta \cdot E_D^{MP} - \frac{1}{2} \cdot \log |A| + \frac{m}{2} \cdot \log(\alpha) + \frac{N}{2} \cdot \log(\beta) - \frac{N}{2} \cdot \log(2\pi) \quad (2.3.29)$$

Valorile optime ale hiperparametrilor  $\alpha$  și  $\beta$ ,  $\alpha_{MP}$  și  $\beta_{MP}$ , sunt apoi obținute prin diferențierea logaritmului evidenței în raport cu acești hiperparametri, rezultând:

$$\alpha_{MP} = \frac{\gamma}{2 \cdot E_W^{MP}}; \quad \beta_{MP} = \frac{N - \gamma}{2 \cdot E_D^{MP}} \quad (2.3.30)$$

În relația (2.3.30)  $E_W^{MP} = E_W(w_{MP})$ ,  $E_D^{MP} = E_D(w_{MP})$ , iar  $\gamma$  reprezintă numărul parametrilor bine determinați și este dat de relația:

$$\gamma = \sum_{k=1}^m \left( \frac{\lambda_k}{\lambda_k + \alpha} \right) \quad (2.3.31)$$

În relația (2.3.31)  $\lambda_k$  este valoarea proprie a matricei hessiene a erorii neregularizate  $E_D$ , adică  $H = \beta \cdot \nabla \nabla E_D$ .

Așa cum s-a putut observa (contrar metodelor cross-validării), pentru calculul valorilor optime nu s-a folosit un set de validare. Așadar, datele disponibile pot fi utilizate atât pentru ajustarea modelului cât și pentru optimizarea parametrilor de control. Mai mult, metoda permite căutarea în întreg spațiul de definiție al parametrilor de control, deoarece este posibil calculul gradientului evidenței în raport cu parametrii de control. Spre deosebire de tehnica clasică de regularizare, se pot evalua un număr mare de coeficienți de regularizare. Tehnicile de cross-validare utilizează o măsură a performanței zgomotului, cum ar fi eroarea de validare, pe când metodele bayesiene de optimizare folosesc evidențele, care nu sunt o funcție cu zgomot a parametrilor.

### 2.3.4. Interpretarea numerică a cadrului evidență

Deoarece trebuie găsite atât valorile optime  $\alpha_{MP}$  și  $\beta_{MP}$  ale hiperparametrilor  $\alpha$  și  $\beta$  cât și valorile optime ale vectorului pondere  $w_{MP}$ , se va recurge la un proces iterativ pentru a ajusta RNA.

Secțiunea de față descrie această procedură iterativă. Ea se derulează în patru pași:

- *Pasul 1*

Se aleg valori inițiale, relativ reduse, pentru hiperparametrii  $\alpha$  și  $\beta$ . Se inițializează ponderile în RNA utilizând valori preluate din distribuția priori. La o iterație oarecare  $i$ , cunoscând estimările curente ale ponderilor ( $w^i$ ), hiperparametrilor ( $\alpha^i$  și  $\beta^i$ ), cu relația (2.3.22) se poate calcula valoarea curentă a lui  $S^i(w)$ .

- *Pasul 2*

Se determină ponderile  $w_{MP}^{i+1}$  care minimizează  $S^i(w)$  utilizând un algoritm de optimizare neliniar standard (Newton, quasi Newton sau gradient conjugat scalat [Kilyeni2015]). Apoi, cu  $w_{MP}^{i+1}$  calculați, se vor calcula  $E_W^{i+1}$  și  $E_D^{i+1}$ .

- *Pasul 3*

Se calculează noile valori  $\alpha^{i+1}$  și  $\beta^{i+1}$ :

$$\gamma^{i+1} = \sum_{k=1}^m \left( \frac{\lambda_k}{\lambda_k + \alpha^i} \right) \quad (2.3.32)$$

unde  $\lambda_k$  – valoarea proprie k a matricei hessiene a erorii neregularizate  $E_D$ , adică  $H = \beta^i \cdot \nabla \nabla E_D^{i+1}$ ;

$$\alpha^{i+1} = \frac{\gamma^{i+1}}{2 \cdot E_W^{i+1}} \quad (2.3.33)$$

$$\beta^{i+1} = \frac{N - \gamma^{i+1}}{2 \cdot E_D^{i+1}} \quad (2.3.34)$$

- *Pasul 4*

Se revine la pasul 2 și se utilizează parametrii  $w^{i+1}$ ,  $\alpha^{i+1}$  și  $\beta^{i+1}$  pentru a calcula noile valori ale parametrilor. Pașii 2 și 3 se repetă până se ajunge la convergență.

În ceea ce privește inițializarea lui  $\alpha$ , se recomandă să se înceapă cu valori relativ mici, astfel încât modelul să aibă suficientă flexibilitate pentru a ajusta datele.

Convergența procedurii se obține atunci când eroarea regularizată, definită de relația (2.3.22), nu depășește jumătate din numărul de probe  $N$ . Într-adevăr, teoria afirmă că  $S(w) \leq N/2$  când  $\alpha = \alpha_{MP}$  și  $\beta = \beta_{MP}$ .

### 2.3.5. Selecția variabilelor de intrare prin tehnica bayesiană ARD

Scenariul în care s-a lucrat până acum a fost în ipoteza unei singure clase de ponderi  $w$ , controlată de un singur hiperparametru  $\alpha$ . În cazul general ponderile se împart în mai multe grupuri ( $g_i$ ).

De exemplu:  $g_1$  – grupul ponderilor de pe stratul de intrare;  $g_2$  – grupul ponderilor de pe stratul ascuns;  $g_3$  – grupul pragurilor de activare (bias-urilor) de pe stratul de intrare;  $g_4$  – grupul pragurilor de activare (bias-urilor) de pe stratul ascuns.

Grupurile  $g_i$  sunt controlate, printr-un prior gaussian, de un hiperparametru  $\alpha_{g_i}$ . Tehnica ARD constă în asocierea separată a coeficientului de regularizare  $\mu = \frac{\alpha}{\beta}$  la fiecare intrare, adică toate ponderile legate de aceeași intrare sunt controlate de același hiperparametru  $\alpha_{g_i}$ . Acest hiperparametru este asociat cu un prior gaussian cu media zero și varianța  $\frac{1}{\alpha_{g_i}}$ .

La finele procesului de antrenare ponderile cu  $\alpha_{g_i}$  mare, adică varianță mică, sunt aproape de zero, deci intrările corespunzătoare sunt irelevante și pot fi eliminate din modelul RNA.

### 2.3.6. Determinarea barelor de eroare asupra ieșirii RNA

Interpretarea probabilistică a învățării RNA oferă un alt avantaj important, pe lângă tehnica bayesiană ARD. Incertitudinea parametrilor poate fi integrată în cadrul predicției.

Prin abordarea clasică se obțin "cele mai bune" estimări, pe când tehnica bayesiană permite derivarea unei bare de eroare asupra ieșirii RNA. Într-adevăr, în formalismul bayesian, distribuția (posterioră) a ponderilor dă naștere la o distribuție a ieșirilor RNA.

Făcând unele aproximări și utilizând aproximarea gaussiană a posteriorului ponderilor, se poate arăta că distribuția ieșirii RNA este tot o distribuție gaussiană, de forma:

$$p(t|x, D) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma_t^2}} \cdot \exp\left[-\frac{(t - y_{MP})^2}{2 \cdot \sigma_t^2}\right] \quad (2.3.35)$$

Această distribuție are media  $y_{MP} = y(x, w_{MP})$ , modelul fiind responsabil de estimarea optimă  $w_{MP}$ . Varianța este dată de relația:

$$\sigma_t^2 = \sigma^2 + g^T \cdot A^{-1} \cdot g \quad (2.3.36)$$

În relația de mai sus  $g = \nabla_w \mathcal{Y}|_{w_{MP}}$  reprezintă gradientul ieșirii RNA evaluat la cea mai bună estimare.

Deviația standard a distribuției ieșirii RNA se poate interpreta ca o bară de eroare pe valoarea medie  $\mathcal{Y}_{MP}$ .

Această bară de eroare are două contribuții:

- prima, care apare din zgomotul intrinsec al datelor;
- a doua, care apare din lățimea distribuției posterioare, este legată de incertitudinile ponderilor RNA.

De subliniat faptul că în cadrul acestei tehnici incertitudinea hiperparametrilor și a intrărilor nu sunt luate în considerare.

### 2.3.7. Selecția modelului bayesian

Așa cum s-a arătat în paragrafele anterioare, metodele bayesiene sunt utilizate în rezolvarea problemelor de estimare a parametrilor, dar abordarea bayesiană poate fi și un instrument util în cazul problemelor de selecție a modelului RNA.

Aplicând teorema lui Bayes, se pot calcula și atașa probabilități modelului RNA. Aceste probabilități, numite și *evidențe* ale RNA, se pot utiliza ca o măsură de selecție a celui mai bun model.

Modelul care prezintă cea mai mare evidență este cel mai probabil, în raport cu datele. În contextul RNA, modelele cu un număr diferit de straturi ascunse se pot clasifica și compara în funcție de *evidența* lor.

Pentru a ilustra cele afirmate mai sus, se consideră  $M_i$  seturi de modele, care corespund unui set de RNA cu număr variabil de straturi ascunse. Aplicând teorema lui Bayes, se poate calcula posteriorul probabilității diferitelor modele  $M_i$ , pentru un anumit set de date  $D$ , astfel:

$$p(M_i | D) = \frac{p(D | M_i) \cdot p(M_i)}{p(D)} \quad (2.3.37)$$

unde:  $p(M_i)$  – probabilitatea priori asociată modelului  $M_i$ ;

$p(D)$  – constanta de normalizare;

$p(D | M_i)$  – *evidența* pentru modelul  $M_i$ .

Nu există niciun motiv de a atribui priori de valoare diferită la diversele modele, ele fiind comparate și clasificate conform *evidenței* lor.

Ținând cont de unele ipoteze, în special cele legate de aproximarea gaussiană a distribuției posterioare a ponderilor, conform [Bishop2006] se obține expresia de mai jos a logaritmului *evidenței* unei RNA cu  $h$  straturi ascunse:

$$\begin{aligned} \log p(D | M_i) = & -\alpha_{MP} \cdot E_W^{MP} - \beta_{MP} \cdot E_D^{MP} - \frac{1}{2} \cdot \log |A| + \frac{m}{2} \cdot \log(\alpha_{MP}) + \\ & + \frac{N}{2} \cdot \log(\beta_{MP}) + \log(h!) + 2 \cdot \log h + \frac{1}{2} \cdot \log\left(\frac{2}{\gamma}\right) + \frac{1}{2} \cdot \log\left(\frac{2}{N-\gamma}\right) \end{aligned} \quad (2.3.38)$$

Maximul logaritmului *evidenței* va corespunde modelului celui mai probabil (MP) al RNA sau, altfel spus, structurii optime a RNA.

## 2.4. Concluzii

În cadrul acestui capitol s-au prezentat noțiunilor teoretice legate de abordarea bayesiană, de rețelele bayesiene, de rețelele neuronale bayesiene și a unor elemente conexe. Noțiunile respective sunt necesare atât pentru înțelegerea capitolelor următoare, legate de utilizarea conceptelor și modelelor bayesiene în domeniul electroenergeticii cât și a modelului matematic al prognozei consumului de energie și al instrumentului soft aferent (capitolul 6).

În prima parte a capitolului s-a realizat o trecere în revistă a unei serii de elemente de probabilități și de statistică: probabilități condiționate, interpretare frecventistă versus subiectivistă a probabilităților, teorema lui Bayes, legile de probabilitate etc.

A doua parte s-a referit la învățarea automată (Machine Learning – ML) în contextul modelării probabiliste: învățarea automată bayesiană (BML), metodele de aproximare a posteriorului și a probabilităților marginale, inferența bayesiană etc.

Ultima parte a fost consacrată în exclusivitate RNA bayesiene: compararea RNA "clasice" cu cele bayesiene, principiile învățării (antrenării) la RNA bayesiene, optimizarea bayesiană a parametrilor de control (noțiunea de *cadru evidentă*, inclusiv abordarea sa numerică).

În continuare se prezintă o trecere în revistă a contribuțiilor personale din acest capitol:

- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a elementelor teoretice legate de abordarea bayesiană și de RNA bayesiene, în contextul înțelegerii exemplurilor de utilizare prezentate în capitolele următoare;
- evidențierea aspectelor esențiale necesare la elaborarea modelului matematic utilizat pentru prognoza consumului de energie electrică, a puterii și a curbelor de sarcină;
- schițarea algoritmului de învățare (antrenare) bayesiană a RNA, care va fi dezvoltat în capitolul 6.



### **3. APLICAȚII ALE REȚELELOR BAYESIENE ÎN DOMENIUL INGINERIEI SISTEMELOR ELECTROENERGETICE**

Obiectivul capitolului 3 constă în prezentarea sistematizată a unor aplicații ale rețelelor bayesiene (RB) în domeniul ingineriei sistemelor electroenergetice.

Se trec în revistă o gamă largă de exemple, începând cu fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a sistemului electroenergetic (SEE) în ansamblu, continuând cu estimarea stării SEE, cu analiza stabilității SEE, cu diagnoza și localizarea defectelor în rețelele electrice, diagnoza defectelor legate de transformatoare și generatoare, cu estimarea valorii parametrilor elementelor de rețea (linii electrice, transformatoare) etc.

Cele mai numeroase aplicații se regăsesc în domeniul prognozei consumului de energie electrică și putere. Ele vor fi tratate separat, în Capitolul 4, având în vedere că prognoza utilizând RB constituie și obiectul acestei teze de doctorat.

#### **3.1. Considerații preliminare**

Înainte a trece la prezentarea relativ mai în detaliu a aplicațiilor concrete, se consideră utilă enumerarea principalelor surse bibliografice utilizate. Ele acoperă, cu câteva excepții, perioada ultimilor 10 ani. Lucrările discutate au fost publicate în reviste semnificative ale domeniului (Applied Energy, Electrical Power and Energy Systems, Electric Power Systems Research, Energy, IEEE Transactions on Power Systems, IEEE Transactions on Power Delivery, IEEE Transactions on Industrial Electronics, IEEE Transactions on Industrial Informatics, IEEE Transactions on Sustainable Energy, IEEE Transactions on Smart Grid, International Journal of Electrical Power & Energy Systems, Neural Networks etc.) sau în volumele unor conferințe de prestigiu – Australasian Universities Power Engineering Conference, IEEE International Conference on Probabilistic Methods Applied to Power Systems, IEEE Mediterranean Electrotechnical Conference (MELECON), IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), IEEE PES Innovative Smart Grid Technologies Conference Europe, IEEE PowerTech Conference, International Conference on Intelligent Systems Applications to Power Systems, International Universities Power Engineering Conference (UPEC) etc.

Subcapitolele următoare tratează aplicațiile RB în câte unul dintre domeniile menționate mai sus:

- fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a grupurilor generatoare și a SEE în ansamblu: [Lihua2009], [Ebrahimi2010], [Gui2010], [Gui2011], [Daemi2012], [Zehani2017], [Konig2010], [Konig2011], [Tang J2013], [Ursianu 2013], [Iesmantas2014], [Zhang2014], [Eliassi2015], [Eliassi 2015a], [Borges 2016], [Sykora2016], [Lorencin2017];
- estimarea stării SEE și a valorii parametrilor elementelor de rețea (linii electrice, transformatoare: [Singh2010], [Hu2011], [Chen2012], [Chen2013], [Schenato 2014], [Amini2015], [Gaber2015], [Angioni2016], [Pegoraro2017], [Petra2017], [Soltan2018], [Massignan2019], [Mestav2019], [Ji2021];
- analiza stabilității SEE: [Fan2009], [WuChao2009], [Augutis2012], [Ma2013], [Seppanen2016], [Vakili2015], [Chevalier2019];

- diagnoza și localizarea defectelor în rețelele electrice, diagnoza defectelor legate de transformatoare și generatoare: [XuT2010], [Zhao2010], [Zheng 2010], [Teive2011], [WuCheng2011], [Zhou2012], [Li2014], [WangT2015], [XuB2019];
- alte aplicații ale RB: [WangY2011], [Montenegro2012], [Dong2014], [Neumayer 2014], [Dehghanpour2016], [XuQ2016], [Fahiman2018], [Mitridati2018], [Monteiro2018], [Zuluaga2018].

### 3.2. Aplicații în domeniul fiabilității rețelelor și sistemelor electroenergetice

În [Lihua2009] se prezintă un algoritm de evaluare a fiabilității rețelelor de distribuție a energiei electrice, care combină utilizarea RB cu o tehnică de simulare secvențială (cronologică). Algoritmul poate să furnizeze secvențe de durate aleatoare a stării elementelor de rețea și să acumuleze cunoștințe despre starea sistemului, duratele de întrerupere a alimentării consumatorilor, frecvențele perioadelor de nealimentare, cantitatea de energie nelivrată etc. Utilizând aceste informații, se pot calcula indicii care caracterizează siguranța în funcționare a rețelei: LOLP (Loss of Load Probability – probabilitatea neasigurării puterii cerute), SAIFI (System Average Interrupted Frequency Index – indicele frecvenței medii a întreruperilor) sau LOLF (Loss of Load Frequency, CAIDI (Customer Average Interrupted Duration Index – indicele duratei medii a întreruperilor), LOLE (Loss of Load Expectation – media timpului total al neasigurării puterii cerute) sau LOD (Loss of Load Duration – durata medie a neasigurării puterii cerute), ENS (energy not-supplied – energia nelivrată) și AENS (average energy not-supplied – energia medie nelivrată). Pe lângă evaluarea globală a stării rețelei este posibilă și identificarea părților (zonelor) sale vulnerabile. O abordare asemănătoare este prezentată și în [Zehani2017].

Indicele LOLP este utilizat și în [Ebrahimi2010], unde se prezintă o nouă tehnică de obținere a RB asociate unui sistem electroenergetic. RB au capacitatea de a învăța din seturi (eșantioane) de date pentru a realiza analiza siguranței în funcționare a SEE, pentru a ierarhiza ieșirea din funcțiune a elementelor de sistem și pentru a identifica elementele critice pe baza valorii indicilor LOLP. Metoda se poate aplica la SEE de mari dimensiuni, permițând evaluarea fiabilității SEE din punctul de vedere al diverselor noduri consumatoare. În scopul obținerii seturilor de date s-a utilizat o metodă de tip Monte-Carlo. Aplicația se referă la sistemul test IEEE pentru studiile de fiabilitate (IEEE Reliability Test System – 24 noduri, 32 generatoare, 33 linii electrice și 5 transformatoare). Aceeași tehnică este utilizată și în [Daemi2012], unde se prezintă posibilitatea determinării indicilor de tip SAIFI sau LOLF fără a efectua o simulare secvențială (cronologică).

În [Gui2010] este discutată problema întreruperilor de alimentare în rețelele de distribuție care cuprind linii electrice aeriene, cauzate de animale (păsări, veverițe etc.). Modelul prezentat utilizează o RB cu două straturi ascunse, având ca date de intrare luna din an, numărul zilelor cu vreme frumoasă într-o săptămână și nivelul de întrerupere a alimentării pentru săptămâna anterioară. Datele de ieșire oferă o estimare a situației întreruperilor pentru săptămâna în curs. Sunt analizate și comparate diversele posibilități pentru clasificarea mărimilor de intrare și a celor de ieșire, pentru a obține cea mai bună combinație. Analiza este aprofundată în [Gui2011], unde se implementează o simulare de tip Monte-Carlo pentru estimarea numărului lunar de întreruperi și a limitelor gradului de încredere (inferioară și superioară).

[Konig2010] și [Konig2011] prezintă un model probabilistic relațional, bazat pe utilizarea RB, pentru evaluarea siguranței în funcționare a rețelelor de distribuție

cu generare distribuită. Prima lucrare are ca obiect prezentarea suportului teoretic (însotită de un exemplu simplu), iar a doua se referă la analiza probabilistă a siguranței în funcționare a echipamentelor informatice și a sistemelor de comunicație. Un subiect asemănător, în abordare bayesiană, este prezentat și în lucrările [Eliassi2015] și [Eliassi2015a]: includerea funcționării defectuoase a sistemelor de protecție în aprecierea fiabilității sistemelor electroenergetice complexe. Aplicațiile concrete vizează sistemul test IEEE pentru studiile de fiabilitate (IEEE Reliability Test System).

Problema sistemelor informatice este analizată și în [Ursianu2013]: fiabilitatea pachetelor software care monitorizează funcționarea stațiilor electrice. Modelul matematic elaborat utilizează RB și elemente de teorie din domeniul lanțurilor Markov.

O problemă interesantă este abordată în [TangJ2013]: influența erorilor comise de operatorul uman siguranței în funcționare a sistemelor electroenergetice. Lucrarea definește noțiunea de "fiabilitate umană" a sistemelor electroenergetice și cadrul cauzal al erorilor operatorului uman, propunând un model probabilist de inferență bazat pe utilizarea RB. Exemplul prezintă posibilitatea integrării factorilor organizaționali, situaționali și individuali în estimarea cantitativă a gradului de "fiabilitate umană" a sistemelor electroenergetice.

În [Iesmantas2014] se argumentează faptul că RB pot îmbunătăți metodele de analiză a fiabilității rețelelor de transport al energiei electrice, atât datorită abilității de a lucra cu date și parametri cu un grad de certitudine relativ redus cât și de a trata structurile ierarhice complexe asociate lor. Abordarea bayesiană a evidențiat nesimilaritățile situațiilor de ieșire din funcțiune generate de liniile de transport. Rezultatele analizelor ierarhizate de ieșire din funcțiune au fost utilizate la evaluarea fiabilității configurațiilor unor părți reprezentative ale SEE. La fel, analiza ieșirilor din funcționare în cascadă a unor linii a relevat nesimilarități între diversele situații de această factură. Structura ierarhică a modelului a condus la urmări mai grave ale situațiilor de această natură, rezultând o probabilitate mai accentuată a evenimentelor în cascadă, în contradicție cu studiile anterioare. Analizele efectuate pentru rețeaua de transport nord-americană nu au condus la concluzii relevante despre natura ierarhică a situațiilor de ieșire din funcțiune, ceea ce a subliniat incertitudinea legată de aceste fenomene. Rezultatele obținute nu pot fi aplicate direct în evaluarea fiabilității rețelei utilizând indici de tip SAIDI sau CAIDI (care presupun estimarea duratei de întrerupere a alimentării consumatorilor, a energiei nelivrate etc.). Totuși, dacă se extinde analiza cu rețeaua de distribuție și cu datele sarcinii, atunci rezultatele pot fi utilizate la evaluarea fiabilității din punctul de vedere al consumatorilor.

Înmulțirea atacurilor cibernetice asupra sistemelor de tip SCADA (Supervisory Control and Data Acquisition) au condus la scăderea fiabilității SEE din acest motiv. În [Zhang2014] s-au luat în considerare șase scenarii posibile de atacuri cibernetice, utilizând un model bayesian pentru evaluarea probabilității unor atacuri reușite asupra sistemelor SCADA, care ar avea drept urmare declanșarea unor întreruptoare. Se propune un model de rată de întrerupere forțată luând în considerare atacurile reușite asupra generatoarelor și liniilor de transport al energiei electrice. Rezultatele obținute utilizând sistemul test IEEE pentru studiile de fiabilitate (IEEE Reliability Test System – 24 noduri, 32 generatoare, 33 linii electrice și 5 transformatoare) au demonstrat că SEE devin mai puțin fiabile în condițiile creșterii frecvenței atacurilor cibernetice reușite.

[Borges2016] utilizează un model de reprezentare a mărimilor variabile în timp dependente statistic, care se poate utiliza în cadrul metodelor mixte de evaluare a fiabilității prin simulare Monte Carlo non-secvențială. Modelul a fost dezvoltat prin combinarea unei metode de estimare non-parametrice a funcțiilor de densitate de probabilitate pentru variabilele continue cu măsurarea dependenței statistice neliniare și reprezentarea grafică a probabilității condiționate dată de utilizarea RB. Aplicația

concretă se referă la sistemul test IEEE pentru studiile de fiabilitate (IEEE Reliability Test System), completat cu 27 ferme eoliene fictive, cu diverse serii reale de vânt. Simulările au arătat că modelul poate reproduce exact statistica seriilor istorice și să surprindă influența oricărui tip de corelare asupra indicilor de fiabilitate. Cu alte cuvinte, este la fel de precis ca simularea Monte Carlo secvențială și la fel de eficient din punctul de vedere al volumului de calcul ca cea non secvențială. Modelul se poate utiliza direct pentru a reprezenta corelația dintre puterea generată de sursele eoliene și debitul de apă intrat într-un sistem hidroenergetic. De asemenea, se poate analiza influența surselor intermitente de putere generată sau a consumatorilor variabili în timp asupra sistemelor electroenergetice complexe.

În [Sykora2016] se prezintă utilizarea RB pentru a evalua riscurile legate de fiabilitatea unui grup generator din cadrul unei centrale termoelectrice. Pentru implementarea abordării statistice se acordă o atenție sporită datelor legate de ratele de defectare, obținute din istoria anterioară și pe baza părerii specialiștilor. Informațiile discutate vizează întregul lanț termo-mecanic și electric: cazanul, turbina și generatorul. Concluzia este că RB reprezintă un instrument eficient pentru analizele de risc și de (in)disponibilitate, oferind informații importante privind procesul de mentenanță, reparațiile necesare și situațiile în care se impune înlocuirea unor echipamente. RB facilitează și evaluarea tendinței de modificare a parametrilor tehnici descriind funcționarea instalațiilor și echipamentelor componente. O abordare asemănătoare este descrisă și în [Lorencin2017].

### 3.3. Aplicații în domeniul estimării stării sistemelor electroenergetice

Identificarea modificării configurației rețelei în estimarea stării statice a rețelelor de distribuție a energiei electrice, realizată printr-o abordare bayesiană recursivă, constituie obiectul cercetărilor prezentate în [Singh2010]. Configurațiile critice din punctul de vedere al estimării stării sunt memorate într-o bancă de date (de "modele"). Toate modelele au fost obținute pe baza unor măsurători obișnuite, la care se adaugă cele virtuale și pseudo-măsurătorile. Lucrarea propune o abordare bayesiană recursivă pentru a identifica modificările de configurație. Pe baza rezultatelor obținute din estimarea stării, algoritmul determină pentru fiecare model probabilitatea de a corespunde configurației reale a rețelei. Modelul cu cea mai ridicată probabilitate indică configurația posibilă a rețelei. Modelelor incorecte li se asignează un indice de probabilitate de valoare redusă sau chiar nulă, fiind rejectate. Eficiența algoritmului, dovedită prin rezultatele concrete obținute, permite implementarea sa în instrumentele soft uzuale de estimare a stării sistemelor electroenergetice, rezultatul fiind obținut practic în timp real.

În [Hu2011] se prezintă utilizarea RB la estimarea stării statice a sistemelor de distribuție a energiei electrice. Se pornește de la faptul că RB este un model probabilistic bazat pe teoria grafurilor. Se utilizează un graf orientat, fără circuite, pentru a reprezenta o mulțime de variabile și interdependențele dintre ele. RB au capacitatea de a exprima probabilitatea ca oricare dintre cauzele posibile cunoscute să constituie factorul decisiv pentru producerea unui eveniment. În problema discutată grafurile înglobează toate variabilele de stare și dependențele dintre ele, exprimate în manieră probabilistică (atât cele de natură electrică cât și cele de mediu, legate de implementarea surselor regenerabile de energie). Acolo unde există probleme de observabilitate (număr insuficient de măsurători) se propune ca în loc de pseudo-măsurători să se utilizeze un algoritm de tip "belief propagation" (BP).

Abordarea bayesiană recursivă de tip Seidel propusă în [Chen2012] este utilizată în identificarea și estimarea parametrilor elementelor de rețea, dar poate fi de folos și în estimarea poziției plotului de reglaj la transformatoare și autotransformatoare, diagnoza defectelor sau analize de fiabilitate. Detaliile privind estimarea poziției plotului de reglaj sunt dezvoltate în [Chen2013], cu câte o aplicație pentru sistemul test IEEE cu 14 noduri și pentru un SEE real de mari dimensiuni din China. A rezultat în final un instrument soft de estimare a stării SEE cu performanțe superioare celor existente.

Estimarea stării statice a rețelelor electrice de distribuție este abordată și în [Schenato2014], în condițiile în care pseudo-măsurătorile sunt înlocuite de datele obținute de la sincrofazori (PMU – Phasor Measurement Unit). Estimarea "clasică" cu metoda celor mai mici pătrate ponderate (WLS) este înlocuită cu un estimator liniar bayesian bazat pe aproximarea liniară a circulației de puteri în rețeaua de distribuție. Pe baza puterilor active și reactive consumate se obțin informații apriori despre distribuțiile statistice ale fazorilor de tensiune (modului și faza tensiunii). Acestea pot fi calculate off-line și, odată ce măsurătorile PMU sunt disponibile, ele se pot utiliza pentru estimarea fazorilor reali de tensiune și pentru reducerea gradului de incertitudine dat de distribuțiile statistice aposteriori ale erorilor de estimare a stării. În acest context pot fi rezolvate și o serie de aspecte legate de numărul și amplasarea PMU, fără simulări extinse de tip Monte-Carlo. O abordare asemănătoare este prezentată și în [Amini2015], rezultatele pentru un sistem test fiind comparate cu cele obținute prin metoda WLS.

În [Angioni2016] se propune un estimator bazat pe RB pentru a soluționa problemele legate de distribuția non-gaussiană a incertitudinii pseudo-măsurătorilor legate de puterile consumate și/sau cele generate. Abordarea prezentată permite luarea în considerare a diverselor tipuri de funcții de densitate de probabilitate, inclusiv cele care nu pot fi reprezentate prin modele de distribuție standard. O problemă similară este tratată și în [Pegoraro2017], în ambele lucrări aplicația concretă referindu-se la o rețea de distribuție radială de dimensiuni reduse. [Ji2021] realizează o abordare mult mai elevată a acestei probleme, aplicațiile vizând sisteme test de mari dimensiuni (IEEE 118 și IEEE 300).

[Petra2017] are ca obiect estimarea stării dinamice a sistemelor electroenergetice. Se prezintă o abordare bayesiană a estimării parametrilor dinamici cu un anumit grad de incertitudine. În condițiile implementării pe scară largă a PMU și a extinderii surselor regenerabile de energie, caracteristicile de inerție ale sistemului nu mai sunt cunoscute. Ele trebuie estimate, împreună cu gradul lor de certitudine, pentru a asigura buna funcționare a sistemului din punctul de vedere al stabilității la mari perturbații.

Problema estimării statice a SEE în urma unor atacuri cibernetice este abordată în [Soltan2018]. În prima etapă se aplică o procedură de regresie bayesiană pentru găsirea mulțimii liniilor electrice cu cel mai înalt grad de probabilitate de a fi avariate (deconectate). În a doua etapă doar pentru aceste linii se aplică o procedură de explorare exhaustivă de tip BFS (Brute Force Search), ceea ce conduce la o scădere semnificativă a timpului de calcul. Rezultă o soluție de compromis între precizia rezultatelor și eficiența metodei. O problemă similară este discutată și în [Gaber2015], rezultând o nouă strategie de detectare a datelor eronate în estimarea stării rețelelor electrice inteligente, cauzate de atacurile cibernetice, utilizând o abordare bayesiană.

În [Massignan2019] estimarea stării statice a sistemelor electroenergetice se realizează printr-o abordare utilizând inferența bayesiană. În condițiile utilizării pe scară largă a PMU apare problema combinării măsurătorilor obținute pe această cale cu cele oferite de sistemele SCADA (Supervisory Control and Data Acquisition) clasice,

în condițiile unor diferențe semnificative în ceea ce privește ratele de eșantionare și precizia. Se propune o abordare în două etape. Pentru început se realizează o estimare inițială "clasică" de tip WLS pe baza măsurătorilor furnizate de sistemele SCADA. În a doua etapă se utilizează informațiile oferite de PMU pentru a realiza o interpretare probabilistică a soluției din prima etapă. Se remarcă ameliorarea calității estimării chiar și în condițiile unui număr mai redus de PMU, inclusiv pentru nodurile care nu sunt direct monitorizate de PMU.

[Mestav2019] are ca obiect estimarea stării sistemelor de distribuție a energiei electrice care prezintă probleme de observabilitate. Metoda propusă presupune în prima fază învățarea distribuită a injecțiilor de putere stohastice în nodurile sistemului. Apoi se utilizează o metodă de tip Monte-Carlo pentru antrenarea unei RNA cu mai multe straturi ascunse. În final se realizează un algoritm bayesian de detectare și filtrare a datelor eronate. Rezultatele obținute evidențiază avantajele unei asemenea metode de abordare în comparație cu utilizarea pseudo-măsurătorilor.

### **3.4. Aplicații în domeniul analizei stabilității sistemelor electroenergetice**

În [Augustis2012] se prezintă o metodă de evaluare a stabilității la mari perturbări a sistemelor electroenergetice pentru diverse regimuri de funcționare utilizând RB. Este vorba în esență de o tehnică de analiză hibridă, care combină metoda clasică de analiză prin modelarea în detaliu a sistemului electroenergetic cu o abordare bazată pe RB. Cea din urmă utilizează un model de estimare pentru determinarea caracteristicilor de stabilitate pentru anumite generatoare sincrone. În acest mod toate generatoarele pot fi analizate prin estimarea bazată pe abordarea bayesiană în locul unei analize utilizând modelarea în detaliu a sistemului. Avantajul major constă în reducerea substanțială a efortului de calcul, fără a altera semnificativ acuratețea rezultatelor. Calitatea rezultatelor poate fi ameliorată prin gruparea generatoarelor pe baza coerenței, apreciată pe baza unui coeficient de corelare a curbilor de oscilație (variația în timp a unghiului intern). O abordare asemănătoare este prezentată și în [Fan2009].

Spre deosebire de lucrările anterioare, în [WuChao2009], [Seppanen2016] și [Ma2013] analizele se referă la stabilitatea la mici perturbări a SEE, incluzând în modelul de analiză și RB.

În [Chevalier2019] se urmărește localizarea sursei oscilațiilor, în condițiile unor incertitudini în ceea ce privește parametrii generatoarelor sincrone și acuratețea măsurătorilor obținute de la sincrofazori (PMU – Phasor Measurement Unit), elemente care justifică o utilizarea a RB.

[Vakili2015] are ca obiect analiza stabilității tensiunii, utilizând o metodă directă de tip Lyapunov, combinată cu determinarea bayesiană a celui mai rapid punct de schimbare.

### **3.5. Aplicații în domeniul diagnozei și localizării defectelor**

[Teive2011] prezintă un sistem inteligent de diagnoză a defectelor în rețelele de transport al energiei electrice (exclusiv liniile electrice, fără echipamentele din stațiile de transformare), bazat pe utilizarea RB. Sistemul are la bază informațiile legate de tipurile de defecte, de cauzele acestora, de relațiile de tip cauză – efect

dintre ele, de penalizările datorate nefuncționării liniilor etc. RB oferă un instrument adecvat pentru rezolvarea unor probleme de raționament abductiv, care presupun trecerea paradigmatică de la informațiile particulare existente la un mecanism intrinsec sau extrinsec care evidențiază, în manieră probabilistă, o cauzalitate mai adâncă. O asemenea tratare permite ambele tipuri de raționament – diagnoza și prognoza. În [WuCheng2011] abordarea este asemănătoare, exploatând capacitatea RB de a trata problemele în care informațiile sunt de regulă nesigure și incomplete.

În [Li2014] metoda de diagnoză bayesiană a defectelor are la bază analiza de izolare a defectului. Modelul este construit din două puncte de vedere – izolarea întreruptorului și izolarea protecției, care reflectă în mod direct modul de acțiune al întreruptorului și al protecției în momentul apariției defectului. În același timp, împărțirea întreruptoarelor în trei nivele, în funcție de tipul protecției și timpul de acționare, reduce numărul de echipamente de comutație suspicinate în zona afectată, ameliorând eficiența diagnozei defectului.

Pentru a trata mulțimea de informații incerte legate de defectele care pot să apară în rețelele de transport al energiei electrice, diagnoza acestora este soluționată în [WangT2015] prin utilizarea unor RB speciale orientate pe obiecte. Graful conex și fără circuite asociat RB cuprinde atât vârful de tip Noisy-OR cât și Noisy-AND. Dacă un anumit vârf are valoarea "false" ("fals") când toate vârfurile antercedente au valoarea "false", atunci este un vârf de tipul Noisy-OR (seamănă cu definiția lui OR (SAU) logic, cu deosebirea că nu se poate afirma că vârful respectiv are valoarea "true" ("adevărat") dacă unul dintre vârfurile antercedente are valoarea "true". Dacă un anumit vârf are valoarea "true" când toate vârfurile antercedente au valoarea "true", atunci este un vârf de tipul Noisy-AND (seamănă cu definiția lui AND (ȘI) logic, cu deosebirea că nu se poate afirma că vârful respectiv are valoarea "false" dacă unul dintre vârfurile antercedente are valoarea "false". Pentru antrenarea rețelei și actualizarea parametrilor săi se utilizează un algoritm de tip "backpropagation" (propagare în sens invers). Pentru a minimiza abaterea pătratică medie dintre valoarea calculată și cea măsurată se utilizează metoda gradientului conjugat [Kilyeni2015], [Deacu2015]. Per ansamblu este un model de localizare a defectelor simplu și rapid, utilizând informațiile (uneori incerte) despre acțiunea protecțiilor și starea întreruptoarelor.

În [XuT2010] se prezintă o metodă de localizare a defectelor în rețelele de distribuție rurale utilizând inferența bayesiană. Pe baza informațiilor oferite de apelurile legate de deranjamente (cele mai multe nesigure și incomplete) și a experienței personalului de exploatare (având un grad de încredere relativ scăzut) s-a realizat un model probabilistic de învățare, de raționament, bazat pe metoda bayesiană. Algoritmul de localizare a defectelor a fost implementat în sistemele GIS (Geographic Information System – Sistem Informațional Geografic) aferente rețelelor de distribuție rurale.

Diagnoza defectelor pentru cazul hidrogenatoarelor este abordată în [XuB2019], luând în considerare atât cauzele de natură electrică cât și cele de natură mecanică sau hidraulică. Metodologia utilizată are la bază un sistem expert și utilizarea RB. S-a realizat un model bayesian complet de diagnoză a defectelor, care se bazează pe cunoașterea aprofundată a vibrațiilor care apar la diverse tipuri de defecte și a caracteristicilor de defect asociate. RB cuprinde vârful de tip Noisy-OR, pentru a evita calculele complicate și dependența de date la obținerea tabelului de probabilitate condiționată. Sistemul expert realizat combină experiența specialiștilor cu inferențele bayesiene. Rezultatele obținute permit înlocuirea mentenanței la intervale de timp planificate cu cea bazată pe starea echipamentelor, ceea ce conduce

la reducerea costurilor de mentenanță pentru centralele hidroelectrice. Suplimentar, datele istorice colectate de la centrala hidroelectrică permit o mai bună diagnoză, obținerea diagnozei de la fabricanții echipamentelor fiind dificilă datorită confidențialității informațiilor.

În [Zhao2010] se prezintă un sistem de monitorizare și diagnoză a defectelor pentru transformatoarele și autotransformatoarele de mare putere, având la bază un sistem de tip multi-agent, combinat cu un algoritm de clasificare bayesiană. Din punct de vedere fenomenologic, diagnoza are la bază analiza gazelor rezultate în cuva cu ulei în cazul unor scurtcircuite interioare, care au ca efect vaporizarea uleiului determinat de arcul electric. Un sistem de tip multi-agent cuprinde mai mulți agenți software inteligenți, similari sau diferiți, care interacționează prin schimb de mesaje, contribuind individual la rezolvarea în colectiv a unei probleme. Agenții individuali trebuie să aibă capacitatea de cooperare, de coordonare și de negociere cu ceilalți agenți. Asemenea sisteme pot rezolva probleme care pentru un sistem de tip mono-agent (software monolitic) sunt dificile sau nerezolvabile. Clasificatorul bayesian oferă un model statistic, care utilizează informația (probabilitatea) "priori" și datele eșantion (cunoscute) pentru a determina probabilitatea "posterioră" (finală) a unui eveniment. Diagnoza realizează o funcție de mapare între semnele apariției unui defect și tipul defectului, esența sa fiind procesul de clasificare ce determină tipurile de variabile pe baza atributelor acestora. Sistemul realizat conduce la creșterea acurateții diagnozei defectelor la transformatoarele și autotransformatoarele de mare putere.

La fel ca în cazul anterior, abordarea din [Zheng2010] a diagnozei defectelor în transformatoare are la bază analiza gazelor rezultate în cuva cu ulei în cazul unor scurtcircuite interioare, care au ca efect vaporizarea uleiului datorită arcului electric. În această lucrare se analizează comparativ mai multe tipuri de clasificatoare bayesiene (NB – Naïve Bayesian classifier, TBA Tree Augmented Naïve Bayesian classifier, GBN – General Bayesian Network classifier), cu evidențierea avantajelor și dezavantajelor.

În [Zhou2012] se prezintă un model de simulare a duratei de viață a transformatoarelor din rețelele de distribuție a energiei electrice. Defectarea transformatoarelor este un eveniment destul de rar, ceea ce înseamnă un volum redus de date inițiale cunoscute. Pentru a surmonta acest aspect, durata de viață a transformatorului este tratată ca o variabilă aleatoare, cu o anumită distribuție de probabilitate. Aplicând acest model probabilistic pentru un grup de transformatoare se poate estima numărul de transformatoare care trebuie înlocuite. În lucrare se propune ca modelul inițial să fie realizat pe baza informațiilor legate de siguranța în funcționare a unui număr mare de transformatoare similare. În continuare se utilizează o procedură de actualizare (actualizare) bayesiană pentru a incorpora cunoștințele de tip prior (anterioare) referitoare la avariile reale în modelul inițial, rezultând astfel un model avansat al duratei de viață a transformatoarelor. În final se propune o actualizare secvențială a modelului, ceea ce conduce la o manieră dinamică a ameliorării modelului duratei de viață a transformatorului.

### 3.6. Alte aplicații ale rețelelor bayesiene

Suplimentar față de domeniile de utilizare ale rețelelor bayesiene în ingineria sistemelor electroenergetice prezentate în subcapitolele anterioare, se menționează și următoarele exemple de aplicații diverse:



- În [WangY2011] se utilizează un clasificator bayesian on-line în tehnicile de management dinamic al puterii consumate.
- Abordarea bayesiană recursivă de tip Seidel propusă în [Chen2012] este utilizată în identificarea și estimarea parametrilor elementelor de rețea, dar poate fi de folos și în estimarea poziției plotului de reglaj la transformatoare și autotransformatoare, diagnoza defectelor sau analize de fiabilitate. Detaliile privind estimarea poziției plotului de reglaj sunt dezvoltate în [Chen2012], cu o aplicație pentru sistemul test IEEE cu 14 noduri, respectiv pentru un SEE real de mari dimensiuni din China.
- În [Montenegro2012] se utilizează o RB pentru a determina cea mai probabilă cauză și consecințele unei perturbații în sistemul electroenergetic.
- Estimarea stării consumatorilor în rețelele inteligente emergente reprezintă un element esențial al oricărei analize. În [Dong2014] se prezintă o metodă de determinare a profilului sarcinii utilizând un model gaussian mixt. Elementul de noutate constă în utilizarea inferenței variaționale bayesiene pentru a seta parametrii modelului. Comparativ cu alte metode de aproximare, abordarea bayesiană rezolvă o serie de probleme legate de singularitatea datelor și de situațiile de "over-fitting".
- În [Neumayer2014] se prezintă un model de estimare a parametrilor transformatoarelor utilizând un set redus de măsurători. Abordarea bayesiană oferă instrumentul necesar pentru a obține informațiile referitoare la parametri de interes din rezultatele unor măsurători indirecte. Exemplul concret vizează determinarea rezistenței exclusiv din măsurători de curent alternativ.
- Incertitudinile legate de puterile generate și consumate îngreunează luarea celor mai bune decizii ale agenților care participă la piața de energie electrică. Strategiile optime de licitare sunt dificil de stabilit în condițiile evaluării evoluției pieței pe baza unor informații incomplete. În [Dehghanpour2016] se propune un model probabilistic al pieței bazat pe RB dinamice, care folosesc un algoritm bayesian lacunar de învățare online, pentru a estima starea viitoare a pieței și a adopta strategia optimă de licitare.
- În [XuQ2016] se propune o abordare bayesiană a stabilirii prețului rezervei turnante, în condițiile în care incertitudinile legate de capacitatea de producție a centralelor eoliene au condus la creșterea cuantumului unei asemenea rezerve. Aplicațiile prezentate în lucrare se referă la SEE al Chinei, unde există o serie de subsisteme zonale independente, pentru care corelarea rezervei turnante devine stringentă.
- O problemă asemănătoare este tratată în [Fahiman2018], ținând cont de lipsa de predictibilitate a producției surselor regenerabile de energie. Pentru dimensionarea rezervei se utilizează un model bazat pe RB dinamice.
- În [Mitridati2018] se prezintă un model bazat pe inferența bayesiană pentru estimarea curbei agregate a ofertei în piața de energie electrică pentru ziua următoare.
- Rețelele neuronale artificiale cu algoritm de antrenare bazat pe regularizarea bayesiană sunt utilizate pentru reducerea consumului propriu tehnologic în rețelele electrice de distribuție cu sarcină variabilă și mijloace de stocare a energiei [Monteiro2018].
- În [Zuluaga2018] determinarea probabilistă a circulației de puteri este abordată ca o problemă de inferență bayesiană.

### 3.6. Concluzii

În cadrul acestui capitol s-a realizat o prezentare sistematizată a utilizării rețelelor bayesiene în domeniul ingineriei sistemelor electroenergetice. Cele mai multe aplicații vizează diversele aspecte ale prognozei consumului de energie electrică și putere. Acestea vor fi tratate separat, mai pe larg, în Capitolul 4, având în vedere că prognoza utilizând RB constituie obiectul acestei teze de doctorat.

S-au trecut în revistă o gamă largă de aplicații, începând cu fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a sistemului electroenergetic în ansamblu, continuând cu estimarea stării și analiza stabilității SEE, cu diagnoza și localizarea defectelor în rețelele electrice, diagnoza defectelor legate de transformatoare și generatoare, cu estimarea valorii parametrilor elementelor de rețea (linii electrice, transformatoare). În ultimul subcapitol s-au prezentat și o serie de aplicații diverse, neîncadrate în domeniile menționate mai sus.

În continuare se prezintă o trecere în revistă a contribuțiilor personale din acest capitol:

- identificarea domeniilor din cadrul ingineriei sistemelor electroenergetice în care utilizarea avantajelor oferite de RB este benefică, numărul din ce în ce mai mare de lucrări publicate în ultima perioadă (practic ultimii 10-15 ani) constituind o dovadă clară a interesului manifestat față de abordarea specifică, în manieră bayesiană, a unui număr din ce în ce mai mare de aplicații;
- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a problemelor din domeniile identificate, unde utilizarea RB aduce avantaje incontestabile;
- evidențierea subdomeniilor în care, pe baza numărului de lucrări publicate în ultima perioadă, abordarea bayesiană se va extinde în continuare.

## 4. PROGNOZA CONSUMULUI DE ENERGIE ELECTRICĂ

Obiectivul capitolului 4 constă în prezentarea problemelor legate de prognoza consumului de energie electrică (putere de vârf, putere orară, energie consumată, curbe de sarcină etc.) și a metodelor utilizate pentru obținerea prognozei.

Prima parte a capitolului cuprinde aspecte generale legate de prognoză, clasificarea metodelor utilizate după diverse criterii, insistându-se asupra orizontului de timp la care se referă prognoza.

Urmează prezentarea propriu-zisă a metodelor, în funcție de orizontul de timp la care se referă, pe baza unui studiu bibliografic consistent. Sunt urmărite atât metodele "clasice", bazate pe modelarea matematică, cât și cele "moderne", de dată mai recentă, utilizând tehnici de inteligență artificială, logică fuzzy, sisteme expert, "support vector machine" (SVM) etc.

Un subcapitol aparte, consistent, este dedicat metodelor care utilizează rețele neuronale bayesiene (RNB), care constituie obiectul acestei teze de doctorat.

### 4.1. Clasificarea metodelor de prognoză

Prognoza consumului de energie electrică și a puterii este activitatea ce are drept scop previzionarea consumului de energie și putere pe baza analizei calculelor și interpretărilor asupra unui ansamblu de date diversificate, astfel încât în final să se realizeze o concordanță cât mai exactă între consumurile estimate și cele efectiv realizate.

Prognoza consumului de energie poate fi clasificată după mai multe criterii [Luștrea2001], cu observația că părerile nu sunt întotdeauna unitare, mai ales în privința definirii limitelor intervalului de timp.

În funcție de durata la care se referă, se discută de următoarele tipuri de prognoză:

- pe termen foarte scurt – de la ore până la un an;
- pe termen scurt – între 1-5 ani;
- pe termen mediu – între 5-10 ani;
- pe termen lung – între 10-20 de ani;
- pe termen foarte lung – peste 20 de ani.

În funcție de aria de acoperire spațială vizată, se poate discuta despre prognoză pentru:

- consumatori individuali;
- consumatori regionali;
- consumatori zonali;
- consumatori naționali;
- consum mondial.

În funcție de scopul urmărit, se poate discuta despre prognoză:

- în profil teritorial;
- pe ramuri economice;
- la nivel național.

În funcție de modul de exprimare a rezultatelor prognozei se poate vorbi despre:

- metode deterministe;
- metode probabiliste.

După tipul metodei se pot distinge următoarele categorii de metode:

- explorative;
- normative;
- mixte.

În funcție de natura variabilei independente, se discută despre următoarele metode de prognoză:

- directe / endogene;
- indirecte / exogene / condiționale;
- analitice;
- de tip Delphi.

După numărul de componente ale consumului se poate vorbi despre:

- metode globale / sintetice;
- metode pe componente / analitice.

Conform [Luștea2001], *metodele directe de prognoză* se bazează pe ipoteza conform căreia cauzele, factorii și tendințele care au determinat evoluția consumului de energie sau de putere în perioada anterioară se mențin și în perioada viitoare, pe întreaga durată a prognozei neintervenind schimbări esențiale, care să influențeze evoluția consumului.

Din punct de vedere matematic problema constă în stabilirea celei mai potrivite funcții care să estimeze variația consumului. Este necesară stabilirea numărului de variabile, a formei funcției, evaluarea coeficienților numerici ai funcției, verificarea modelului pentru date existente, corectarea modelului și validarea sa finală.

Metodele de prognoză prin extrapolare sunt utilizate pe scară largă datorită avantajelor pe care le prezintă: sunt relativ simple și intuitive, putând fi transpuse destul de comod în cadrul unor programe adecvate de calcul; rezultatele obținute sunt suficient de corecte dacă ipotezele de lucru își păstrează valabilitatea în viitor.

*Metodele indirecte de prognoză* a consumului de energie sau putere fac uz de corelația dintre consum și factorii demografici, climatici, economici etc.

Principalele problemele care trebuie rezolvate în cazul metodelor indirecte de prognoză sunt legate de alegerea factorilor care determină consumul de energie, un rol decisiv avându-l orizontul de timp al prognozei. Pentru prognozele pe termen scurt sunt importanții factorii climatici (temperatura medie zilnică, viteza medie a vântului, umiditatea medie zilnică, durata perioadei cu soare etc.). Pentru prognozele pe termen mediu factorii globali au o mare importanță (indicele demografic, producția industrială, volumul investițiilor etc.). Prognozele pe termen lung sunt puternic influențate de factorii specifici – productivitatea muncii, produsul brut pe cap de locuitor, prețul energiei etc.

Rezultatele obținute prin utilizarea metodelor indirecte oferă informații utile, comparabile cu cele furnizate de metodele directe, însă dificultățile pe care le ridică estimarea evoluției viitoare a variabilelor explicative, de care depinde consumul de energie electrică sau de putere, fac ca aceste metode să fie folosite mai rar decât cele directe de extrapolare. Obținerea datelor despre factorii climatici, economici sau demografici ridică în general mari probleme.

*Metodele analitice de prognoză* a consumului de energie se bazează pe ideea descompunerii consumului în componente, urmată de prognoza fiecărei componente în parte cu ajutorul uneia dintre metodele discutate anterior (directă sau indirectă).

Folosirea unei metode analitice pentru estimarea consumului de energie este foarte laborioasă, oferind rezultate bune doar dacă compoziția consumului nu suferă modificări pe durata analizată și dacă între diversele componente nu se manifestă influențe.

*Metodele de tip Delphi* s-au aplicat cu succes în prognoza pe termen lung a consumului de energie în situațiile în care rezultatele obținute nu au fost satisfăcătoare din diverse motive: date inițiale insuficiente, ipotezele neconcordante cu situația reală, apariția unor importante modificări (tehnologice, sociale etc.), dificil de a fi incluse în mod corect în modele matematice.

Metoda Delphi [Lilja2011] obține datele necesare pentru prognoză printr-un proces interactiv de consultare a specialiștilor (individual sau tip "panel"). Față de variantele inițiale, bazate exclusiv pe consens, la ora actuală se preferă cele de tip argumentativ.

## 4.2. Metode pentru prognoze pe termen mediu și lung

În cadrul acestui subcapitol, la fel ca în cel următor (referitor la prognozele pe termen scurt), se prezintă o gamă largă de metode, exceptând cele care utilizează RNB. Acestor metode le este consacrat un subcapitol aparte, relativ mai extins (4.4), având în vedere faptul că ele constituie obiectul acestei teze de doctorat.

### □ Modele de tip "end-use"

Abordarea "end-use" estimează direct consumul de energie folosind o gamă largă de informații despre consumul final și utilizatorul final. La baza prognozei stau datele statistice de consum și dinamica schimbărilor [Chow2005]. Modelul se aplică în general la consumatorii rezidențiali și la cei comerciali, dar și la cei industriali.

În mod ideal această abordare ar fi foarte precisă. În mod real, ea depinde semnificativ de acuratețea datelor inițiale. Faptul că informațiile nu trebuie să acopere o perioadă anterioară foarte lungă reprezintă un avantaj incontestabil.

### □ Metode econometrice

Abordarea econometrică combină informațiile de natură economică și tehnicile statistice pentru prognoza consumului de energie electrică [Chow2005]. Ea estimează legătura dintre consumul de energie (variabila dependentă) și factorii ce influențează consumul (variabilele independente). Estimarea se bazează pe metoda celor mai mici pătrate [Kilyeni2014] sau pe metoda seriilor temporale [Luștrea2001].

În [Fu2003] se prezintă un model econometric bazat pe metoda regresiei, în combinație cu o tehnică de tip "wavelet". Identificarea parametrilor modelului de prognoză se realizează prin soluționarea unei probleme de optimizare neliniară secvențial pătratică [Kilyeni2015]. În final se include în model, într-o manieră probabilistă, și influența temperaturii asupra consumului de energie electrică.

### □ Metode mixte

Este posibilă și utilizarea combinată a celor două categorii de metode de mai sus, rezultând o serie de metode "mixte" din acest punct de vedere. O asemenea abordare este avantajoasă atunci când consumul de energie electrică din diverse sectoare (rezidențial, comercial, industrial etc.) se determină în funcție de date de natură economică, climatică, socială etc., în final prognozele fiind comparate cu cele obținute pe baza istoriei recente (câțiva ani anteriori) [Chow2005].

#### □ **Abordări moderne**

Pe lângă metodele "clasice" menționate anterior, în ultima perioadă se remarcă și o gamă largă de abordări moderne, care utilizează tehnici de inteligență artificială (rețele neuronale, calcul evolutiv, abordări în manieră fuzzy etc.).

În [HeY2006] prognoza se realizează cu ajutorul unei rețele neuronale recurente de tip Elman, combinată cu teoria entropiei și cu abordarea fuzzy, în scopul identificării factorilor relevanți de influență.

[Amjady2008] prezintă o metodă de prognoză pe termen mediu a puterii de vârf zilnice (considerată a fi un "semnal" neliniar, volatil și nestaționar). Problema este complicată și datorită volumului insuficient de informații. Se utilizează o tehnică hibridă, care reunește o prelucrare eficientă a datelor inițiale, un mecanism de prognoză preliminară și o combinație de rețea neuronală artificială cu un algoritm de calcul evolutiv. Aplicația se referă atât la date test (EUNITE – European Network on Intelligent TEchnologies) cât și la sistemul electroenergetic din Iran, rezultatele fiind promițătoare.

Un algoritm de optimizare de tip roi de particule (Particle Swarm Optimization – PSO) este utilizat în [Rashidi2010], urmărind minimizarea erorii asociate parametrilor modelului estimat. Aplicația se referă la rețele de distribuție din Kuweit și Egipt, fiind vizat atât consumul de energie electrică cât și puterea de vârf. Rezultatele sunt comparate cu cele obținute cu metoda celor mai mici pătrate (în locul algoritmului PSO), cu o concluzie favorabilă noii metode.

În [Tao2013] prognoza pe termen mediu și lung se efectuează cu ajutorul unor serii de timp utilizate în manieră fuzzy. Aplicația numerică se referă la consumul de energie pentru provincia Jiangsu (China). Datele se cunosc pe 12 ani: primii 10 se utilizează pentru efectuarea prognozei consumului pentru anii 11 și 12, erorile față de datele reale de consum fiind de (2-4) %. Și în [Bolturk2012] se utilizează logica fuzzy, aplicația concretă având ca obiect o companie de distribuție a energiei electrice din Turcia.

Instrumentul utilizat în [Ganguly2018] este o rețea neuronală artificială. Se realizează prognoza pe termen mediu a consumului de putere urban pe diferite categorii de consum: industrial, comercial, rezidențial și de iluminat.

### **4.3. Metode pentru prognoze pe termen scurt**

În cadrul acestui subcapitol, la fel ca în cel anterior (referitor la prognozele pe termen mediu și lung), se prezintă o gamă largă de metode, exceptând cele care utilizează RNB. Acestor metode le este consacrat un subcapitol aparte, relativ mai extins (4.4), având în vedere faptul că ele constituie obiectul acestei teze de doctorat.

Sintagma de "termen scurt" acoperă toate accepțiunile, ceea ce înseamnă practic perioade de timp de la câteva zile la câțiva ani (evident, datele inițiale diferă în funcție de mărimea perioadei de prognoză).

#### □ **Metoda zilei similare**

Abordarea are la bază cercetarea datelor istorice pentru a găsi zile cu caracteristici similare celei pentru care se face prognoza. Caracteristici similare includ condițiile meteo, ziua în cadrul săptămânii și data. În locul prognozei pe baza unei singure zile similare, se poate utiliza o combinație liniară sau o procedură de regresie care include mai multe zile similare.

[Senjyu1998] prezintă o abordare de tip fuzzy pentru obținerea curbei de sarcină a zilei următoare cu metoda zilei similare. Logica fuzzy se utilizează pentru aprecierea gradului de similaritate, determinându-se în primă fază o serie de coeficienți de corecție pentru curbele de sarcină aferente zilelor anterioare similare. După corectarea lor, curba de sarcină pentru ziua prognozată rezultă ca o medie a celor pentru zilele similare anterioare. Autorii au ilustrat această abordare cu ajutorul unei aplicații reale pentru Okinawa Electric Power Company Japan. Cercetarea este dezvoltată în continuare în [Senjyu2004], utilizând de data aceasta pentru găsirea "similarității" o rețea neuronală artificială. Aplicațiile concrete se referă tot la Okinawa Electric Power Company.

Metoda este utilizată în [Ruzic2003], pentru prognoza pe termen scurt a unor curbe de sarcină sensibile la condițiile meteo (valoarea temperaturii). Aplicația a fost implementată la Compania de Distribuție a energiei electrice din Serbia.

[Eapen2019] utilizează metoda zilei similare, comparând-o cu o tehnică ce utilizează o rețea neuronală artificială cu retro-propagare. Testarea abordărilor propuse s-a realizat utilizând consumurile orare ale Electric Reliability Council din Texas (SUA) și cele ale Global Energy Forecasting Competition din 2012.

În [Chen2010] metoda zilei similare se utilizează, împreună cu o descompunere de tip wavelet și o rețea neuronală artificială, pentru a prognoza consumul pentru ziua următoare. Aplicația concretă se referă la datele test New England 2006.

Metoda zilei similare apare și în [Barman2018], în corelație cu o mașină vector suport (SVM – Support Vector Machine), fiind folosită pentru prognoza pe termen scurt a puterii consumate în statul Assam (India).

#### □ Metoda regresiei

Metoda regresiei este una dintre cele mai des folosite tehnici statistice. Pentru prognoza consumului de energie (putere) electrică, asemenea abordări sunt utilizate pentru a face legătura între consum și alți factori (condiții meteo, tipul zilei, natura consumului etc.). De regulă se utilizează regresia liniară; totuși când se analizează și influența temperaturii, se apelează și la modele neliniare. Avantajele metodei sunt legate de implementarea relativ simplă, de înțelegerea facilă a legăturii dintre variabilele de intrare și cele de ieșire și de aprecierea facilă a performanțelor metodei de prognoză [Hahn2009]. Totuși, datorită dependenței complexe neliniare între consumul de energie electrică și factorii de influență, apar probleme inerente legate de identificarea modelului corect [Kyriakides2007].

În [Hor2005] se prezintă un model de regresie multiplă și se analizează influența variabilelor legate de vreme asupra consumului de energie electrică în Anglia și Țara Galilor.

Regresia liniară este folosită și în [Goia2010] pentru prognoza puterii de vârf și a curbelor de sarcină, asociată cu o tehnică de clusterizare a datelor. Seturile de date (puterile orare) se referă la 4 perioade diferite, de 198 de zile fiecare. Utilizând o procedură de clusterizare, se obține o clasificare a curbelor de sarcină, pentru care se aplică regresia liniară multiplă.

În [Wi2012] se utilizează o metodă de regresie polinomială multiplă, aplicată în manieră fuzzy. Exemplul concret se referă la prognoza puterii pentru ziua următoare (zilele de sărbătoare), sistemul electroenergetic din Coreea de Sud. O problemă similară este tratată și în [Liu2017], în abordare probabilistă. Aplicația concretă utilizează datele standard din Global Energy Forecasting Competition 2014. În [Liang2019] regresia polinomială multiplă este asociată cu utilizarea unei rețele neuronale artificiale. Aplicația numerică se referă la un sistem electroenergetic real – cel din provincia Langfang (China).

### □ Metoda seriilor de timp

Această metodă este bazată pe ipoteza că datele au o structură internă clară, cum ar fi autocorelarea, trendul sau variațiile sezonale. Metodele de prognoză bazate pe serii de timp detectează și explorează asemenea structuri. Serii de timp au fost folosite în domeniul economic și cel al procesării semnalelor digitale, dar și la prognoza consumului de energie electrică (cele mai vechi metode). Cele mai utilizate metode legate de seriile de timp sunt următoarele: ARMA (autoregressive moving average), ARIMA (autoregressive integrated moving average), ARMAX (autoregressive moving average with exogenous variables) și ARIMAX (autoregressive integrated moving average with exogenous variables). Modelele ARMA sunt folosite de regulă pentru procesele staționare în timp ce ARIMA (o extensie a ARMA) pentru procesele nestaționare. ARMA și ARIMA folosesc timpul și consumul ca singuri parametri de intrare. Deoarece sarcina depinde în general de mai mulți factori (condițiile meteo, perioada din timpul zilei etc.), dintre diversele tipuri de serii de timp, ARIMAX constituie cel mai "natural" instrument pentru prognoza consumului.

[Jin2010] utilizează modelul ARIMA pentru a prognoza consumul de energie electrică pe termen scurt din New South Wales (Australia).

În [Lee2011] modelul ARIMA este utilizat împreună cu un algoritm genetic, în cadrul unei proceduri hibride, calitatea rezultatelor obținute fiind superioară comparativ cu alte metode.

### □ Metode bazate pe Rețele Neuronale Artificiale (RNA)

RNA au fost utilizate la prognoza consumului de energie electrică începând din anii '90 [Peng1992]. RNA sunt, în esență, circuite neliniare care au capacitatea de a realiza aproximarea numerică a unor funcții neliniare. Mărimile de ieșire ale RNA sunt funcții liniare sau neliniare de mărimile de intrare. Mărimile de intrare pot fi și mărimile de ieșire ale altor rețele. Practic elementele RNA sunt dispuse într-un număr relativ redus de straturi, între mărimile de intrare și cele de ieșire. Uneori se utilizează și căi de reacție inversă [Chow2005].

Utilizarea RNA la prognoza consumului de energie (putere) electrică presupune selectarea unei anumite arhitecturi (Hopfield, Backpropagation, mașină Boltzman etc.), a numărului și a modului de conectare a straturilor și a elementelor rețelei, a sensului legăturilor (uni-direcțional sau bi-direcțional), a tipului și formatului mărimilor de intrare și ieșire și a celor interne (binar sau real).

De regulă se utilizează RNA cu arhitectură Backpropagation, care fac uz de funcții cu variabile reale (variație continuă) și învățarea supervizată (adică ponderile atribuite mărimilor de intrare se determină astfel încât să "lege" mărimile cunoscute (timp, vreme) de ieșirile dorite (consumurile aferente cunoscute) în cadrul unei sesiuni pre-operaționale de învățare.

[Qingle2010] aplică o metodă de prognoză bazată pe RNA pentru situațiile când gradul de corelare a datelor cunoscute este extrem de scăzut ("rough set"), iar [Ismail2013] utilizează o tehnică mixtă – un sistem de inferență adaptiv neuro-fuzzy (ANFIS) – bazat pe sistemul de inferență fuzzy de tip Takagi–Sugeno.

În [Pandey2014] prognoza pe termen scurt a consumului este realizată cu ajutorul unei RNA. S-au utilizat instrumentele specializate din Matlab. Antrenarea rețelei s-a realizat utilizând datele orare de consum din perioada aprilie – iunie 2014, furnizate de Uttar Pradesh Power Corporation (India). Prognoza s-a efectuat pentru 2 săptămâni (pentru date de verificare cunoscute), eroarea medie fiind de 3.05 %.

O tehnică similară a fost utilizată și în [Khaton2015], prognoza fiind realizată tot pentru o companie de distribuție din India (Noida, din statul Uttar Pradesh). Pentru



antrenarea RNA s-au utilizat 744 valori ale puterii medii orare (octombrie 2013). Asupra datelor de intrare s-au aplicat o serie de procedee de tip fuzzy, eroarea medie de prognoză (pentru date de verificare cunoscute) fiind de circa 2 %.

În [Kumar 2016] prognoza se referă la curbele zilnice de sarcină. Pentru RNA s-au utilizat tot instrumentele specializate din Matlab, aplicând o regresie liniară multiplă. Datele de antrenare cuprind curbe de sarcină zilnică reale pentru perioada 1-15 iunie 2015.

Aplicația prezentată în [Sahay2016] utilizează tot mediul Matlab, fiind încercate diverse tipuri de RNA. Drept date de antrenare au fost utilizate puterile medii orare pentru consumul din orașul Toronto (Canada), din perioada 2007 – 2013. Testarea performanțelor rețelei s-a realizat cu datele (deja cunoscute) pentru anul 2014. Eroarea absolută procentuală (MAPE – Mean Absolute Percentage Error) a fost sub 1 % (valoare, totuși, foarte scăzută pe baza experienței noastre). O procedură similară este utilizată și în [Singh2017], prognoza fiind realizată pentru compania ISO-NE (New England Independent System Operator) din Massachusetts (SUA). Prognoza s-a realizat separat pentru zilele din timpul săptămânii, respectiv cele din weekend. Valoarea medie a MAPE a fost de 1.38 %, respectiv 1.39 % (valori remarcabile).

Elementul de noutate adus în [Hsu2018] constă în utilizarea unui model cu două RNA "în serie". Prima RNA prognozează curba de sarcină zilnică, iar a doua puterea de vârf, respectiv puterea minimă de gol de sarcină. Pe baza acestora este corectată prognoza obținută în prima etapă pentru curba de sarcină. Aplicația concretă se referă la o companie de energie electrică din Taiwan. Un model similar este folosit și în [Jarndal2018], pentru prognoza consumului în orașul Sharjah (Emiratele Arabe Unite). Datele cunoscute se referă la 3 ani (2016 – 2018), primii 2 ani fiind utilizați pentru antrenarea RNA, iar ultimul pentru verificarea calității prognozei. Cercetările au fost aprofundate în [Azad2018].

#### □ Metode care încorporează și logica fuzzy

Logica fuzzy (termenul de "fuzzy" însemnând „vag”, „neclar”, „estompat”) a fost definită în 1965 de către Lotfi Zadeh. Spre deosebire de logica clasică, în care se lucrează cu două valori de adevăr exacte (notate de exemplu cu 0 pentru fals și 1 pentru adevărat), logica fuzzy folosește o plajă continuă de valori logice cuprinse în intervalul  $[0, 1]$ , unde 0 indică falsitatea completă, iar 1 indică adevărul complet. Astfel, dacă în logica clasică un obiect poate aparține (1) sau nu (0) unei mulțimi date, logica fuzzy lucrează cu gradul de apartenență al obiectului la mulțime, acesta putând lua valori între 0 și 1.

Avantajele logicii fuzzy, la modul general și la cel particular al prognozei consumului de energie electrică, sunt legate de absența necesității unui model matematic riguros care să "mapeze" mărimile de intrare cu cele de ieșire precum și de absența necesității unor semnale de intrare exacte (fără "zgomot").

Cu astfel de reguli generice de condiționare, sistemele cu logică fuzzy pot oferi un suport solid pentru activitatea de prognoză a consumului de energie electrică (mai ales când există o serie de incertitudini legate de datele de intrare). Evident, mărimile de ieșire trebuie să aibă un caracter determinist (o anumită valoare clară a puterii consumate). În aceste condiții, după prelucrarea logică a mărimilor de intrare fuzzy, este necesară "defuzzificarea" rezultatului, pentru a obține mărimea de ieșire necesară.

Pentru a contracara dezavantajele legate de metodele convenționale de prognoză a consumului, în [Hu2009] se prezintă o metodă bazată pe rețelele neuro-fuzzy (RNA + logica fuzzy) pentru prognoza pe termen scurt a puterii consumate. Acest model combină abilitatea ridicată de învățare a RNA cu capacitatea logicii fuzzy

de a "mapa" funcțiile neliniare și de a găsi similaritatea într-un volum foarte mare de date. Aplicația se referă la curbele zilnice de sarcină ale Combinatului de Aluminiu Alcoa din Shanghai, înregistrate în decursul câtorva luni din 2006, împreună cu condițiile meteo corespunzătoare. Două treimi din volumul de date au fost utilizate pentru procesul de antrenare a RNA, iar restul de o treime pentru verificarea prognozelor obținute.

În [Yi2014] se utilizează o tehnică fuzzy de clustering a datelor privind istoria consumului, combinată cu o metodă de identificare și modificare a pseudo-datelor. Rezultatele obținute privind prognoza pe termen scurt a consumului pentru zona deservită de un operator de distribuție.

Logica fuzzy este utilizată și în [Mukhopadhyay2017], în scopul includerii în modelul prognozei consumului pe termen scurt a factorilor meteorologici (temperatura și umiditatea relativă).

În [XieZ2019] se propune nou model de prognoză pe termen scurt a consumului în rețelele de tip "smart grid", bazat pe o RNA de tip fuzzy utilizând un arbore de decizie îmbunătățit. Modelul pre-procesează datele "istorice" de consum și fiecare caracteristică, apoi realizează o clasificare a datelor de antrenare cu ajutorul unui algoritm de clusterizare și al unui bazat pe arbori de decizie. Datele astfel procesate sunt transmise RNA pentru antrenare și realizarea prognozei. Rezultatele concrete dovedesc eficiența sporită a noului model în ceea ce privește gradul de precizie a prognozei și reducerea erorii relative.

Tot la prognoza pe termen scurt a consumului din cadrul unui "smart grid" se referă și lucrarea [Akarslan2018], care propune un nou sistem adaptiv de inferență neuro-fuzzy. O contribuție interesantă vizează includerea în setul de date de intrare a derivatei (variației) consumului. Rezultatele obținute confirmă efectul pozitiv al acestei măsuri.

În [Sadaei2019] se propune o metodă hibridă pentru prognoza de scurtă durată, care utilizează seriile de timp (evoluția anterioară a consumului) în manieră fuzzy și o rețea neuronală convoluțională. Pe lângă valorile consumului orar, se cunoaște și evoluția temperaturii mediului ambiant. Datele au fost convertite într-o "imagine" de tip multi-canal, folosite ca date de intrare pentru RNA convoluțională. RNA poate extrage în mod automat, fără interacțiunea elementului uman sau a unor sisteme expert, toți parametrii necesari pentru realizarea prognozei. Fuzzyficarea seriilor de timp referitoare la evoluția anterioară a consumului reușește să evite fenomenul de "suprareglare" care poată să apară la rezultatele prognozei în cazul unor intrări deterministe. Un moment al seriei de timp este înlocuit cu un domeniu fuzzy (un spectru de valori în locul unei valori deterministe). Rezultatele prezentate se referă la o aplicație test, fără corespondent real.

#### □ Metode care utilizează SVM (Support Vector Machine)

În ultimii ani, mașinile vector suport (SVM) oferă un instrument performant pentru rezolvarea unor probleme de regresie sau de clasificare. Abordarea aceasta are la bază teoria de învățare statistică elaborată de Vapnik [Vapnik1995]. Spre deosebire de rețelele neuronale, care încearcă să definească funcții complexe în raport cu mărimile caracteristice de intrare, SVM execută o corelare (mapare) neliniară (folosind așa numitele funcții Kernel) ale datelor într-un spațiu (caracteristic) multi-dimensional. SVM utilizează funcții liniare simple pentru a crea limite (granițe) de decizie liniare în noul spațiu. Problema alegerii arhitecturii RNA este înlocuită aici cu alegerea unui "kernel" potrivit pentru SVM.

SVM sunt modele cu învățare supervizată. Considerând un set de date de antrenare, fiecare dintre ele marcată ca aparținând uneia din două categorii posibile. Algoritmul de învățare SVM construiește un model care asignează noile date ca aparținând uneia sau celeilalte categorii, rezultând de fapt un clasificator non-probabilistic liniar binar. Modelul SVM constituie de fapt o reprezentare a datelor ca puncte într-un domeniu, mapate astfel încât datele categoriilor separate să fie despărțite de o zonă cât mai largă. Noile date sunt mapate în același domeniu și asignate ca aparținând uneia dintre cele două categorii, dependent de poziția lor față de zona de graniță.

[Chen2002] prezintă un model SVM pentru prognoza consumului zilnic, pe durata unei luni, în contextul competiției organizate de EUNITE (EUropea Network on Intelligent TEchnologies for Smart Adaptive Systems) în scopul prognozei puterilor zilnice de vârf pentru luna ianuarie 1999. Datele disponibile se refereau la perioada 1997-1998: puterile din jumătate în jumătate de oră, temperatura medie zilnică și datele zilelor de sărbătoare. Modelul prezentat a câștigat competiția. [Chen2004] prezintă o variantă extinsă a studiului EUNITE. De data aceasta SVM folosește doar informațiile pentru ultimele 7 zile ca variabile de intrare. Pentru antrenare s-au luat în considerare doar datele de "iarnă" – perioada octombrie-decembrie și ianuarie-martie, deoarece autorii au identificat "tipare" (pattern-uri) diferite pentru seriile de timp referitoare la perioada de iarnă, respectiv cea de vară. Eroarea maximă relativă procentuală a fost de 1,95 %.

În [Xinhui2010] autorii studiază utilizarea SVM pentru prognoza consumului de energie electrică în situațiile în care numărul de eșantioane pentru procesul de antrenare este relativ redus. Se încearcă găsirea celor mai bune funcții kernel și acordarea corespunzătoare a valorii parametrilor variabili ai SVM. Rezultatele obținute pentru condițiile menționate sunt mai bune decât cele determinate cu RNA. Preocupări similare se remarcă și în [Zheng2010], încercându-se o ajustare automată a valorii parametrilor.

Ajustarea optimă a parametrilor SVM și a funcțiilor de tip kernel utilizate este un element cheie pentru succesul prognozei. În [Cai2011] se utilizează un SVM combinat cu un algoritm genetic, determinarea celor mai bune valori ale parametrilor fiind realizată în mod automat. Aplicația prezentată în lucrare se referă la prognoza pe termen scurt a puterii consumate într-un oraș din provincia Hebei (China). Rezultatele se consideră a fi bune: eroarea medie procentuală este de 3.92 % pentru o zi de sărbătoare, respectiv 3.22 % pentru cazul a două zile libere. Preocupări similare apar și în [Lei 2018] și [Dai2020], scopul urmărit fiind determinarea valorilor optime pentru parametrii ajustabili ai SVM.

Lucrarea [Ghelardoni2013] folosește o metodă de descompunere empirică, pe baza căreia se obțin două seturi de componente: primul descrie trendul și al doilea oscilațiile locale ale valorilor consumului de energie. Aceste seturi sunt utilizate apoi la antrenarea SVM. Rezultatele experimentale obținute atât pentru un domeniu public cât și pentru o clădire de birouri validează metoda propusă.

În [Limei2017] se utilizează un SVM cu funcție kernel multiplă, ceea ce conduce la un proces de învățare (antrenare) de calitate mai bună. Rezultatele se referă doar la niște date test, care nu au corespondent real.

Comparația dintre SVM și RNA constituie obiectul studiului din [Mitchell2017]. În opinia autorilor SVM a furnizat rezultate mai bune pentru prognoza pe termen scurt a consumului, aplicația referindu-se la o insulă din arhipelagul Trinidad Tobago. Pentru situațiile când variația consumului nu prezenta discontinuități accentuate, eroarea medie procentuală a fost sub 1.5 %. În caz contrar sau al unor date eronate, ea a depășit chiar 5%.

#### 4.4. Utilizare rețelelor neuronale bayesiene (RNB) în studiile de prognoză

Acest subcapitol este destinat în exclusivitate aplicațiilor în care rețelele neuronale bayesiene (RNB) sunt utilizate în studiile de prognoză din domeniul electroenergeticii. Marea majoritate a exemplelor se referă la prognoza consumului de energie (putere) consumată, dar apar și situații în care obiectul prognozei este prețul energiei electrice, puterile generate de centralele eoliene sau fotovoltaice, viteza vântului, iradianța solară etc.

##### □ Primele încercări

Prima menționare a utilizării abordării bayesiene a prognozei consumului de putere apare în [Bakirtzis1997], unde se propune un predictor bayesian mixt, realizat prin combinarea unui predictor bazat pe utilizarea unei RNA cu alți doi predictorii specifici regresiei liniare (RL). Aplicația se referă la prognoza pe termen scurt a puterii consumate în Grecia. Pentru anumite ore ale zilei era mai bună prognoza obținută cu RNA, iar pentru alte ore cea obținută prin RL. Predictorul mixt bayesian are la bază o medie ponderată a celor doi predictorii. Coeficienții de ponderare se calculează utilizând o corecție adaptivă a probabilității bayesiene de tip aposteriori a fiecărui predictor, în funcție de performanțele anterioare de prognoză.

O altă abordare bayesiană a prognozei consumului, necesară pentru studiile de planificare a extinderii sistemelor electroenergetice, este prezentată în [Douglas 1998]. Algoritmii recursivi bayesiani fac uz de distribuțiile apriori și aposteriori, alături de eșantioanele cunoscute, pentru a prognoza consumul viitor. O asemenea abordare oferă posibilitatea exprimării probabiliste a rezultatelor, element important, mai ales când studiile de extindere se realizează în condițiile incertitudinii evoluției consumului.

##### □ Prognoza pe termen scurt

În [Mori2005] se propune o nouă metodă probabilistică de prognoză pe termen scurt a consumului (PTSC), care utilizează un model bayesian ierarhizat, în scopul diminuării influenței incertitudinii datelor. Estimarea bayesiană ierarhizată (proces Gaussian) presupune că se cunoaște distribuția apriori a parametrilor utilizați pentru obținerea distribuției aposteriori în estimarea bayesiană. Această abordare conduce la o ameliorare a preciziei modelului comparativ cu modelul bayesian clasic. Aplicația practică, referitoare la o companie japoneză de distribuție a energiei electrice, demonstrează avantajele metodei propuse. O procedură similară este utilizată și în [Mori2009] pentru prognoza temperaturii, asociată cu PTSC. În [Mori2011] au fost continuate cercetările din cele două lucrări menționate anterior, propunându-se o metodă inteligentă hibridă pentru abordarea probabilistică a PTSC. S-a utilizat un arbore de regresie pentru clasificarea datelor în mai multe cluster. Pentru fiecare cluster s-a efectuat câte o prognoză separată utilizând inferența bayesiană, ținând cont atât de istoricul consumului cât și cel al condițiilor meteo (temperatura).

Scopul urmărit în [Lauret2008] și [Lauret2012] este optimizarea modelului bazat pe RNA pentru PTSC prin utilizarea tehnicilor specifice RNB. Avantajele obținute prin utilizarea antrenării bayesiene sunt legate de acordarea automată a coeficienților de ponderare, selecția celor mai importante variabile de intrare, obținerea unui interval de încredere pentru mărimile de ieșire, posibilitatea de a compara mai multe modele și de a selecta pe cel optim. Preocupări similare sunt prezentate și în [Hippert2010]

pornind de la premiza că utilizarea RNA pentru PTSC ridică două aspecte sensibile: alegerea nivelului de complexitate al RNA și alegerea datelor de intrare. Lucrarea evaluează tehnicile de modelare automată a RNA într-un cadru bayesian. Selectarea variabilelor de intrare este realizată prin tehnica bayesiană de determinare automată a relevanței (ARD). Structura optimă a RNA (numărul de neuroni) se determină pe baza "cadru evidențiat" bayesien. Rezultatele unor prognoze realizate pentru date obținute din 5 țări evidențiază superioritatea modelului propus, comparativ cu metodele care utilizează tehnici de tip "cross-validation" (validare încrucișată).

În [Ning2010] PTSC se realizează utilizând o RNA de tip "backpropagation" cu învățare (antrenare) bayesiană. Acest tip de învățare facilitează obținerea celor mai probabile valori ale hiperparametrilor, care conduc la o arhitectură optimă a RNA de tip "backpropagation". Testarea performanțelor modelului s-a realizat utilizând date de consum reale din provincia Guizhou (China), atât pentru antrenarea rețelei cât și pentru verificarea prognozelor, rezultatele dovedind superioritatea acestuia comparativ cu RNA convenționale de tip "backpropagation". S-a remarcat o creștere a vitezei de învățare, a convergenței și a acurateței prognozei.

Utilizarea RNA bayesiene pentru PTSC este discutată și în [Shi2010]. Noutatea adusă de această lucrare se referă la metoda de antrenare: aproximarea gaussiană a distribuției a posteriori a fost înlocuită cu o aproximare realizată prin intermediul unui algoritm hibrid de tip Monte Carlo. Rezultatele concrete obținute utilizând date de consum reale din orașul Baoding (China) evidențiază superioritatea metodei propuse.

O metodă mult mai complexă este prezentată în [Ghayekhloo2015], care utilizează un algoritm de preprocesare a datelor de intrare în scopul ameliorării calității prognozei. Se utilizează o transformare discretă de tip "wavelet" pentru descompunerea componentelor sarcinii în niveluri adecvate de rezoluție, după un criteriu bazat pe entropie, urmată de o analiză de regresie, rezultând cel mai bun set de date de intrare. O analiză de corelare împreună cu o RNA furnizează o primă estimare a valorilor prognozate asociate mărimilor de intrare, urmată de o procedură de standardizare care ține cont de gradul de corelare a mărimilor de ieșire cu setul de mărimi de intrare asociate. În final rezultă cele mai potrivite date de intrare pentru RNA bayesiană. Pentru optimizarea coeficienților de ponderare ale diverselor componente ale prognozei și minimizarea erorilor valorilor prognozate se utilizează un algoritm genetic. Aprecierea performanțelor și preciziei metodei propuse pentru PTSC este realizată cu ajutorul unei baze de date consacrate de consum ("New England load data"), concluziile fiind pozitive (comparativ cu tehnicile cunoscute de prognoză a consumului).

Metodele și rezultatele prezentate în [Ghayekhloo2019] aprofundează cercetările din lucrarea discutată mai sus.

O abordare asemănătoare, la fel de complexă, apare și în [He2019], care prezintă o metodă hibridă de PTSC utilizând RNB recurente de tip LSTM (Long Short-Term Memory).

[Dagdougui2019] are ca obiect prognoza pe termen scurt și foarte scurt a consumului de putere în zonele de clădiri "inteligente", cuprinzând câteva blocuri eterogene din punctul de vedere al funcționalității, utilizând modele bazate pe RNA. Lucrarea urmărește 3 obiective: evaluarea performanțelor RNA considerând două tehnici de antrenare de tip "backpropagation" – regularizarea bayesiană și metoda Levenberg-Marquardt; analiza comparativă a performanțelor modelului pentru prognozele de tip "hour-ahead" și "day-ahead" aferente diverselor tipuri de clădiri; analiza influenței structurii RNA (numărul de straturi ascunse și al neuronilor din aceste

straturi, numărul de intrări și de seturi de date de antrenare) asupra acurateții valorilor prognozate. Eficiența metodei propuse este demonstrată pentru cazul unui cartier din centrul orașului Montreal (Canada), care cuprinde o mare varietate de tipuri de clădiri.

În [Sarajcev2020] PTSC este asociată cu o tehnică de clusterizare a datelor de consum (împreună cu cei climatici), utilizând o abordare bazată pe inferența bayesiană. Aplicația concretă se referă la prognoza consumului de putere pentru orașul Newcastle (Australia).

Prognoza pe termen scurt și foarte scurt a prețului energiei electrice este abordată în [Brusaferri2019] utilizând o tehnică bayesiană de învățare profundă (deep learning).

În [Izudheen2019] se prezintă un studiu de PTSC utilizând un model bazat pe RNA bayesiene. Pentru validarea performanțelor modelului s-au utilizat datele de consum și condițiile meteorologice pentru o perioadă de 2 ani aferente regiunii Kerala (India). Rezultatele obținute au demonstrat că acest model, utilizând RNA bayesiene, are calități superioare comparativ cu cele care utilizează RNA "clasice". O abordare asemănătoare apare și în [Lopez2019], în contextul planificării funcționării optime a rețelelor de distribuție a energiei electrice. Aplicația practică vizează o rețea de distribuție reală de foarte mari dimensiuni (peste 5000 de noduri), care alimentează trei tipuri de consumatori (rezidențiali, comerciali și industriali). Profilele individuale de consum au fost generate în mod aleator cu un instrument soft specializat (Load ProfileGenerator).

[Sun2019a] prezintă un interesant studiu comparativ al metodelor probabilistice de PTSC. S-au avut în vedere următoarele metode: estimarea bayesiană, estimarea bayesiană de ordin redus, regresia de tip Ridge (o tehnică de estimare a coeficienților modelelor de regresie multiplă pentru situațiile în care variabilele independente prezintă un grad de corelare ridicat), estimarea de tip LASSO (Least Absolute Shrinkage and Selection Operator – o metodă de analiză de regresie care realizează atât selecția variabilelor cât și regularizarea, în scopul ameliorării calității prognozei și a gradului de interpretare a modelului statistic) și RNA cu învățare supervizată (antrenarea utilizând metoda gradientului conjugat). Concluzia studiului evidențiază faptul că estimarea bayesiană de ordin redus conduce la cele mai bune rezultate.

Abordarea din [Bessani2020] pornește de la constatarea că pentru consumul rezidențial (rețele de joasă tensiune) incertitudinea datelor este mult mai accentuată decât în cazul consumurilor agregate la nivel de medie sau înaltă tensiune. În acest context lucrarea propune un model multivariabil pentru prognoza de foarte scurtă durată a consumului, bazat pe utilizarea RB. Se ține cont de evoluția anterioară a consumului, de factorii climatici, de cei socio-economici și de pattern-urile (tiparele) de consum. Analiza concretă se referă la un ansamblu de peste 1000 consumatori rezidențiali din Dublin (Irlanda). Comparația cu rezultatele obținute prin alte metode evidențiază faptul că modelul bazat pe utilizarea RB prezintă performanțe superioare. O preocupare similară este prezentată și în [Gilanifar2020], unde RNB sunt asociate cu un model de învățare (antrenare) de tip multitasking. Fiecare task în parte se referă la antrenarea modelului PTSC pentru un anumit consumator rezidențial, iar "multitasking" înseamnă utilizarea unei combinații a modelelor individuale pentru procesul de antrenare a RNB. Rezultatele prezentate pentru un exemplu relativ mai simplu evidențiază plusurile unei asemenea abordări, neconfirmate totuși prin aplicații mai semnificative. Un model de tip "multitasking" mai complex, asociat cu un procedeu de optimizare bayesiană, este descris în [Yang2020].

### □ Prognoza pe termen mediu și lung

[Saini2008] tratează prognoza pe termen mediu și lung a puterii de vârf, rezultatele urmând a fi utilizate în studiile de extindere a sistemelor electroenergetice (referitoare la rețeaua de transport a energiei electrice și/sau la capacitățile de producere a energiei electrice). Se compară modelele bazate pe RNA utilizând tehnici adaptive și reziliante de învățare de tip retropropagare (backpropagation), alături de cele bazate pe metoda gradientului conjugat scalat sau regularizarea bayesiană. Alături de evoluția anterioară în timp a puterii de vârf se iau în considerare și 11 parametri legați de condițiile meteo. Foarte interesantă este discuția despre alegerea valorii parametrilor "reglabili" ai procesului de antrenare (rata de învățare, eroarea admisă etc.) în scopul evitării situațiilor de blocare într-un minim local. În scopul reducerii timpului de calcul se realizează o preprocesare a datelor de intrare pe baza unei analize a gradului de corelare, rezultând setul cu care se face antrenarea unei RNA cu 3 straturi ascunse. O abordare asemănătoare este prezentată și în [Song2009].

În [Rivero2015] se realizează o prognoză pe termen lung a puterii consumate. Se utilizează o RNA cu inferență bayesiană, singura mărime de intrare fiind evoluția anterioară în timp a consumului. Ieșirea RNA furnizează prognoza consumului pentru următoarele luni. Aplicația concretă se referă la prognoza puterii consumate pentru sistemul electroenergetic al Argentinei. Similar, în [Silva2019] se prezintă o aplicație de prognoză pe termen lung a consumului de putere pentru sistemul electroenergetic din Brazilia, inferența bayesiană fiind utilizată pentru estimarea parametrilor modelului, ceea ce permite includerea gradului de incertitudine a prognozei realizate cu modelul propus.

Prognoza pe termen lung a consumului de energie electrică constituie tema studiului în [Jian2008], [Yuan2017], [He2018], [Tang2019] și [Ahmadi2020]. Pentru a ține cont de gradul de incertitudine a consumului se propune o abordare bayesiană de tip fuzzy. Rezultatele de natură deterministă sunt înlocuite cu cele de natură probabilistă, fiind indicat și intervalul de încredere (valoarea cea mai probabilă, însoțită de valoarea minimă și cea maximă). În [Tang2019] aplicația concretă se referă la o serie de țări importante, pentru care se cunoaște evoluția consumului pentru o perioadă de 38 de ani (1980-2017). Datele din perioada 1980-2010 sunt utilizate pentru antrenarea RNA, prognoza fiind realizată pentru 20 de ani (2011-2020). Datele cunoscute pentru perioada 2011-2017 sunt utilizate pentru aprecierea calității prognozei. În [Ahmadi2020], aplicația vizează consumul de energie electrică din Iran (prognoză pentru 20 de ani), iar în [Jian2008], [Yuan2017] și [He2018] – consumul de energie electrică pentru China.

### □ Prognoza puterii produse de centralele eoliene și cele fotovoltaice

Implementarea pe scară largă a surselor regenerabile distribuite în rețelele moderne de distribuție a energiei electrice a condus la o serie de studii de prognoză legate de centralele eoliene și cele fotovoltaice. În [Yang2013] se prezintă o abordare practică a prognozei pe termen scurt, în manieră probabilistă, a puterii generate de un parc eolian. Metoda propusă are la bază un algoritm bayesian lacunar de învățare, care conduce la o exprimare probabilistă a rezultatelor prognozei, obținută pe baza estimării densității probabiliste a ponderilor funcțiilor gaussiene. Din cauza caracterului "nestaționar" al evoluției în timp a datelor, a informațiilor despre puterea generată, se propune o strategie bazată pe descompunerea seriei temporale în componente cu o predictibilitate crescută, utilizând o transformare discretă de tip wavelet. Prognoza efectivă cu algoritmul bayesian lacunar se efectuează separat pentru fiecare componentă în parte, rezultatul final fiind obținut prin însumarea celor parțiale. Aplicația

concretă se referă la un parc eolian din Oklahoma (SUA), demonstrând eficacitatea metodei propuse. O abordare similară este prezentată în [YangM2015], utilizând metoda Dempster-Shafer, care constituie, în esență, o generalizare a metodei bayesiene. În [WangY2019] algoritmul bayesian lacunar de învățare se utilizează pentru prognoza vitezei vântului.

Pe aceeași linie se înscriu și preocupările din [Lin2019], cu observație că se utilizează o metodă de tip multi-model. În paralel cu funcția de distribuție de probabilitate de tip Gauss se utilizează și cea de tip beta ( $\beta$ ). Testarea modelului propus s-a realizat utilizând setul de date GEFC (Global Energy Forecasting Competition) 2014, care include atât evoluția în timp a puterii generate cât și a vitezei vântului (la înălțimea de 10 m și 100 m față de sol) pentru 10 zone diferite. Setul de date, din oră în oră, se referă la o perioadă de 10 ani, fiind divizat în două sub-seturi de antrenare și un set de validare a prognozei. Primul sub-set de învățare se utilizează pentru antrenarea componentelor modelului, în timp ce al doilea are ca rol optimizarea ponderilor modelelor componente.

Tot o perioadă de 20 de ani pentru datele cunoscute (pentru IESO – Independent Ontario Electricity System Operator) a fost utilizată și în [Sahu2019] pentru prognoza pe termen scurt a puterii generate de sursele eoliene și fotovoltaice. O parte din datele respective au fost folosite pentru antrenarea RNA, restul pentru aprecierea calității prognozei. Antrenarea RNA s-a realizat prin regularizare bayesiană, pentru seriile temporale fiind luate în considerare regresia automată neliniară, regresia automată neliniară cu date de intrare exogene și modelul intrare – ieșire (a doua fiind considerată cea mai bună).

În [Liu2020] se prezintă o metodă de prognoză probabilistă spațio-temporală a vitezei vântului într-o anumită regiune, utilizând o RNA spațio-temporală și o tehnică de învățare profundă (deep learning) bazată pe inferența bayesiană. Elementele temporale și spațiale legate de viteza vântului înregistrată în diverse locații sunt reunite într-un spațiu de tip grilă, aplicând apoi tehnica de învățare profundă menționată mai sus. Metoda propusă a fost folosită cu succes în două zone reale din SUA.

[WangG2020] propune o abordare hibridă a prognozei puterii generate de centralele eoliene, în funcție de condițiile meteo previzionate, bazată pe un model bayesian. Studiul de caz se referă la o situație reală – o centrală eoliană din China.

În scopul evaluării riscurilor în funcționarea rețelelor de distribuție în condițiile pătrunderii pe scară largă a surselor distribuite de natură fotovoltaică, în [Tao2016] se propune utilizarea unei RNB dinamice pentru prognoza probabilistă a puterii generate de centralele fotovoltaice. Aplicația concretă se referă la sistemul test IEEE cu 53 de noduri. O abordare asemănătoare este prezentată în [Silva2017], aplicațiile vizând situații concrete din sistemul electroenergetic al Braziliei.

În [Panamtash2020] se propune un model probabilistic bayesian multi-variabil pentru prognoza puterii generate în centralele fotovoltaice. Pe lângă seriile de timp referitoare la puterea generată, se evidențiază și dependența acestora de condițiile meteo (temperatura). Pentru antrenarea rețelei se utilizează datele cunoscute din 2015 pentru o centrală fotovoltaică din SUA, calitatea prognozei fiind verificată cu ajutorul datelor din 2016 (de asemenea cunoscute).

#### □ Alte aplicații de prognoză utilizând RNB

O abordare asemănătoare este prezentată în [Theocharides2020], combinată cu o tehnică de clusterizare a datelor de intrare cunoscute. Aplicația se referă la prognoza pentru ziua următoare a puterii generate de sursele fotovoltaice, utilizând date reale din Nicosia (Cipru) și Albuquerque (New Mexico, SUA).



Legat de centralele fotovoltaice, în [Jiang2017] radianța solară este obiectul prognozei, realizată cu utilizarea inferenței bayesiene.

În [Bassamzadeh2017] problema prognozei consumului de energie pentru ansambluri rezidențiale este privită în contextul rețelelor de distribuție inteligente (smart grid). La modul general, multitudinea de variabile stohastice care influențează consumul casnic reprezintă o problemă dificilă din punctul de vedere al prognozei. RB au capacitatea de a estima o distribuție probabilistă comună în asemenea sisteme complexe, oferind cadrul pentru a modela incertitudinile și de a realiza o inferență probabilistă. Datele reale utilizate în aplicația numerică se referă la o zonă de consum rezidențial din Washington (SUA). Prognoza a fost realizată pentru 86 de gospodării, atât pentru consumul agregat (date înregistrate orar sau la 15 minute) cât și pentru cel individual (date înregistrate orar). În [Jing2019] abordarea este asemănătoare, prognoza referindu-se la consumul aferent ansamblului de clădiri al unui centru comercial de mari dimensiuni.

Prognoza pe termen scurt a consumului este abordată tot în contextul rețelelor inteligente de distribuție (smart grid) în [Bracale2016] și [Bracale2016a]. Se utilizează o metodă hibridă, bazată pe seriile de timp stohastice și inferența bayesiană, aplicabilă atât pentru consumatorii individuali cât și pentru cei multipli.

[Yang2020] se referă tot la rețele inteligente, propunând un model probabilistic bayesian multi-variabil pentru prognoza puterii consumate. Se utilizează o RNA spațio-temporală și o tehnică de învățare profundă (deep learning) bazată pe inferența bayesiană, combinat cu o tehnică de clusterizare a datelor cunoscute (în scopul diversificării setului de mărimi de intrare). Aplicație concretă se referă la un grup de 1000 de consumatori rezidențiali.

În [Ferreira2009] și [Ferreira2009a] prognoza puterii consumate utilizând RNB are drept scop oferirea unor informații utile dispecerilor pentru a evita posibilele congestii – depășirea limitei superioare (curentul maxim admisibil din punct de vedere termic) a capacității de încărcare a liniilor electrice.

Inferența bayesiană este utilizată și în [Nadimi2017], unde se realizează o prognoză combinată a consumului de putere obținută din surse regenerabile și non-regenerabile.

În [Cheng2019] obiectul prognozei este prețul energiei electrice, efectuându-se o optimizare bayesiană a parametrilor modelului în scopul ameliorării performanțelor sale și a calității rezultatelor.

## 4.5. Concluzii

În cadrul acestui capitol s-a realizat o prezentare sistematizată problemelor legate de prognoza consumului de energie electrică (putere de vârf, putere orară, energie consumată, curbe de sarcină etc.) și a metodelor utilizate pentru obținerea prognozei.

Prima parte a capitolului a trecut în revistă o serie de aspecte generale legate de prognoză, de clasificarea metodelor utilizate după diverse criterii, insistând asupra orizontului de timp la care se referă prognoza.

A urmat prezentarea propriu-zisă a metodelor, în funcție de orizontul de timp la care se referă, pe baza unui studiu bibliografic consistent. Sunt urmărite atât metodele "clasice", bazate pe modelarea matematică, cât și cele "moderne", de dată mai recentă, utilizând tehnici de inteligență artificială, logică fuzzy, sisteme expert, "support vector machine" (SVM) etc.

Un subcapitol aparte, consistent, a fost dedicat metodelor care utilizează rețele neuronale bayesiene (RNB), care constituie obiectul acestei teze de doctorat.

În continuare se prezintă o trecere în revistă a contribuțiilor personale din acest capitol:

- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a metodelor utilizate pentru prognoza consumului de energie electrică (putere de vârf sau orară, energie consumată, curbe de sarcină etc.), atât cele care la ora actuală pot fi considerate "clasice" (bazate pe modelarea matematică), cât și cele "moderne", utilizând tehnici de inteligență artificială, logică fuzzy, sisteme expert, "support vector machine" (SVM) etc.;
- prezentarea aspectelor caracteristice abordărilor actuale, în condițiile pieței libere a energiei electrice, a dereglementării și a pătrunderii pe scară largă a surselor regenerabile de energie;
- focalizarea unei atenții speciale asupra metodelor de prognoză care utilizează rețele neuronale bayesiene (utilizate în cadrul acestei teze);
- pregătirea elementelor pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.

## 5. REȚELE NEURONALE ARTIFICIALE (RNA)

Capitolul 5 este destinat prezentării rețelelor neuronale artificiale (RNA). El oferă baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică și putere (prezentată în capitolul 6).

Prima parte a capitolului trece în revistă o gamă largă de aspecte generale privind RNA: terminologia de bază, structura RNA, clasificarea RNA etc.

A doua parte a capitolului are ca obiect prezentarea modelului RNA. Se pornește de la neuronul artificial și se ajunge la structura RNA. Un paragraf aparte este dedicat tehnicilor de învățare (antrenare) utilizate de RNA – învățarea supravegheată, respectiv cea nesupravegheată.

Ultima parte a capitolului este consacrată prezentării RNA de tip perceptron, cu un singur strat și cu mai multe straturi, cu o atenție specială pentru cele de tip backpropagation.

### 5.1. Prezentarea generală a RNA

#### 5.1.1. Considerații preliminare

Rețelele neuronale artificiale – RNA (Artificial Neural Network – ANN) constituie un sistem de procesare a semnalelor, compus din procesoare elementare interconectate, (neuroni artificiali – NA), care cooperează pentru rezolvarea unor sarcini specifice. Adaptarea la condițiile specifice constă în modificarea ponderilor asociate conexiunilor dintre neuroni și a structurii RNA. Aceste modele conexiunilor oferă o serie de avantaje, caracteristice doar sistemelor neuronale biologice, inexistente în cazul sistemelor de calcul tradiționale (secvențiale) [Tiponut2002], [Luștreă2004]:

- proprietatea de a învăța și de a se adapta;
- posibilitatea de a opera cu date imprecise;
- capacitatea de generalizare – RNA va opera corect și cu date de intrare care nu au fost prezentate în timpul procesului de antrenament;
- RNA reprezintă sisteme tolerante la erori – funcționarea defectuoasă sau chiar pierderea unor neuroni nu afectează semnificativ performanța ansamblului RNA;
- RNA pot fi folosite cu succes în modelarea sistemelor neliniare;
- RNA modelează cu ușurință sistemele multivariabile.

Orice rețea neuronală este definită prin:

- a) specificul unităților de calcul – fiecare NA are o anumită caracteristică de intrare / ieșire (I/O) cunoscută, implementând un proces local de calcul sau o funcție. Funcțiile caracteristice pot fi diferite, dar se preferă ca anumite grupuri de neuroni să aibă funcții identice. Ieșirea fiecărui neuron depinde de caracteristica proprie de I/O, de interconexiunile cu alți neuroni și (posibil) de intrările externe;
- b) funcționarea rețelei – procesul prin care rețeaua transformă semnalele de intrare în semnale de ieșire (răspunsul rețelei);
- c) antrenarea rețelei – definește funcționalitatea globală a RNA. O rețea neuronală se poate antrena prin ajustarea valorilor conexiunilor (ponderilor) dintre elemente;
- d) arhitectura rețelei – modul de dispunere a unităților de calcul și interconectarea lor.

O rețea neuronală poate fi reprezentată printr-un graf orientat [Kilyeni2015], în care vârfurile sunt neuronii, iar arcele orientate specifică fluxul informațional sau sensul de propagare a semnalelor de la unitățile de calcul de intrare către unitățile din stratul de ieșire.

RNA sunt constituite dintr-un număr mare de NA interconectați. Neuronii sunt de obicei organizați în mulțimi distincte numite straturi (layers). Există și rețele neuronale cu o topologie specială, când neuronii nu sunt organizați pe straturi, ci pe submulțimi.

O RNA "clasică" constă dintr-o secvență de straturi de neuroni, cu conexiuni totale sau aleatoare între neuronii conținuți în straturi succesive. Întotdeauna există cel puțin două straturi de neuroni, care au rolul principal de a comunica cu mediul exterior:

- stratul de intrare, care are rolul de a prelua datele de intrare  $x_i, i = 0, 1, 2, \dots, n$  (cu termen bias) sau  $x_i = \pm 1, i = 1, 2, \dots, n$  (fără termen bias);
- stratul de ieșire, unde se obțin rezultatele furnizate de RNA ( $y_j, j = 1, 2, \dots, m$ ) ca răspuns la vectorul de intrare și al propagării acestor date de la stratul de intrare către stratul de ieșire;
- toate celelalte straturi ale RNA, dacă există, se numesc straturi ascunse (hidden layers).

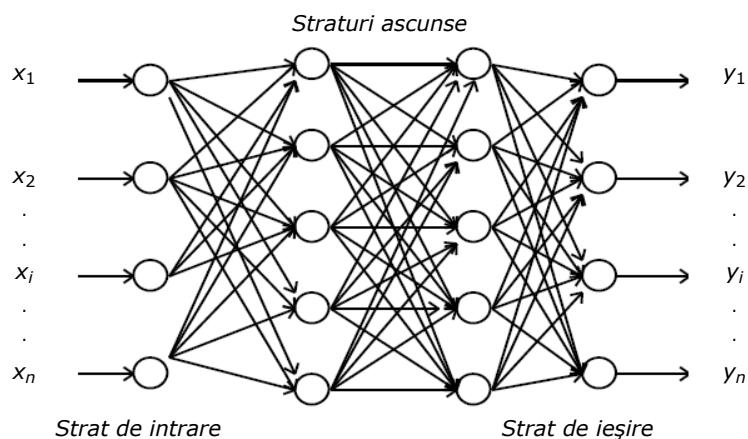


Fig. 5.1.1. Arhitectura generală a unei rețele neuronale

Neuronii din stratul de intrare au funcție de activare liniară, rolul lor fiind de a propaga către stratul următor vectorul de intrare. Stratul de intrare are doar rolul unui zone tampon, de preluare a datelor de intrare, fără a efectua nicio procesare a acestora. Ceilalți neuroni, din celelalte straturi, pot avea orice funcții de activare.

### 5.1.2. Clasificarea RNA

Clasificarea RNA poate fi făcută după mai multe criterii [Luștreă2004]:

- După *numărul de straturi* (layers) pe care sunt organizați NA există RNA:
  - cu un singur strat;
  - cu două straturi: un strat de intrare și un strat de ieșire;
  - cu mai multe straturi, straturile situate între cel de intrare și cel de ieșire fiind denumite straturi ascunse.

- După *existența reacției* se disting RNA:
  - fără reacție (feedforward);
  - cu reacție:
    - rețele cu memorii asociative, la care pentru un vector de intrare se asociază un vector de ieșire conform cu valorile coeficienților sinapselor, stabilite prin procesul de învățare;
    - rețele Hopfield – caz particular, discretizat, al memoriilor asociative, utilizând o topologie cu două nivele, în care ieșirile sunt reduse la intrări; dacă ieșirile sunt binare, atunci mulțimea tuturor ieșirilor posibile sunt dispuse în vârfurile unui hiper cub în spațiul  $n$  dimensional, iar ieșirea activă se stabilește prin parcurgerea vârfurilor hiper cubului, până la atingerea unei valori stabile.
- După *tipul de învățare* se disting RNA cu:
  - învățare supravegheată (supervizată) – mulțimea datelor de antrenare trebuie să conțină perechi I/O, pe baza cărora algoritmul de învățare stabilește corecția ponderilor asociate legăturilor (sinapselor) dintre NA;
  - învățare nesupravegheată – caracteristică rețelelor Kohonen, care evoluează autonom spre o stare de autoorganizare.
- După *modul de propagare* a corecțiilor coeficienților de ponderare a RNA:
  - cu retropropagare (backpropagation) – valorile conexiunilor dintre straturi se determină în cadrul procesului de învățare, prin propagarea înapoi (de la ieșire spre intrare) a corecțiilor necesare anulării diferenței dintre valoarea ieșirii cauzate de intrare și valoarea dorită a ieșirii, caracteristică procesului analizat, care trebuie obținută în urma procesului de învățare;
  - cu contrapropagare sau antrenare rapidă.

## 5.2. Modelul RNA

### 5.2.1. Modelul neuronului artificial

*Neuronul Artificial* (NA) este o copie mult simplificată a neuronului biologic, obținută prin adoptarea următoarelor ipoteze [Luștrea2004]:

- activitatea NA este de tipul "totul sau nimic", adică ieșirea sa poate avea doar două valori: 0 – inactiv, 1- activ;
- pentru activitatea NA este necesar ca la un moment dat cel puțin una din sinapsele (legăturile) sale să fie activă;
- activarea neuronului este posibilă numai dacă valoarea cumulată a intrărilor active depășește un anumit prag minim de excitație;
- activarea oricărei sinapse inhibitoare determină trecerea neuronului receptor în stare inactivă;
- singura întârziere existentă în sistemul nervos este cea de la nivelul sinapselor, ceea ce permite modelarea funcționării NA în domeniul timpului eșantionat;
- topologia conexiunilor dintre neuroni este invariantă în timp.

Conform acestor ipoteze, NA este descris prin schema din fig. 5.2.1, cu relațiile (5.2.1) între mărimile atașate modelului [Luștrea2004]:

$$\begin{aligned} \tilde{y} &= \sum_{i=1}^n w_i \cdot x_i \\ y &= f(\tilde{y}) \end{aligned} \quad (5.2.1)$$

unde:  $x_i$  ( $0 \leq x_i \leq 1$ ) – mărimea de intrare aferentă sinapsei  $i$ ;  
 $w_i$  coeficientul de ponderare asociat acestei intrări, cu care ea se multiplică  
 (suma ponderile trebuie să fie 1);  
 $\tilde{y}$  – mărimea care măsoară efectul cumulat al intrărilor asupra NA;  
 $f$  – funcția de activare;  
 $y$  – ieșirea NA.




Fig. 5.2.1. Neuronul artificial (NA)

Funcția de activare a NA poate avea diverse forme, cele mai utilizate fiind funcția treaptă (relația 5.2.2), cea sigmoidă (relația 5.2.3), funcția tangentă hiperbolică (relația 5.2.4) și funcția erorilor (5.2.5):

$$f(\tilde{y}) = \begin{cases} 1 & \text{pentru } \tilde{y} \geq \theta; \quad \theta - \text{ prag de activare} \\ 0 & \text{pentru } \tilde{y} < \theta \end{cases} \quad (5.2.2)$$

$$f(\tilde{y}) = \frac{1}{1 + e^{-\lambda \tilde{y}}} \quad (5.2.3)$$

$$f(\tilde{y}) = \tanh(\tilde{y}) = \frac{e^{\tilde{y}/2} - e^{-\tilde{y}/2}}{e^{\tilde{y}/2} + e^{-\tilde{y}/2}} \quad (5.2.4)$$

$$f(\tilde{y}) = \text{ERF}(\tilde{y}) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\tilde{y}} e^{-z^2} \cdot dz \quad (5.2.5)$$

*Funcția treaptă* este cea mai simplă. *Funcție sigmoidă* prezintă avantaje în procesul de calcul al ponderilor sinapselor cu metoda retropropagării (backpropagation); în plus, coeficientul  $\lambda > 0$  acționează ca un control automat al câștigului: pentru valori mici ale semnalului funcția sigmoidă se apropie de cea treaptă, producând câștiguri mari, iar pentru valori mari ale semnalului de intrare câștigul scade mult. Ultimele două forme ale funcției de activare (*funcția tangentă hiperbolică* și *funcția erorilor*) au o frecvență de folosire mult mai mică decât primele două.

În general, atunci când se modelează un proces fizic, inclusiv cu o RNA, se urmărește scalarea variabilelor, astfel ca domeniul lor după scalare să corespundă intervalului de valori  $[0, 1]$ . În acest caz crește precizia de calcul, crește capacitatea de control asupra convergenței calculelor iterative, pot fi comparate rezultatele unor procese similare între ele etc. Pentru RNA, procesul de scalare este obligatoriu, deoarece din ipotezele adoptate rezultă că ieșirea  $y$  a rețelei neuronale trebuie să fie  $0 \leq y \leq 1$ .

Pornind de la modelul prezentat în fig. 5.2.1, cunoscut sub numele de modelul McCulloch-Pitts (MCP), Rosenblatt a introdus noțiunea de *perceptron* sau *neuron clasificator* având ca ecuații de funcționare relațiile [Luștrea2004]:

$$\tilde{y} = \sum_{i=1}^n w_i \cdot x_i$$

$$y = f(\tilde{y}) = \begin{cases} 0 & \text{pentru } \tilde{y} \leq 0 \\ 1 & \text{pentru } \tilde{y} > 0 \end{cases} \quad (5.2.6)$$

### 5.2.2. Structura RNA

Din punctul de vedere al structurii rețelelor neuronale artificiale se pot distinge două mari categorii [Tiponuț2002]:

#### a) RNA feedforward (cu propagare înainte)

Aceste RNA sunt caracterizate de prezența unui strat de neuroni de intrare, 0, 1, 2, ... straturi ascunse și un strat de ieșire. Un neuron primește semnale doar de la neuronii aflați în stratul (straturile) precedent (precedente). RNA este total conectată dacă fiecare neuron dintr-un anumit strat este conectat la fiecare neuron din stratul precedent. Dacă anumite conexiuni sinaptice lipsesc, atunci se spune că RNA este parțial conectată.

#### b) RNA recurent (feedback, cu propagare înapoi)

RNA recurente se individualizează prin existența unui semnal de reacție, din partea neuronului de ordin superior, pentru cei de ordin inferior sau chiar pentru propriile lor intrări.

Elementele caracteristice ale RNA recurente constau în faptul că unitățile de procesare sunt neliniare, conexiunile sinaptice sunt simetrice și feedback-ul este folosit intensiv. Din această categorie fac parte RNA de tip Hopfield. Abordarea lui Hopfield se referă la rețelele recurente care pot fi folosite la simularea memoriilor asociative și la rezolvarea problemelor de optimizare combinatorie. Memoriile asociative sunt sisteme dinamice care permit stocarea și extragerea informațiilor prin intermediul parametrilor, pe baza unor exemple incomplete sau deteriorate. Stabilirea ponderilor conexiunilor dintre neuroni se realizează astfel încât informațiile de memorat să devină puncte fixe (stări staționare) ale dinamicii rețelei [Tudor2012].

### 5.2.3. Învățarea RNA

#### 5.2.3.1. Considerații preliminare

RNA achiziționează cunoștințele prin învățare. Învățarea presupune adaptarea parametrilor RNA (ponderi, praguri, rată de învățare, uneori chiar forma funcției de activare sau structura rețelei) ca urmare a stimulilor mediului în care se găsește RNA [Tiponuț2002].

Vectorii (datele) de instruire sunt prezentați RNA în mod secvențial, iar ponderile sinaptice, care memorează practic cunoștințele rețelei, sunt adaptate pentru a extrage informația pe care acești vectori o conțin. Tipul de învățare este determinat de maniera în care sunt ajustați parametrii liberi ai RNA.

La modul general, metodele de învățare se pot clasifica în maniera următoare:

- învățare supervizată:
  - cu algoritm de corecție a erorilor;
    - algoritm Widrow-Hoff (LMS sau regula delta)
    - algoritm de propagare înapoi a erorii (backpropagation);
  - cu algoritm Bolzman (stochastic);

- învățare nesupervizată (cu autoorganizare):
  - cu algoritm hebbian;
  - cu algoritm competitiv;
- învățare prin întărire.

Cunoștințele RNA sunt înglobate în valorile ponderilor aparținând sinapselor. Contrar programării clasice, în care cunoștințele se transmit prin intermediul secvenței de instrucțiuni care alcătuiesc programul de calcul, la RNA valorile ponderilor pot fi stabilite numai în urma unui proces de învățare (antrenament).

### 5.2.3.2. Învățarea supervizată

Învățarea supervizată presupune existența perechilor exemplu intrări – ieșiri. Se adaptează ponderile sinaptice astfel ca la aplicarea intrărilor RNA să calculeze tocmai ieșirile pereche. Matematic, problema constă în minimizarea unei funcții a erorilor definită pe baza diferențelor între ieșirile furnizate de RNA și cele "așteptate", funcție care depinde de ponderile sinapselor. Caracteristica generală a RNA este capacitatea lor de generalizare: furnizându-se RNA o intrare care nu face parte din mulțimea intrărilor de antrenament, ea este capabilă să stabilească ieșirea corectă.

Învățarea supervizată este caracterizată de prezența unui supervisor care cunoaște modul de asociere al intrărilor RNA cu ieșirile acestora fig. 5.2.2.

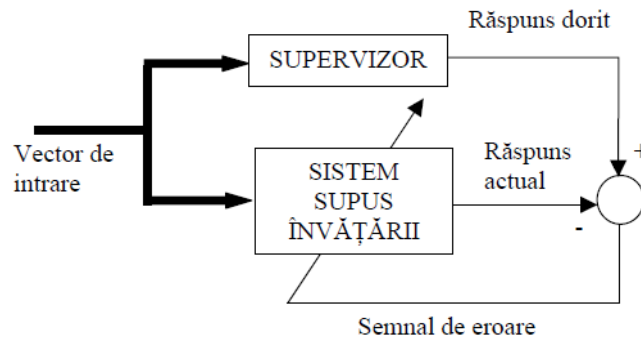


Fig. 5.2.2. Arhitectura unui sistem cu învățare supervizată

Parametrii RNA sunt modificați în funcție de influența combinată a mărimilor de antrenament și a erorii (diferența dintre răspunsul dorit și cel actual).

Pentru efectuarea antrenamentului trebuie întrunite câteva condiții esențiale [Tiponuş2002]:

- Să se dispună de o bază de învățare (antrenament) – o mulțime de perechi de valori I/O ale procesului în discuție, *suficient de mare* pentru ca în urma antrenamentului să se obțină un rezultat bun. Este necesar ca numărul perechilor de date intrare-ieșire să depășească substanțial numărul de neuroni antrenați.
- Baza de învățare să fie reprezentativă (consistentă) pentru procesul considerat. Fiecare proces stocastic este caracterizat prin baza sa de generalizare – totalitatea valorilor pe care le pot lua perechile de date intrare-ieșire. Baza de generalizare corespunde populației statistice formate din valorile intrare-ieșire, iar baza de învățare este un eșantion reprezentativ al acesteia, *suficient de mare*.
- Să existe un algoritm eficient de învățare care să conducă la soluția dorită, adică la diferențe neglijabile între valorile reale ale ieșirilor RNA obținute atunci când sunt aplicate intrările din baza de învățare și valorile de ieșire existente în baza de învățare.



Algoritmul standard de retropropagare este o metodă de tipul CMMP (cele mai mici pătrate), care minimizează funcția de eroare, când vectorul intrărilor parcurge baza de învățare. Procesul de minimizare este realizată cu tehnicile specifice optimizării neliniare (metode de gradient) [Kilyeni2015].

Algoritmul de învățare a RNA cuprinde următoarele etape [Luștea2004]:

- a) Se inițializează parametrii RNA cu valori mici, aleatoare.
- b) Se alege o pereche de vectori I/O din baza de antrenament.
- c) Se aplică vectorul de intrare și, prin calcule succesive pentru fiecare strat al RNA, se determină ieșirile corespunzătoare, până la găsire ieșirilor de pe ultimul strat, care constituie de fapt ieșirile oferite de RNA. Acesta este *etapa de propagare înainte* a informației în RNA.
- d) Se calculează vectorul eroare, ca diferență dintre vectorul ieșirilor obținute prin calcul și vectorul ieșirilor dorite, existent în baza de date. Cu ajutorul lui, utilizând metode de optimizare neliniară, se determină corecțiile ponderilor legăturilor asociate ultimului strat.

Pe o cale similară se stabilesc intrările dorite în ultimul strat, pentru ca folosind ponderile corectate să obținem ieșirile dorite, existente în baza de antrenament.

Având valorile dorite ale intrărilor pentru ultimul strat, care trebuie să coincidă cu ieșirile de pe penultimul strat al RNA, printr-o metodă identică cu cea aplicată ultimului strat, se determină pentru penultimul strat corecțiile ponderilor sinaptice și intrările dorite la acest penultim strat.

Se parcurg în această manieră toate straturile ascunse, până se ajunge la primul strat (cel de intrare).

Această etapă de calcul constituie *propagarea înapoi* (*retropropagarea*, *backpropagation*) a erorilor și a corecțiilor corespunzătoare anulării erorilor. În acest moment coeficienții sinapselor RNA au valorile corespunzătoare pentru a obține rezultatele dorite în cazul perechii intrare-ieșire considerată în această etapă.

- e) Se revine la etapa de calcul de la punctul c), pentru perechea următoare din baza de antrenament.
- f) După ce s-a parcurs în întregime baza de antrenament, se reia din nou procesul de corecție a coeficienților RNA, începând cu etapa b) de calcul. Acest lucru este necesar, deoarece prin parcurgerea vectorilor pereche din baza de învățare, coeficienții RNA au suferit modificări care îi fac să difere față de valorile obținute la pasul corespunzător parcurgerii anterioare a bazei de antrenament.
- g) Procesul de calcul se încheie atunci când, eroarea maximă dintre ieșirea calculată și cea dorită, pentru datele bazei de învățare, este mai mică decât un prag de eroare considerat acceptabil. În acest caz RNA oferă răspunsul corect (în limita erorii admise) pentru toate intrările existente în eșantionul de date de învățare, procesul de antrenament fiind încheiat.
- h) După ce RNA a depășit procesul de învățare, se trece la *etapa de exploatare a rețelei*. Prin aplicarea intrărilor corespunzătoare procesului considerat, ieșirile RNA vor trebuie să aproximeze, în limita pragului de eroare, ieșirile din procesul pentru care RNA a fost construită. Deci, după terminarea antrenamentului, RNA este un model adecvat al procesului considerat.

Funcția de eroare, care trebuie minimizată în procesul de antrenament al RNA, are forma:

$$J(w_{i,j}^m) = \frac{1}{2} \sum_{i=1}^{n_m} (y_i^m - \hat{y}_i^m)^2 \quad (5.2.7)$$

$$\begin{aligned}\tilde{y}_i^m &= \sum_{k=1}^{n_{m-1}} w_{k,i}^m \cdot x_k^m \\ \bar{y}_i^m &= f_i^m(\tilde{y}_i^m)\end{aligned}\quad (5.2.8)$$

Calculând derivata funcției de eroare  $J$  în raport cu ponderea unei sinapse de pe ultimul strat se obține:

$$\frac{\partial J}{\partial w_{i,j}^m} = \frac{\partial J}{\partial \tilde{y}_i^m} \cdot \frac{\partial \tilde{y}_i^m}{\partial w_{i,j}^m} = \frac{\partial J}{\partial \tilde{y}_i^m} \cdot \frac{\partial \sum_{k=1}^{n_{m-1}} w_{k,i}^m \cdot x_k^m}{\partial w_{i,j}^m} = \delta_i^m \cdot x_j^m \quad (5.2.9)$$

cu:

$$\delta_i^m = \frac{\partial J}{\partial \tilde{y}_i^m} = \frac{\partial J}{\partial \bar{y}_i^m} \cdot \frac{\partial \bar{y}_i^m}{\partial \tilde{y}_i^m} = -(y_i^m - \bar{y}_i^m) \cdot (f_i^m)' \quad (5.2.10)$$

Valoarea ponderii corectate, pentru NA din stratul de ieșire se determină cu următoarea formulă:

$$(w_{i,j}^m)_{\text{corectat}} = w_{i,j}^m + \eta \cdot \delta_i^m \cdot x_j^m = w_{i,j}^m - \eta \cdot (f_i^m)' \cdot x_j^m \cdot (y_i^m - \bar{y}_i^m) \quad (5.2.11)$$

iar pentru NA din stratul ascuns  $r$ , în locul erorii de la ieșire trebuie introdusă eroarea de ieșire pentru stratul ascuns:

$$(w_{i,j}^r)_{\text{corectat}} = w_{i,j}^r - \eta \cdot (f_i^r)' \cdot x_j^r \cdot \sum_{k=1}^{n_{r+1}} \delta_k^{r+1} \cdot w_{k,i}^{r+1} \quad (5.2.12)$$

Stratul  $(r+1)$  este cel imediat superior (mai aproape de ieșire) stratului  $r$ . Din acest motiv, ca urmare a direcției de propagare a calculelor spre înapoi (spre intrare), toate mărimile din stratul superior sunt deja cunoscute.

$\eta$  reprezintă *rata de învățare* și ea poate fi aleasă constantă pentru întreg procesul iterativ sau variabilă descrescătoare în funcție de numărul iterației. De valoarea ei (stabilită prin încercări sau pe baza experienței) depinde numărul de iterații necesar pentru obținerea soluției.

Funcția sigmoidă, folosită pentru activarea neuronului, are expresia:

$$(Y)' = \frac{\partial f(\tilde{y})}{\partial \tilde{y}} = \frac{\partial}{\partial \tilde{y}} \left( \frac{1}{1 + e^{-\lambda \cdot \tilde{y}}} \right) = \frac{\lambda \cdot e^{-\lambda \cdot \tilde{y}}}{(1 + e^{-\lambda \cdot \tilde{y}})^2} = \lambda \cdot f(\tilde{y}) \cdot [1 - f(\tilde{y})] = \lambda \cdot y \cdot (1 - y) \quad (5.2.13)$$

În procesul de antrenare a RNA pot să apară următoarele probleme [Luștea 2004]:

- *Paralizarea RNA* – se produce atunci când ponderile sinapselor ajung la valori foarte mari, situație în care valoarea derivatei funcției de activare este foarte mică. Corecția ponderilor este proporțională cu derivata funcției de activare – se poate ajunge la situația în care modificarea ponderilor de la o iterație la alta este nesemnificativă, ceea ce practic blochează ("paralizează") procesul de calcul. De regulă, o rată de învățare relativ mai redusă micșorează probabilitatea paralizării RNA.
- *Atingerea unui minim local* al funcției de eroare  $J$  poate "împotmoli" procesul de calcul. Ponderile sinapselor nu se modifică semnificativ de la o iterație la alta,

iar eroarea globală la ieșire se situează peste limita impusă. Singura soluție de rezolvare a "împotmolirii" într-un minim local este reluarea procesului de antrenare în condiții modificate: valorile inițiale ale ponderilor schimbate, rata de învățare modificată, funcția de activare schimbată etc.

### 5.2.3.3. Învățarea nesupervizată

Învățarea nesupervizată este caracterizată de absența unui semnal supervisor care să aprecieze corectitudinea asociațiilor dintre semnalele de intrare și cele de ieșire. RNA va descoperi singură "legitățile" conținute în datele de intrare printr-o reprezentare internă adecvată a trăsăturilor vectorului de intrare [Tiponuț2002].

Învățarea nesupervizată poate fi utilizată doar atunci când în mulțimea datelor de intrare există redundanță. Fără redundanță este imposibilă descoperirea vreunui model (pattern) sau a unei trăsături comune în mulțimea datelor de intrare.

Tipurile de modele detectabile de către o RNA cu învățare nesupervizată depind de arhitectura rețelei. Analizând posibilitățile a ceea ce pot reprezenta datele de ieșire ale unei astfel de RNA, avem următoarele cazuri [Enăchescu2008]:

- *Similaritate* – valoarea de ieșire reală generată de unicul neuron al stratului de ieșire al RNA ne poate furniza informații relativ la gradul de similaritate al unei noi date de intrare relativ la un model mediu prezentat RNA în trecut. Rețeaua neuronală va învăța treptat ceea ce reprezintă un model mediu.
- *Analiza componentei principale (PCA – Principal Component Analysis)* – extinde cazul precedent la situația RNA cu mai mulți neuroni în stratul de ieșire. Rezultă o mulțime de axe în lungul cărora se măsoară gradul de similaritate relativ la date de antrenament prezentate anterior.
- *Clustering* – o RNA cu valori de ieșire binare, având un unic neuron de ieșire activ (generând valoare binară 1) iar ceilalți neuroni de ieșire inactivi (generând valoarea binară 0), care va desemna cărei categorii îi aparține un vector de intrare. Apartenența la o anumită categorie trebuie stabilită de RNA pe baza informațiilor de corelare a vectorilor de intrare. Vectorii de intrare similari sau asemănători vor constitui o mulțime numită *cluster*, fiind considerați în aceeași clasă de ieșire – același neuron din stratul de ieșire va fi activat.
- *Prototipuri* – în acest caz RNA va forma categorii ca și în cazul clusteringului, dar valoarea de ieșire nu va fi o unică valoare binară 1, ci un prototip sau exemplar reprezentativ al clasei sau categoriei corespunzătoare. RNA se comportă și ca o memorie asociativă.
- *Hărți de trăsături (Feature Mapping)* – această situație apare în cazul când stratul de ieșire al RNA posedă o arhitectură geometrică fixă (de exemplu o matrice bidimensională) și doar câte un neuron de ieșire este activ la un moment dat. În acest fel, vectorii de intrare sunt aplicați în diverse puncte din schema (harta) reprezentată de stratul de ieșire, rezultând o hartă topografică a vectorilor de intrare. Vectorii de intrare asemănători sunt întotdeauna aplicați în "punctele apropiate" ale hărții de trăsături reprezentată de stratul de ieșire.

La *învățarea nesupervizată* sau *prin competiție*, nu se impune ieșirea dorită, dar se lasă ca ponderile sinaptice să se organizeze singure într-un astfel de mod ca ele să reproducă similitudinile care pot să existe între intrări. Un exemplu de rețea RNA care folosește învățarea nesupervizată este *rețeaua Kohonen*.

În contextul preocupărilor din cadrul tezei de doctorat, aceste tipuri de RNA nu prezintă interes.

### 5.3. Rețele neuronale de tip perceptron

#### 5.3.1. RNA de tip perceptron cu un singur strat

Arhitectura RNA de tip perceptron cu un singur strat (perceptron simplu) este prezentată în fig. 5.3.1.




Fig. 5.3.1. Arhitectura perceptronului simplu

Perceptronul simplu reprezintă în esență o particularizare a neuronului artificial (fig. 5.3.1) pentru cazul în care funcția de activare este de tip treaptă unitate bipolară (relația 5.2.2, cu  $-1$  în loc de  $0$ ) [Tiponuț2002].

În funcționarea perceptronului simplu se disting două etape [Eremia2006]:

- etapa de învățare pe baza exemplelor;
- etapa de clasificare a exemplelor necunoscute.

Etapa de învățare are drept scop calculul ponderilor și al valorii pragului de activare pe baza unei mulțimi de  $M$  exemple. Pentru fiecare exemplu se specifică valorile de intrare  $x_1^j, x_2^j, \dots, x_n^j, j = 1, 2, \dots, M$ , împreună cu ieșirea  $y$  aferentă. Corecția ponderilor se efectuează în felul următor:

- dacă pentru un exemplu perceptronul se activează când ar trebui să fie inactiv, se reduc ponderile  $w_i^j$  cu o cantitate proporțională cu  $x_i^j$ ;
- dacă perceptronul nu se activează deși ar trebui să o facă, se cresc ponderile  $w_i^j$  cu o cantitate proporțională cu  $x_i^j$ .

Algoritmul de antrenare al perceptronului simplu se poate sintetiza în modul [Eremia2006]:

- a) se inițializează ponderile ( $w_i^j(0) = 0, i = 1, 2, \dots, n, j = 1, 2, \dots, M$ ) și valoarea pragului de activare  $T(0)$  la momentul de timp (pasul)  $t = 0$  cu valori aleatoare mici, de regulă în intervalul  $[-0,1; 0,1]$ ;
- b) se prezintă cele  $M$  exemple, fiecare exemplu  $j$  ( $j = 1, 2, \dots, M$ ) fiind specificat prin valorile intrărilor  $x_1^j, x_2^j, \dots, x_n^j, j = 1, 2, \dots, M$  și valoarea ieșirii  $y_j, y_j(0) = 0$  este valoarea ieșirii perceptronului la "momentul" (pasul)  $t = 0$ , pentru exemplul  $j$ ;
- c) la un pas oarecare  $t$  ( $t = 0, 1, 2, \dots$ ) se determină noile valori ale ieșirii perceptronului pentru fiecare dintre cele  $M$  exemple:

$$y_j(t) = f \left( \sum_{i=1}^n w_i^j \cdot x_i^j - T \right), \quad j = 1, 2, \dots, M \quad (5.3.1)$$

d) la același pas  $t$  se calculează noile valori ale ponderilor:

$$w_i^j(t+1) = w_i^j(t) + \eta \cdot [d_j - y_j(t)] \cdot x_i, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, M \quad (5.3.2)$$

unde

$$d_j = \begin{cases} 0 & \text{dacă exemplul aparține clasei A} \\ 1 & \text{dacă exemplul aparține clasei B} \end{cases} \quad (5.3.3)$$

și  $\eta$  este rata de învățare;

e) condiția de terminare a antrenării:

$$y_j = d_j, \quad j = 1, 2, \dots, M \quad (5.3.4)$$

### 5.3.2. RNA de tip perceptron cu mai multe straturi

Structura de principiu a unei RNA de tip perceptron multistrat (Multilayer Perceptron – MLP) este prezentată în fig. 5.3.2.




Fig. 5.3.2. Structura unei rețele neuronale organizată pe mai multe straturi

Ea cuprinde un strat de intrare, un strat de ieșire și mai multe straturi ascunde formate din NA (perceptroni) interconectați complex. Fiecare strat folosește un anumit număr de NA, care se alege în funcție de natura problemei abordate, acest element constituind unul din aspectele importante ce trebuie rezolvate la proiectarea unei RNA. Nu există rețele general valabile în acest sens. Încercarea mai multor variante, care diferă prin numărul de NA pe strat, poate conduce, prin compararea performanțelor, la stabilirea corectă a soluției optime.

Numărul de NA pentru un strat poate diferi de cele ale straturilor învecinate. Fără a pierde din gradul de generalitate, se poate presupune că toate straturile au un număr identic de NA.

De regulă, fiecare NA de pe un anumit strat este conectat cu toți NA din stratul imediat următor – RNA conectate complet (fully connected ANN).

În general nu se admit legături între elementele care nu aparțin straturilor succesive. Există totuși excepții – așa numitele *conexiuni de scurtcircuitare* (short-cut connections), atunci când se urmărește creșterea influenței anumitor intrări asupra ieșirilor RNA.

Numărul de straturi ascunde se alege prin încercări, însă practica a dovedit că în majoritatea situațiilor este suficientă prezența a 1-2 straturi ascunde.

În RNA, semnalele de intrare se propagă de la stratul de intrare spre stratul de ieșire. Numai NA din straturile ascunde și eventual cei din stratul de ieșire realizează o prelucrare propriu-zisă a informației. Stratul de intrare are doar rolul de a distribui intrările primite din exterior, spre primul strat ascuns.

După stabilirea structurii RNA, doar ponderile  $w$  ale sinapselor pot fi modificate. În acest fel, numai prin fixarea adecvată a ponderilor pot fi rezolvate diverse probleme concrete.

Stabilirea ponderilor RNA se face printr-un proces de învățare (antrenare). Pe această cale, informația înglobată în valorile ponderilor legăturilor dintre neuroni poate rezolva cu succes situațiile concrete legate de sistemul fizic pentru care a fost proiectată RNA.

Perceptronii multistrat cu mai multe ieșiri și funcții de transfer sigmoide se mai numesc și RNA cu *backpropagation*, denumire care provine de la algoritmul de învățare și algoritmul de propagare înapoi a erorii [Eremia2006].

Intrările acestor rețele sunt valori reale cuprinse în intervalul  $[0, 1]$  și funcția de transfer trebuie să fie continuă și derivabilă pe domeniul de definiție. De obicei se utilizează funcția sigmoid, discutată în paragraful 5.2.1:

$$y = \frac{1}{1 + e^{-\sum_{i=1}^n x_i}} \quad (5.3.5)$$

Dacă suma intrărilor este 0, valoarea este  $y = 0,5$ . Dacă suma intrărilor crește, ieșirea tinde către +1. Dacă scade, valoarea ieșirii tinde către 0. Datorită caracterului funcției de transfer, valorile ieșirilor nu vor putea fi niciodată 0 sau 1. Într-un proces de clasificare, fiecare ieșire corespunde unei regiuni de decizie sau unei clase; pentru un exemplu nou se selectează clasa corespunzătoare ieșirii cu cea mai mare valoare, de obicei cea care tinde către 1.

Așa cum s-a precizat și pentru cazul perceptronului simplu, funcționarea unei rețele perceptron multistrat cuprinde două etape: *etapa de învățare* în care, pe baza mulțimii de exemple cunoscute, se sintetizează ponderile și valorile pragurilor de activare, și etapa de recunoaștere (testare), în care rețeaua este utilizată pentru a clasifica mulțimi de valori necunoscute.

Algoritmul de învățare al rețelelor de tip backpropagation cuprinde două etape principale:

- *parcursere directă a rețelei*, de la intrări spre ieșiri, în care se activează RNA și se determină valorile ieșirilor;
- *parcursere înapoi a rețelei*, de la ieșiri spre intrări, în care ieșirile calculate se compară cu ieșirile din exemple și se determină o estimare a erorii, această estimare a erorii fiind propagată înapoi și utilizată la actualizarea ponderilor.

Sintetic, algoritmul acestor RNA se prezintă în maniera următoare [Eremia 2006]:

#### □ Inițializarea

Ponderile și pragurile rețelei sunt inițializate aleator cu valori nenule, distribuite într-un interval redus (de exemplu  $[-0,1; 0,1]$  sau  $\left[-\frac{2,4}{NI}; \frac{2,4}{NI}\right]$ , unde  $NI$  – numărul de intrări ale RNA.

Dacă toate valorile inițiale ar fi 0, valorile gradientilor care vor fi calculați pe parcursul antrenării vor fi tot 0 (rețeaua nu va învăța). Este indicat să se realizeze mai multe antrenări, cu ponderi inițiale diferite, pentru a găsi cele mai bune valori pentru funcția obiectiv (minimumul erorii). Dacă valorile inițiale sunt mari, derivata funcției sigmoid este foarte mică, învățarea fiind lentă.

□ *Realizarea unei epoci de antrenare*

O epocă reprezintă prelucrarea tuturor exemplurilor din mulțimea de antrenare. În majoritatea cazurilor, antrenarea rețelei presupune mai multe epoci de antrenare, o singură epocă de antrenare nefiind suficientă.

Ponderile vor fi ajustate numai după ce toate exemplele care constituie mulțimea de antrenare au fost parcurse. Gradientii ponderilor și eroarea curentă se inițializează cu 0:

$$\Delta w_{ij} = 0; E = 0 \quad (5.3.6)$$

□ *Propagarea înainte*

- La intrările rețelei se aplică un exemplu din setul de antrenare.
- Se calculează ieșirile neuronilor din stratul ascuns:

$$y_j(p) = f \left( \sum_{i=1}^n [x_i(p) \cdot w_{ij}(p) - T_j] \right), \quad j = 1, 2, \dots, b \quad (5.3.7)$$

unde:  $n$  – numărul de intrări ale neuronului  $j$  din stratul ascuns;  
 $f$  – funcția de activare sigmoidă;  
 $p$  – se referă la exemplul curent de învățare.

- Se calculează ieșirile reale ale rețelei:

$$y_k(p) = f \left( \sum_{j=1}^b [x_{jk}(p) \cdot w_{jk}(p) - T_k] \right), \quad k = 1, 2, \dots, m \quad (5.3.8)$$

unde  $m$  este numărul de intrări ale neuronului  $k$  din stratul de ieșire.

- Se actualizează eroarea pe epocă:

$$E = E + \frac{[e_k(p)]^2}{2} \quad (5.3.9)$$

□ *Propagarea erorilor înapoi și ajustarea ponderilor*

- Se calculează gradientii erorilor pentru neuronii din stratul de ieșire:

$$\delta_k(p) = f' \cdot e_k(p) \quad (5.3.10)$$

unde:  $f'$  este derivata funcției de activare, iar eroarea:

$$e_k(p) = y_{d,k}(p) - y_k(p) \quad (5.3.11)$$

unde:  $y_{d,k}(p)$  – valoarea reală a ieșirii  $k$ ;  
 $y_k(p)$  – valoarea calculată a ieșirii  $k$ .

În cazul funcției sigmoid derivata acesteia este:

$$f'(p) = \frac{2 \cdot a \cdot e^{-a \cdot x}}{(1 + e^{-a \cdot x})^2} = \frac{a}{2} \cdot [1 - f(x)] \cdot [1 + f(x)] \quad (5.3.12)$$

iar gradientii erorilor pentru neuronii din stratul de ieșire devin:

$$\delta_k(p) = y_k(p) \cdot [1 - y_k(p)] \cdot e_k(p) \quad (5.3.13)$$

- Se actualizează gradientii ponderilor dintre stratul ascuns și stratul de ieșire:

$$\Delta w_{jk}(p) = \Delta w_{jk}(p) - y_i(p) \cdot \delta_k(p) \quad (5.3.14)$$

- Se calculează gradientii erorilor pentru neuronii din stratul ascuns:

$$\delta_i(p) = y_i(p) \cdot [1 - y_i(p)] \cdot \sum_{k=1}^m [\delta_k(p) \cdot w_{jk}(p)] \quad (5.3.15)$$

unde  $m$  este numărul de ieșiri ale rețelei.

- Se actualizează gradientii ponderilor dintre stratul de intrare și stratul ascuns:

$$\Delta w_{jk}(p) = \Delta w_{jk}(p) + x_j(p) \cdot \delta_i(p), \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, b \quad (5.3.16)$$

#### □ Trecerea la o nouă iterație

Dacă mai sunt vectori de test în epoca de antrenare curentă, se efectuează faza de *Propagarea înainte* și cea de *Propagarea erorilor înapoi și ajustarea ponderilor*, până la epuizarea tuturor exemplilor.

#### □ Verificarea condiției de terminare

Dacă s-a încheiat o epocă de antrenare, se actualizează ponderile tuturor conexiunilor pe baza gradientilor ponderilor ( $\eta$  – rata de învățare):

$$w_{ij}(p) = w_{ij}(p) + \eta \cdot \Delta w_{ij}(p), \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, b \quad (5.3.17)$$

Se testează dacă s-a îndeplinit criteriul de terminare ( $E < E_{max}$ ) sau dacă s-a atins un număr maxim de epoci de antrenare (s-a depășit numărul maxim de iterații). Dacă nici una din cele două condiții nu este satisfăcută, se trece la realizarea unei noi epoci de antrenare.

În situația în care este satisfăcut criteriul de terminare, algoritmul a reușit (rețeaua a învățat), în caz contrar, rețeaua nu a învățat. Pentru a putea găsi o soluție, fie se modifică viteza de antrenare, fie se aleg alte valori inițiale pentru ponderi (sau se aplică ambele măsuri).

În general, este acceptată ideea că perceptronul multistrat poate aproxima cu o precizie bună orice funcție continuă neliniară, însă cu prețul creșterii dimensiunilor rețelei. Teorema lui Kolmogorov dă și numărul unui asemenea MLP:  $M$ ,  $2M+1$ ,  $N$ .  $M$  și  $N$  reprezintă numărul de elemente din primul strat (care nu efectuează procesări), respectiv din ultimul strat [Eremia2006].

Se consideră utile următoarele recomandări pentru construcția RNA de tip perceptron cu mai multe straturi:

- Numărul neuronilor din stratul de intrare depinde de specificul problemei și de numărul de intrări considerate în aplicația respectivă.
- Dimensiunile stratului de ieșire depind, de asemenea, de specificul problemei, precum și de alți factori: tipul mărimilor de ieșire (analogice, binare), existența sau absența unei ieșiri speciale pentru semn etc. Cu alte cuvinte, numărul neuronilor din stratul de ieșire depinde de forma și de structura în care se doresc a fi prezentate estimările pentru mărimile de ieșire.
- Numărul neuronilor din straturile ascunse – se recomandă să se utilizeze un număr cât mai mic de neuroni, deoarece fiecare neuron ascuns multiplică numărul conexiunilor.



- O posibilitate de dezvoltare a RNA, cunoscută sub numele de *Cascade Correlation*, pornește de la un singur neuron ascuns și, pe durata antrenării, creează neuroni suplimentari, în măsura în care aceștia contribuie la ameliorarea performanțelor.
- Un alt parametru, care influențează într-o mare măsură performanțele RNA este *rata de învățare*  $\eta$ . De obicei, inițial se adoptă valori mici, de ordinul 0,05 până la 0,25, pentru a asigura orientarea și apropierea rețelei de soluția problemei. Asemenea valori ale ratei de învățare conduc la un număr mare de iterații, dar cel mai adesea, acesta este "prețul" pentru obținerea performanțelor dorite. În unele cazuri, este necesară creșterea valorii lui  $\eta$  în cursul antrenării. Mărirea ratei de învățare, pe măsură ce eroarea scade, contribuie adesea la accelerarea convergenței. Nu se recomandă utilizarea unor valori prea mari, deoarece ar putea conduce la oscilații în jurul soluției.
- O altă posibilitate de creștere a vitezei de convergență constă în *actualizarea ponderilor*, folosind un termen adițional, numit "*momentum*", care ține seama de corecția ponderilor în iterația anterioară.

$$w_{ij}(t+1) = w_{ij}(t) + \eta \cdot \delta_i \cdot y_j + \alpha \cdot \Delta w_{ij}(t) \quad (5.3.18)$$

Metoda definită de această relație se numește *retropropagare cu moment*, fiind vorba de fapt despre o variantă a metodei gradientului conjugat – tehnică de optimizare neliniară [Kilyeni2015].

După cum s-a arătat, după ce rețeaua a găsit un minim, indiferent dacă acesta este local sau global, potrivit criteriului de oprire, algoritmul de învățare se întrerupe. Totuși, dacă este vorba de un minim local, este foarte probabil ca eroarea la ieșirea rețelei să fie inacceptabil de mare. Dacă însă RNA furnizează o soluție acceptabilă, din punct de vedere al erorii, nu contează dacă minimul este local sau global.

- Alegerea *seturilor de învățare (antrenare) și generalizare pentru MLP*. Criteriul de minimizare folosit în algoritmul de învățare de tip backpropagation prezintă un inconvenient: urmărește minimizarea funcției eroare folosind numai baza de învățare, în timp ce performanțele reale ale RNA trebuie apreciate pentru baza de generalizare. De aceea, o învățare performantă implică existența unei legături între baza de învățare și cea de generalizare. Astfel, se presupune că cele două baze sunt realizări aleatorii conforme, cu aceeași densitate de probabilitate.
- *Scalarea variabilelor de intrare și ieșire ale RNA*, astfel ca valorile acestora să se găsească între 0 și 1; în acest scop, se raportează mărimile de intrare și cele de ieșire la mărimi de bază corespunzătoare.

## 5.4. Concluzii

În cadrul acestui capitol s-au prezentat rețelele neuronale artificiale (RNA). El oferă baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică și putere (prezentată în capitolul 6).

În prima parte a capitolului s-au prezentat o serie de aspecte generale privind RNA: terminologia de bază, structura RNA, clasificarea RNA etc.

A doua parte a capitolului a avut ca obiect prezentarea modelului RNA. S-a pornit de la neuronul artificial și s-a ajuns la structura RNA. Un paragraf aparte a fost dedicat tehnicilor de învățare (antrenare) utilizate de RNA – supravegheată, respectiv nesupravegheată.

Ultima parte a capitolului a fost consacrată prezentării RNA de tip perceptron, cu un singur strat și cu mai multe straturi, cu o atenție specială pentru cele de tip backpropagation.

În continuare se prezintă o sinteză a contribuțiilor personale:

- realizarea unei sinteze documentate asupra unei game largi de aspecte legate de rețelele neuronale artificiale;
- pregătirea elementelor teoretice necesare pentru modelul de prognoză utilizat în cadrul tezei;
- evidențierea parametrilor "reglabili" ai perceptronului cu mai multe straturi, în scopul ameliorării performanțelor de aplicare în problema prognozei consumului de energie electrică.

## 6. MODEL MATEMATIC ȘI INSTRUMENT SOFT PENTRU PROGNOZA CONSUMULUI DE ENERGIE ELECTRICĂ ȘI DE PUTERE

Obiectivul capitolului 6 constă în prezentarea atât a modelului matematic al prognozei consumului de energie electrică și putere (inclusiv curbe de sarcină) cât și a instrumentului soft realizat pe baza modelului respectiv (care va fi utilizat în capitolul următor, care constituie principala parte aplicativă a tezei de doctorat). Au fost utilizate elementele teoretice prezentate în capitolele anterioare (2 și 5) ale tezei.

Prima parte a capitolului detaliază tehnica bayesiană în contextul aplicației de prognoză, trecându-se în revistă principiile inferenței bayesiene, priorul RNA, calculul funcțiilor de eroare și al gradientului, procedura *evidență*, predicția și barele de eroare.

A doua parte prezintă tehnica de optimizare utilizată în cadrul aplicației – metoda gradientul conjugat scalat (SCG).

Ultima parte prezintă o serie de detalii despre instrumentul soft care înglobează toate modelele matematice prezentate în acest capitol. A fost conceput în mediul Matlab, utilizând toate facilitățile (de interfață și portabilitate) specifice sistemelor de operare și mediilor informatice actuale. În cadrul aplicației soft au fost implementate și o serie de proceduri din toolbox-ul Netlab al Matlab [Nabney2002], care constituie instrumente utile pentru simularea algoritmilor specifici rețelelor neuronale artificiale.

### 6.1. Tehnica bayesiană

#### 6.1.1. Considerații preliminare

Modelarea datelor se realizează preponderent utilizând metoda MLE (Maxim Likelihood Estimation), prezentată în paragraful 2.2.3.2. Această metodă presupune faptul că cel mai bun set de parametri este acela care generează setul de date observat. În abordarea MLE modelul nu generează setul de date în mod exact. Diferența dintre modelul bayesian și MLE (incertitudinea din datele generate) este interpretată probabilistic utilizând un model cu zgomot (noise).

$$y = f(x;w) + \varepsilon \quad (6.1.1)$$

unde:  $x$  – setul datelor de intrare în rețeaua neuronală artificială (RNA);

$w$  – setul de ponderi ale RNA;

$f$  – funcția modelului;

$\varepsilon$  – zgomotul.

Modelul definit de relația (6.1.1) ia în considerare un factor de incertitudine în generarea datelor (prin introducerea zgomotului), în schimb nu ia în considerare incertitudinea în estimarea parametrilor. Rulând de mai multe ori o aplicație cu un zgomot dat, date de intrare și ponderi fixe, se obțin seturi de rezultate diferite.

Cu cât funcția modelului este mai complexă, cu atât datele de antrenare se portivesc mai bine cu modelul. Acest lucru se datorează faptului că ajustarea se face, de fapt, pe zgomot și nu pe tendința de variație a datelor, rezultând astfel

fenomenul de overfitting – pentru datele de testare (date neobservate) rezultatele nu sunt exacte. În cazul tehnicii bayesiene, incertitudinea legată de estimarea parametrilor (ponderilor) din date este reprezentată de o distribuție de probabilitate.

În abordarea bayesiană se pornește cu o distribuție de probabilitate prior asupra ponderilor, notată  $p(w)$ , aceasta exprimând cunoștințele despre parametri înainte de observarea datelor. Odată ce datele sunt observate, se poate utiliza teorema lui Bayes pentru a obține densitatea de probabilitate posterioară, notată  $p(w|D)$ .

Există două abordări bayesiene asupra RNA care s-au demonstrat a fi cele mai eficiente în aplicațiile practice.

Prima se bazează pe aproximare gaussiană locală a distribuției posterioare în spațiul ponderilor (aproximare Laplace). Aceasta este legată de procedura *Evidenței* (date observate) pentru estimarea hiperparametrilor (alpha, beta) optimi. Cea de a doua se bazează pe tehnici de tip Monte Carlo (MC), în special pe tehnică hibridă Monte Carlo (HMC).

În teză s-a aplicat prima abordare: estimarea hiperparametrilor optimi în cadrul procedurii *Evidenței*.

### 6.1.2. Principiile inferenței bayesiene

Inferența bayesiană are la bază teorema lui Bayes [Koch2007], care, în contextul modelării, poate fi scrisă astfel:

$$p(w|D) = \frac{p(D|w) \cdot p(w)}{p(D)} \quad (6.1.2)$$

unde:

- $p(w|D)$  reprezintă distribuția de probabilitate posterioară a parametrilor (ponderile  $w$ ) ținând cont de datele observate  $D$ ;
- $p(w)$  reprezintă distribuția de probabilitate prior a ponderilor  $w$ ;
- $p(D|w)$  reprezintă model generator al setului de date  $D$ , numit likelihood – legat de ipoteză;
- $p(D)$  reprezintă *evidența*, fiind dată de integrala asupra spațiului ponderilor (factor de normalizare, care asigură faptul că integrala are valoarea 1):

$$p(D) = \int p(D|w') \cdot p(w') \cdot dw' \quad (6.1.3)$$

Relația (6.1.2) răspunde la întrebarea: *Ce se poate afirma (cunoaște) despre distribuția parametrului  $w$ , după ce s-a observat setul de date  $D$  și s-au folosit cunoștințele pe care le avem despre mecanismul implicit de generare a datelor?*

Odată ce posteriorul a fost calculat, orice tip de inferență se realizează prin integrare peste această distribuție. Pentru a face predicție la o nouă dată de intrare  $x^*$ , trebuie calculată distribuția de predicție

$$p(y|x^*, D) = \int p(y|x^*, w) \cdot p(w|D) \cdot dw \quad (6.1.4)$$

Media acestei distribuții este utilizată la calculul predicției într-un punct, predicția fiind dată de relația:

$$E(y|x^*, D) = \int y \cdot p(y|x^*, D) \cdot dy \quad (6.1.5)$$

în timp ce varianța distribuției de predicție poate fi utilizată pentru barele de eroare (conform paragrafului 2.3.6).

Problema care apare este legată de dificultatea calcului integralei, calculul fiind posibil doar pentru clase mici de distribuții de probabilitate prior și likelihood. Dimensiunea integralei este dată de numărul de parametri, astfel încât chiar și algoritmi de integrare numerici simpli eșuează. În acest punct intervin aproximarea posterioară și metodele numerice pentru evaluarea integralelor (metode MC combinate cu eșantionarea șirului Markov) care ocupă un rol important în utilizarea metodelor bayesiene cu RNA. Luând în considerare incertitudinea ponderilor se reduce problema overfitting-ului.

Metodele bayesiene au următoarele avantaje:

- luând în considerare incertitudinea parametrilor, problema overfitting-ului este rezolvată;
- regularizarea poate da o interpretare naturală în cadrul bayesian, fiind posibil un raționament consecvent cu parametrii de regularizare, devenind mai facilă găsirea valorilor optime (optimizarea parametrilor de regularizare în cadrul procesului de antrenare a RNA);
- incertitudinea parametrilor poate fi luată în considerare în predicția RNA. Pentru problemele de regresie se pot asocia bare de eroare sau intervale de predicție;
- utilizând tehnica Automatic Relevance Determination (ARD), se pot determina importanțele relative ale variabilelor de intrare ale RNA.

### 6.1.3. Priorul în RNA

Tehnica bayesiană începe prin alegerea distribuției de probabilitate a priorului ponderilor în RNA. Un RNA având ponderi de valori mari va genera o serie de probleme legate de rezultate, fiind recomandabilă alegerea unor valori mai reduse. Acest fapt sugerează o distribuție de probabilitate prior de tip gaussiană cu media zero, de forma:

$$p(w) = \frac{1}{Z_W(\alpha)} \cdot \exp\left(-\frac{\alpha}{2} \|w\|^2\right) \quad (6.1.6)$$

unde  $\alpha$  reprezintă inversul varianței distribuției. Constanta de normalizare are forma:

$$Z_W(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{W^2} \quad (6.1.7)$$

Deoarece  $\alpha$  este un parametru pentru distribuția altor parametri (ponderi, praguri de activare, bias-uri), el poartă denumirea de *hiperparametru*. Ignorând constanta de normalizare, care nu depinde de ponderi, după aplicarea logaritmului negativ priorul devine echivalent cu un termen de eroare al ponderii, de forma:

$$\alpha \cdot E_W = \frac{\alpha}{2} \cdot \|w\|^2 = \frac{\alpha}{2} \cdot \sum_{i=1}^n w_i^2 \quad (6.1.8)$$

Acest termen de eroare regularizează ponderea, penalizând valorile relativ mari.

Generalizarea acestei abordări se poate aplica pe hiperparametrii multipli  $\alpha_1, \alpha_2, \dots, \alpha_g$  ce corespund grupelor de ponderi  $W_1, W_2, \dots, W_g$ . Există două generalizări de interes de acest tip:

- generalizarea *Priori Conformi*;
- tehnica *Automatic Relevance Determination* (ARD).

În *Priori Conformi* [Bishop2006] un singur parametru de regularizare este inconsistent cu rescalarea liniară a modelelor de intrare și ieșire. În schimb un prior de forma:

$$p(w) \propto \exp\left(-\frac{\alpha_1}{2} \cdot \sum_{w \in W_1} W^2 - \frac{\alpha_2}{2} \cdot \sum_{w \in W_2} W^2\right) \quad (6.1.9)$$

unde  $W_1$  și  $W_2$  reprezintă setul de ponderi fără pragurile de activare (bias-uri) de pe primul strat, respectiv de pe al doilea strat al RNA, face ca ponderile să se scaleze invariant în straturi și pragurile de activare să se translateze invariant. Aceasta este în conformitate cu rescalarea liniară, atâta timp cât parametrii de regularizare  $\alpha_1$  și  $\alpha_2$  sunt de asemenea rescalați.

În tehnica *ARD* ponderile sunt împărțite în mai multe grupuri ( $g_i$ ). De exemplu:  $g_1$  – grupul ponderilor de pe stratul de intrare;  $g_2$  – grupul ponderilor de pe stratul ascuns;  $g_3$  – grupul pragurilor de activare (bias-urilor) de pe stratul de intrare;  $g_4$  – grupul pragurilor de activare (bias-urilor) de pe stratul ascuns. Grupurile  $g_i$  sunt controlate, printr-un prior gaussian, de un hiperparametru  $\alpha_{g_i}$ . Tehnica *ARD* constă în asocierea separată a coeficientului de regularizare  $\mu = \frac{\alpha}{\beta}$  la fiecare intrare, adică toate ponderile legate de aceeași intrare sunt controlate de același hiperparametru  $\alpha_{g_i}$ . Acest hiperparametru este asociat cu un prior gaussian cu media zero și varianța  $\frac{1}{\alpha_{g_i}}$ .

#### 6.1.4. Calculul funcției erorii și funcției gradientului

Odată de priorul a fost construit în cadrul RNA și introdus în structura datelor, prin antrenarea RNA se poate găsi cea mai probabilă pondere  $w_{MP}$ . În cadrul bayesian eroarea modelului este dată de logaritmul probabilității posterioare  $-\log p(w|D)$ . Utilizând teorema lui Bayes, relația (6.1.2), și ignorând termenul *evidenței*  $p(D)$ , care nu depinde de ponderi, se obține funcția de eroare de forma (6.1.10), utilizând relațiile (6.1.6) și (6.1.8):

$$E = -\log p(D|w) - \log p(w) = -\log p(D|w) - \alpha \cdot E_W \quad (6.1.10)$$

Pentru o problemă de regresie se lucrează în ipoteza că modelul cu zgomot  $\beta$  pentru datele de ieșire cunoscute este un model gaussian cu media zero și varianță inversă constantă  $\beta$ . Probabilitatea variabilei de ieșire  $t$  asociată vectorului de intrare  $x$  este dată de relația:

$$p(t|x, w) \propto \exp\left\{-\frac{\beta}{2} \cdot [y(x; w) - t]^2\right\} \quad (6.1.11)$$

Pentru un set de variabile aleatoare independente, cu distribuție identică, probabilitatea devine:

$$p(D|w) = \frac{1}{Z_D(\beta)} \cdot \exp\left\{-\frac{\beta}{2} \sum_{n=1}^N [y(x^n; w) - t^n]^2\right\} \quad (6.1.12)$$

unde factorul de normalizare este:

$$Z_D(\beta) = \left(\frac{2\pi}{\beta}\right)^{\frac{N}{2}} \quad (6.1.13)$$

Acest fapt arată că componenta legată de date din cadrul funcției de eroare este reprezentată de suma pătratelor erorilor ponderate de  $\beta$ :

$$\beta \cdot E_D = \frac{\beta}{2} \cdot \sum_{n=1}^N [y(x^n; w) - t^n]^2 \quad (6.1.14)$$

Asociind relațiile (6.1.8) și (6.1.14), se obține eroarea cu regularizare:

$$S(w) = \beta \cdot E_D + \alpha \cdot E_W \quad (6.1.15)$$

Similar se procedează și pentru calculul funcției gradientului. Gradientul va avea de asemenea două componente:  $G_D$  – componenta legată de date, respectiv  $G_W$  – componenta legată de ponderile RNA. Astfel gradientul este dat de relația:

$$G = \beta \cdot G_D + \alpha \cdot G_W \quad (6.1.16)$$

În relația (6.1.16) intervine:

$$\alpha \cdot w_i = \frac{\partial E_W}{\partial w_i} \quad (6.1.17)$$

Relația (6.1.17) se extinde pentru grupuri de ponderi.

Contribuția din componenta  $E_W$  asupra matricei hessiene  $H$  este dată de relația simplă  $\alpha \cdot I$  (sau de extensia relației asupra grupurilor de ponderi).

### 6.1.5. Procedura *Cadru Evidență*

Procedura *Cadru Evidență* este un algoritm iterativ pentru determinarea ponderilor optime și a hiperparametrilor RNA. Ea răspunde la întrebarea: "Cum se ajustează în practică hiperparametrii RNA pentru a ține cont de datele de antrenare?". În principiu, cel mai corect este să se aplice integrala asupra tuturor parametrilor necunoscuți ai RNA, adică atât asupra ponderilor cât și a hiperparametrilor  $\alpha$  și  $\beta$ . Astfel distribuția posterioară asupra ponderilor RNA este dată de relația (2.3.24):

$$p(w | D) = \iint p(w, \alpha, \beta | D) \cdot d\alpha \cdot d\beta = \iint p(w | \alpha, \beta, D) \cdot p(\alpha, \beta | D) \cdot d\alpha \cdot d\beta \quad (6.1.18)$$

Aceasta presupune să integrăm distribuția posterioară a ponderilor  $p(w | \alpha, \beta, D)$  asupra unui spațiu care are dimensiunea egală cu numărul de hiperparametri ( $\geq 2$ ). Operația de integrare poate fi simplificată și alegând un prior  $p(\alpha) = \frac{1}{\alpha}$  asupra hiperparametrilor, putând fi chiar calculată analitic. Aproximarea realizată în procedura *Evidență* are rezultate bune în practică [Mackay2003]: densitatea posterioară a hiperparametrilor  $p(\alpha, \beta | D)$  are vârful ascuțit în jurul valorilor  $\alpha_{MP}$  și  $\beta_{MP}$ , cele mai probabile valori ale hiperparametrilor (aproximare Laplace). Cu aceste ipoteze integrala din relația (6.1.18) se reduce la:

$$p(w | D) = p(w | \alpha_{MP}, \beta_{MP}, D) \cdot \iint p(\alpha, \beta | D) \cdot d\alpha \cdot d\beta \approx p(w | \alpha_{MP}, \beta_{MP}, D) \quad (6.1.19)$$

Acest lucru este echivalent cu a găsi valorile hiperparametrilor care optimizează probabilitatea posterioară a ponderilor și apoi a efectua toate celelalte calcule care implică  $p(w | D)$  (cum ar fi predicția RNA) utilizând distribuția cu hiperparametrii fixați pe acele valori.

Următorul pas constă în calculul integralelor ce implică distribuții posterioare ale ponderilor  $p(w|\alpha, \beta, D)$ , care necesită la rândul lor aproximări. În [Mackay2003] este folosită o distribuție gaussiană sferică în jurul modului / dominantei posteriorului (valoarea cea mai des întâlnită). În cazul MLP există mai multe dominante / module din cauza dependenței neliniare a ieșirii RNA asupra ponderilor. Modul cel mai favorabil este de a privi această aproximare ca pe un minim local pur în jurul unei dominante particulare  $w_{MP}$ , bazată pe dezvoltarea în serie Taylor asupra lui  $S(w)$ , cu reținerea termenilor până la cel cu derivata de ordinul 2 (inclusiv):

$$S(w) \approx S(w_{MP}) + \frac{1}{2}(w - w_{MP})^T \cdot A(w - w_{MP}) \quad (6.1.20)$$

În ipoteza că  $w_{MP}$  este un minim local al funcției de eroare, termenul de ordinul 1 este nul, astfel că pentru toate coordonatele avem  $\frac{\partial S(w_{MP})}{\partial w_i} = 0$ . Matricea  $A$  este matricea hessiană pentru funcția de eroare cu regularizare:

$$A = \nabla \nabla S(w_{MP}) = \beta \cdot \nabla \nabla E_D(w_{MP}) + \alpha \cdot I \quad (6.1.21)$$

unde  $\nabla \nabla E_D(w_{MP})$  este hessiana funcției RNA. Eroarea funcției  $S(w)$  este logaritmul negativ al probabilității posterioare a ponderilor, ceea ce evidențiază că distribuția este gaussiană:

$$p(w|\alpha, \beta, D) = \frac{1}{Z_S^*} \cdot \exp \left[ -S(w_{MP}) - \frac{1}{2} \cdot \Delta w^T \cdot A \cdot \Delta w \right] \quad (6.1.22)$$

unde  $\Delta w = w - w_{MP}$  și  $Z_S^*$  este constanta de normalizare a aproximării gaussiene, fiind dată de relația:

$$Z_S^*(\alpha, \beta) = \exp[-S(w_{MP})] \cdot (2\pi)^{\frac{w}{2}} \cdot (\det A)^{-\frac{1}{2}} \quad (6.1.23)$$

Abordarea bayesiană în a calcula  $\alpha_{MP}$  și  $\beta_{MP}$  este de a considera dominanța distribuțiilor lor posterioare:

$$p(\alpha, \beta|D) = \frac{p(D|\alpha, \beta) \cdot p(\alpha, \beta)}{p(D)} \quad (6.1.24)$$

Numitorul relației poate fi ignorat deoarece nu depinde de hiperparametri, iar  $p(\alpha, \beta)$  (numit *hiperprior*) se va considera o distribuție uniformă, ceea ce înseamnă că poate fi și el ignorat. Trebuie maximizat  $p(D|\alpha, \beta)$ , ceea ce este cunoscută sub denumirea de *Evidență* pentru hiperparametri, prin ajustarea lui  $\alpha$  și  $\beta$ . Acest termen se determină prin integrarea probabilității datelor observate asupra ponderilor:

$$p(D|\alpha, \beta) = \int p(D|w, \alpha, \beta) \cdot p(w|\alpha, \beta) \cdot dw = \int p(D|w, \alpha, \beta) \cdot p(w|\alpha) \cdot dw \quad (6.1.25)$$

A doua egalitate are loc datorită faptului că distribuția ponderilor este independentă de varianța zgomotului. Utilizând relațiile (6.1.8) și (6.1.14), relația (6.1.25) se poate rescrie sub forma:

$$p(D|\alpha, \beta) = \frac{1}{Z_D(\beta)} \cdot \frac{1}{Z_W(\alpha)} \cdot \int \exp[-S(w)] \cdot dw \quad (6.1.26)$$



Utilizând relațiile (6.1.7), (6.1.13), (6.1.23) și (6.1.26), se poate calcula logaritmul *Evidenței* astfel (conform celor prezentate în subcapitolul 2.3):

$$\log p(D|\alpha, \beta) = -\alpha \cdot E_W^{MP} - \beta \cdot E_D^{MP} - \frac{1}{2} \cdot \ln|A| + \frac{W}{2} \cdot \ln(\alpha) + \frac{N}{2} \cdot \ln(\beta) - \frac{N}{2} \cdot \ln(2\pi) \quad (6.1.27)$$

unde  $W$  este numărul total de parametri.

Expresia logaritmului *Evidenței* pentru hiperparametrii  $\alpha$  și  $\beta$  nu se poate optimiza direct. Primul pas în optimizarea logaritmului *Evidenței* față de  $\alpha$  este de a calcula derivata parțială. Cel mai dificil termen îl reprezintă logaritmul determinantului matricei  $|A|$ . Dacă  $\lambda_1, \lambda_2, \dots, \lambda_W$  sunt valorile proprii ale matricei hessiene  $H$ , atunci  $|A|$  va avea valorile proprii  $\lambda_j \cdot d + \alpha$ , rezultând

$$\frac{d}{d\alpha} \ln|A| = \frac{d}{d\alpha} \ln(\prod_{i=1}^W \lambda_i + \alpha) = \frac{d}{d\alpha} \sum_{i=1}^W \ln(\lambda_i + \alpha) = \sum_{i=1}^W \frac{1}{\lambda_i + \alpha} = \text{tr}(A^{-1}) \quad (6.1.28)$$

Utilizând aproximarea, derivata relației (6.1.27) în raport cu  $\alpha$  devine:

$$-E_W^{MP} - \frac{1}{2} \sum_{i=1}^W \frac{1}{\lambda_i + \alpha} + \frac{W}{2\alpha} \quad (6.1.29)$$

Egalând realția (6.1.29) cu zero și rearanjând termenii, se obține o ecuație implicită pentru  $\alpha$ :

$$2 \cdot \alpha \cdot E_W^{MP} = W - \sum_{i=1}^W \frac{\alpha}{\lambda_i + \alpha} \quad (6.1.30)$$

Partea dreaptă a relației (6.1.30) este egală cu o valoare  $\gamma$ , definită astfel:

$$\gamma = \sum_{i=1}^W \frac{\lambda_i}{\lambda_i + \alpha} \quad (6.1.31)$$

Conform [Bishop2006]  $\gamma$  este o măsură a parametrilor *binedeterminați*, deoarece componentele sumei pentru care  $\lambda_j \gg \alpha$  au o contribuție apropiată de 1, pe când componentele pentru care  $0 \ll \lambda_j \ll 1$  au o contribuție apropiată de 0.

Al doilea pas în optimizare logaritmului *Evidenței* față de  $\beta$ , în relația (6.1.27) se consideră  $\mu_j$  valoarea proprie a matricei  $\nabla \nabla E_D$ . Cum  $H = \beta \cdot \nabla \nabla E_D$ , rezultă că  $\lambda_j = \beta \cdot \mu_j$ , rezultând astfel relația:

$$\frac{d\lambda_j}{d\beta} = \mu_j = \frac{\lambda_j}{\beta} \quad (6.1.32)$$

Prin urmare:

$$\frac{d}{d\beta} \ln|A| = \frac{d}{d\beta} \sum_{i=1}^W \ln(\lambda_i + \alpha) = \frac{1}{\beta} \cdot \sum_{i=1}^W \frac{\lambda_i}{\lambda_i + \alpha} \quad (6.1.33)$$

Derivând similar cu ceea ce a condus la relația (6.1.30), rezultă că valoarea optimă a lui  $\beta$  este dată de relația:

$$2 \cdot \beta \cdot E_D^{MP} = N - \sum_{i=1}^W \frac{\lambda_i}{\lambda_i + \alpha} = N - \gamma \quad (6.1.34)$$

Pentru a aplica procedura *Evidență*, relațiile (6.1.30) și (6.1.34) trebuie convertite din condiții satisfăcute de  $\alpha$  și  $\beta$  optimi în metode practice de estimare.

Algoritm de mai jos descrie pașii de aplicare a procedurii *Evidență*:

- Se aleg hiperparametrii  $\alpha$  și  $\beta$  și se inițializează ponderile în RNA.
- Se antrenează RNA cu un algoritm de optimizare potrivit pentru a minimiza funcția de eroare cu regularizare  $S(w)$ .
- Când RNA este antrenată și a atins un minim local, se poate utiliza aproximarea gaussiană pentru a calcula *Evidența* pentru hiperparametri. Aceștia pot fi re-estimați cu ajutorul următoarelor relații, derivate din relațiile (6.1.30) și (6.1.34):

$$\alpha^{nou} = \frac{\gamma}{2 \cdot E_W} \quad (6.1.35)$$

$$\beta^{nou} = \frac{N - \gamma}{2 \cdot E_D} \quad (6.1.36)$$

Aceste relații de re-estimare pot fi aplicare și iterativ. Deoarece ele utilizează valorile proprii ale matricei hessiene  $A$ , timpul de calcul este destul de mare.

- Se repetă pașii 2 și 3 până la convergență. Convergența procedurii de re-estimare a hiperparametrilor se obține atunci când eroarea regularizată nu depășește jumătate din dimensiunea vectorului de intrare  $x$  (conform paragrafului 2.3.4).

### 6.1.6. Predicția pentru regresie și barele de eroare

Odată ce RNA a fost antrenată pentru a găsi cea mai probabilă pondere  $w_{MP}$  și au fost estimați hiperparametrii  $\alpha$  și  $\beta$ , se poate realiza predicția în RNA. Utilizând o aproximare gaussiană a posteriorului ponderilor dat de relația (6.1.22), se poate calcula distribuția valorilor de ieșire pentru o intrare dată  $x$ :

$$p(t|x, D) = \int p(t|x, w) \cdot p(w|D) \cdot dw \quad (6.1.37)$$

Distribuția  $p(t|x, w)$  este pur și simplu modelul pentru distribuția zgomotului asupra ieșirii cunoscute pentru un vector pondere  $w$ .

Integrala care trebuie calculată pe baza sumei pătratelor funcției de eroare (corespunzător unui model gaussian cu zgomot) și a aproximării gaussiene asupra distribuției posterioare a ponderilor are forma:

$$p(t|x, D) \propto \int \exp\left[-\frac{\beta}{2} \cdot [y(x; w) - t]^2\right] \cdot \exp\left(-\frac{1}{2} \cdot \Delta w^T \cdot A \Delta w\right) \cdot dw \quad (6.1.38)$$

Pentru funcții neliniare  $y(w; w)$  relația (6.1.37) nu este calculabilă. Cu toate acestea, dacă setul de date de antrenare este destul de mare, posteriorul ponderilor va avea un minim local cu vârful ascuțit în jurul valorilor cele mai des întâlnite (modul / dominanță) și astfel se va putea aproxima ieșirea  $y$  a RNA cu o liniarizare în jurul valorii lui  $w_{MP}$ . În aceste condiții se obține:

$$y(x; w) = y(x; w_{MP}) + g^T \cdot \Delta w \quad (6.1.39)$$

unde  $g$  reprezintă gradientul lui  $y$  dat de ponderile  $w$  și calculat în  $w_{MP}$ . În aceste condiții integrala poate fi calculată, pentru a obține distribuția gaussiană cu media  $y(x; w_{MP})$ , predicția standard pentru ponderile cele mai probabile și varianța:

$$\sigma^2 = \frac{1}{\beta} + g^T \cdot A^{-1} \cdot g \quad (6.1.40)$$

Se observă că varianța are două componente: prima este dată de modelul de zgomot de ieșire  $\frac{1}{\beta}$ , iar a doua este generată de distribuția posterioară a ponderilor RNA.

Această distribuție predictivă permite introducerea barelor de eroare în cadrul ieșirii RNA (în locul unei singure ieșiri). Mărimea barei de eroare variază aproximativ cu inversa densității datelor, astfel că în regiunea cu date de antrenare având densitate mare bara de eroare este scăzută și invers.

## 6.2. Metoda de optimizare – Gradient Conjugat Scalat

Soluționarea problemelor de optimizare neliniară, de tipul celei discutate în subcapitolul precedent, se realizează, de regulă, cu metode care utilizează doar derivatele de ordinul 1 ale funcției pentru care se caută minimumul (gradient clasic, gradient conjugat) sau metode care utilizează și derivatele de ordinul 2 (Newton clasic, quasi Newton) [Kilyeni2015].

Metoda gradientului conjugat scalat (SCG – Scaled Conjugate Gradient) face parte din categoria metodelor de gradient conjugat.

Versiunea clasică a metodei de gradient are la bază faptul că vectorul gradient  $g$  indică direcția celei mai mari creșteri a valorii lui  $f(x)$ . Geometric, gradientul reprezintă vectorul ortogonal la conturul lui  $f(x)$ , care trece printr-un anumit punct  $x$ . Cea mai accentuată descreștere (se caută minimumul) a valorii lui  $f(x)$  este dată de  $-g$ .

În aceste condiții algoritmul metodei este următorul [Kilyeni2015]:

- a) se inițializează valoarea lui  $x$  cu  $x_0$ , ales pe baza experienței sau a informațiilor legate de natura problemei;
- b) la o iterație oarecare  $j$ ,  $j = 1, 2, \dots$ , se calculează valoarea lui  $f$  în punctul curent

$$f_j = f(x_j) \quad (6.2.1)$$

și direcția de deplasare  $d_j$ :

$$d_j = -g_j \quad (6.2.2)$$

unde  $g_j$  reprezintă valoarea curentă a gradientului

- c) la aceeași iterație  $j$  se calculează noul punct  $x_{j+1}$ :

$$x_{j+1} = x_j + \alpha_j \cdot d_j \quad (6.2.3)$$

unde scalarul  $\alpha_j$ , care se determină de regulă prin interpolare parabolică [Kilyeni 2015], indică mărimea deplasării după direcția  $d_j$ :

$$\alpha_j = \frac{h}{2} \cdot \frac{3 \cdot f^0 - 4 \cdot f^1 + f^2}{f^0 - 2 \cdot f^1 + f^2} \quad (6.2.4)$$

unde scalarul  $h$  reprezintă pasul de căutare,  $f^0, f^1, f^2$  sunt valorile funcției  $f$  în punctele  $x^0 = x_j$ ,  $x^1 = x_j + h \cdot d_j$ ,  $x^2 = x_j + 2 \cdot h \cdot d_j$ ;

- d) calculul se consideră terminat când modulul gradientului devine practic nul (pragul de eroare admis fiind  $\varepsilon$ ):

$$\|g_j\| < \varepsilon \quad (6.2.5)$$

Principalul dezavantaj al versiunii clasice a metodei de gradient este legat de ortogonalitatea direcțiilor de deplasare la două iterații succesive, având ca efect o mișcare în zig-zag către minim. Rezultă o convergență relativ lentă în apropierea minimului ("ciclare" în jurul minimului).

Metoda gradientelor conjugate elimină dezavantajul menționat mai sus [Kilyeni 2015].

Algoritmul metodei este similar cu cel al gradientului simplu, singura deosebire fiind legată de determinarea direcției de deplasare, care acum este de forma:

$$d_j = -g_j + \beta_j \cdot d_{j-1} \quad (6.2.6)$$

unde coeficientul  $\beta_j$  ține cont de "istoria" anterioară ("mixează" în direcția de la pasul curent o corecție ponderată funcție de direcția de deplasare de la pasul anterior), având expresia:

$$\beta_j = \frac{g_j \cdot g_j^T}{g_{j-1} \cdot g_{j-1}^T} \quad (6.2.7)$$

Așa cum s-a văzut, la ambele versiuni ale metodei de gradient, prezentate anterior, la fiecare pas trebuie determinată valoarea scalarului  $\alpha_j$ , care indică mărimea deplasării după direcția  $d_j$ . Metoda gradientului conjugat scalat [Moller1993] elimină acest dezavantaj. Ea oferă o modalitate de a alege direcții de căutare conjugate fără a efectua căutarea după direcția  $d_j$  și fără a calcula matricea hessiană  $H$  (matricea derivatelor de ordinul 2 ale funcției  $f$ ).

În ipoteza utilizării matricei hessiene (metode de tip Newton, care fac uz și de derivatele de ordinul 2),  $\alpha_j$  se poate calcula în maniera:

$$\alpha_j = \frac{g_j^T \cdot d_j}{d_j^T \cdot H \cdot d_j} \quad (6.2.8)$$

Pentru reducerea timpului de calcul și evitarea căutării după direcția  $d_j$ , se propune introducerea unei aproximări a lui  $H \cdot d_j$ , bazată pe o formulă diferențială finită. În acest scop se consideră  $\sigma_0$  o cantitate mică pozitivă, care se scrie sub forma:

$$\sigma = \frac{\sigma_0}{\|d_j\|} \quad (6.2.9)$$

Dezvoltând în serie Taylor și reținând termenii până la cel cu derivata de ordinul 1 (inclusiv), se obține:

$$\nabla f(x_j + \sigma d_j) \approx \nabla f(x_j) + \sigma \cdot H \cdot d_j \quad (6.2.10)$$

Rezultă:

$$H \cdot d_j \approx \frac{\nabla f(x_j + \sigma d_j) - \nabla f(x_j)}{\sigma} \quad (6.2.11)$$

Se definește:

$$\theta_j = d_j^T \cdot \left[ \frac{\nabla f(x_j + \sigma d_j) - \nabla f(x_j)}{\sigma} \right] \approx d_j^T \cdot H \cdot d_j \quad (6.2.12)$$

Dacă funcția  $f$  nu are formă pătratică, atunci  $H$  s-ar putea să nu fie pozitiv definită și valoarea funcției  $f$  ar putea să crească (în loc să scadă). Acest lucru poate fi prevenit prin adăugare la matricea hessiană  $H$  a unui termen multiplicativ între  $\theta_j$  și matricea unitate:  $H + \theta_j \cdot I$ . Astfel se obține forma actualizată:

$$\alpha_j = \frac{g_j^T \cdot d_j}{d_j^T \cdot H \cdot d_j + \theta_j \cdot \|d_j\|^2} \quad (6.2.13)$$

Dacă  $\theta_j$  are o valoare mare atunci pasul  $\alpha_j$  este mic. Acest fapt reprezintă abordarea unui *model de regiune de încredere*, deoarece modelul (pentru funcție) este de încredere într-o regiune mică în jurul punctului de căutare. O altă modalitate o reprezintă restricționarea mărimii pasului pentru a nu părăsi regiunea de validare a unei dezvoltări în serie Taylor.

Se știe că pentru a obține un minim al funcției  $f$ , matricea hessiană trebuie să fie pozitiv definită (sau cel puțin  $d_j^T \cdot H \cdot d_j > 0$ ).

Se introduce notația:

$$\delta_j = d_j^T \cdot H \cdot d_j + \theta_j \cdot \|d_j\|^2 \quad (6.2.14)$$

Dacă  $\delta_j < 0$  atunci sigur  $d_j^T \cdot H \cdot d_j < 0$  și trebuie mărit  $\theta_j$ . Algoritmul original a lui Moller [Moller1993] utilizează:

$$\bar{\theta}_j = 2 \cdot \left( \theta_j - \frac{\delta_j}{\|d_j\|^2} \right) \quad (6.2.15)$$

Apoi se fac setările:

$$\bar{\delta}_j = \delta_j + (\bar{\theta}_j - \theta_j) \cdot \|d_j\|^2 = -\delta_j + \bar{\theta}_j \cdot \|d_j\|^2 = -d_j^T \cdot H \cdot d_j > 0 \quad (6.2.16)$$

Dacă se consideră și condiția ca funcția să fie pătratică, se calculează:

$$\Delta_j = \frac{f(x_j) - f(x_j + \alpha_j d_j)}{f(x_j) - f_Q(x_j + \alpha_j d_j)} \quad (6.2.17)$$

unde  $f_Q$  reprezintă aproximarea pătratică locală a lui  $f$  de-a lungul direcției  $d_j$ :

$$f_Q(x_j + \alpha_j d_j) = f(x_j) + \alpha_j \cdot d_j^T \cdot g_j + \frac{\alpha_j^2}{2} \cdot d_j^T \cdot H \cdot d_j \quad (6.2.18)$$

Dacă  $\Delta_j \approx 1$ , aceasta este o aproximare bună și  $\theta_j$  poate să descrească. Dacă  $\Delta_j$  este mic, atunci  $\theta_j$  trebuie să crească. Simplificând relația (6.2.17) rezultă:

$$\Delta_j = \frac{2 \cdot [f(x_j) - f(x_j + \alpha_j \cdot d_j)]}{\alpha_j \cdot d_j^T \cdot d_j} \quad (6.2.19)$$

Relația (6.2.19) poate fi aplicată utilizând numai gradientul, fără a apela la derivate de ordin superior. Definirea lui  $\Delta_j$  "a fi mic" este în esență euristică. Valori ale lui  $\Delta_j$  care au condus la rezultate bune sunt următoarele:

$$\begin{cases} \Delta_j > 0.75 & \theta_{j+1} = \theta_j / 2 \\ 0.25 < \Delta_j < 0.75 & \theta_{j+1} = \theta_j \\ \Delta_j < 0.25 & \theta_{j+1} = 4 \cdot \theta_j \\ \Delta_j < 0 & \theta_{j+1} = 4 \cdot \theta_j \text{ si stagneaza} \end{cases} \quad (6.2.20)$$

Cu toate că valorile 0.25 și 0.75 sunt arbitrare, algoritmul nu este prea sensibil la schimbarea lor.

### 6.3. Instrumentul software *RNA bayesiană*

#### 6.3.1. Considerații preliminare

Instrumentul soft care implementează toate modelele matematice prezentate în acest capitol, a fost conceput în mediul Matlab. Se utilizează din plin toate facilitățile (de interfață și portabilitate) specifice sistemelor de operare și mediilor informatice actuale. Matlab (Matrix Laboratory) reprezintă un mediu de dezvoltare produs de firma The MathWorks, Inc., dedicat calculului numeric și reprezentărilor grafice în știință și inginerie [Matlab].

Realizat structural sub forma unui nucleu de bază, cu interpretor propriu, Matlab este de asemenea însoțit de așa numitele toolbox-uri (instrumente de lucru cu structură deschisă). În implementarea aplicației realizate în cadrul tezei s-a folosit toolbox-ul Netlab, conceput de Ian Nabney [Nabney2002], pentru a oferi instrumentele centrale necesare pentru simularea algoritmilor specifici aplicațiilor care utilizează rețelelor neuronale artificiale.

#### 6.3.2. Funcțiile Netlab utilizate

Așa cum s-a specificat, instrumentul software *RNA bayesiană* realizat în cadrul tezei de doctorat utilizează o serie de funcții din toolbox-ul Netlab al mediului Matlab [Nabney2002].

În tabelul 6.3.1 se prezintă principalele funcții Netlab folosite, în ordinea "cronologică" a utilizării lor în cadrul aplicației.

Tabelul 6.3.1. Funcțiile Netlab utilizate în instrumentul soft RNA bayesiană

Funcția	Sintaxa	Rezultat returnat	Pas
<i>mlpprior.m</i>	<i>prior = mlpprior(nin, nhidden, nout, aw1, ab1, aw2, ab2)</i>	creare prior gaussian pentru RNA	3.1
<i>mlp.m</i>	<i>net = mlp(nin, nhidden, nout, func, prior, beta)</i>	creare RNA de tip feedforward cu 2 straturi	3.2
<i>mlpinit.m</i>	<i>net = mlpinit(net, prior)</i>	inițializare ponderi în RNA	3.3
<i>netopt.m</i>	<i>[net, options, varargout] = netopt(net, options, x, t, alg)</i>	optimizare ponderi în RNA	5
<i>scg.m</i>	<i>[x, options, flog, pointlog, scalelog] = scg(f, x, options, gradf, varargin)</i>	optimizare gradient conjugat scalat	5.1
<i>mlperr.m</i>	<i>[e, edata, eprior] = mlperr(net, x, t)</i>	evaluare funcție de eroare în RNA	5.1
<i>errbayes.m</i>	<i>[e, edata, eprior] = errbayes(net, edata)</i>	evaluare funcție eroare bayesiană în RNA.	5.1
<i>mlpgrad.m</i>	<i>[g, gdata, gprior] = mlpgrad(net, x, t)</i>	evaluare gradient funcție de eroare în RNA	5.1

Funcția	Sintaxa	Rezultat returnat	Pas
<i>gbayes.m</i>	$[g, gdata, gprior] = gbayes(net, gdata)$	evaluare gradient funcție de eroare bayesiană în RNA	5.1
<i>mlpfwd.m</i>	$[y, z, a] = mlpfwd(net, x)$	propagare de tip forward în RNA	5.1
<i>evidence.m</i>	$[net, gamma, logev] = evidence(net, x, t, num)$	re-estimare hiperparametri utilizând aproximarea <i>Evidență</i>	5.2
<i>mlpevfwd.m</i>	$[y, extra, invhess] = mlpevfwd(net, x, t, x\_test, invhess)$	propagare de tip forward cu <i>Evidență</i> în RNA	6

În cele ce urmează se prezintă o descriere succintă pentru fiecare funcție în parte.

#### □ **mlpprior.m**

*prior = mlpprior(nin, nhidden, nout, aw1, ab1, aw2, ab2)*

Funcția creează un prior gaussian pentru RNA. Argumentele funcției sunt numărul de neuroni din stratul de intrare, cel de ieșire și cele ascunse, coeficienții de regularizare a ponderilor, respectiv a pragurilor de activare. Funcția returnează o structură *prior* cu două câmpuri, *prior.valoare* și *prior.grup*, care specifică o distribuție gaussiană prior a ponderilor într-o RNA (de tip MLP feedforward cu 2 straturi). Sunt posibile două cazuri. Primul caz, în care coeficienții de regularizare ai ponderilor sunt scalari și ei reprezintă coeficienții pentru cele patru grupuri de parametri corespunzători ponderilor din primul strat, pragurilor de activare din primul start, respectiv ponderilor din stratul doi și pragurilor de activare din stratul 2. În acest caz *prior.valoare* reprezintă vectorul coloană având lungimea egală cu 4 și conținând parametrii; *prior.grup* este o matrice care specifică apartenența ponderilor în grup (1 – ponderea aparține grupului, 0 – ponderea nu aparține grupului). În cazul al doilea argumentul *aw1* este vector și acest prior este apropiat tehnicii ARD (Automatic Relevance Determination).

#### □ **mlpinit.m**

*net = mlpinit(net, prior)*

Funcția inițializează ponderile RNA (de tip MLP feedforward cu 2 straturi). Argumentele funcției sunt structura RNA, respectiv priorul. Funcția ia în considerare structura rețelei și setează ponderile, respectiv pragurile de activare, prin eșantionare dintr-o distribuție gaussiană. În cazul în care argumentul *prior* este un scalar atunci toți parametrii (atât ponderile cât și pragurile de activare) sunt eșantionate dintr-o distribuție izotropă gaussiană, cu inversul varianței egal cu priorul. Dacă argumentul *prior* este o structură de date (asemănătoare cu cea generată de funcția *mlpprior*) atunci parametrii (ponderi, praguri de activare) sunt eșantionați dintr-o distribuție izotropă gaussiană multiplă, în concordanță cu gruparea lor (definită de câmpul *grup*), având varianța corespunzătoare definită de câmpul *valoare*.

#### □ **mlp.m**

*net = mlp(nin, nhidden, nout, func, prior, beta)*

Funcția creează o RNA de tip feedforward cu 2 straturi. Argumentele funcției sunt numărul de neuroni din stratul de intrare, cele ascunse respectiv cel de ieșire, funcția de activare și hiperparametrii RNA (*prior*, *beta*). Funcția returnează structura RNA. Ponderile sunt extrase dintr-o distribuție gaussiană izotropă cu media zero și varianță unitară. Este utilizată funcția Matlab *randn()* pentru a genera varianța scalată din numărul de neuroni de pe stratul ascuns / ieșire (după caz):

- $w1 = randn(nin, nhidden)/sqrt(nin + 1)$ ;
- $b1 = randn(1, nhidden)/sqrt(nin + 1)$ ;
- $w2 = randn(nhidden, nout)/sqrt(nhidden + 1)$ ;
- $b2 = randn(1, nout)/sqrt(nhidden + 1)$ .

Funcția de activare din stratul ascuns este *tanh*. Prior este fie un scalar fie o structură de date (asemănătoare cu cea generată de funcția *mplprior*) și generează câmpul *net.prior*, iar *beta* este hiperparametrul dat de inversul varianței zgomotului și generează câmpul *net.beta*.

□ **netopt.m**

$[net, options, varargout] = netopt(net, options, x, t, alg)$

Funcția optimizează ponderile într-o RNA. Argumentele funcției sunt structura RNA, vectorul *options* ai parametrilor care determină comportamentul algoritmului de optimizare, matricea *x* a vectorilor de intrare, matricea *t* a vectorilor ieșire cunoscută. Funcția returnează atât RNA antrenată cât și vectorul *options* actualizat. *alg* determină ce algoritm de optimizare (*conjgrad*, *quasinew*, *SCG* etc.) sau algoritm de tip Monte Carlo (cum a fi HMC – Monte Carlo Hibrid) este folosit.

Funcția facilitează antrenarea RNA utilizând fie optimizare, fie eșantionare (dintr-o distribuție posterioară a parametrilor utilizând algoritmi de eșantionare de tip Lanțuri Markov Monte Carlo). Ea poate fi utilizată împreună cu orice funcție care caută în spațiul parametrilor utilizând funcție de eroare și de gradient.

□ **scg.m**

$[x, options, flog, pointlog, scalelog] = scg(f, x, options, gradf, varargin)$

Funcția optimizează gradientul conjugat scalat. Argumentele sunt funcția obiectiv, *x* – vector linie, vectorul opțiuni ai parametrilor care determină comportamentul algoritmului de optimizare, gradientul funcției obiectiv. Funcția utilizează un algoritm de tip gradient conjugat scalat pentru a determina minimumul local al unei funcții obiectiv  $f(x)$  a cărui gradient este dat de  $gradf(x)$ . *x* reprezintă vectorul linie și *f* returnează o valoare scalară.

Punctul în care *f* atinge un minim local este returnat în *x*, iar valoarea funcției în acel punct este returnată în vectorul *options*, în componenta *options(8)*. Componenta *options(1)* se poate seta astfel: 0 pentru a fi afișate doar mesaje de avertizare, 1 pentru a se afișa valori de eroare, -1 pentru a inhiba afișarea. *Options(2)* și *options(3)* reprezintă eroarea maximă admisă pentru terminarea calculelor (pentru ponderi și pentru funcția obiectiv). *Options(14)* este numărul maxim admisibil de iterații (valoarea implicită – 100).

□ **mlperr.m**

$[e, edata, eprior] = mlperr(net, x, t)$

Evaluează funcția de eroare a RNA. Argumentele funcției sunt structura RNA, matricea *x* a vectorilor de intrare, matricea *t* a vectorilor de ieșire (cunoscuți). Se returnează funcția de eroare *e*. Alegerea funcției de eroare corespunde cu funcția de activare a neuronilor din stratul de ieșire. Fiecare linie din *x* corespunde cu un vector de intrare și fiecare linie din *t* corespunde cu un vector de ieșire. Funcția returnează și componentele erorii corespunzătoare datelor, respectiv priorului, asumând un prior gaussian cu media zero și inversul varianței ponderilor egală cu hiperparametrul alpha și hiperparametrul beta, ambii preluați din structura RNA – *net*.

□ **errbayes.m**

$[e, edata, eprior] = errbayes(net, edata)$

Evaluează funcția erorii bayesiene a RNA. Argumentele funcției sunt structura RNA, împreună cu componenta care contribuie asupra erorii pentru un set de intrări și ieșiri cunoscute. Funcția returnează eroarea regularizată utilizând orice prior gaussian cu media zero asupra ponderilor definite în structura RNA – *net*. În plus sunt returnate componentele erorii legate de date respectiv prior.



□ **mlpgrad.m**

$[g, gdata, gprior] = mlpgrad(net, x, t)$

Evaluează gradientul funcției de eroare RNA. Argumentele sunt structura RNA, matricea  $x$  a vectorilor de intrare, matricea  $t$  a vectorilor de ieșire (cunoscuți). Se returnează gradientului  $g$  al funcției de eroare în raport cu ponderile RNA. Alegerea funcției de eroare corespunde cu funcția de activare a neuronilor din startul de ieșire. Fiecare linie din  $x$ , respectiv  $t$ , corespunde unui vector de intrare, respectiv de ieșire. În plus este returnată contribuția datelor și a priorului asupra gradientului. În cazul în care priorul este format din mai multe grupuri,  $gprior$  este o matrice cu câte o linie pentru fiecare grup și câte o coloană pentru fiecare parametru pondere.

□ **gbayes.m**

$[g, gdata, gprior] = gbayes(net, gdata)$

Evaluează gradientul funcției erorii bayesiene a RNA. Argumentele funcției sunt structura RNA, împreună cu componenta care are influență asupra gradientului funcției de eroare pentru un set de intrări și ieșiri cunoscute. Se returnează gradientul funcției de eroare regularizate utilizând orice prior gaussian cu media zero asupra ponderilor definite în structura RNA –  $net$ . Sunt returnate și componentele gradientului funcției de eroare legate de date, respectiv de prior.

□ **mlpfwd.m**

$[y, z, a] = mlpfwd(net, x)$

Realizează propagarea de tip forward în RNA. Argumentele funcției sunt structura RNA împreună cu matricea  $x$  a vectorilor de intrare. Se propagă înainte intrările prin RNA și este generată o matrice  $y$  de vectori de ieșire. Fiecare linie din  $x$  corespunde unui vector de intrare și fiecare linie din  $y$  unui vector de ieșire. Mai sunt returnate: matricea  $z$  corespunzătoare activărilor neuronilor de pe startul ascuns, în care fiecare linie corespunde unui singur model, respectiv matricea  $a$ , care conține intrările însumate pentru fiecare neuron de ieșire, în care fiecare linie corespunde unui singur model.

□ **evidence.m**

$[net, gamma, logev] = evidence(net, x, t, num)$

Funcția re-estimează hiperparametrii utilizând aproximarea *Evidență* prin aplicarea formulei de re-estimare bayesiană pentru o anumită iterație. Argumentele de intrare ale funcției sunt structura RNA, matricea  $x$  a vectorilor de intrare, matricea  $t$  a vectorilor ieșirii cunoscute și numărul de iterații. Hiperparametrul  $alpha$  poate fi un scalar asociat cu un prior izotropnic asupra ponderilor sau un vector în care fiecare componentă este asociată cu un grup de ponderi (cazul utilizării  $mlpprior$ ). Inițial valorile hiperparametrilor pentru re-estimările iterative sunt luate din structura RNA, care le are ca și argumente de intrare, în timp ce structura RNA returnată conține valorile re-estimate ale hiperparametrilor. Funcția permite aplicarea formulei de re-estimare pentru un anumit număr de iterații, în care valorile re-estimate pentru hiperparametrii în fiecare iterație sunt folosiți pentru re-evaluarea matricei hessiene a iterației următoare. Este returnată valoarea  $gamma$  care reprezintă numărul de parametri bine-determinați și valoarea  $logev$ , care reprezintă logaritmul *Evidență*.

□ **mlpevfwd.m**

$[y, extra, invhess] = mlpevfwd(net, x, t, x\_test, invhess)$

Realizează propagarea de tip forward cu *Evidență* în RNA. Argumentele funcției sunt structura RNA, intrarea  $x$ , ieșirea cunoscută  $t$  a datelor de antrenare, datele de

testare și inversa matricei hessiene (argument opțional). Este returnată valoarea lui  $y$ , ce conține rezultatul propagării de tip forward în RNA și matricea *extra*, care conține barele de eroare (varianța), respectiv (în cazul argumentului opțional) inversa matricei hessiene calculată asupra intrărilor datelor de antrenare și a ieșirii cunoscute.

### 6.3.3. Implementarea modelului matematic în instrumentul soft

Implementarea modelului matematic în instrumentul soft s-a realizat prin parcurgerea următorilor pași:

1. Generarea variabilei de intrare, vectorul  $x$ , și a variabilei de ieșire (cunoscută), matricea  $t$ ;
2. Setarea parametrilor RNA;
3. Crearea priorului gaussian, crearea RNA cu prior și zgomot (RNA bayesiană) și inițializarea ponderilor în RNA bayesiană și ;
4. Setarea opțiunilor pentru algoritmul de optimizare *Gradient Conjugat Scalat*;
5. Antrenarea RNA bayesiană cu algoritmul de optimizare și re-estimarea hiperparametrilor  $\alpha$  și  $\beta$ ;
6. Realizarea prognozei și reprezentarea grafică a datelor de antrenare, a ieșirii reale a RNA bayesiană și a barelor de eroare.

Se menționează faptul că în cazul prognozei ansamblului curbei de sarcină ieșirea este o matrice, iar în cazul prognozei orare / lunare a curbei de sarcină ieșirea cunoscută  $t$  este un vector.

În cele ce urmează se prezintă în detaliu cei 6 pași ai implementării modelului matematic în instrumentul soft.

#### □ Pasul 1

Aplicația realizează citirea variabilei de intrare, vectorul  $x$ , și variabila de ieșire cunoscută, matricea  $t$ , la care se adaugă un zgomot gaussian, cu ajutorul funcției Matlab *randn()*. Cu aceste variabile va fi antrenată o RNA de tip MLP.

#### □ Pasul 2

Utilizatorul are posibilitatea de a introduce valoarea zgomotului modelului. În cadrul aplicației, numărul de neuroni de pe stratul ascuns poate fi de asemenea stabilit de către utilizator. În cadrul modelului sunt introduși cei doi hiperparametri,  $\alpha$  și  $\beta$ . Hiperparametrul  $\alpha$  poate fi un scalar sau un vector de forma  $\alpha = [\alpha_{w_1}, \alpha_{w_2}, \alpha_{b_1}, \alpha_{b_2}]$ . El reprezintă varianța inversă asupra ponderilor  $w$  în cazul scalar, respectiv varianțele inverse asupra seturilor de ponderi  $w_1, w_2$  și de praguri de activare  $b_1, b_2$ . Pentru cazul  $\alpha$  scalar:

$$\alpha_w = \frac{1}{\text{var}(w)} \quad (6.3.1)$$

iar pentru cazul  $\alpha$  vector:

$$\alpha_{w_1} = \frac{1}{\text{var}(w_1)}, \quad \alpha_{w_2} = \frac{1}{\text{var}(w_2)}, \quad \alpha_{b_1} = \frac{1}{\text{var}(b_1)}, \quad \alpha_{b_2} = \frac{1}{\text{var}(b_2)} \quad (6.3.2)$$

Hiperparametrul  $\beta$  reprezintă inversul varianței zgomotului din ieșirea cunoscută  $t$ :

$$\beta = \frac{1}{\text{var}(\text{noise})} \quad (6.3.3)$$

Inițial hiperparametrii sunt fixați. Pe baza experienței, valoarea de start a hiperparametrului  $\alpha$  se alege relativ mică pentru ca modelul să aibă suficientă flexibilitate în ajustarea datelor.

### □ Pasul 3

#### 3.1. Crearea priorului gaussian

În procesul de creare a priorului ponderilor, se pornește cu un set de coeficienți de regularizare a ponderilor  $\alpha_{w_1}$  și  $\alpha_{w_2}$ , respectiv a pragurilor de activare  $\alpha_{b_1}$  și  $\alpha_{b_2}$ , introduși de către utilizator. Aceste valori sunt în continuare procesate în aplicație, împreună cu numărul de neuroni din stratul de intrare, cel ascuns și cel de ieșire. Este creată o structură cu două câmpuri (*grup, valoare*) specifică unei distribuții gaussiene asupra ponderilor RNA  $p(w|\alpha_w)$  sau  $p(w|\alpha_{w_1}, \alpha_{w_2}, \alpha_{b_1}, \alpha_{b_2})$ , numită în continuare *prior*.

#### 3.2. Crearea RNA cu prior și zgomot (RNA bayesiană)

În etapa de creare a RNA bayesiană este generată structura rețelei, fiind luate în considerare: numărul de neuroni din stratul de intrare, din cel ascuns și din cel de ieșire (furnizate de utilizator). Se preia și structura ponderilor din *priorul* creat anterior și hiperparametrul  $\beta$  care reprezintă inversul varianței zgomotului. Ponderile sunt extrase dintr-o distribuție gaussiană izotropă cu media zero și varianța unitară. Este utilizată funcția Matlab *randn()* pentru a genera varianța scalată din numărul de neuroni de pe stratul ascuns sau cel de ieșire, după caz. Funcția de activare, din stratul ascuns, utilizată în cadrul RNA bayesiană este tangenta hiperbolică.

#### 3.3. Inițializarea ponderilor în RNA bayesiană

Următoarea etapă este cea de inițializare a ponderilor RNA bayesiană. Se preia structura RNA bayesiană (care la rândul ei conține structura priorului) și se inițializează toți parametrii RNA (atât ponderile cât și pragurile de activare) prin eșantionare dintr-o distribuția gaussiană multiplă în concordanță cu apartenența la grupuri, cu varianțele date de inversii coeficienților de regularizare:

$$\sigma = \frac{1}{\sqrt{\alpha_w}} \quad \text{sau} \quad \sigma = \frac{1}{\sqrt{[\alpha_{w_1}, \alpha_{w_2}, \alpha_{b_1}, \alpha_{b_2}]}} \quad (6.3.4)$$

$$w = \sigma \cdot \text{randn}(1, (n_{intrare} + 1) \cdot n_{ascuns} + (n_{ascuns} + 1) \cdot n_{iesire}) \quad (6.3.5)$$

unde:

- *nintrare* reprezintă numărul neuronilor de pe stratul de intrare a RNA bayesiană;
- *nascuns* reprezintă numărul neuronilor de pe stratul ascuns a RNA bayesiană;
- *nieșire* reprezintă numărul neuronilor de pe stratul de ieșire a RNA bayesiană.

La sfârșit se realizează separarea parametrilor (ponderile de pragurile de activare). Acum RNA bayesiană este pregătită pentru etapa de antrenare.

### □ Pasul 4

Deoarece antrenarea RNA bayesiană se face cu ajutorul algoritmului de optimizare *Gradient Conjugat Scalat*, în prealabil antrenării avem nevoie de setarea parametrilor care se utilizează în cadrul algoritmului de optimizare. Utilizatorul are posibilitatea setării unor parametri care fac parte din vectorul de opțiuni:

- eroarea maximă absolută pentru ponderi;
- eroarea maximă admisă pentru funcția obiectiv;
- numărul de cicluri de antrenare (utilizat în algoritmul de optimizare *Gradient Conjugat Scalat*).

#### □ Pasul 5

Utilizatorul are posibilitatea de a alege numărul de iterații în care RNA bayesiană va fi antrenată respectiv hiperparametrii  $\alpha = [\alpha_{w_1}, \alpha_{w_2}, \alpha_{b_1}, \alpha_{b_2}]$  și  $\beta$  vor fi re-estimați. În cazul în care ponderile nu se introduc sub formă de prior gaussian, parametrul  $\alpha$  va fi de tip scalar  $\alpha = \alpha_w$ .

Procedeele următorul: hiperparametrii sunt păstrați ficși, iar ponderile sunt optimizate cu algoritmul de optimizare *Gradient Conjugat Scalat*. După terminarea algoritmului (satisfacere uneia dintre condițiile de convergență de la pasul 5.1), hiperparametrii  $\alpha$  și  $\beta$  sunt re-estimați. Procesul de optimizare a ponderilor cu parametrii ficși și re-estimarea hiperparametrilor se repetă de un număr egal cu numărul de iterații ai buclei externe. La rularea RNA bayesiană pentru ansamblul curbei de sarcină s-a lucrat cu o singură iterație.

În cele ce urmează procedeul este descris relativ mai în detaliu.

##### 5.1. Antrenarea RNA bayesiană cu algoritmul de optimizare

Ieșirea RNA bayesiană este liniară, iar antrenarea se face pentru a minimiza funcția definită prin suma pătratelor erorilor cu regularizator izotrop Gaussian:

$$S(w) = \beta \cdot E_D(w) + \alpha \cdot E_W(w) = \frac{\beta}{2} \cdot \sum_{i=1}^N [y(x_i; w) - t_i]^2 + \frac{\alpha}{2} \cdot \sum_{i=1}^m w_i^2 \quad (6.3.6)$$

utilizând algoritmul de optimizare *Gradient Conjugat Scalat*.

Algoritmul de optimizare al gradientului este utilizat pentru a găsi un minim local al funcției obiectiv  $f(x)$  al cărui gradient este dat de  $gradf(x)$ .  $x$  reprezintă un vector linie, iar  $f$  returnează o valoare scalară. Punctul în care  $f$  are un minim local este returnat ca și  $x$ . Valoarea funcției în acel punct este returnată într-o componentă a vectorului opțiuni (*options(8)*). Preciziile ponderilor și ale funcției obiectiv, setate la pasul 4, sunt de asemenea luate în considerare în cadrul algoritmului.

În cadrul algoritmului de optimizare a gradientului se impun două condiții de terminare:

- modulul gradientului este sub valoarea erorii maxime admise (pragul de 0);
- atingerea numărului maxim de cicluri de antrenare.

În procesul de optimizare se iau în considerare: structura RNA, vectorul opțiunilor care controlează comportamentul algoritmului (ale cărui componente au fost setate la Pasul 4), variabila de intrare (vectorul  $x$ ), variabila de ieșire cunoscută (matricea  $t$ ) și algoritmul de optimizare al gradientului (descriș mai sus).

Relațiile (6.1.15) și (6.1.16) reflectă faptul că ponderile influențează atât eroarea cât și gradientul, prin componentele  $E_W$  respectiv  $G_W$ .

În RNA bayesiană are loc o *propagare de tip forward*, iar funcția de activare pentru stratul ascuns este  $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ , așa cum s-a precizat la Pasul 3.

În urma procesului de optimizare cu algoritmul *Gradient Conjugat Scalat* sunt determinate ponderile  $w_{MP}$  care minimizează  $S(w)$ . Apoi cu  $w_{MP}$  determinate sunt calculate componentele erorii,  $E_W^{MP}$  și  $E_D^{MP}$ .

### 5.2. Re-estimarea hiperparametrilor $\alpha$ și $\beta$

Când la antrenarea RNA bayesiană s-a atins un minim local, se poate aplica aproximarea gaussiană pentru a optimiza parametrii de control ai RNA bayesiană – *Cadru Evidență*. În acest proces iterativ de re-estimare (numărul de bucle interne fiind ales de către utilizator) se pornește cu valorile de start ale hiperparametrilor introduse de utilizator (Pasul 2). La sfârșitul procesului iterativ, valorile re-estimate ale hiperparametrilor  $\alpha = [\alpha_{w_1}, \alpha_{w_2}, \alpha_{b_1}, \alpha_{b_2}]$  sau  $\alpha = \alpha_w$  și  $\beta$  sunt returnate în cadrul structurii RNA.

În cadrul re-estimării se parcurg următoarele etape:

- Re-estimarea hiperparametrului  $\alpha = [\alpha_{w_1}, \alpha_{w_2}, \alpha_{b_1}, \alpha_{b_2}]$  sau  $\alpha = \alpha_w$ :

$$\alpha_{MP} = \frac{\gamma}{2 \cdot E_W^{MP}} \quad (6.3.7)$$

unde  $\gamma$  reprezintă numărul parametrilor bine determinați, conform relației (6.1.31):

$$\gamma = \sum_{k=1}^m \left( \frac{\lambda_k}{\lambda_k + \alpha} \right) \quad (6.3.8)$$

iar  $\lambda_k$  este valoarea proprie a matricei hessiene a erorii neregularizate  $E_D$ , adică  $H = \beta \nabla \nabla E_D$ ;

- Re-estimarea hiperparametrului  $\beta$ :

$$\beta_{MP} = \frac{N - \gamma}{2 \cdot E_D^{MP}} \quad (6.3.9)$$

- Evaluarea noului logaritmul *Cadrului Evidență*, conform relației (6.1.27):

$$\begin{aligned} \log p(D | \alpha, \beta) &= \\ &= -\alpha \cdot E_W^{MP} - \beta \cdot E_D^{MP} - \frac{1}{2} \cdot \log |A| + \frac{m}{2} \cdot \log(\alpha) + \frac{N}{2} \cdot \log(\beta) - \frac{N}{2} \cdot \log(2\pi) \end{aligned} \quad (6.3.10)$$

Re-estimarea hiperparametrilor se realizează atunci când  $S(w)$  a ajuns într-un minim local, adică ia valoarea  $S(w_{MP})$ . În plus convergența procedurii de re-estimare a se obține atunci când eroarea regularizată nu depășește jumătate din dimensiunea vectorului de intrare  $x$ :

$$S(w) \leq \frac{N}{2} \quad \text{când} \quad \alpha = \alpha_{MP} \quad \text{și} \quad \beta = \beta_{MP} \quad (6.3.11)$$

### □ Pasul 6

După ce s-a realizat antrenarea RNA bayesiană și re-estimarea hiperparametrilor utilizatorul introduce datele pentru care dorește realizarea prognozei.

Sunt obținute prognozele și se construiește graficul format din datele de antrenare, funcția ce reprezintă ieșirea reală a RNA bayesiană și barele de eroare.

Graficul funcției reprezentate de RNA bayesiană antrenată și testată corespunde predicției. Acesta reprezintă media distribuției de predicție. Prezentarea grafică a barelor de eroare este un element specific al tehnicii bayesiene și ea reprezintă  $\pm$  deviația standard a predicției. Se observă faptul că intervalul de confidență a barelor de eroare este mai mic în regiunea datelor cu densitate mai mare și el crește în regiunile în care densitatea datelor scade.

## 6.4. Concluzii

În cadrul acestui capitol s-a realizat prezentarea atât a modelului matematic al prognozei consumului de energie electrică și putere (inclusiv curbe de sarcină) cât și a instrumentului soft realizat pe baza modelului respectiv (care va fi utilizat în capitolul următor, care constituie principala parte aplicativă a tezei de doctorat).

Primul subcapitol a avut ca obiect tehnica bayesiană în contextul aplicației de prognoză, trecându-se în revistă principiile inferenței bayesiene, priorul RNA, calculul funcțiilor de eroare și al gradientului, procedura *evidență*, predicția și barele de eroare. Al doilea subcapitol s-a focalizat asupra tehnicii de optimizare utilizate în cadrul aplicației – metoda gradientul conjugat scalat (SCG).

Ultima parte a fost dedicată prezentării instrumentului soft realizat în cadrul tezei de doctorat, care înglobează toate modelele matematice descrise în acest capitol. Programul de calcul a fost realizat în limbajul specific Matlab, utilizând toate facilitățile (de interfață și portabilitate) sistemelor de operare și mediilor informatice actuale. În cadrul aplicației soft au fost implementate și o serie de proceduri din toolbox-ul Netlab al mediului Matlab, care constituie instrumente utile pentru simularea algoritmilor specifici rețelelor neuronale artificiale, inclusiv cele bayesiene.

În continuare se prezintă o trecere în revistă a contribuțiilor personale din acest capitol:

- utilizarea eficientă a elementelor teoretice referitoare la RNA bayesiene pentru elaborarea unui model matematic destinat prognozei consumului de energie electrică și de putere (inclusiv curbe de sarcină);
- implementarea unor tehnici de optimizare neliniară (metoda gradientului conjugat scalat) în scopul ameliorării performanțelor RNA bayesiene;
- realizarea unei aplicații soft performante, care exploatează în mod eficient posibilitățile oferite de mediul Matlab, cu multiple posibilități de utilizare în domeniul prognozei consumului de energie electrică și putere, inclusiv a curbelor de sarcină.

## 7. STUDII DE CAZ ȘI REZULTATE

Capitolul 7 constituie partea aplicativă a tezei de doctorat. Se prezintă rezultatele obținute privind prognoza puterii consumate și a curbelor de sarcină utilizând tehnici de inteligență artificială – RNA bayesiene.

Aspectele teoretice, modelele și metodele de calcul elaborate și instrumentele soft prezentate în capitolele anterioare au fost folosite pentru obținerea prognozelor menționate, abordând o gamă largă de studii de caz.

S-a pornit de la cazuri simple și de la baze de date test, în scopul validării metodelor propuse și "calibrării" instrumentelor soft. În același scop au fost realizate o serie de studii comparative cu rezultatele obținute în [Deacu2015] și [Chiș2015]. În continuare s-au analizat situații reale, referitoare la operatori de distribuție din România: Enel, Electrica, Delgaz Grid etc.

Din motive de spațiu, pentru acest capitol s-au selectat doar o serie de studii de caz vizând Enel Distribuție Banat. O parte a rezultatelor sunt prezentate în extenso, restul în sinteză, detaliile fiind oferite în Anexele 7.1, 7.2 și 7.3 (sub formă electronică).

Rezultatele obținute și pentru alte sisteme de distribuție a energiei electrice din România au fost și sunt utilizate în contractele derulate în ultimii ani prin Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor de Funcționare a Sistemelor Electroenergetice din cadrul Universității Politehnica Timișoara (director prof.dr.ing. Ștefan Kilyeni), beneficiarii fiind Enel Distribuție Banat, Electrica Muntenia Nord, Delgaz Grid (operatori importanți de distribuție a energiei electrice în România) și entități economice cu preocupări în domeniul implementării resurselor regenerabile de energie [UPT2017], [UPT2018], [UPT2019], [UPT2020a], [UPT 2020b].

Primul subcapitol are rolul de a valida modelele de calcul și instrumentele soft elaborate în cadrul acestei teze de doctorat, prin realizarea unor comparații cu rezultatele obținute în [Deacu2015] și [Chiș2015], în scopul demonstrării calităților superioare ale metodelor utilizând RNA bayesiene.

Al doilea subcapitol prezintă o serie de studii de prognoză realizate atât pentru ansamblul rețelei de distribuție din cadrul Enel Distribuție Banat cât și pentru unitățile teritoriale rețea (UTR) componente: Arad, Deva, Reșița și Timișoara.

Al treilea subcapitol este dedicat stațiilor de transformare de 110 kV / m.t. din cadrul UTR Timișoara. Pentru prezentarea rezultatelor în detaliu au fost selectate 5 stații semnificative de 110 / 20 kV (3 din municipiul Timișoara, una dintr-o localitate importantă a jud. Timiș și una care alimentează o exploatare petrolieră): Bucovina, IMT, Musicescu, Deta și Satchinez.

La finele fiecărui subcapitol în parte și al ansamblului capitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau vizând aspecte de natură mai generală, atât legat de rezultatele concrete ale prognozelor realizate cât și de metodele și modelele utilizate.

### 7.1. Validarea prin comparații a metodelor elaborate

#### 7.1.1. Considerații preliminare

Primul subcapitol are rolul de a valida modelele de calcul și instrumentele soft elaborate în cadrul acestei teze de doctorat, prin realizarea unor comparații cu rezultatele obținute în [Deacu2015] și [Chiș2015], în scopul demonstrării calităților

superioare ale RNA bayesiene. S-au avut în vedere rezultatele obținute cu RNA utilizate în [Deacu2015] și [Chiș2015] și cele cu RNA bayesiene din această teză.

Primul set de comparații se referă la operatorul de distribuție Enel Distribuție Banat și UTR componente (Arad, Deva, Reșița și Timișoara): prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie, utilizând valorile măsurate din oră în oră (ora 1, ora 2, ..., ora 23, ora 24) ale puterii active consumate. Erau disponibile datele pentru 13 ani (2001-2013). Primii 10 ani (2001-2010) s-au utilizat pentru antrenarea RNA, iar ultimii 3 ani (2011-2013) pentru verificarea prognozelor obținute.

Pentru comparare s-au selectat două dintre cele 5 analize efectuate în [Deacu 2015] și [Chiș2015]: UTR Reșița (unde rezultatele erau cele mai proaste, din cauza gradului scăzut de corelare a datelor inițiale – curbele de sarcină menționate) și ansamblul Enel Banat (unde s-au obținut cele mai bune rezultate, datorită gradului de corelare superior al datelor inițiale).

Al doilea set de comparații se referă la stații de transformare de 110 kV / m.t. din cadrul UTR Timișoara: prognoza curbelor de sarcină definite de valorile puterii consumate la o anumită oră a unei anumite zile pentru fiecare dintre cele 12 luni ale anului. Primii 6 ani dintre cei 8 pentru care se cunosc datele de consum (2006-2011) s-au utilizat pentru antrenarea RNA, iar ultimii 2 ani (2012 și 2013) pentru verificarea prognozelor obținute.

Pentru comparare s-a selectat una dintre cele 5 stații analizate în [Deacu2015]: stația de 110 / 20 kV Victoria, cu prognoze efectuate pentru ora 9 și ora 21 a ultimei zile de joi a fiecărei luni, a primei zile de marți și a celei de a doua zile de miercuri.

## **7.1.2. Comparații pentru UTR Reșița și ansamblul Enel Banat**

### **7.1.2.1. Considerații preliminare**

Primul set de comparații se referă la prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie, utilizând valorile medii orare măsurate ale puterii active consumate (ora 1, ora 2, ..., ora 23, ora 24).

S-au selectat două dintre cele 5 analize efectuate în [Deacu 2015] și [Chiș 2015]: UTR Reșița (unde rezultatele erau cele mai proaste, din cauza gradului scăzut de corelare a datelor inițiale – curbele de sarcină menționate) și ansamblul Enel Banat (unde s-au obținut cele mai bune rezultate, datorită gradului de corelare superior al datelor inițiale).

Se menționează că s-au considerat doar zile lucrătoare – zilele de joi cele mai apropiate de ziua de 21 iunie: 2001 – 21 iunie, 2002 – 20 iunie, 2003-19 iunie, 2004 – 24 iunie, 2005 – 23 iunie, 2006 – 22 iunie, 2007 – 21 iunie, 2008 – 19 iunie, 2009 – 18 iunie, 2010 – 24 iunie, 2011 – 23 iunie, 2012 – 21 iunie, 2013 – 20 iunie.

Erau disponibile datele pentru 13 ani (2001-2013). Primii 10 ani (2001-2010) s-au utilizat pentru antrenarea RNA, iar ultimii 3 ani (2011-2013) pentru verificarea prognozelor obținute.

În acest context, pentru comparațiile efective s-au avut în vedere următoarele cazuri:

- a) rezultatele obținute în [Deacu2015] utilizând RNA pentru ansamblul curbei de sarcină;
- b) rezultatele obținute în [Deacu2015] utilizând RNA pentru prognoza separată a consumului la fiecare oră;
- c) rezultatele obținute în [Chiș2015] utilizând RNA pentru ansamblul curbei de sarcină;
- d) rezultatele obținute utilizând RNA bayesiene pentru ansamblul curbei de sarcină;
- e) rezultatele obținute utilizând RNA bayesiene pentru prognoza separată a consumului la fiecare oră.



### 7.1.2.2. UTR Reșița

În tabelul 7.1.1 (Anexa 7.1), respectiv figura 7.1.1, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.2.1). Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.1. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.2 (Anexa 7.1), respectiv figura 7.1.2, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2011, 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.2. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor menționate evidențiază următoarele concluzii:

- pentru perioada 2001-2010 nu există o tendință clară de creștere sau de scădere a puterii;
- curbele de sarcină "se intersectează", adică forma lor diferă;
- remarcile anterioare sunt valabile și pentru anii 2011-2013;
- curba de sarcină pentru anul 2003 are o formă aparte între orele 7 și 12 (probabil un mare consumator era scos din funcțiune);
- gradul de corelare a curbelor de sarcină este relativ redus, atât în ceea ce privește evoluția temporală, cât și forma pe durata unei zile.

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

#### □ RNA, curba de sarcină

În tabelul 7.1.3 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare ( $S_{2011}$ ,  $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.3 - 7.1.5 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

### □ RNA, orar

În tabelul 7.1.4 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare oră în parte, diferențele relative față de valorile cunoscute (în %) și abaterile pătratiche. Indicele global de performanță ( $s_{total}$ ) este definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare ( $s_{2011}$ ,  $s_{2012}$ ,  $s_{2013}$ ). Grafic, rezultatele apar în figurile 7.1.3 - 7.1.5 (comparativ, pentru metodele utilizate în [Deacu2015]).




Figura 7.1.3. Analiza comparativă a rezultatelor pentru anul 2011




Figura 7.1.4. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.5. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se dau rezultatele din [Chiș2015], cu diverse metode de prognoză.

### □ RNA, curba de sarcină

În tabelul 7.1.5 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratiche. Indicele global de performanță ( $s_{total}$ ) este definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare. Grafic, rezultatele apar în figurile 7.1.6 - 7.1.8 (comparativ, pentru metodele utilizate în [Chiș2015]).




Figura 7.1.6. Analiza comparativă pentru 2011




Figura 7.1.7. Analiza comparativă pentru 2012




Figura 7.1.8. Analiza comparativă a rezultatelor pentru anul 2013

În final se prezintă rezultatele obținute cu metoda din cadrul acestei teze.

#### □ RNA bayesiană, curba de sarcină

În tabelul 7.1.6 se prezintă rezultatele obținute (în MW) prin utilizarea RNA bayesiană pentru întreaga curbă de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. În partea de jos a tabelului este dată valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 de valori orare ( $S_{2011}$ ,  $S_{2012}$ ,  $S_{2013}$  – indici parțiali de performanță). Grafic, aceste rezultate sunt prezentate în figurile 7.1.9 - 7.1.11 (comparativ, pentru ambele metode, împreună cu valorile reale).

Tabelul 7.1.6. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	59.4	62.1	4.50	20.22	1	56.8	59.3	4.44	19.68	1	54.2	56.8	4.76	22.66
2	57.7	58.3	1.02	1.05	2	55.6	57.3	3.09	9.57	2	54.9	56.9	3.55	12.62
3	57.9	58.4	0.85	0.72	3	56.8	58.2	2.39	5.73	3	56.1	57.1	1.85	3.44
4	57.6	55.6	-3.40	11.57	4	55.3	56.8	2.78	7.76	4	56.1	57.0	1.64	2.69
5	60.4	58.6	-3.05	9.28	5	58.6	57.8	-1.33	1.77	5	57.8	56.5	-2.34	5.46
6	53.6	56.4	5.21	27.09	6	52.0	54.1	4.08	16.62	6	53.2	55.1	3.55	12.62
7	53.3	54.8	2.81	7.92	7	49.9	53.4	6.93	48.08	7	53.2	55.4	4.15	17.26
8	60.1	63.4	5.52	30.52	8	55.1	58.2	5.55	30.84	8	53.4	57.4	7.40	54.72
9	59.2	62.6	5.79	33.57	9	57.9	59.8	3.32	11.00	9	56.2	58.1	3.42	11.67
10	62.5	63.2	1.04	1.08	10	60.7	62.4	2.87	8.22	10	57.2	60.8	6.21	38.52
11	62.5	61.3	-1.88	3.52	11	61.1	60.6	-0.87	0.75	11	61.8	60.8	-1.60	2.57
12	62.2	61.9	-0.54	0.30	12	60.9	61.3	0.57	0.33	12	61.8	63.4	2.57	6.62
13	59.5	58.8	-1.13	1.27	13	60.1	59.1	-1.63	2.66	13	58.1	59.9	3.17	10.03
14	58.6	56.9	-2.98	8.86	14	62.4	58.1	-6.96	48.37	14	57.8	58.9	1.94	3.75
15	60.5	56.9	-5.92	35.02	15	58.3	55.7	-4.44	19.74	15	55.2	53.1	-3.77	14.20
16	53.8	57.9	7.66	58.64	16	54.7	56.7	3.74	13.95	16	57.3	59.1	3.18	10.09
17	59.4	61.3	3.15	9.91	17	60.6	59.3	-2.21	4.88	17	62.6	59.9	-4.39	19.30
18	59.8	58.9	-1.49	2.23	18	58.4	57.3	-1.82	3.29	18	57.6	56.4	-2.14	4.56
19	55.3	57.9	4.74	22.45	19	54.4	56.8	4.49	20.12	19	51.9	54.1	4.16	17.32
20	49.3	51.4	4.30	18.49	20	48.3	52.8	9.38	87.96	20	47.1	51.5	9.24	85.30
21	50.2	54.6	8.69	75.43	21	51.4	52.9	2.94	8.63	21	54.1	53.1	-1.83	3.35
22	58.1	56.8	-2.28	5.20	22	56.9	55.5	-2.55	6.49	22	53.6	55.1	2.84	8.04
23	64.6	62.3	-3.51	12.34	23	65.8	63.4	-3.63	13.19	23	66.1	64.9	-1.79	3.19
24	64.1	61.7	-3.71	13.79	24	62.8	59.9	-4.55	20.74	24	60.4	56.9	-5.75	33.01
$S_{2011}$	410.47				$S_{2012}$	410.39				$S_{2013}$	402.96			
$S_{total} = 1223.81$														

### □ RNA bayesiană, orar

În tabelul 7.1.7 se prezintă prognoza obținută prin utilizarea RNA bayesiană pentru fiecare oră în parte, diferențele relative față de valorile cunoscute (în %) și abaterea pătratică. Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare ( $S_{2011}$ ,  $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.9 - 7.1.11 (comparativ, pentru ambele metode, împreună cu valorile reale).

Tabelul 7.1.7. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	59.4	58.2	-2.02	4.08	1	56.8	55.1	-2.99	8.96	1	54.2	53.7	-0.92	0.85
2	57.7	57.8	0.24	0.06	2	55.6	55.3	-0.49	0.24	2	54.9	54.1	-1.55	2.40
3	57.9	57.0	-1.50	2.26	3	56.8	56.6	-0.37	0.14	3	56.1	55.7	-0.80	0.64
4	57.6	56.9	-1.25	1.56	4	55.3	56.9	2.86	8.16	4	56.1	56.9	1.39	1.93
5	60.4	59.2	-2.05	4.21	5	58.6	59.2	0.96	0.91	5	57.8	59.2	2.35	5.54
6	53.6	53.1	-0.91	0.84	6	52.0	50.5	-2.88	8.32	6	53.2	51.8	-2.63	6.93
7	53.3	52.8	-0.94	0.88	7	49.9	51.4	3.01	9.04	7	53.2	52.2	-1.88	3.53
8	60.1	59.7	-0.73	0.54	8	55.1	56.0	1.63	2.67	8	53.4	54.8	2.62	6.87
9	59.2	59.5	0.52	0.27	9	57.9	57.0	-1.49	2.21	9	56.2	56.0	-0.36	0.13
10	62.5	64.2	2.77	7.66	10	60,7	60,4	-0.46	0.21	10	57.2	56.2	-1,68	2,82
11	62.5	62.6	0.08	0.01	11	61,1	61,0	-0.25	0.06	11	61.8	60.3	-2,43	5,89
12	62.2	61.6	-0.93	0.87	12	60,9	61,2	0.51	0.26	12	61.8	61.1	-1,10	1,21
13	59.5	60.3	1.31	1.72	13	60,1	59,8	-0.43	0.19	13	58.1	59.3	2,03	4,12
14	58.6	60.0	2.37	5.63	14	62,4	60,6	-2.88	8.32	14	57.8	58.3	0,87	0,75
15	60.5	59.5	-1.59	2.52	15	58,3	57,8	-0.93	0.86	15	55.2	56.6	2,50	6,25
16	53.8	54.6	1.41	2.00	16	54,7	55,6	1.55	2.41	16	57.3	56.3	-1,83	3,36
17	59.4	59.4	-0.07	0.00	17	60,6	60,3	-0.46	0.21	17	62.6	61.3	-2,06	4,25
18	59.8	59.3	-0.84	0.70	18	58,4	58,8	0.75	0.57	18	57.6	56.0	-2,80	7,81
19	55.3	55.8	0.90	0.82	19	54,4	54,2	-0.42	0.18	19	51.9	52.2	0,50	0,25
20	49.3	48.9	-0.77	0.59	20	48,3	48,5	0.37	0.14	20	47.1	48.5	3,04	9,22
21	50.2	51.8	3.17	10.03	21	51,4	51,9	0.89	0.80	21	54.1	52.8	-2,37	5,60
22	58.1	57.3	-1.43	2.04	22	56,9	56,2	-1.28	1.65	22	53.6	53.1	-0,93	0,87
23	64.6	63.8	-1.30	1.69	23	65,8	65,0	-1.26	1.59	23	66.1	65.8	-0,41	0,17
24	64.1	65.1	1.59	2.53	24	62,8	63,3	0.80	0.60	24	60.4	62.0	2,65	7,02
$S_{2011}$	53.51				$S_{2012}$	58.67				$S_{2013}$	88.40			
$S_{total} = 200.58$														

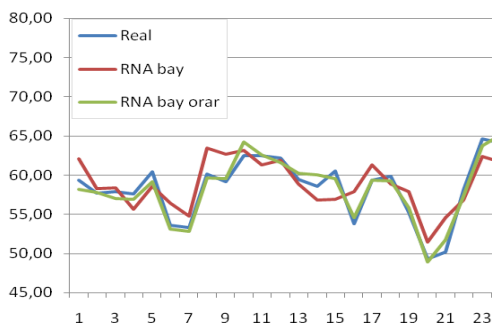


Figura 7.1.9. Analiza comparativă a rezultatelor pentru anul 2011




Figura 7.1.10. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.11. Analiza comparativă a rezultatelor pentru anul 2013

#### □ Analiza comparativă a rezultatelor

În tabelul 7.1.8 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015], [Chiș2015] și teza de față.

Tabelul 7.1.8. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină					RNA, orar		
	[Deacu2015]	[Chiș2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	Ameliorare indice de performanță [%] față de [Chiș2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
<b>S<sub>2011</sub></b>	496.58	659.60	410.47	17.3	37.7	89.87	53.51	40.5
<b>S<sub>2012</sub></b>	476.33	805.60	410.39	13.8	49.1	66.56	58.67	11.9
<b>S<sub>2013</sub></b>	450.67	812.50	402.96	10.6	50.4	73.09	88.40	-20.9
<b>S<sub>total</sub></b>	1423.59	2277.70	1223.81	14.03	46.3	229.52	200.58	12.6

Analiza în detaliu a rezultatelor obținute evidențiază câteva concluzii calitative și cantitative cu valabilitate generală pentru toate situațiile:

- se confirmă în totalitate observațiile făcute la analiza curbelor de sarcină pentru perioada 2001-2010, respectiv 2011-2013;
- rezultatele clar mai bune obținute cu prognoza orară utilizând RNA față de cele cu prognoza ansamblului curbei de sarcină cu RNA se explică prin slaba corelare a formei curbelor de sarcină;
- analiza comparativă a valorii indicilor anuali de performanță ( $S_{2011}$ ,  $S_{2012}$ ,  $S_{2013}$ ) evidențiază valori de același ordin de mărime – cu alte cuvinte aceste metode reușesc să "prindă" relativ bine evoluția consumului (în ciuda gradului redus de corelare a datelor inițiale);
- în spiritul concluziei anterioare, la prognoza ansamblului curbei de sarcină se observă o serie de "vârfuri", datorate slabei corelări a curbelor de sarcină din anii 2001-2010, care conduc la o valoare mai slabă a lui  $S_{total}$  comparativ cu RNA orar;
- zonele orare ale acestor vârfuri sunt legate de zonele orare similare ale curbelor de sarcină reale din perioada 2001-2010, respectiv perioada 2011-2013.

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 12-14%) și [Chiș2015] (cu 46%);
- în ceea ce privește defalcarea pe cei 3 ani (2011, 2012, 2013), la comparația cu [Deacu2015] ameliorarea cea mai accentuată apare pentru anul 2011, scăzând constant pentru 2012 și 2013;

- în același context, la comparația cu [Chiș2015] ordinea este inversă față de cea de la observația precedentă;
- la comparația cu [Deacu2015] apare o excepție la RNA orar pentru anul 2013 – rezultatul obținut cu RNA bayesiană este inferior celui din [Deacu2015] (situație marcată cu culoare albastră în tabelul 7.1.8), fără a afecta concluzia globală de la primul punct.

### 7.1.2.3. Enel Banat

În tabelul 7.1.9 (Anexa 7.1), respectiv figura 7.1.12, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.2.1). Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.12. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.10 (Anexa 7.1), respectiv figura 7.1.13, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2011, 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.13. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor menționate evidențiază următoarele concluzii:

- pentru perioada 2001-2010 tendința de evoluție a consumului pe ansamblu este destul de neclară (perioade de creștere, respectiv de scădere, într-o plajă relativ îngustă de valori);
- curbele de sarcină au o formă destul de asemănătoare (nu "se intersectează" prea mult), ceea ce înseamnă o corelare relativ mai bună "pe orizontală";
- trendul neclar se regăsește și în perioada 2011-2013, din nou cu o formă destul de asemănătoare a curbelor (între ele, respectiv cu cele din perioada 2001-2010);
- gradul de corelare a curbelor de sarcină este relativ bun în privința formei pe durata unei zile, ceea ce prefigurează obținerea unor prognoze relativ mai bune.

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

### □ RNA, curba de sarcină

În tabelul 7.1.11 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $s_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare ( $s_{2011}$ ,  $s_{2012}$ ,  $s_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.14 - 7.1.16 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

### □ RNA, orar

În tabelul 7.1.12 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare oră în parte, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $s_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare ( $s_{2011}$ ,  $s_{2012}$ ,  $s_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.14 - 7.1.16 (comparativ, pentru toate metodele utilizate în [Deacu2015]).




Figura 7.1.14. Analiza comparativă a rezultatelor pentru anul 2011




Figura 7.1.15. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.16. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se prezintă rezultatele obținute în [Chiș2015] cu diverse metode.

### □ RNA, curba de sarcină

În tabelul 7.1.13 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $s_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 valori orare ( $s_{2011}$ ,  $s_{2012}$ ,  $s_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.17 - 7.1.19 (comparativ, pentru toate metodele utilizate în [Chiș2015]).

În final se prezintă rezultatele obținute cu metoda din această teză.

### □ RNA bayesiană, curba de sarcină

În tabelul 7.1.14 se prezintă rezultatele obținute (în MW) prin utilizarea RNA bayesiană pentru întreaga curbă de sarcină, diferențele relative față de valorile cunoscute




Figura 7.1.17. Analiza comparativă a rezultatelor pentru anul 2011




Figura 7.1.18. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.19. Analiza comparativă a rezultatelor pentru anul 2013

(în %) și abaterile pătratic. În partea de jos a tabelului este dată valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 de valori orare ( $S_{2011}$ ,  $S_{2012}$ ,  $S_{2013}$  – indici parțiali de performanță). Grafic, aceste rezultate sunt prezentate în figurile 7.1.20 - 7.1.22 (comparativ, pentru ambele metode, împreună cu valorile reale).

Tabelul 7.1.14. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

Ora	2011				2012				2013					
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	389.4	389.8	0.09	0.01	1	384.8	388.2	0.88	0.78	1	384.2	381.2	-0.79	0.62
2	374.7	372.0	-0.71	0.50	2	370.3	365.6	-1.27	1.60	2	364.6	360.5	-1.14	1.29
3	377.4	382.9	1.46	2.12	3	380.9	380.4	-0.13	0.02	3	373.9	377.5	0.97	0.94
4	370.8	362.1	-2.35	5.53	4	364.9	360.2	-1.30	1.68	4	363.3	356.0	-2.01	4.02
5	370.6	370.7	0.02	0.00	5	367.4	365.0	-0.66	0.44	5	372.5	366.2	-1.69	2.86
6	368.2	364.4	-1.04	1.09	6	358.1	356.2	-0.53	0.28	6	364.3	357.6	-1.84	3.38
7	382.0	380.6	-0.36	0.13	7	381.3	369.5	-3.09	9.55	7	380.1	373.9	-1.63	2.66
8	430.4	421.8	-2.01	4.03	8	421.4	411.6	-2.34	5.45	8	422.7	412.6	-2.39	5.71
9	464.1	458.5	-1.21	1.46	9	450.9	445.1	-1.29	1.65	9	449.9	441.5	-1.87	3.50
10	482.8	475.6	-1.48	2.20	10	472.9	469.1	-0.80	0.63	10	471.2	463.6	-1.62	2.61



2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
11	490.3	483.3	-1.43	2.05	11	486.2	477.1	-1.87	3.50	11	481.9	473.1	-1.82	3.30
12	460.6	456.7	-0.86	0.73	12	453.9	450.6	-0.73	0.54	12	452.7	445.4	-1.62	2.62
13	449.0	447.7	-0.30	0.09	13	442.3	440.7	-0.37	0.13	13	450.7	440.3	-2.31	5.32
14	459.8	450.6	-2.01	4.04	14	454.9	446.7	-1.80	3.26	14	450.5	441.3	-2.04	4.17
15	453.0	457.4	0.97	0.95	15	450.5	453.8	0.74	0.54	15	441.4	449.9	1.93	3.71
16	433.3	432.4	-0.20	0.04	16	431.1	428.5	-0.59	0.35	16	430.0	425.5	-1.06	1.12
17	437.5	429.4	-1.84	3.39	17	440.2	426.3	-3.16	9.97	17	433.8	422.6	-2.59	6.69
18	427.2	428.6	0.34	0.11	18	418.0	424.1	1.46	2.12	18	423.0	420.7	-0.54	0.29
19	419.9	419.8	-0.03	0.00	19	409.6	417.3	1.89	3.55	19	415.9	413.8	-0.50	0.25
20	408.3	404.1	-1.03	1.06	20	402.2	396.1	-1.52	2.30	20	405.6	401.9	-0.91	0.83
21	410.9	402.2	-2.12	4.48	21	411.6	402.4	-2.24	5.00	21	406.0	402.3	-0.91	0.83
22	450.0	437.9	-2.69	7.23	22	439.8	428.4	-2.59	6.69	22	436.4	427.3	-2.09	4.35
23	472.6	469.8	-0.60	0.36	23	474.6	463.7	-2.30	5.28	23	467.7	456.9	-2.31	5.35
24	438.6	436.8	-0.41	0.17	24	439.4	430.1	-2.12	4.48	24	434.6	424.0	-2.44	5.96
$S_{2011}$	41.77				$S_{2012}$	69.80				$S_{2013}$	72.40			
$S_{total} = 183.97$														

#### □ RNA bayesiană, orar

În tabelul 7.1.15 se prezintă rezultatele obținute (în MW) prin utilizarea RNA bayesiană pentru fiecare oră în parte, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. În partea de jos a tabelului este dată valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 3 ani și cele 24 de valori orare ( $S_{2011}$ ,  $S_{2012}$ ,  $S_{2013}$  – indici parțiali de performanță). Grafic, aceste rezultate sunt prezentate în figurile 7.1.20 - 7.1.22 (comparativ, pentru ambele metode, împreună cu valorile reale).

Tabelul 7.1.15. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	389.4	389.7	0.08	0.01	1	384.8	383.4	-0.36	0.13	1	384.2	380.7	-0.91	0.83
2	374.7	373.5	-0.31	0.10	2	370.3	366.9	-0.91	0.82	2	364.6	362.4	-0.60	0.36
3	377.4	380.4	0.79	0.63	3	380.9	378.0	-0.77	0.60	3	373.9	373.6	-0.07	0.01
4	370.8	371.9	0.29	0.08	4	364.9	366.4	0.41	0.17	4	363.3	361.0	-0.65	0.42
5	370.6	373.8	0.86	0.75	5	367.4	369.8	0.65	0.43	5	372.5	368.7	-1.02	1.04
6	368.2	366.2	-0.54	0.30	6	358.1	359.6	0.42	0.18	6	364.3	359.6	-1.29	1.66
7	382.0	382.5	0.13	0.02	7	381.3	379.1	-0.58	0.33	7	380.1	377.0	-0.82	0.67
8	430.4	429.3	-0.26	0.07	8	421.4	425.5	0.97	0.95	8	422.7	423.1	0.09	0.01
9	464.1	465.8	0.36	0.13	9	450.9	454.8	0.86	0.75	9	449.9	445.8	-0.92	0.85
10	482.8	481.6	-0.26	0.07	10	472.9	474.0	0.22	0.05	10	471.2	466.3	-1.03	1.06
11	490.3	488.3	-0.40	0.16	11	486.2	484.2	-0.42	0.17	11	481.9	480.0	-0.39	0.15
12	460.6	462.2	0.35	0.12	12	453.9	455.3	0.32	0.10	12	452.7	448.5	-0.93	0.86
13	449.0	452.5	0.78	0.61	13	442.3	446.5	0.95	0.90	13	450.7	446.1	-1.02	1.04
14	459.8	460.2	0.08	0.01	14	454.9	453.4	-0.34	0.12	14	450.5	446.5	-0.88	0.78
15	453.0	453.5	0.11	0.01	15	450.5	447.5	-0.67	0.45	15	441.4	441.5	0.01	0.00

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
16	433.3	429.5	-0.88	0.77	16	431.1	435.4	0.99	0.97	16	430.0	431.5	0.36	0.13
17	437.5	439.4	0.43	0.19	17	440.2	436.3	-0.89	0.79	17	433.8	433.1	-0.17	0.03
18	427.2	430.1	0.67	0.45	18	418.0	421.7	0.89	0.78	18	423.0	422.0	-0.23	0.05
19	419.9	423.2	0.79	0.62	19	409.6	414.6	1.22	1.49	19	415.9	417.7	0.43	0.19
20	408.3	407.8	-0.12	0.01	20	402.2	405.1	0.72	0.52	20	405.6	402.4	-0.80	0.64
21	410.9	409.2	-0.41	0.17	21	411.6	410.7	-0.22	0.05	21	406.0	410.2	1.03	1.07
22	450.0	452.6	0.58	0.33	22	439.8	444.1	0.98	0.96	22	436.4	435.6	-0.18	0.03
23	472.6	475.7	0.66	0.43	23	474.6	471.2	-0.72	0.51	23	467.7	467.6	-0.02	0.00
24	438.6	439.3	0.16	0.03	24	439.4	439.9	0.11	0.01	24	434.6	436.6	0.46	0.21
$S_{2011}$	6.05				$S_{2012}$	12.23				$S_{2013}$	12.09			
$S_{total} = 30.37$														




Figura 7.1.20. Analiza comparativă a rezultatelor pentru anul 2011




Figura 7.1.21. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.22. Analiza comparativă a rezultatelor pentru anul 2013

#### □ Analiza comparativă a rezultatelor

În tabelul 7.1.16 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015], [Chiș2015] și teza de față.

Analiza în detaliu a rezultatelor obținute evidențiază câteva concluzii calitative și cantitative cu valabilitate generală pentru toate situațiile:

- se confirmă în mare măsură observațiile făcute la analiza curbelor de sarcină pentru perioada 2001-2010, respectiv 2011-2013;
- rezultatele clar mai bune obținute cu prognoza orară utilizând RNA față de cele cu prognoza ansamblului curbei de sarcină cu RNA se explică prin existența unor probleme de corelare a formei curbelor de sarcină;

Tabelul 7.1.16. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină					RNA, orar		
	[Deacu2015]	[Chiș2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	Ameliorare indice de performanță [%] față de [Chiș2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
<b>S<sub>2011</sub></b>	44.58	151.50	41.77	6.3	72.4	7.12	6.05	15.0
<b>S<sub>2012</sub></b>	74.98	78.89	69.80	6.9	11.5	13.41	12.23	8.8
<b>S<sub>2013</sub></b>	77.74	58.72	72.40	6.9	-23.3	13.30	12.09	9.1
<b>S<sub>total</sub></b>	197.30	289.1	183.97	6.8	36.4	33.82	30.37	10.2

- analiza comparativă a valorii indicilor anuali de performanță ( $s_{2011}$ ,  $s_{2012}$ ,  $s_{2013}$ ) evidențiază valori de regulă mai bune pentru anul 2011 (totuși, de același ordin de mărime pentru toți anii) și aproape egale pentru 2012 și 2013 (excepție – rezultatele din [Chiș2015], unde ordinea este inversă);
- în spiritul concluziei anterioare, la prognoza ansamblului curbei de sarcină se observă o serie de "vârfuri", datorate unor probleme de corelare a formei curbelor de sarcină din anii 2001-2010, care conduc la o valoare mai slabă a lui  $s_{total}$  comparativ cu RNA orar;
- zonele orare ale acestor vârfuri sunt legate de zonele orare similare ale curbelor de sarcină reale din perioada 2001-2010, respectiv perioada 2011-2013.

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 6-10%) și [Chiș2015] (cu 36%);
- în ceea ce privește defalcarea pe cei 3 ani (2011, 2012, 2013), la comparația cu [Deacu2015] ameliorarea cea mai accentuată la RNA orar apare pentru anul 2011, înjumătățindu-se pentru 2012 și 2013 (la RNA pentru ansamblul curbei de sarcină ameliorarea este practic constantă la toți anii);
- în același context, la comparația cu [Chiș2015] ordinea este similară;
- la comparația cu [Chiș2015] apare o excepție la RNA pentru ansamblul curbei de sarcină – anul 2013: rezultatul obținut cu RNA bayesiană este inferior celui din [Chiș2015] (situație marcată cu culoare albastră în tabelul 7.1.16), fără a afecta concluzia globală de la primul punct.

### 7.1.3. Comparații stația de 110 / 20 kV Victoria

#### 7.1.3.1. Considerații preliminare

Al doilea set de comparații se referă la stații de transformare de 110 kV / m.t. din cadrul UTR Timișoara: prognoza curbelor de sarcină definite de valorile puterii consumate la o anumită oră (putere medie orară) a unei anumite zile pentru fiecare dintre cele 12 luni ale anului. Primii 6 ani dintre cei 8 pentru care se cunosc datele de

consum (2006-2011) s-au utilizat pentru antrenarea RNA, iar ultimii 2 ani (2012 și 2013) pentru verificarea prognozelor obținute.

Pentru comparare s-a selectat una dintre cele 5 stații analizate în [Deacu2015]: stația de 110 / 20 kV Victoria, cu prognoze efectuate pentru ora 9 și ora 21 a ultimei zile de joi a fiecărei luni, a primei zile de marți și a celei de a doua zile de miercuri.

Pentru comparațiile efective s-au avut în vedere următoarele cazuri:

- rezultatele obținute în [Deacu2015] utilizând RNA pentru ansamblul curbei de sarcină;
- rezultatele obținute în [Deacu2015] utilizând RNA pentru prognoza separată a consumului la fiecare oră;
- rezultatele obținute utilizând RNA bayesiană pentru ansamblul curbei de sarcină;
- rezultatele obținute utilizând RNA bayesiană pentru prognoza separată a consumului la fiecare oră.

### 7.1.3.2. Stația Victoria

#### □ Ultima zi de joi a fiecărei luni, ora 9

În tabelul 7.1.17 (Anexa 7.1), respectiv figura 7.1.23, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 6 ani (2006-2011), pentru ora 9 a ultimei zile de joi din fiecare lună. Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.23. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

În tabelul 7.1.18 (Anexa 7.1), respectiv figura 7.1.24, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.24. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Analiza datelor din tabelele 7.1.17 și 7.1.18 (Anexa A7.1) evidențiază de la bun început următoarele observații:

- pentru perioada 2006-2011 se remarcă o tendință de scădere a consumului, întreruptă de creșteri momentane destul de însemnate;
- pentru anii 2012 și 2013, excepție lunile ianuarie și octombrie, trendul general este de creștere;

- forma curbelor este destul de eterogenă, cu multe "intersecții", observându-se prezența unor minime relative pentru lunile aprilie, iunie, august și decembrie, respectiv maxime relative pentru noiembrie și, parțial, mai și iulie;
- rezultă că gradul de corelare a curbelor de sarcină este relativ redus, atât în privința evoluției în timp cât și a formei pe durata unui an.

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

În tabelul 7.1.19 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ).

Grafic, aceste rezultate sunt prezentate în figurile 7.1.25 și 7.1.26 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

Similar, în tabelul 7.1.20 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare lună în parte, ilustrată grafic tot în figurile 7.1.25 și 7.1.26.




Figura 7.1.25. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.26. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se prezintă rezultatele obținute cu metoda elaborată în cadrul acestei teze.

Valorile prognozate, diferențele față de cele cunoscute și abaterea pătratică relativă sunt prezentate în tabelele 7.1.21 (RNA bayesiană, curba de sarcină) și 7.1.22 (RNA bayesiană, lunar). Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ).

Grafic, aceste rezultate sunt prezentate în figurile 7.1.27 și 7.1.28 (comparativ, pentru ambele metode utilizate).

Tabelul 7.1.21. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

Luna	2012				2013				
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	13.0	14.4	10.93	119.45	Ian	10.0	12.2	22.40	501.76
Feb	9.0	10.1	12.22	149.38	Feb	10.0	10.5	4.89	23.91
Mar	11.0	9.8	-10.75	115.66	Mar	12.5	10.9	-13.12	172.13
Apr	7.5	6.9	-8.63	74.43	Apr	9.0	8.4	-6.44	41.53

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Mai	12.0	13.2	10.25	104.97	Mai	12.5	13.4	6.88	47.33
Iun	7.0	6.1	-12.80	163.91	Iun	7.2	6.4	-10.83	117.36
Iul	11.0	11.1	1.14	1.30	Iul	12.5	11.4	-8.64	74.65
Aug	7.5	8.6	14.67	215.11	Aug	8.1	9.6	18.08	326.76
Sep	13.5	12.1	-10.37	107.54	Sep	13.7	12.4	-9.78	95.67
Oct	12.5	11.0	-11.63	135.16	Oct	11.8	11.2	-4.83	23.33
Nov	12.5	12.7	1.97	3.88	Nov	13.7	12.6	-7.74	59.86
Dec	6.5	6.2	-4.62	21.30	Dec	7.1	6.6	-7.46	55.72
$S_{2012}$	1212.10				$S_{2013}$	1540.03			
$S_{total} = 2752.13$									

Tabelul 7.1.22. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	13.0	12.7	-2.31	5.33	Ian	10.0	10.5	5.00	25.00
Feb	9.0	9.4	4.44	19.75	Feb	10.0	10.0	0.10	0.01
Mar	11.0	11.6	5.45	29.75	Mar	12.5	12.5	-0.24	0.06
Apr	7.5	7.4	-1.20	1.44	Apr	9.0	8.9	-0.78	0.60
Mai	12.0	12.2	1.42	2.01	Mai	12.5	12.3	-1.36	1.85
Iun	7.0	6.8	-3.29	10.80	Iun	7.2	6.8	-5.83	34.03
Iul	11.0	11.6	5.00	25.00	Iul	12.5	11.9	-4.80	23.04
Aug	7.5	7.7	3.07	9.40	Aug	8.1	7.6	-6.17	38.10
Sep	13.5	13.0	-3.85	14.84	Sep	13.7	13.9	1.53	2.35
Oct	12.5	11.9	-5.12	26.21	Oct	11.8	12.0	1.61	2.59
Nov	12.5	12.9	3.20	10.24	Nov	13.7	13.4	-2.41	5.80
Dec	6.5	6.9	6.15	37.87	Dec	7.1	7.2	1.27	1.61
$S_{2012}$	192.64				$S_{2013}$	135.05			
$S_{total} = 327.68$									




Figura 7.1.27. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.28. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.23 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015] și teza de față.

Tabelul 7.1.23. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină			RNA, lunar		
	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
<b>S<sub>2012</sub></b>	1746.15	1212.10	30.6	314.29	192.64	38.7
<b>S<sub>2013</sub></b>	1881.18	1540.03	18.1	221.24	135.05	39.0
<b>S<sub>total</sub></b>	3627.33	2752.13	24.1	535.53	327.68	38.8

Analiza în detaliu a rezultatelor obținute evidențiază câteva concluzii calitative și cantitative cu valabilitate generală pentru toate situațiile:

- rezultatele confirmă comentariile făcute la analiza curbelor de sarcină pentru perioada 2006-2011, respectiv 2012-2013;
- prognoza lunară utilizând RNA conduce la rezultate mai bune decât prognoza ansamblului curbei de sarcină cu RNA, situație explicabilă prin gradul scăzut de corelare a formei curbelor de sarcină;
- analiza comparativă a indicilor anuali de performanță ( $S_{2012}$ ,  $S_{2013}$ ) evidențiază valori de același ordin de mărime, adică prognozele reușesc să "prindă" evoluția consumului (în pofida gradului redus de corelare a datelor inițiale);
- prognozele utilizând RNA pentru ansamblul curbei de sarcină, care țin cont de valorile pentru toate lunile, "nu prinde vârful" (variațiile mari de la o lună la alta), curbele din imaginile grafice fiind mai "aplatizate" decât cele corespunzătoare consumului real sau prognozei pe luni separate.

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 24-39%);
- în ceea ce privește defalcarea pe cei 2 ani (2012 și 2013), ameliorarea este practic aceeași la prognoza lunară, înjumătățindu-se pentru 2013 față de 2012 la prognoza pentru ansamblul curbei de sarcină.

#### □ Ultima zi de joi a fiecărei luni, ora 21

În tabelul 7.1.24 (Anexa 7.1), respectiv figura 7.1.29, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 6 ani (2006-2011), pentru ora 21 a ultimei zile de joi din fiecare lună.

Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.29. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

În tabelul 7.1.25 (Anexa 7.1), respectiv figura 7.1.30, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.30. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Analiza datelor din tabelele 7.1.24 și 7.1.25 (Anexa A7.1) evidențiază de la bun început următoarele observații:

- pentru perioada 2006-2011 se remarcă o tendință de scădere a consumului, întreruptă de creșteri momentane destul de însemnate;
- pentru anii 2012 și 2013 tendința generală este de creștere sau de menținere aproximativ constantă;
- forma curbelor este destul de eterogenă, cu multe "intersecții", observându-se doar un minim relativ în aprilie, respectiv un maxim relativ în noiembrie;
- rezultă că gradul de corelare a curbelor de sarcină este relativ redus, atât în privința evoluției în timp cât și a formei pe durata unui an, cu observația că ele par a fi "mai grupate" decât cele de la ora 9.

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

În tabelul 7.1.26 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.31 și 7.1.32 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

Similar, în tabelul 7.1.27 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare lună în parte, ilustrată grafic tot în figurile 7.1.31 și 7.1.32.




Figura 7.1.31. Analiza comparativă a rezultatelor pentru anul 2012



Figura 7.1.32. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se prezintă rezultatele obținute cu metoda elaborată în cadrul acestei teze.

Valorile prognozate, diferențele față de cele cunoscute și abaterea pătratică relativă sunt prezentate în tabelele 7.1.28 (RNA bayesiană, curba de sarcină) și 7.1.29 (RNA bayesiană, lunar). Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare



( $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.33 și 7.1.34 (comparativ, pentru ambele metode utilizate).

Tabelul 7.1.28. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	12.6	13.19	4.7	21.9	Ian	11.5	12.18	5.9	35.0
Feb	12.4	13.10	5.6	31.9	Feb	12.1	12.94	6.9	48.2
Mar	14.0	13.10	-6.4	41.4	Mar	16.0	13.46	-15.9	252.0
Apr	8.5	8.07	-5.0	25.3	Apr	9.0	8.21	-8.8	77.0
Mai	13.2	12.64	-4.2	18.0	Mai	13.6	12.81	-5.8	33.4
Iun	12.8	11.69	-8.7	75.2	Iun	13.1	11.78	-10.1	101.5
Iul	11.0	10.92	-0.7	0.5	Iul	11.8	11.00	-6.7	45.6
Aug	9.0	10.32	14.7	215.1	Aug	9.7	10.95	12.8	165.1
Sep	12.0	10.31	-14.1	198.3	Sep	12.2	10.39	-14.8	219.1
Oct	14.0	12.47	-10.9	119.4	Oct	14.4	12.51	-13.1	172.3
Nov	12.5	12.56	0.5	0.2	Nov	13.1	12.71	-3.0	8.9
Dec	9.0	8.71	-3.2	10.4	Dec	9.7	8.84	-8.9	78.6
$S_{2012}$	757.65				$S_{2013}$	1236.60			
$S_{total} = 1994.25$									

Tabelul 7.1.29. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	12.6	12.4	-1.67	2.78	Ian	11.5	11.7	1.74	3.02
Feb	12.4	12.3	-1.05	1.10	Feb	12.1	12.2	1.07	1.15
Mar	14.0	14.5	3.86	14.88	Mar	16.0	15.7	-2.06	4.25
Apr	8.5	8.7	1.88	3.54	Apr	9.0	8.8	-2.11	4.46
Mai	13.2	13.2	0.30	0.09	Mai	13.6	13.5	-1.10	1.22
Iun	12.8	12.8	0.08	0.01	Iun	13.1	13.4	1.91	3.64
Iul	11.0	11.2	2.18	4.76	Iul	11.8	11.9	0.85	0.72
Aug	9.0	9.1	1.56	2.42	Aug	9.7	9.6	-1.24	1.53
Sep	12.0	12.2	1.83	3.36	Sep	12.2	12.4	1.89	3.55
Oct	14.0	14.1	0.64	0.41	Oct	14.4	14.2	-1.67	2.78
Nov	12.5	12.7	1.76	3.10	Nov	13.1	13.3	1.15	1.31
Dec	9.0	9.2	1.89	3.57	Dec	9.7	9.6	-1.34	1.80
$S_{2012}$	40.02				$S_{2013}$	29.44			
$S_{total} = 69.45$									




Figura 7.1.33. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.34. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.30 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015] și teza de față.

Tabelul 7.1.30. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină			RNA, lunar		
	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
<b>S<sub>2012</sub></b>	820.31	757.65	7.6	43.10	40.02	6.9
<b>S<sub>2013</sub></b>	1971.28	1236.60	37.9	33.46	29.44	10.8
<b>S<sub>total</sub></b>	2791.59	1994.25	28.5	76.56	69.45	8.6

Analiza în detaliu a rezultatelor obținute evidențiază câteva concluzii calitative și cantitative cu valabilitate generală pentru toate situațiile:

- rezultatele confirmă comentariile făcute la analiza curbelor de sarcină pentru perioada 2006-2011, respectiv 2012-2013;
- prognoza lunară utilizând RNA conduce la rezultate mai bune decât prognoza ansamblului curbei de sarcină cu RNA, situație explicabilă prin gradul scăzut de corelare a formei curbelor de sarcină;
- analiza comparativă a indicilor anuali de performanță ( $s_{2012}$ ,  $s_{2013}$ ) evidențiază valori de același ordin de mărime pentru RNA lunar (cu "probleme" în martie), respectiv diferite pentru RNA referitor la curbele de sarcină (datorită lunilor martie, iunie și septembrie 2013).

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 9-28%);
- în ceea ce privește defalcarea pe cei 2 ani (2012 și 2013), ameliorarea este de același ordin de mărime la prognoza lunară, crescând de 5 ori pentru 2013 față de 2012 la prognoza pentru ansamblul curbei de sarcină.

#### □ Prima zi de marți a fiecărei luni, ora 9

În tabelul 7.1.31 (Anexa 7.1), respectiv figura 7.1.35, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 6 ani (2006-2011), pentru ora 9 a primei zile de marți din fiecare lună. Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.35. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

În tabelul 7.1.32 (Anexa 7.1), respectiv figura 7.1.36, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii similare cu cele prezentate pentru ultima zi de joi, ora 9, a fiecărei luni, cu completarea că gradul de corelare a curbelor de sarcină pare a fi și mai redus.




Figura 7.1.36. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză. În tabelul 7.1.33 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.37 și 7.1.38 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

Similar, în tabelul 7.1.34 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare lună în parte, ilustrată grafic tot în figurile 7.1.37 și 7.1.38.




Figura 7.1.37. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.38. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se prezintă rezultatele obținute cu metoda elaborată în cadrul acestei teze.

Valorile prognozate, diferențele față de cele cunoscute și abaterea pătratică relativă sunt prezentate în tabelele 7.1.35 (RNA bayesiană, curba de sarcină) și 7.1.36 (RNA bayesiană, lunar). Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ).

Grafic, aceste rezultate sunt prezentate în figurile 7.1.39 și 7.1.40 (comparativ, pentru ambele metode utilizate).

Tabelul 7.1.35. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

Luna	2012				2013				
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	
Ian	6.5	6.54	0.63	0.39	Ian	6.0	6.02	0.4	0.1
Feb	12.0	12.26	2.19	4.80	Feb	10.0	11.69	16.9	286.3

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Mar	14.8	12.13	-18.07	326.43	Mar	15.0	13.41	-10.6	112.4
Apr	11.5	10.33	-10.17	103.33	Apr	12.0	10.94	-8.8	78.0
Mai	4.0	4.35	8.76	76.74	Mai	5.9	5.64	-4.4	19.4
Iun	12.0	10.93	-8.95	80.08	Iun	12.5	10.82	-13.5	181.5
Iul	5.5	7.86	42.91	1841.19	Iul	10.0	9.02	-9.8	96.3
Aug	9.5	7.09	-25.35	642.55	Aug	10.0	8.92	-10.8	116.6
Sep	10.0	8.70	-13.03	169.76	Sep	10.5	9.88	-5.9	34.9
Oct	13.0	11.93	-8.23	67.75	Oct	12.0	9.76	-18.7	348.4
Nov	11.5	10.12	-12.00	144.00	Nov	11.0	9.74	-11.5	131.2
Dec	8.5	9.01	6.01	36.09	Dec	9.0	10.54	17.1	292.8
$S_{2012}$	3493,11				$S_{2013}$	1698,05			
$S_{total} = 5191.16$									

Tabelul 7.1.36. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	6.5	6.5	0.15	0.02	Ian	6.0	6.2	3.00	9.00
Feb	12.0	12.1	0.58	0.34	Feb	10.0	10.9	9.00	81.00
Mar	14.8	15.0	1.08	1.17	Mar	15.0	15.0	-0.27	0.07
Apr	11.5	11.4	-0.78	0.61	Apr	12.0	11.9	-1.08	1.17
Mai	4.0	4.2	5.75	33.06	Mai	5.9	5.4	-8.47	71.82
Iun	12.0	12.2	1.50	2.25	Iun	12.5	12.6	0.56	0.31
Iul	5.5	6.1	10.91	119.01	Iul	10.0	8.8	-12.00	144.00
Aug	9.5	9.6	1.26	1.60	Aug	10.0	9.9	-0.80	0.64
Sep	10.0	10.2	2.40	5.76	Sep	10.5	10.5	-0.29	0.08
Oct	13.0	12.7	-2.15	4.64	Oct	12.0	12.3	2.58	6.67
Nov	11.5	11.7	1.65	2.73	Nov	11.0	11.2	1.36	1.86
Dec	8.5	8.9	4.47	19.99	Dec	9.0	9.2	2.22	4.94
$S_{2012}$	191.18				$S_{2013}$	321.57			
$S_{total} = 512.75$									




Figura 7.1.39. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.40. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.37 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015] și teza de față.

Tabelul 7.1.37. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină			RNA, lunar		
	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
<b>S2012</b>	4859.01	3493.11	28.1	1515.08	191.18	87.4
<b>S2013</b>	1645.68	1698.05	-3.2	771.08	321.57	58.3
<b>Stotal</b>	6504.69	5191.16	20.2	2286.16	512.75	77.6

Analiza în detaliu a rezultatelor obținute evidențiază concluzii calitative și cantitative similare cu cele prezentate pentru ultima zi de joi, ora 9, cu completarea că valoarea indicilor globali de performanță este mai proastă (datorită gradului mai redus de corelare a curbelor de sarcină).

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 20-77%);
- în ceea ce privește defalcarea pe cei 2 ani (2012 și 2013), ameliorarea este de același ordin de mărime la prognoza lunară;
- în contextul de la punctul anterior, la prognoza pentru ansamblul curbei de sarcină se remarcă o ușoară înrăutățire a situației la RNA bayesiană (cu 3,2%) pentru anul 2013, fără a fi afectată concluzia de la comparația globală (situație marcată cu culoare albastră în tabelul 7.1.37).

#### □ Prima zi de marți a fiecărei luni, ora 21

În tabelul 7.1.38 (Anexa 7.1), respectiv figura 7.1.41, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 6 ani (2006-2011), pentru ora 21 a primei zile de marți din fiecare lună. Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.41. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

În tabelul 7.1.39 (Anexa 7.1), respectiv figura 7.1.42, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.42. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Analiza datelor evidențiază concluzii similare cu cele prezentate pentru ultima zi de joi, ora 21, a fiecărei luni, cu completarea că gradul de corelare a curbelor de sarcină pare a fi și mai redus.

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

În tabelul 7.1.40 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice și valoarea indicelui global de performanță ( $s_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $s_{2012}$ ,  $s_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.43 și 7.1.44 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

Similar, în tabelul 7.1.41 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare lună în parte, ilustrată grafic tot în figurile 7.1.43 și 7.1.44.




Figura 7.1.43. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.44. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se prezintă rezultatele obținute cu metoda elaborată în cadrul acestei teze.

Valorile prognozate, diferențele față de cele cunoscute și abaterea pătratică relativă sunt prezentate în tabelele 7.1.42 (RNA bayesiană, curba de sarcină) și 7.1.43 (RNA bayesiană, lunar). Este evidențiată și valoarea indicelui global de performanță ( $s_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $s_{2012}$ ,  $s_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.45 și 7.1.46 (comparativ, pentru ambele metode utilizate).

Tabelul 7.1.42. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

Luna	2012				Luna	2013			
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă		Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.0	9.74	-11.5	131.2	Ian	10.0	9.53	-4.7	22.3
Feb	12.0	13.84	15.3	235.1	Feb	10.0	12.86	28.6	818.0
Mar	15.0	14.68	-2.1	4.6	Mar	15.5	14.98	-3.3	11.2
Apr	12.0	13.56	13.0	169.0	Apr	11.5	13.27	15.4	236.9
Mai	9.0	7.39	-17.9	319.2	Mai	9.8	8.21	-16.2	263.2
Iun	11.0	11.53	4.8	23.2	Iun	12.0	11.78	-1.8	3.3
Iul	9.5	10.58	11.4	129.2	Iul	12.0	11.06	-7.8	60.9
Aug	10.0	9.02	-9.8	96.4	Aug	10.2	9.27	-9.1	83.1
Sep	10.5	9.52	-9.3	87.1	Sep	10.0	9.36	-6.4	41.5
Oct	13.0	11.32	-12.9	167.0	Oct	11.5	10.90	-5.2	27.0

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Nov	12.5	11.06	-11.5	132.7	Nov	12.0	10.89	-9.2	85.4
Dec	11.5	12.09	5.1	26.1	Dec	12.0	12.68	5.7	32.1
$S_{2012}$	1520.79				$S_{2013}$	1684.94			
$S_{total} = 3205.72$									

Tabelul 7.1.43. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.0	10.6	-3.73	13.89	Ian	10.0	10.2	2.10	4.41
Feb	12.0	12.4	3.17	10.03	Feb	10.0	10.8	8.10	65.61
Mar	15.0	15.0	-0.13	0.02	Mar	15.5	15.4	-0.77	0.60
Apr	12.0	12.0	-0.25	0.06	Apr	11.5	11.6	0.43	0.19
Mai	9.0	9.3	3.11	9.68	Mai	9.8	9.7	-1.12	1.26
Iun	11.0	11.4	3.82	14.58	Iun	12.0	12.2	1.25	1.56
Iul	9.5	10.4	9.79	95.83	Iul	12.0	11.3	-5.50	30.25
Aug	10.0	10.0	-0.40	0.16	Aug	10.2	10.1	-0.78	0.62
Sep	10.5	10.5	-0.48	0.23	Sep	10.0	10.3	2.80	7.84
Oct	13.0	12.5	-4.15	17.25	Oct	11.5	11.7	1.65	2.73
Nov	12.5	12.5	-0.40	0.16	Nov	12.0	12.1	0.92	0.84
Dec	11.5	11.6	0.70	0.48	Dec	12.0	12.0	-0.33	0.11
$S_{2012}$	162.38				$S_{2013}$	116.02			
$S_{total} = 278.39$									




Figura 7.1.45. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.46. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.44 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015] și teza de față.

Tabelul 7.1.44. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină			RNA, lunar		
	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
$S_{2012}$	2103.09	1520.79	27.7	204.12	162.38	20.4
$S_{2013}$	3663.67	1684.94	54.0	191.35	116.02	39.4
$S_{total}$	5766.76	3205.72	44.4	395.47	278.39	29.6

Analiza în detaliu a rezultatelor obținute evidențiază concluzii calitative și cantitative similare cu cele prezentate pentru ultima zi de joi, ora 21, cu completarea că valoarea indicilor globali de performanță este mai proastă (datorită gradului mai redus de corelare a curbilor de sarcină).

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 30-44%);
- în ceea ce privește defalcarea pe cei 2 ani (2012 și 2013), ameliorarea este de 2 ori mai mare pentru anul 2013 față de 2012, atât la prognoza lunară cât și la cea pentru ansamblul curbei de sarcină.

#### □ A doua zi de miercuri a fiecărei luni, ora 9

În tabelul 7.1.45 (Anexa 7.1), respectiv figura 7.1.47, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 6 ani (2006-2011), pentru ora 9 a celei de-a doua zile de miercuri din fiecare lună. Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.47. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

În tabelul 7.1.46 (Anexa 7.1), respectiv figura 7.1.48, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.48. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Analiza datelor din tabelele 7.1.45 și 7.1.46 (Anexa A7.1) evidențiază de la bun început următoarele observații:

- pentru perioada 2006-2011 apare o tendință inițială de creștere, urmată de o scădere destul de accentuată;
- pentru 2012-2013 trendul este de creștere, cu foarte mici excepții;
- forma curbilor este eterogenă, cu multe "intersecții" și cu "sincope" care vor pune probleme la efectuarea prognozelor: aprilie 2006, martie 2009 și 2010, iunie 2010, iulie 2006, 2007 și 2009, noiembrie 2008-2010, decembrie 2008 (câte 2 luni cu valori "discrepante" pentru fiecare an);
- pe ansamblu gradul de corelare a curbilor de sarcină este redus, atât din punctul de vedere al evoluției temporale, cât și al formei pe durata unui an.



În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

În tabelul 7.1.47 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.49 și 7.1.50 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

Similar, în tabelul 7.1.48 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare lună în parte, ilustrată grafic tot în figurile 7.1.49 și 7.1.50.

În continuare se prezintă rezultatele obținute cu metoda elaborată în cadrul acestei teze.




Figura 7.1.49. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.50. Analiza comparativă a rezultatelor pentru anul 2013

Valorile prognozate, diferențele față de cele cunoscute și abaterea pătratică relativă sunt prezentate în tabelele 7.1.49 (RNA bayesiană, curba de sarcină) și 7.1.50 (RNA bayesiană, lunar). Este evidențiată și valoarea indicelui global de performanță ( $S_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $S_{2012}$ ,  $S_{2013}$ ). Grafic, aceste rezultate sunt prezentate în figurile 7.1.51 și 7.1.52 (comparativ, pentru ambele metode utilizate).

Tabelul 7.1.49. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

Luna	2012				Luna	2013			
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă		Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.0	13.07	18.8	354.1	Ian	10.5	12.86	22.5	505.2
Feb	14.0	14.92	6.5	42.9	Feb	15.0	15.08	0.5	0.3
Mar	10.7	11.86	10.8	117.5	Mar	12.8	12.35	-3.5	12.1
Apr	10.8	10.40	-3.7	13.5	Apr	11.5	10.68	-7.1	50.8
Mai	13.0	13.66	5.1	25.9	Mai	14.5	13.94	-3.9	14.9
Iun	9.0	10.74	19.3	373.8	Iun	10.4	11.10	6.7	45.1
Iul	10.0	9.32	-6.8	45.8	Iul	10.7	9.74	-9.0	80.5
Aug	10.0	10.50	5.0	25.0	Aug	11.2	10.88	-2.9	8.2
Sep	13.0	11.07	-14.8	220.4	Sep	12.5	10.51	-16.0	254.6
Oct	11.5	12.66	10.1	101.7	Oct	13.0	13.96	7.4	54.3
Nov	13.0	11.88	-8.6	74.4	Nov	14.0	12.34	-11.9	140.6
Dec	12.5	13.84	10.7	114.9	Dec	13.9	14.19	2.1	4.5
$S_{2012}$	1509.96				$S_{2013}$	1171.01			
$S_{total} = 2680.97$									

Tabelul 7.1.50. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.0	11.1	1.3	1.6	Ian	10.5	10.4	-0.7	0.4
Feb	14.0	14.2	1.1	1.3	Feb	15.0	14.6	-2.4	5.8
Mar	10.7	11.4	6.5	42.8	Mar	12.8	12.2	-4.8	22.7
Apr	10.8	11.1	2.3	5.4	Apr	11.5	11.2	-2.6	6.8
Mai	13.0	13.6	4.7	22.0	Mai	14.5	14.7	1.2	1.5
Iun	9.0	9.6	6.7	44.4	Iun	10.4	10.3	-1.0	0.9
Iul	10.0	10.2	1.8	3.2	Iul	10.7	10.5	-2.2	5.0
Aug	10.0	10.4	3.9	15.2	Aug	11.2	10.9	-2.3	5.4
Sep	13.0	12.9	-0.8	0.6	Sep	12.5	12.4	-0.8	0.6
Oct	11.5	11.4	-1.0	1.1	Oct	13.0	13.1	0.5	0.3
Nov	13.0	12.9	-0.8	0.7	Nov	14.0	13.8	-1.7	2.9
Dec	12.5	12.9	3.1	9.7	Dec	13.9	13.5	-2.8	7.9
$S_{2012}$	148.13				$S_{2013}$	60.35			
$S_{total} = 208.47$									




Figura 7.1.51. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.52. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.51 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015] și teza de față.

Tabelul 7.1.51. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină			RNA, lunar		
	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
$S_{2012}$	1766.67	1509.96	14.5	211.74	148.13	30.0
$S_{2013}$	1309.12	1171.01	10.5	96.48	60.35	37.4
$S_{total}$	3075.79	2680.97	12.8	308.22	208.47	32.4

Analiza în detaliu a rezultatelor obținute evidențiază câteva concluzii calitative și cantitative cu valabilitate generală pentru toate situațiile:

- rezultatele prognozei confirmă observațiile făcute la analiza curbelor de sarcină pentru perioada 2006-2011, respectiv 2012-2013;
- prognoza lunară utilizând RNA conduce la rezultate mai bune decât prognoza ansamblului curbei de sarcină cu RNA, situație explicabilă prin gradul scăzut de corelare a formei curbelor de sarcină și prin "sincopel" menționate;

- analiza comparativă a valorii indicilor anuali de performanță ( $s_{2012}$ ,  $s_{2013}$ ) arată valori mai mari pentru  $s_{2012}$ , tabelele 7.1.49 și 7.1.50 indicând cauzele: lunile ianuarie, martie, mai, iunie, septembrie;
- prognoza utilizând RNA pentru ansamblul curbei de sarcină urmărește mai greu "discontinuitățile" ("salturile") din consumul real decât prognoza pe luni cu RNA.  
Analiza comparativă cantitativă a rezultatelor conduce la următoarele concluzii:
- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 13-32%);
- în ceea ce privește defalcarea pe cei 2 ani, ameliorarea este de același ordin de mărime, atât la prognoza lunară cât și la cea pentru ansamblul curbei de sarcină.

#### □ A doua zi de miercuri a fiecărei luni, ora 21

În tabelul 7.1.52 (Anexa 7.1), respectiv figura 7.1.53, sunt prezentate datele referitoare la curbele de sarcină pentru 6 ani (2006-2011), pentru ora 21 a celei de-a doua zile de miercuri din fiecare lună. Ele au fost utilizate pentru antrenarea RNA.




Figura 7.1.53. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

În tabelul 7.1.53 (Anexa 7.1), respectiv figura 7.1.54, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2012 și 2013, utilizate pentru verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.1.54. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Analiza datelor evidențiază concluzii asemănătoare cu cele prezentate pentru ora 9, a celei de-a doua zile de miercuri a fiecărei luni, cu mențiunea că tendințele de creștere sau de scădere a consumului sunt mai contradictorii, mai diferite de la un an la altul, ceea ce semnalează un grad mai redus de corelare a curbelor de sarcină.

În primă instanță se prezintă rezultatele obținute în [Deacu2015] cu diverse metode de prognoză.

În tabelul 7.1.54 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru ansamblul curbei de sarcină, diferențele relative față de valorile cunoscute (în %) și abaterile pătratice. Este evidențiată și valoarea indicelui global de performanță ( $s_{total}$ ), definit ca suma pătratelor abaterilor pentru cei 2 ani și cele 12 valori lunare ( $s_{2012}$ ,  $s_{2013}$ ).

Grafic, aceste rezultate sunt prezentate în figurile 7.1.55 și 7.1.56 (comparativ, pentru toate metodele utilizate în [Deacu2015]).

Similar, în tabelul 7.1.55 (Anexa 7.1) se prezintă prognoza obținută prin utilizarea RNA pentru fiecare lună în parte, ilustrată grafic tot în figurile 7.1.55 și 7.1.56.




Figura 7.1.55. Analiza comparativă a rezultatelor pentru anul 2012




Figura 7.1.56. Analiza comparativă a rezultatelor pentru anul 2013

În continuare se prezintă rezultatele obținute cu metoda elaborată în cadrul acestei teze. Valorile prognozate, diferențele față de cele cunoscute și abaterea pătratică relativă sunt prezentate în tabelele 7.1.56 (RNA bayesiană, curba de sarcină) și 7.1.57 (RNA bayesiană, lunar). Grafic, ele sunt prezentate în figurile 7.1.57 și 7.1.58.

Tabelul 7.1.56. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	15.0	16.02	6.8	46.6	Ian	12.0	14.12	17.7	312.1
Feb	12.5	14.17	13.4	178.5	Feb	13.9	14.88	7.0	49.3
Mar	13.0	13.31	2.4	5.7	Mar	14.0	13.60	-2.9	8.2
Apr	11.5	11.44	-0.6	0.3	Apr	12.7	11.81	-7.0	49.1
Mai	12.8	12.20	-4.7	21.6	Mai	13.4	12.96	-3.3	10.8
Iun	10.0	10.93	9.3	86.5	Iun	12.9	11.42	-11.5	131.6
Iul	8.0	9.14	14.3	203.1	Iul	9.0	9.64	7.1	51.0
Aug	9.5	9.58	0.8	0.7	Aug	10.0	9.65	-3.5	12.4
Sep	13.0	11.96	-8.0	64.0	Sep	12.0	11.33	-5.6	30.8
Oct	11.0	12.64	14.9	222.3	Oct	13.5	13.51	0.0	0.0
Nov	15.0	14.26	-4.9	24.3	Nov	14.0	13.94	-0.4	0.2
Dec	13.0	13.61	4.7	22.0	Dec	14.5	13.77	-5.0	25.2
$S_{2012}$	875.58				$S_{2013}$	680.79			
$S_{total} = 1556.37$									

Tabelul 7.1.57. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	15.0	14.5	-3.1	9.8	Ian	12.0	12.6	4.9	24.2
Feb	12.5	12.9	3.4	11.3	Feb	13.9	13.5	-2.7	7.5

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Mar	13.0	12.9	-0.5	0.2	Mar	14.0	13.8	-1.8	3.2
Apr	11.5	11.3	-1.4	1.9	Apr	12.7	12.2	-4.0	16.1
Mai	12.8	12.9	0.9	0.9	Mai	13.4	13.2	-1.4	2.0
Iun	10.0	11.2	12.1	146.4	Iun	12.9	11.8	-8.4	71.4
Iul	8.0	7.8	-2.5	6.3	Iul	9.0	8.7	-3.3	11.1
Aug	9.5	9.5	-0.2	0.0	Aug	10.0	9.9	-1.0	1.0
Sep	13.0	12.7	-2.1	4.3	Sep	12.0	12.4	3.1	9.5
Oct	11.0	11.8	7.6	58.3	Oct	13.5	13.1	-2.7	7.1
Nov	15.0	14.8	-1.1	1.3	Nov	14.0	14.4	2.6	6.6
Dec	13.0	13.5	3.8	14.2	Dec	14.5	14.0	-3.6	12.9
$S_{2012}$	254.96				$S_{2013}$	172.57			
$S_{total} = 427.53$									




Figura 7.1.57. Analiza comparativă pentru 2012




Figura 7.1.58. Analiza comparativă pentru 2013

În tabelul 7.1.59 s-au reunit indicii de performanță pentru metodele de prognoză utilizate în [Deacu2015] și teza de față.

Tabelul 7.1.59. Valoarea comparativă a indicilor de performanță

	RNA, curba de sarcină			RNA, lunar		
	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]	[Deacu2015]	Bayesian	Ameliorare indice de performanță [%] față de [Deacu2015]
$S_{2012}$	1218.71	875.58	28.2	387.21	254.96	34.2
$S_{2013}$	819.13	680.79	16.9	244.18	172.57	29.3
$S_{total}$	2037.84	1556.37	23.6	631.39	427.53	32.3

Analiza în detaliu a rezultatelor obținute evidențiază concluzii calitative și cantitative asemănătoare cu cele menționate anterior, pentru ora 9 a celei de-a doua zile de miercuri a fiecărei luni.

Analiza comparativă cantitativă a rezultatelor obținute cu diverse metode conduce la următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele prezentate în [Deacu2015] (cu 24-32%);
- în ceea ce privește defalcarea pe cei 2 ani (2012 și 2013), ameliorarea este de același ordin de mărime pentru ambii ani, atât la prognoza lunară cât și la cea pentru ansamblul curbei de sarcină.

#### 7.1.4. Concluzii privind studiile comparative

Prima secțiune a părții aplicative a tezei de doctorat validează modelele de calcul elaborate, prin realizarea unor comparații cu rezultatele obținute în alte două teze de doctorat cu subiect similar ([Deacu2015] și [Chiș2015]), în scopul demonstrării calităților superioare ale metodelor de prognoză bazate pe utilizarea rețelelor neuronale bayesiene.

Primul set de comparații se referă la operatorul Enel Distribuție Banat și UTR componente: prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie, utilizând valorile măsurate din oră în oră (ora 1, ..., ora 24) ale puterii active consumate.

Datele pe 10 ani (2001-2010) s-au utilizat pentru antrenarea RNA, iar cele pentru următorii 3 ani (2011-2013) pentru verificarea prognozelor obținute.

S-au selectat două dintre cele 5 analize efectuate în [Deacu 2015] și [Chiș2015] (UTR Reșița și ansamblul Enel Banat), rezultând următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele din [Deacu2015] (cu 12-14% pentru UTR Reșița și 6-10% pentru Enel Banat) și [Chiș2015] (cu 46% pentru UTR Reșița și 36% pentru Enel Banat);
- în ceea ce privește defalcarea pe cei 3 ani (2011, 2012, 2013), la comparația cu [Deacu2015] pentru UTR Reșița ameliorarea cea mai accentuată apare pentru anul 2011, scăzând constant în 2012 și 2013 (atât pentru prognoza orară cât și cea pentru ansamblul curbei de sarcină);
- în același context, pentru Enel Banat situația este similară pentru prognoza orară, iar la cea pentru ansamblul curbei de sarcină este practic constantă la toți anii;
- la componentele anuale apar și două excepții, când rezultatele obținute cu RNA bayesiene sunt ușor inferioare, fără a afecta concluzia globală de la primul punct (prognoza orară pentru anul 2013 față de [Deacu2015] și cea pentru ansamblul curbei de sarcină, anul 2013, față de [Chiș2015]).

Al doilea set de comparații vizează stații de transformare de 110 kV / m.t. din UTR Timișoara: prognoza curbelor de sarcină definite de puterile consumate la o anumită oră a unei anumite zile pentru fiecare dintre cele 12 luni ale anului.

Primii 6 ani dintre cei 8 pentru care se cunosc datele de consum (2006-2011) s-au utilizat pentru antrenarea RNA, iar ultimii 2 ani (2012 și 2013) pentru verificarea prognozelor obținute.

S-a ales una dintre cele 5 stații analizate în [Deacu2015]: 110 / 20 kV Victoria, cu prognoze efectuate pentru ora 9 și 21 a ultimei zile de joi a fiecărei luni, a primei zile de marți și a celei de a doua zile de miercuri, rezultând următoarele concluzii:

- în toate situațiile metodele utilizând RNA bayesiene conduc, per total, la rezultate mai bune față de cele din [Deacu2015], ameliorarea fiind de 13-28% pentru prognoza curbei de sarcină în ansamblu, respectiv 9-39% pentru prognoza lunară;
- există 2 cazuri (pentru ziua de marți) când ameliorarea este foarte mare (prognoza lunară pentru ora 9-77% și cea a ansamblului curbei de sarcină, ora 21-44%), explicabile prin corelarea extrem de slabă a curbelor de sarcină cunoscute;
- tot pentru ziua de marți (ora 9) apare singura situație când rezultatul obținut cu RNA bayesiană pentru unul dintre anii pentru care s-a efectuat prognoza (2013) este inferior (cu 3,2%) celui din [Deacu2015], fără a fi afectată concluzia de la comparația globală (superioritatea rezultatelor obținute cu RNA bayesiană).

## 7.2. Enel Distribuție Banat și UTR componente

### 7.2.1. Considerații preliminare

Acest subcapitol prezintă o serie de studii de prognoză realizate atât pentru ansamblul rețelei de distribuție aflată în gestiunea Enel Distribuție Banat cât și pentru unitățile teritoriale rețea (UTR) componente: Arad, Deva, Reșița și Timișoara.

Se efectuează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie, utilizând valorile cunoscute ale puterii medii orare din oră în oră (ora 1, ora 2, ..., ora 23, ora 24). Se menționează că s-au considerat în exclusivitate zilele lucrătoare – zilele de joi cele mai apropiate de ziua de 21 iunie: 2006 – 22 iunie, 2007 – 21 iunie, 2008 – 19 iunie, 2009 – 18 iunie, 2010 – 24 iunie, 2011 – 23 iunie, 2012 – 21 iunie, 2013 – 20 iunie, 2014 – 19 iunie, 2015 – 18 iunie, 2016 – 23 iunie, 2017 – 22 iunie, 2018 – 21 iunie.

Primii 10 ani (din cei 13 pentru care se cunosc datele de consum), 2006-2015, s-au utilizat pentru antrenarea RNA, iar ultimii 3 ani, 2016-2018, pentru verificarea prognozelor obținute.

Pentru prognoza curbelor de sarcină s-au aplicat abordări bazate pe utilizarea RNA bayesiene:

- prognoza pentru ansamblului curbei de sarcină – 24 ore (RNA curba de sarcină);
- prognoza individuală pentru fiecare oră în parte (RNA orar).

Ultima parte a subcapitolului prezintă un studiu de previzionare a calității prognozelor în funcție de datele cunoscute, utilizând metoda prezentată în [Deacu2015], bazată pe diferențe finite.

La finele subcapitolului se evidențiază o serie de comentarii și concluzii, cu caracter mai general sau particular, vizând atât rezultatele concrete ale prognozelor cât și RNA utilizate. O atenție specială se acordă comparării rezultatelor obținute cu cele două metode, evidențierii calității acestora, aprecierii influenței gradului de corelare a curbelor de sarcină asupra calității prognozelor realizate.

### 7.2.2. UTR Arad

În tabelul 7.2.1, respectiv figura 7.2.1, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2006-2015), aferente zilei cele mai semnificative de vară (în condițiile menționate în paragraful 7.2.1). Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.2.2, respectiv figura 7.2.2, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2016, 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.2.1. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)

Tabelul 7.2.1. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
1	69.9	65.0	55.3	61.2	63.3	64.8	61.3	62.6	65.0	71.0
2	67.4	61.2	52.3	58.0	59.3	59.9	56.4	57.6	59.9	65.2
3	66.2	58.0	50.1	55.8	56.9	57.6	54.1	56.3	58.5	63.0
4	65.1	57.3	49.0	54.1	55.7	55.8	54.3	55.4	57.4	61.2
5	66.3	59.0	50.9	56.0	58.0	58.1	58.5	55.2	58.4	62.2
6	69.3	63.6	54.6	59.8	61.7	60.3	58.6	58.3	58.2	64.1
7	72.3	65.8	56.4	64.2	63.4	63.6	61.8	60.6	60.7	67.5
8	84.9	80.7	70.6	82.9	79.9	81.3	78.3	78.8	78.7	82.2
9	89.9	86.0	77.6	86.5	85.0	84.8	83.0	84.6	83.0	87.6
10	88.1	88.1	78.6	84.5	85.0	85.4	81.6	85.5	84.3	87.5
11	84.1	84.0	75.3	81.3	80.8	81.1	78.5	81.9	80.8	85.0
12	83.6	85.0	75.9	80.5	80.6	82.3	80.3	83.7	80.9	86.3
13	84.6	84.6	77.8	81.6	83.2	84.9	81.5	84.5	82.3	87.2
14	84.4	84.6	78.2	81.9	84.8	88.0	81.7	86.8	83.8	87.0
15	83.1	79.7	77.2	82.2	82.2	87.3	80.0	84.0	84.1	86.6
16	78.2	73.8	70.8	76.0	77.6	81.9	74.5	78.6	79.9	80.0
17	75.3	72.0	68.6	73.4	74.2	78.1	71.5	75.9	79.0	79.0
18	73.9	70.5	66.5	71.5	70.6	76.6	69.7	75.0	74.5	77.4
19	72.3	67.8	64.8	69.6	69.5	72.1	66.8	71.8	71.7	76.3
20	71.6	67.2	65.0	67.7	68.3	68.5	66.0	71.4	71.2	74.3
21	80.2	73.6	69.1	70.0	69.8	72.8	68.1	74.0	72.4	74.4
22	90.5	89.0	83.6	80.1	79.5	74.6	76.4	87.0	88.1	89.3
23	81.5	84.8	81.4	81.1	81.3	75.4	82.4	81.0	83.3	84.2
24	71.7	73.6	69.5	70.8	70.8	69.0	72.3	69.5	75.4	76.1




Figura 7.2.2. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Tabelul 7.2.2. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Anul / Ora	2016	2017	2018	Anul / Ora	2016	2017	2018
1	69.3	72.1	76.5	13	91.6	89.9	94.2
2	64.4	65.7	69.9	14	93.8	91.5	94.1
3	63.5	66.2	71.3	15	90.9	91.0	93.4
4	62.3	64.8	69.1	16	85.6	86.9	87.0
5	62.2	65.3	69.6	17	82.7	85.9	85.9
6	65.0	66.1	71.0	18	81.9	81.5	84.5
7	67.7	68.9	73.0	19	78.6	78.7	83.4
8	85.7	85.7	89.3	20	78.2	78.0	81.2
9	91.6	90.8	94.5	21	81.0	79.3	81.3
10	92.6	91.3	94.4	22	93.9	95.1	96.5
11	89.1	87.8	91.8	23	88.4	90.6	91.4
12	90.8	88.8	93.3	24	76.6	82.5	83.0



Analiza datelor din tabelele 7.2.1 și 7.2.2, respectiv a figurilor 7.2.1 și 7.2.2, evidențiază următoarele concluzii:

- pentru perioada 2006-2015 evoluția este ambiguă, cu alte cuvinte nu există o tendință explicită de creștere sau de scădere a puterii pe ansamblu;
- curbele de sarcină "se intersectează", ceea ce înseamnă că forma lor diferă (mai ales în anumite zone orare), semnalând probleme de corelare "pe orizontală";
- pentru perioada 2016-2018 se poate remarca un trend general crescător al puterii medii orare pe ansamblu (cu mici "sincope" pentru anul 2017, zonele orară 9-13 și 18-21), ceea ce, corelat cu prima observație, poate conduce la probleme în ceea ce privește calitatea prognozelor care vor fi obținute;
- gradul de corelare a curbelor de sarcină este relativ redus (evoluție în timp și forma pe durata unei zile), ceea ce întărește previziunea de la punctul anterior.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.2.3 (RNA bayesiană, curba de sarcină) și 7.2.4 (RNA bayesiană, orar). În ultima linie a tabelului este dată valoarea indicelui de performanță ( $S_{total}$ ), definit ca suma indicilor parțiali ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor celor 24 valori orare pentru anul aferent. Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figurile 7.2.3 (anul 2016), 7.2.4 (anul 2017) și 7.2.5 (anul 2018).

Tabelul 7.2.3. Curbele de sarcină prognozate (puterile în MW) pentru perioada 2016-2018 (RNA bayesiană, curba de sarcină)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	69.3	71.1	2.61	6.83	1	72.1	72.3	0.24	0.06	1	76.5	73.4	-3.99	15.91
2	64.4	64.0	-0.68	0.46	2	65.7	65.5	-0.25	0.06	2	69.9	67.1	-3.94	15.56
3	63.5	63.7	0.34	0.11	3	66.2	64.6	-2.41	5.82	3	71.3	67.9	-4.77	22.74
4	62.3	61.6	-1.18	1.40	4	64.8	62.9	-2.96	8.77	4	69.1	65.6	-5.07	25.66
5	62.2	61.0	-1.99	3.94	5	65.3	62.5	-4.26	18.15	5	69.6	65.3	-6.18	38.17
6	65.0	63.6	-2.11	4.45	6	66.1	65.1	-1.49	2.23	6	71.0	66.6	-6.17	38.02
7	67.7	71.2	5.18	26.83	7	68.9	72.1	4.60	21.19	7	73.0	72.7	-0.41	0.17
8	85.7	87.5	2.05	4.22	8	85.7	88.7	3.51	12.32	8	89.3	90.0	0.74	0.55
9	91.6	93.6	2.21	4.89	9	90.8	94.4	4.01	16.11	9	94.5	95.3	0.81	0.66
10	92.6	92.6	0.00	0.00	10	91.3	93.8	2.71	7.35	10	94.4	95.0	0.59	0.35
11	89.1	90.1	1.12	1.26	11	87.8	89.8	2.28	5.19	11	91.8	94.1	2.51	6.28
12	90.8	93.3	2.75	7.58	12	88.8	92.5	4.17	17.36	12	93.3	96.9	3.86	14.89
13	91.6	93.6	2.20	4.86	13	89.9	94.1	4.67	21.83	13	94.2	96.7	2.63	6.91
14	93.8	91.2	-2.75	7.59	14	91.5	92.4	0.95	0.90	14	94.1	93.5	-0.61	0.37
15	90.9	93.0	2.26	5.09	15	91.0	94.4	3.74	13.97	15	93.4	95.9	2.64	6.96
16	85.6	87.4	2.10	4.42	16	86.9	90.3	3.91	15.31	16	87.0	92.4	6.21	38.53
17	82.7	82.5	-0.23	0.05	17	85.9	83.6	-2.71	7.33	17	85.9	84.6	-1.46	2.13
18	81.9	83.7	2.21	4.89	18	81.5	84.7	3.93	15.43	18	84.5	85.7	1.41	2.00
19	78.6	75.7	-3.69	13.64	19	78.7	77.5	-1.50	2.26	19	83.4	79.4	-4.83	23.36
20	78.2	79.7	1.92	3.68	20	78.0	80.8	3.59	12.89	20	81.2	82.9	2.09	4.38
21	81.0	78.6	-2.98	8.88	21	79.3	79.8	0.66	0.44	21	81.3	81.1	-0.28	0.08
22	93.9	93.1	-0.83	0.69	22	95.1	94.2	-0.95	0.91	22	96.5	95.3	-1.28	1.64
23	88.4	90.7	2.60	6.77	23	90.6	92.6	2.21	4.87	23	91.4	93.9	2.74	7.48
24	76.6	79.0	3.11	9.65	24	82.5	80.8	-2.11	4.47	24	83.0	82.6	-0.53	0.28
$S_{2016}$	132.19				$S_{2017}$	215.21				$S_{2018}$	273.05			
$S_{total} = 620.45$														

Tabelul 7.2.4. Curbele de sarcină prognozate (puterile în MW) pentru perioada 2016-2018 (RNA bayesiană, orar)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	69.3	71.1	2.54	6.44	1	72.1	73.1	1.45	2.09	1	76.5	75.3	-1.60	2.55
2	64.4	65.9	2.33	5.45	2	65.7	66.8	1.61	2.60	2	69.9	67.6	-3.26	10.63
3	63.5	64.3	1.30	1.68	3	66.2	66.7	0.70	0.49	3	71.3	69.1	-3.12	9.74
4	62.3	63.3	1.55	2.41	4	64.8	65.6	1.22	1.50	4	69.1	68.0	-1.60	2.57
5	62.2	63.7	2.40	5.78	5	65.3	65.7	0.64	0.42	5	69.6	67.8	-2.58	6.66
6	65.0	65.4	0.67	0.45	6	66.1	67.3	1.87	3.48	6	71.0	69.3	-2.43	5.89
7	67.7	68.2	0.71	0.51	7	68.9	70.1	1.71	2.94	7	73.0	72.0	-1.34	1.78
8	85.7	85.2	-0.64	0.41	8	85.7	86.9	1.35	1.81	8	89.3	88.6	-0.81	0.66
9	91.6	90.6	-1.10	1.22	9	90.8	92.1	1.45	2.10	9	94.5	93.7	-0.89	0.79
10	92.6	91.7	-0.98	0.96	10	91.3	92.7	1.55	2.40	10	94.4	93.7	-0.69	0.48
11	89.1	88.3	-0.88	0.77	11	87.8	89.7	2.16	4.64	11	91.8	91.1	-0.78	0.60
12	90.8	89.4	-1.56	2.44	12	88.8	90.7	2.15	4.63	12	93.3	92.1	-1.33	1.77
13	91.6	90.3	-1.43	2.06	13	89.9	91.7	1.98	3.92	13	94.2	93.1	-1.18	1.39
14	93.8	92.8	-1.09	1.18	14	91.5	92.9	1.53	2.33	14	94.1	93.0	-1.16	1.34
15	90.9	90.6	-0.35	0.12	15	91.0	91.8	0.90	0.81	15	93.4	93.1	-0.36	0.13
16	85.6	85.7	0.16	0.03	16	86.9	86.5	-0.48	0.23	16	87.0	87.2	0.27	0.07
17	82.7	83.4	0.88	0.77	17	85.9	84.9	-1.22	1.48	17	85.9	86.3	0.47	0.22
18	81.9	81.4	-0.64	0.41	18	81.5	82.6	1.38	1.91	18	84.5	83.9	-0.72	0.52
19	78.6	78.0	-0.76	0.57	19	78.7	80.4	2.10	4.42	19	83.4	82.8	-0.77	0.59
20	78.2	77.8	-0.45	0.20	20	78.0	79.3	1.61	2.59	20	81.2	80.7	-0.64	0.41
21	81.0	80.4	-0.71	0.51	21	79.3	80.6	1.66	2.74	21	81.3	80.8	-0.61	0.37
22	93.9	94.2	0.32	0.10	22	95.1	95.3	0.21	0.04	22	96.5	96.3	-0.17	0.03
23	88.4	88.2	-0.23	0.05	23	90.6	89.9	-0.78	0.60	23	91.4	91.6	0.22	0.05
24	76.6	78.3	2.28	5.19	24	82.5	80.9	-1.97	3.88	24	83.0	83.5	0.57	0.32
$S_{2016}$	39.72				$S_{2017}$	54.04				$S_{2018}$	49.57			
$S_{total} = 143.33$														

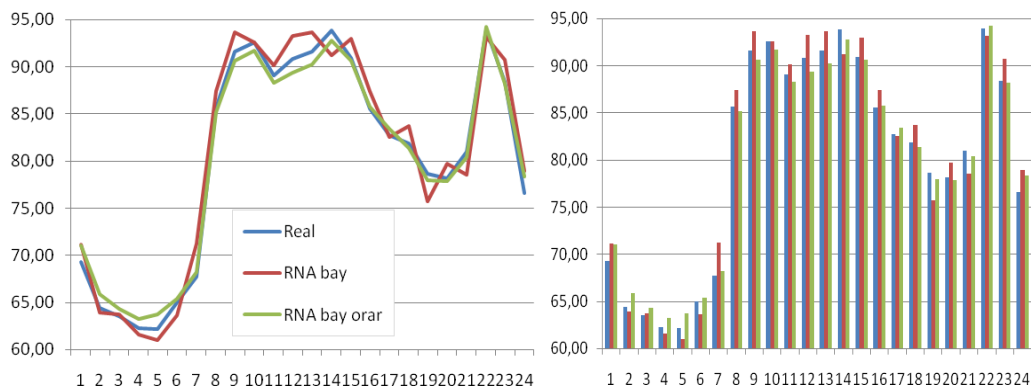


Figura 7.2.3. Analiza comparativă a rezultatelor pentru anul 2016




Figura 7.2.4. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.2.5. Analiza comparativă a rezultatelor pentru anul 2018

În tabelul 7.2.5 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.

Tabelul 7.2.5. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2016}$	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	132.19	215.21	273.05	620.45
RNA bayesiană, orar	39.72	54.04	49.57	143.33

Analiza comparativă a rezultatelor obținute cu cele două metode de prognoză conduce la următoarele concluzii:

- rezultatele confirmă observațiile făcute la analiza curbelor de sarcină pentru perioada 2006-2015, respectiv 2016-2018;
- prognoza orară oferă rezultate mult mai bune față de cele obținute cu prognoza ansamblului curbei de sarcină (indice global de performanță 143 față de 621), situație explicabilă prin slaba corelare a formei curbelor de sarcină;
- totuși, comparativ, se poate afirma că prognoza orară reușește să "prindă" mai bine forma curbelor de sarcină pentru perioada 2016-2018;
- analiza valorii indicilor anuali de performanță ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) evidențiază valori practic de același ordin de mărime, totuși crescătoare, ceea ce înseamnă o ușoară alterare a calității prognozelor pe măsură ce ne îndepărtăm de zona cunoscută;
- în ton cu concluziile anterioare, la curbele de culoare roșie din fig. 7.2.3-7.2.5 (prognoza ansamblului curbei de sarcină) se observă zone unde diferența este relativ mai mare față de cele de culoare albastră și verde (consumul real, respectiv cel prognozat cu RNA orar), datorate slabei corelări a formei curbelor de sarcină.

### 7.2.3. UTR Deva

În tabelul 7.2.6 (anexa 7.2), respectiv figura 7.2.6, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2006-2015), aferente zilei celei mai semnificative de vară (în condițiile menționate în paragraful 7.2.1). Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.2.7 (anexa 7.2), respectiv figura 7.2.7, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2016, 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.2.6. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)




Figura 7.2.7. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Analiza datelor din tabelele 7.2.6 și 7.2.7 (Anexa 7.2), respectiv a figurilor 7.2.6 și 7.2.7, evidențiază următoarele concluzii:

- se remarcă o tendință destul de clară de scădere a puterii pe ansamblu pentru perioada 2006-2015 ;
- curbele de sarcină "se intersectează", ceea ce înseamnă că forma lor diferă (mai ales în anumite zone orare), semnalând probleme de corelare "pe orizontală", cam în aceeași măsură ca la UTR Arad, dar mai puțin decât pentru UTR Reșița;
- pentru perioada 2016-2018 continuă trendul general descrescător, cu excepția, orelor 11, 15, 21, 23 și cu unele creșteri în 2018 (orele 4, 6, 7, 11-14), ceea ce va pune probleme la prognoza curbelor de sarcină;
- gradul de corelare a curbelor de sarcină este relativ redus (evoluție în timp și forma pe durata unei zile), situația fiind totuși mai bună comparativ cu UTR Arad și mult mai bună față de UTR Reșița.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.2.8 (RNA bayesiană, curba de sarcină) și 7.2.9 (RNA bayesiană, orar), Anexa 7.2. În ultima linie a tabelului este dată valoarea indicelui de performanță ( $S_{total}$ ), definit ca suma indicilor

parțiali ( $s_{2016}$ ,  $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor celor 24 valori orare pentru anul aferent. Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figurile 7.2.8 (anul 2016), 7.2.9 (anul 2017) și 7.2.10 (anul 2018).




Figura 7.2.8. Analiza comparativă a rezultatelor pentru anul 2016




Figura 7.2.9. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.2.10. Analiza comparativă a rezultatelor pentru anul 2018

În tabelul 7.2.10 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.

Tabelul 7.2.10. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$s_{2016}$	$s_{2017}$	$s_{2018}$	$s_{total}$
RNA bayesiană, curba de sarcină	63.63	121.20	115.72	300.55
RNA bayesiană, orar	34.33	68.72	69.60	172.65

Analiza comparativă a rezultatelor obținute cu cele două metode de prognoză conduce la următoarele concluzii:

- rezultatele confirmă observațiile făcute la analiza curbelor de sarcină pentru perioada 2006-2015, respectiv 2016-2018;
- prognoza orară oferă rezultate mult mai bune față de cele obținute cu prognoza ansamblului curbei de sarcină (indice global de performanță 173 față de 301), situație explicabilă prin gradul de corelare a formei curbelor de sarcină;
- analiza indicilor anuali de performanță evidențiază valori de aceeași ordin de mărime pentru  $s_{2017}$  și  $s_{2018}$ , respectiv mult mai bune pentru  $s_{2016}$ , ceea ce înseamnă că pentru anul 2016 curba de sarcină "seamănă" mai mult cu cele din anii anteriori (comparativ cu cea din 2017 sau 2018);
- la curbele de culoare roșie din figurile 7.2.8 - 7.2.10 (prognoza ansamblului curbei de sarcină cu RNA ) se observă unele ore unde diferența este relativ mai mare față de cele de culoare albastră și verde (consumul real, respectiv cel prognozat cu RNA orar), element legat de forma curbelor de sarcină din anii 2006-2015 (la acele ore nu este respectată tendința generală de scădere a consumului de la celelalte ore);
- prognoza cu RNA orar, care consideră consumurile la diverse ore independente între ele, reușește să soluționeze mai bine aceste situații.

#### 7.2.4. UTR Reșița

În tabelul 7.2.11 (anexa 7.2), respectiv figura 7.2.11, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2006-2015), aferente zilei celei mai semnificative de vară (în condițiile menționate în paragraful 7.2.1). Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.2.12 (anexa 7.2), respectiv figura 7.2.12, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2016, 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.2.11. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)




Figura 7.2.12. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Analiza datelor din tabelele 7.2.11 și 7.2.12 (Anexa 7.2), respectiv a curbelor de sarcină figurile 7.2.11 și 7.2.12, evidențiază de la bun început o serie de concluzii, ce permit previzionarea calității prognozelor care vor fi obținute:

- pentru perioada 2006-2015 evoluția este ambiguă, cu alte cuvinte nu există o tendință explicită de creștere sau de scădere a puterii pe ansamblu;
- curbele de sarcină "se intersectează", ceea ce înseamnă că forma lor diferă (mai ales în anumite zone orare), semnalând probleme mult mai mari de corelare "pe orizontală" comparativ cu UTR Arad și UTR Deva;
- observațiile anterioare sunt valabile și pentru anii 2016-2018;
- consumurile cele mai mari se remarcă în primii 3 ani (2006-2008), cu scăderi importante între orele 17-22 (în 2007), respectiv 1-7 (2008), când, probabil, un mare consumator era în funcțiune;
- gradul de corelare a curbelor de sarcină este extrem de redus, atât din punctul de vedere al evoluției în timp, cât și al formei pe durata unei zile.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.2.13 (RNA bayesiană, curba de sarcină) și 7.2.14 (RNA bayesiană, orar), Anexa 7.2. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2016}$ ,  $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 24 valori orare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.2.13 (anul 2016), figura 7.2.14 (anul 2017) și figura 7.2.15 (anul 2018).




Figura 7.2.13. Analiza comparativă a rezultatelor pentru anul 2016




Figura 7.2.14. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.2.15. Analiza comparativă a rezultatelor pentru anul 2018

În tabelul 7.2.15 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.

Tabelul 7.2.15. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2016}$	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	358.93	381.99	362.50	1103.42
RNA bayesiană, orar	57.54	60.61	72.06	190.21

Analiza comparativă a rezultatelor obținute cu cele două metode de prognoză conduce la următoarele concluzii:

- rezultatele confirmă pe deplin observațiile făcute la analiza curbelor de sarcină pentru perioada 2006-2015, respectiv 2016-2018;
- prognoza orară oferă rezultate mult mai bune față de cele obținute cu prognoza ansamblului curbei de sarcină (indice global de performanță 190 față de 1103), situație explicabilă prin gradul redus de corelare a formei curbelor de sarcină;
- totuși, comparativ, se poate afirma că prognoza orară reușește să "prindă" mai bine forma curbelor de sarcină pentru perioada 2016-2018;
- analiza valorii indicilor anuali de performanță ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) evidențiază valori practic de același ordin de mărime, totuși crescătoare, ceea ce înseamnă o ușoară alterare a calității prognozelor pe măsură ce ne îndepărtăm de zona cunoscută;
- în spiritul concluziei anterioare, la curbele de culoare roșie din figurile 7.2.13 - 7.2.15 (prognoza ansamblului curbei de sarcină cu RNA) se observă o serie de "vârfuri", datorate slabei corelări a formei curbelor de sarcină din anii 2006-2015, care conduc la o valoare mai slabă a lui  $S_{total}$  comparativ cu RNA orar;
- zonele orare ale acestor vârfuri sunt legate de zonele orare similare ale curbelor de sarcină reale din perioada 2006-2015 (figura 7.2.11), respectiv perioada 2016-2018 (figura 7.2.12).

### 7.2.5. UTR Timișoara

În tabelul 7.2.16 (Anexa 7.2), respectiv figura 7.2.16, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2006-2015), aferente zilei celei mai semnificative de vară (în condițiile menționate în paragraful 7.2.1). Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.2.17 (Anexa 7.2), respectiv figura 7.2.17, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2016, 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.






Figura 7.2.16. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)




Figura 7.2.17. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Analiza datelor din tabelele 7.2.16 și 7.2.17 (Anexa 7.2), respectiv a figurilor 7.2.16 și 7.2.17, evidențiază următoarele concluzii:

- pentru perioada 2006-2015 evoluția este neclară, observându-se alternarea unor perioade de creștere, respectiv de scădere, într-o plajă relativ îngustă de valori;
- curbele de sarcină nu "se intersectează" prea mult, ceea ce reflectă o corelare relativ mai bună "pe orizontală" decât la cele trei UTR-uri prezentate anterior (Arad, Deva și Reșița);
- pentru perioada 2016-2018 continuă același trend destul de neclar, la fel ca pentru perioada 2006-2015, dar din nou cu o formă asemănătoare (între ele, respectiv cu cele din perioada 2006-2015);
- în concluzie, gradul de corelare a curbelor de sarcină este relativ bun din punctul de vedere al formei pe durata unei zile, superior celor de la celelalte UTR-uri (Reșița, Arad și Deva), ceea ce prefigurează posibilitatea obținerii unor prognoze de calitate superioară.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.2.18 (RNA bayesiană, curba de sarcină) și 7.2.19 (RNA bayesiană, orar), Anexa 7.2.

În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 24 valori orare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.2.18 (anul 2016), figura 7.2.19 (anul 2017) și figura 7.2.20 (anul 2018).




Figura 7.2.18. Analiza comparativă a rezultatelor pentru anul 2016




Figura 7.2.19. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.2.20. Analiza comparativă a rezultatelor pentru anul 2018

În tabelul 7.2.20 s-au reunit indicii de performanță pentru metodele utilizate.

Tabelul 7.2.20. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2016</sub>	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	85.10	96.19	92.54	273.83
RNA bayesiană, orar	16.39	15.99	15.73	48.11

Analiza comparativă a rezultatelor obținute cu cele două metode de prognoză conduce la următoarele concluzii:

- rezultatele confirmă observațiile făcute la analiza curbelor de sarcină pentru perioada 2006-2015, respectiv 2016-2018;

- prognoza orară oferă rezultate mult mai bune față de cele obținute cu prognoza ansamblului curbei de sarcină (indice global de performanță 48 față de 274), situație explicabilă prin gradul totuși relativ redus de corelare a formei curbelor de sarcină pentru perioada 2016-2018 (anii pentru care se efectuează prognoza);
- totuși, comparativ cu cele trei UTR-uri prezentate anterior (Arad, Deva și Reșița), rezultatele sunt pe departe cele mai bune, situație previzibilă dacă se au în vedere comentariile privind curbele de sarcină (cele pentru antrenare și cele pentru verificare);
- analiza valorii indicilor anuali de performanță ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) evidențiază valori foarte apropiate, ceea ce înseamnă calitate similară a prognozei pentru toți anii;
- la curbele de culoare roșie din figurile 7.2.18-7.2.20 (prognoza ansamblului curbei de sarcină cu RNA) se observă câteva ore unde diferența este relativ mai mare față de cele de culoare albastră și verde (consumul real, respectiv cel prognozat cu RNA orar): 3-5, 9-10, 22-23 (în tabelul 7.2.18 valorile aferente ale abaterii pătratice relative sunt cele mai mari);
- prognoza cu RNA orar, care consideră consumurile la diverse ore independente între ele, reușește să soluționeze mai bine aceste situații.

### 7.2.6. Enel Banat

În tabelul 7.2.21 (Anexa 7.2), respectiv figura 7.2.21, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2006-2015), aferente zilei celei mai semnificative de vară (în condițiile menționate în paragraful 7.2.1), pentru ansamblul Enel Distribuție Banat. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.2.22 (Anexa 7.2), respectiv figura 7.2.22, sunt prezentate datele referitoare la curbele de sarcină pentru anii 2016, 2017 și 2018, pentru ansamblul Enel Distribuție Banat, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.2.21. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)




Figura 7.2.22. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Analiza datelor din tabelele 7.2.21 și 7.2.22 (Anexa 7.2), respectiv a figurilor 7.2.21 și 7.2.22, evidențiază următoarele concluzii:

- pentru perioada 2006-2015 evoluția este neclară, observându-se alternarea unor perioade de creștere, respectiv de scădere, într-o plajă totuși relativ îngustă de valori;
- curbele de sarcină nu "se intersectează" prea mult, ceea ce reflectă o corelare mult mai bună "pe orizontală" decât la primele trei UTR-uri (Arad, Deva, Reșița) și chiar decât la UTR Timișoara;
- pentru perioada 2016-2018 continuă practic trendul destul de neclar, la fel ca și pentru perioada 2006-2015, dar din nou cu o formă destul de asemănătoare a curbelor (între ele, respectiv cu cea din perioada 2006-2015);
- în concluzie, gradul de corelare a curbelor de sarcină este relativ bun din punctul de vedere al formei pe durata unei zile, asemănător celui din cazul UTR Timișoara, ceea ce prefigurează posibilitatea obținerii unor prognoze mai bune (probabil unele dintre "necorelările" de la UTR-uri se anulează reciproc).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.2.23 (RNA bayesiană, curba de sarcină) și 7.2.24 (RNA bayesiană, orar), Anexa 7.2. În ultima linie a tabelului este dată valoarea indicelui de performanță ( $S_{total}$ ), definit ca suma indicilor parțiali ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor celor 24 valori orare pentru anul aferent. Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figurile 7.2.23 (anul 2016), 7.2.24 (anul 2017) și 7.2.25 (anul 2018).

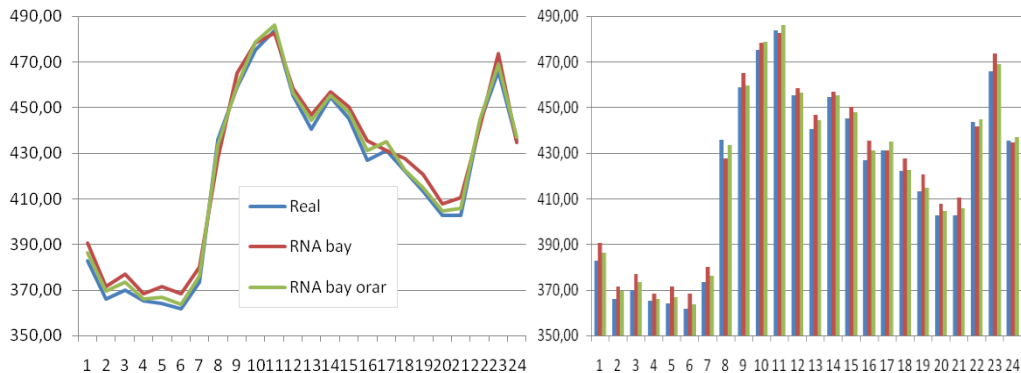


Figura 7.2.23. Analiza comparativă a rezultatelor pentru anul 2016




Figura 7.2.24. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.2.25. Analiza comparativă a rezultatelor pentru anul 2018

În tabelul 7.2.20 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.

Tabelul 7.2.25. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2016</sub>	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	48.51	62.01	50.22	160.74
RNA bayesiană, orar	9.91	13.89	13.98	37.76

Analiza comparativă a rezultatelor obținute cu cele două metode de prognoză conduce la următoarele concluzii:

- rezultatele confirmă în bună măsură observațiile de la analiza curbelor de sarcină;
- prognoza orară, utilizând prelucrarea independentă a datelor pentru fiecare oră în parte, oferă rezultate mai bune decât prognoza ansamblului curbei de sarcină (indice global de performanță 37.76, față de 160.74);
- observația anterioară sugerează că și în acest caz există probleme de corelare a formei curbelor de sarcină, situația fiind totuși mai bună decât la UTR Reșița, Arad sau Deva;
- se poate formula ipoteza "anulării" reciproce a unor necorelări existente în cazul UTR Reșița, Arad și Deva, rezultând o situație asemănătoare cu UTR Timișoara;
- analiza comparativă a indicilor anuali de performanță evidențiază valori de același ordin de mărime, cu alte cuvinte evoluția consumului este destul de bine "prinsă";
- analiza tabelelor 7.2.23 și 7.2.24 (Anexa 7.2) și a figurilor 7.2.23-7.2.25 indică totuși trei zone unde diferența este relativ mai mare față de consumul real – orele 4-6, 13 și 18-21, cauza regăsindu-se în figura 7.2.22 – curba roșie (2017) are o tendință diferită față de cea albastră și cea verde (2016, 2018);
- prognoza orară, care consideră consumurile independente la diverse ore, reușește să soluționeze mai bine aceste situații.

### 7.2.7. Analiza comparativă a rezultatelor

În acest paragraf se efectuează o analiză comparativă a rezultatelor pe baza valorii indicelui global (total) de performanță.

În tabelul 7.2.26 se prezintă rezultatele analizei, centralizând cele obținute pentru cele 4 UTR și ansamblul Enel Banat. Clasamentul s-a întocmit pe baza valorii unui indice specific de performanță, obținut prin divizarea valorii indicelui global de performanță cu 72 (3 ani x 24 ore = 72). Indicele specific oferă și posibilitatea comparării calității rezultatelor referitoare la UTR din acest subcapitol cu cele obținute pentru stații (subcapitolul 7.3).

Tabelul 7.2.26. Indicii specifici globali de performanță

Nr. crt.	UTR	RNA bayesiană, curbă de sarcină		RNA bayesiană, orar		Raport indici specifici
		Total	Specific	Total	Specific	
1	Enel Banat	160.74	2.23	37.76	0.52	4.26
2	UTR Timișoara	273.83	3.80	48.11	0.67	5.69
3	UTR Deva	300.55	4.17	172.65	2.40	1.74
4	UTR Arad	620.45	8.62	143.33	1.99	4.33
5	UTR Reșița	1103.42	15.33	190.21	2.64	5.80

În același context, tabelele 7.2.27, 7.2.28 și 7.2.29 conțin rezultatele prelucrate similar ale indicilor parțiali de performanță aferenți celor 3 ani ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ), pentru cele 4 UTR și ansamblul Enel Banat. De data aceasta indicele specific de performanță a rezultat prin divizarea celui parțial anual cu 24 (24 ore).

Tabelul 7.2.27. Indicii specifici anuali de performanță (2016)

Nr. crt.	UTR	RNA bayesiană, curbă de sarcină		RNA bayesiană, orar		Raport indici specifici
		Anual	Specific	Anual	Specific	
1	Enel Banat	48.51	2.02	9.91	0.41	4.90
2	UTR Timișoara	85.10	3.55	16.39	0.68	5.19
3	UTR Deva	63.63	2.65	34.33	1.43	1.85
4	UTR Arad	132.19	5.51	39.72	1.66	3.33
5	UTR Reșița	358.93	14.96	57.54	2.40	6.24

Tabelul 7.2.28. Indicii specifici anuali de performanță (2017)

Nr. crt.	UTR	RNA bayesiană, curbă de sarcină		RNA bayesiană, orar		Raport indici specifici
		Anual	Specific	Anual	Specific	
1	Enel Banat	62.01	2.58	13.89	0.58	4.46
2	UTR Timișoara	96.19	4.01	15.99	0.67	6.02
3	UTR Deva	121.20	5.05	68.72	2.86	1.77
4	UTR Arad	215.21	8.97	54.04	2.25	3.98
5	UTR Reșița	381.99	15.92	60.61	2.53	6.30

Tabelul 7.2.29. Indicii specifici anuali de performanță (2018)

Nr. crt.	UTR	RNA bayesiană, curbă de sarcină		RNA bayesiană, orar		Raport indici specifici
		Anual	Specific	Anual	Specific	
1	Enel Banat	50.22	2.09	13.98	0.58	3.59
2	UTR Timișoara	92.54	3.86	15.73	0.66	5.88
3	UTR Deva	115.72	4.82	69.60	2.90	1.66
4	UTR Arad	273.05	11.38	49.57	2.07	5.51
5	UTR Reșița	362.50	15.10	72.06	3.00	5.03

Pe baza analizei rezultatelor comparative de mai sus se pot formula o serie de concluzii, atât cu caracter particular cât și cu caracter mai general:

- clasamentul din tabelul 7.2.26 are pe primul loc ansamblul Enel Banat, urmat îndeaproape de UTR Timișoara și la o distanță relativ mai mare de celelalte UTR;
- concluzia anterioară se poate explica și prin faptul că prin însumare erorile se pot atenua, datorită semnelor contrare;

- la prognoza ansamblului curbei de sarcină indicii specifici de performanță acoperă o plajă relativ largă de valori, de la 2.02 (Enel Banat, 2016) până la 15.92 (UTR Reșița, 2017);
- la prognoza orară plaja de valori este mult mai restrânsă (0.41 – Enel Banat 2016, 3.00 – UTR Reșița 2018);
- pe baza ultimei coloane din tabelul 7.2.26 se poate concluziona că prognoza orară este de 2-6 ori mai bună decât cea a ansamblului curbei de sarcină;
- valoarea indicelui specific de performanță depinde de datele inițiale (2006-2015), de gradul de corelare a curbelor de sarcină utilizate pentru antrenarea RNA, de evoluția reală a consumului în perioada pentru care s-a efectuat confruntarea cu prognoza (2016-2018) și de "conservarea" formei curbelor de sarcină comparativ cu cea din perioada 2006-2015;
- valorile supraunitare ale indicilor de performanță sugerează posibilitatea unor date de consum eronate (total "discrepante"), prin eliminarea ("corectarea") cărora s-ar ajunge la o situație mai plauzibilă;
- gradul de corelare a curbelor de sarcină din punctul de vedere al formei, respectiv al valorilor de consum, constituie două elemente distincte, cu influențe diferite asupra rezultatelor prognozei.

### 7.2.8. Previzionarea calității prognozelor pentru UTR

În acest paragraf se prezintă o estimare (previzionare) a calității prognozelor pentru curbele de sarcină în funcție de calitatea datelor cunoscute (gradul de corelare) pentru o anumită perioadă trecută (un anumit număr de ani). Acest instrument are la bază calculul unor diferențe finite [Kilyeni2015], [Deacu2015], cu ajutorul cărora se determină o serie de indici globali caracteristici.

Toate mărimile discutate se exprimă atât în unități absolute, cât și în unități relative. Pentru aprecierea comparativă a unei game largi de curbe de sarcină, exprimarea în unități relative are un grad sporit de relevanță (este eliminată dependența de nivelul consumului).

Se consideră cunoscute curbele de sarcină orare pentru o anumită zi a anului pentru o perioadă de  $n$  ani. Se notează cu  $P_i^j$ ,  $i = 1, 2, \dots, n$ ;  $j = 1, 2, \dots, 24$ , puterea aferentă orei  $j$  a curbei de sarcină din anul  $i$ .

Se definesc diferențele finite anuale absolute de ordinul 1 aferente orei 1:

$$\Delta_a^1 P_i^1 = P_{i+1}^1 - P_i^1, \quad i = 1, 2, \dots, n-1 \quad (7.2.1)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^1 P_i^1 = \frac{P_{i+1}^1 - P_i^1}{P_i^1} = \frac{\Delta_a^1 P_i^1}{P_i^1}, \quad i = 1, 2, \dots, n-1 \quad (7.2.2)$$

Diferențele finite absolute de ordinul  $k$ ,  $k = 2, 3, \dots, n-1$ , în număr de  $(n - k)$ , se determină cu relația:

$$\Delta_a^k P_i^1 = \Delta_a^{k-1} P_{i+1}^1 - \Delta_a^{k-1} P_i^1, \quad i = 1, 2, \dots, n-k \quad (7.2.3)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^k P_i^1 = \Delta_{ar}^{k-1} P_{i+1}^1 - \Delta_{ar}^{k-1} P_i^1, \quad i = 1, 2, \dots, n-k \quad (7.2.4)$$

Evident, pentru ordinul  $n-1$  rezultă o singură valoare:

$$\Delta_a^{n-1} P_1^1 = \Delta_a^{n-2} P_2^1 - \Delta_a^{n-2} P_1^1 \quad (7.2.5)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^{n-1}P_1^1 = \Delta_{ar}^{n-2}P_2^1 - \Delta_{ar}^{n-2}P_1^1 \quad (7.2.6)$$

Generalizând relațiile anterioare, se poate scrie expresia diferențelor finite anuale absolute de ordinul  $k$ ,  $k = 1, 2, \dots, n-1$ , aferente orei  $j$ ,  $j = 1, 2, \dots, 23$ :

$$\Delta_a^k P_i^j = \Delta_a^{k-1} P_{i+1}^j - \Delta_a^{k-1} P_i^j, \quad i = 1, 2, \dots, n-k \quad (7.2.7)$$

Evident:

$$\Delta_a^0 P_i^j = P_i^j, \quad i = 1, 2, \dots, n; j = 1, 2, \dots, 24 \quad (7.2.8)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^k P_i^j = \Delta_{ar}^{k-1} P_{i+1}^j - \Delta_{ar}^{k-1} P_i^j, \quad i = 1, 2, \dots, n-k \quad (7.2.9)$$

Se definește în final indicele global de calitate anual  $IC_a$  pentru setul de date inițiale menționate la începutul paragrafului:

$$IC_a = \sum_{j=1}^{23} (\Delta_a^{n-1} P_1^j)^2 \quad (7.2.10)$$

În exprimare relativă indicele global de calitate anual  $IC_{ar}$  are expresia:

$$IC_{ar} = \sum_{j=1}^{23} (\Delta_{ar}^{n-1} P_1^j)^2 \quad (7.2.11)$$

În continuare se procedează analog în privința diferențelor finite orare. Se definesc diferențele finite orare absolute de ordinul 1 aferente orei 1:

$$\Delta_o^1 P_i^1 = P_i^2 - P_i^1, \quad i = 1, 2, \dots, n \quad (7.2.12)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{or}^1 P_i^1 = \frac{P_i^2 - P_i^1}{P_i^1} = \frac{\Delta_o^1 P_i^1}{P_i^1}, \quad i = 1, 2, \dots, n \quad (7.2.13)$$

Diferențele finite absolute de ordinul  $k$ ,  $k = 2, 3, \dots, n$  – în număr de  $n - (k - 1)$  – se determină cu relația:

$$\Delta_o^k P_i^1 = \Delta_o^{k-1} P_{i+1}^1 - \Delta_o^{k-1} P_i^1, \quad i = 1, 2, \dots, n-k+1 \quad (7.2.14)$$

Pentru diferența finită relativă rezultă:

$$\Delta_{or}^k P_i^1 = \Delta_{or}^{k-1} P_{i+1}^1 - \Delta_{or}^{k-1} P_i^1, \quad i = 1, 2, \dots, n-k+1 \quad (7.2.15)$$

Evident, diferența finită de ordinul  $n$  (evident, una singură) este cea care ne interesează:  $\Delta_o^n P_1^1$ , respectiv  $\Delta_{or}^n P_1^1$ .

Generalizând relațiile anterioare, se poate scrie expresia diferențelor finite orare absolute de ordinul  $k$ ,  $k = 1, 2, \dots, n$ , aferente orei  $j$ ,  $j = 1, 2, \dots, 23$ :

$$\Delta_o^k P_i^j = \Delta_o^{k-1} P_{i+1}^j - \Delta_o^{k-1} P_i^j, \quad i = 1, 2, \dots, n-k+1 \quad (7.2.16)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{or}^k P_i^j = \Delta_{or}^{k-1} P_{i+1}^j - \Delta_{or}^{k-1} P_i^j, \quad i = 1, 2, \dots, n-k+1 \quad (7.2.17)$$



Se definește în final indicele global de calitate orar  $IC_o$  pentru setul de date inițiale menționate la începutul paragrafului:

$$IC_o = \sum_{j=1}^{23} (\Delta_o^n P_1^j)^2 \quad (7.2.18)$$

În exprimare relativă indicele global de calitate orar  $IC_{or}$  are expresia:

$$IC_{or} = \sum_{j=1}^{23} (\Delta_{or}^n P_1^j)^2 \quad (7.2.19)$$

Pentru aprecierea comparativă a unei game largi de curbe de sarcină, exprimarea în unități relative are un grad sporit de relevanță (este eliminată dependența de nivelul consumului), cu alte cuvinte prezintă interes  $IC_{ar}$ , determinat cu relația (7.2.11), respectiv  $IC_{or}$ , determinat cu relația (7.2.19).

Pentru fiecare UTR și pentru ansamblul Enel Banat s-au calculat valorile indicilor pătratici globali caracteristici  $IC_a, IC_{ar}, IC_o, IC_{or}$ , conform relațiilor (7.2.10), (7.2.11), (7.2.18), (7.2.19). Rezultatele sunt centralizate în tabelul 7.2.30, cu mențiunea că pentru o apreciere comparativă, valorile relative ale indicilor sunt relevante (valorile absolute depind și de nivelul consumului).

Tabelul 7.2.30. Valorile indicilor pătratici globali caracteristici

Nr. crt.	UTR	$IC_a$	$IC_{ar}$	$IC_o$	$IC_{or}$
1	Arad	$473.4 \times 10^6$	$83.3 \times 10^3$	$161.7 \times 10^6$	$31.3 \times 10^3$
2	Deva	$1252.3 \times 10^6$	$41.1 \times 10^3$	$1357.0 \times 10^6$	$54.2 \times 10^3$
3	Reșița	$573.8 \times 10^6$	$168.0 \times 10^3$	$511.1 \times 10^6$	$131.5 \times 10^3$
4	Timișoara	$440.4 \times 10^6$	$27.3 \times 10^3$	$374.2 \times 10^6$	$22.2 \times 10^3$
5	Banat	$1263.6 \times 10^6$	$7.0 \times 10^3$	$1645.5 \times 10^6$	$8.6 \times 10^3$

În tabelul 7.2.31 se realizează o evaluare comparativă a valorii indicilor relativi, rezultând clasamentele obținute pe baza acestui criteriu. În tabelul 7.2.32 se prezintă o apreciere comparativă a valorii indicilor specifici (echivalenți) de performanță, preluate din tabelul 7.2.26, rezultând clasamentele obținute pe baza acestui criteriu.

În tabelul 7.2.33 s-au reunit clasamentele din tabelele și 7.2.31 și 7.2.32, iar în tabelul 7.2.34 s-a realizat o ierarhizare pe baza acordării unor note calculate cu relația:

$$Nota = \frac{\text{Valoare maxima indice} - \text{Valoare curenta indice}}{\text{Valoare maxima indice} - \text{Valoare minima indice}} \cdot 10 \quad (7.2.20)$$

Tabelul 7.2.31. Clasamente pe baza indicilor caracteristici

Nr. crt.	UTR	$IC_{ar}$	Clasament $IC_{ar}$	$IC_{or}$	Clasament $IC_{or}$	$IC_{ar} + IC_{or}$	Clasament $IC_{ar} + IC_{or}$	Clasament final
1	Arad	$83.3 \times 10^3$	4	$31.3 \times 10^3$	3	$114.6 \times 10^3$	4	4
2	Deva	$41.1 \times 10^3$	3	$54.2 \times 10^3$	4	$95.3 \times 10^3$	3	3
3	Reșița	$168.0 \times 10^3$	5	$131.5 \times 10^3$	5	$299.5 \times 10^3$	5	5
4	Timișoara	$27.3 \times 10^3$	2	$22.2 \times 10^3$	2	$49.5 \times 10^3$	2	2
5	Banat	$7.0 \times 10^3$	1	$8.6 \times 10^3$	1	$15.6 \times 10^3$	1	1

Tabelul 7.2.32. Clasamente pe baza indicilor specifici (echivalenți) de performanță

Nr. crt.	UTR	RNA bayesiană, curbă de sarcină		RNA bayesiană, orar		Sumă $S_{specific}$	Clasament	Clasament final
		$S_{specific}$	Clasament	$S_{specific}$	Clasament			
1	Arad	8.62	4	1.99	3	10.61	4	4
2	Deva	4.17	3	2.40	4	6.57	3	3
3	Reșița	15.33	5	2.64	5	17.97	5	5
4	Timișoara	3.80	2	0.67	2	4.47	2	2
5	Banat	2.23	1	0.52	1	2.75	1	1

Tabelul 7.2.33. Comparație clasamente

Nr. crt.	UTR	Indici caracteristici				Indici specifici de performanță			
		$IC_{ar}$	$IC_{or}$	Sumă	Final	RNA bayesiană, curbă de sarcină	RNA bayesiană, orar	Sumă	Final
1	Arad	4	3	4	4	4	3	4	4
2	Deva	3	4	3	3	3	4	3	3
3	Reșița	5	5	5	5	5	5	5	5
4	Timișoara	2	2	2	2	2	2	2	2
5	Banat	1	1	1	1	1	1	1	1

Tabelul 7.2.34. Comparație note

Nr. crt.	UTR	Indici caracteristici				Indici specifici de performanță			
		$IC_{ar}$	$IC_{or}$	Sumă	Medie	RNA bayesiană, curbă de sarcină	RNA bayesiană, orar	Sumă	Medie
1	Arad	5.26	8.15	6.51	6.64	5.12	3.07	4.84	4.34
2	Deva	7.88	6.29	7.19	7.12	8.52	1.13	7.49	5.71
3	Reșița	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
4	Timișoara	8.74	8.89	8.81	8.81	8.80	9.29	8.87	8.99
5	Banat	10.0	10.0	10.0	10.0	10.0	10.0	10.0	10.0

Analiza comparativă a celor două clasamente (tabelul 7.2.33) și a elementelor de detaliu din tabelele 7.2.31 și 7.2.32, respectiv a notelor din tabelul 7.2.34, permite evidențierea concluziilor de mai jos:

- cele două clasamente indică o foarte bună corespondență între clasamentele obținute pe baza valorilor indicilor specifici de performanță ai prognozelor și cele obținute pe baza valorilor indicilor pătratici globali caracteristici (obținuți pe baza calculului diferențelor finite anuale și orare);
- notele din tabelul 7.2.34 întăresc aprecierea de la punctul anterior;
- o situație interesantă se remarcă în tabelul 7.2.31 – la clasamentul obținut pe baza indicelui caracteristic anual relativ UTR Arad se situează pe locul 4 și UTR Deva pe locul 3, iar la cel obținut pe baza indicelui caracteristic orar relativ UTR Arad se situează pe locul 3 și UTR Deva pe 4.
- situația menționată este în deplină concordanță cu datele din tabelul 7.2.32, unde pe baza indicelui specific pentru prognoza ansamblului curbei de sarcină UTR Arad se situează pe locul 4 și UTR Deva pe 3, iar la cel obținut pe baza indicelui specific pentru prognoza orară UTR Arad se situează pe locul 3 și UTR Deva pe 4;
- cele două puncte anterioare oferă un argument în plus pentru capacitatea metodei, (bazate pe diferențe finite) de previzionare a calității prognozei.

În final se poate întări concluzia formulată în [Deacu2015]: indicii de calitate determinați pe baza diferențelor finite sunt utili pentru pronosticarea calității prognozei.

## 7.3. Stații din cadrul Enel Distribuție Banat

### 7.3.1. Considerații preliminare

A treia parte a capitolului se referă la stațiile de transformare de 110 kV / m.t. gestionate de UTR Timișoara: Azur, Bucovina, Cetate, Dumbrăvița, Fratelia, Freidorf, IMT, Musicescu, Pădurea Verde, Venus, Victoria, Buziaș, Călacea, Cărpiniș, Deta, Făget, Giulvăz, Gătaia, IURT, Jimbolia, Lovrin, Lugoj, Nădrag, Orțișoara, Satchinez, Sănnicolau Mare.

Din motive de spațiu, pentru prezentarea rezultatelor în detaliu au fost selectate 5 stații semnificative de 110 / 20 kV: 3 cu profil diferit, cu consumatori industriali sau casnici în majoritate, din municipiul Timișoara (Bucovina, IMT și Musicescu), una dintr-o localitate importantă a jud. Timiș (Deta) și una care alimentează o exploatare petrolieră (Satchinez).

Analizele efectuate se referă la prognoza curbelor de sarcină definite de valorile puterii consumate la o anumită oră a unei anumite zile, pentru fiecare dintre cele 12 luni ale anului.

În acest subcapitol se prezintă rezultatele pentru ora 9 și ora 21 a primei zile de miercuri a fiecărei luni, pentru aceleași ore ale celei de a doua zile de joi, respectiv pentru ultima zi de marți.

Se menționează că s-au considerat în exclusivitate zilele lucrătoare (în situația în care era vorba de o zi de sărbătoare, se înlocuia cu ziua similară din săptămâna anterioară sau următoare).

Primii 8 ani (din cei 10 pentru care se cunosc datele de consum), 2009-2016, s-au utilizat pentru antrenarea RNA, iar ultimii 2 ani, 2017 și 2018, pentru verificarea prognozelor obținute.

Pentru prognoza curbelor de sarcină s-au aplicat abordări bazate pe utilizarea RNA bayesiene:

- prognoza pentru ansamblului curbei de sarcină – 12 luni (RNA curba de sarcină);
- prognoza individuală pentru fiecare lună în parte (RNA lunar).

Ultima parte a subcapitolului prezintă un studiu de previzionare a calității prognozelor în funcție de datele cunoscute, utilizând metoda prezentată în [Deacu2015], bazată pe diferențe finite.

La finele subcapitolului se evidențiază o serie de comentarii și concluzii, cu caracter mai general sau particular, vizând atât rezultatele concrete ale prognozelor cât și RNA utilizate. O atenție specială se acordă comparării rezultatelor obținute cu cele două metode, evidențierii calității acestora, aprecierii influenței gradului de corelare a curbelor de sarcină asupra calității prognozelor realizate.

### 7.3.2. Stația Bucovina

#### 7.3.2.1. Prima zi de miercuri a fiecărei luni, ora 9

În tabelul 7.3.1 (Anexa 7.3), respectiv figura 7.3.1, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a primei zile de miercuri a fiecărei luni (în condițiile menționate în paragraful 7.3.1). Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.2 (Anexa 7.3), respectiv figura 7.3.2, sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.3.1. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.2. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza datelor din tabelele 7.3.1 și 7.3.2 (Anexa 7.3), respectiv a figurilor 7.3.1 și 7.3.2, evidențiază următoarele concluzii:

- pentru perioada 2009-2016 se observă o tendință generală de scădere a consumului în primii 4 ani, urmată de o creștere în următorii 4 ani;
- pentru 2017-2018 tendința generală este de creștere (excepție lunile martie și august);
- forma curbelor este destul de diferită, cu multe "intersecții";
- în consecință, gradul de corelare a curbelor de sarcină este relativ redus, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față se situează, din acest punct de vedere, în zona mediană.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.3 (RNA bayesiană, curba de sarcină) și 7.3.4 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.3 (anul 2017) și figura 7.3.4 (anul 2018).

În tabelul 7.3.5 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.3. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.4. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.5. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	34.04	43.58	77.62
RNA bayesiană, lunar	12.73	18.14	30.87

- Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:
- rezultatele confirmă observațiile de la analiza curbelor de sarcină;
  - prognoza lunară conduce la rezultate sensibil mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 30, față de 77), explicabilă prin relativ slaba corelare a formei curbelor de sarcină;
  - totuși, comparativ, se poate afirma că prognoza lunară (curba verde) reușește să "prindă" mai bine forma curbelor de sarcină reale (curba albastră);
  - indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime, ceva mai mari cele pentru 2018 (comparativ cu 2017).

**7.3.2.2. Prima zi de miercuri a fiecărei luni, ora 21**

În tabelul 7.3.6 (Anexa 7.3), respectiv figura 7.3.5, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.7 (Anexa 7.3), respectiv figura 7.3.6, sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.3.5. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.6. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza datelor din tabelele 7.3.6 și 7.3.7 (Anexa 7.3), respectiv a figurilor 7.3.5 și 7.3.6, evidențiază concluzii asemănătoare cu cele din subparagraful precedent, gradul de corelare a curbelor de sarcină fiind cu o idee mai scăzut.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.8 (RNA bayesiană, curba de sarcină) și 7.3.9 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.7 (anul 2017) și figura 7.3.8 (anul 2018).

În tabelul 7.3.10 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.7. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.8. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.10. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	41.31	55.08	96.39
RNA bayesiană, lunar	11.13	16.20	27.33

Analiza comparativă a rezultatelor obținute evidențiază concluzii asemănătoare cu cele din subparagraful precedent, remarcându-se faptul că prognoza lunară conduce din nou la rezultate sensibil mai bune decât cea a ansamblului curbei de sarcină (indice de performanță 27, față de 96). În privința prognozei ansamblului curbei de sarcină rezultatele sunt ușor mai proaste decât cele de la ora 9 (96 față de 77), explicația fiind legată de gradul de corelare a formei curbelor de sarcină.

### 7.3.2.3. A doua zi de joi a fiecărei luni, ora 9

În tabelul 7.3.11 (Anexa 7.3), respectiv figura 7.3.9, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.12 (Anexa 7.3), respectiv figura 7.3.10, sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.3.9. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.10. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza datelor din tabelele 7.3.11 și 7.3.12 (Anexa 7.3), respectiv a figurilor 7.3.9 și 7.3.10, evidențiază concluzii asemănătoare cu cele din subparagraful precedent, gradul de corelare a curbelor de sarcină fiind și mai scăzut.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.13 (RNA bayesiană, curba de sarcină) și 7.3.14 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.11 (anul 2017) și figura 7.3.12 (anul 2018).

În tabelul 7.3.15 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.11. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.12. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.15. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	57.25	58.85	116.10
RNA bayesiană, lunar	20.28	24.8	45.08

Analiza comparativă a rezultatelor obținute evidențiază concluzii asemănătoare cu cele din subparagraful precedent, remarcându-se că prognoza lunară conduce din nou la rezultate sensibil mai bune decât cea a ansamblului curbei de sarcină (indice de performanță 45, față de 116). În privința prognozei ansamblului curbei de sarcină rezultatele sunt și mai proaste decât cele de până acum (116 față de 96 sau 77), explicația fiind legată de gradul de corelare a formei curbelor de sarcină. Așa cum se vede în figurile 7.3.9 și 7.3.10, există o diferență accentuată între curbele din perioada 2009-2014 și cele din ultimii 4 ani. Din acest motiv și prognoza lunară conduce la cele mai proaste rezultate obținute până acum (indice de performanță 45, față de 30, 27).

#### 7.3.2.4. A doua zi de joi a fiecărei luni, ora 21

În tabelul 7.3.16 (Anexa 7.3), respectiv figura 7.3.13, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.17 (Anexa 7.3), respectiv figura 7.3.14, sunt prezentate curbele de sarcină pentru 2017 și 2018, utilizate la verificarea rezultatelor prognozelor.




Figura 7.3.13. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)






Figura 7.3.14. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza datelor din tabelele 7.3.16 și 7.3.17 (Anexa 7.3), respectiv a figurilor 7.3.13 și 7.3.14, evidențiază concluzii similare cu cele din subparagraful precedent, gradul de corelare a curbelor de sarcină fiind la fel de scăzut.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.18 (RNA bayesiană, curba de sarcină) și 7.3.19 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.15 (anul 2017) și figura 7.3.16 (anul 2018).

În tabelul 7.3.20 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.15. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.16. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.20. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
<b>RNA bayesiană, curba de sarcină</b>	92.91	99.10	192.01
<b>RNA bayesiană, lunar</b>	19.16	23.96	43.12

Analiza comparativă a rezultatelor obținute evidențiază concluzii similare cu cele din subparagraful precedent, remarcându-se faptul că prognoza lunară conduce din nou la rezultate mai bune decât cea a ansamblului curbei de sarcină (indice de performanță 43, față de 192). La prognoza ansamblului curbei de sarcină rezultatele sunt cele mai slabe de până acum (192 față de 116. 96 sau 77), explicația fiind legată

de gradul redus de corelare a formei curbelor de sarcină. La fel ca pentru ora 9 există o diferență accentuată între curbele din perioada 2009-2014 și cele din ultimii 4 ani.

### 7.3.2.5. Ultima zi de marți a fiecărei luni, ora 9

În tabelul 7.3.21 (Anexa 7.3), respectiv figura 7.3.17, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.22 (Anexa 7.3), respectiv figura 7.3.18, sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.3.17. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.18. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza datelor din tabelele 7.3.21 și 7.3.22 (Anexa 7.3), respectiv a figurilor 7.3.17 și 7.3.18, duce la concluzii similare cu cele pentru ora 21 a zilei de miercuri (subparagraful 7.3.2.2), gradul de corelare a curbelor de sarcină fiind la fel de scăzut.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.23 (RNA bayesiană, curba de sarcină) și 7.3.24 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.19 (anul 2017) și figura 7.3.20 (anul 2018).

În tabelul 7.3.25 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.19. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.20. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.25. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	44.36	45.31	89.67
RNA bayesiană, lunar	21.92	23.20	45.12

Analiza comparativă a rezultatelor obținute evidențiază concluzii similare cu cele din subparagrafele precedente, remarcându-se că și de data aceasta prognoza lunară conduce la rezultate mai bune decât cea a ansamblului curbei de sarcină (indice de performanță 45, față de 90). Totuși, la prognoza ansamblului curbei de sarcină rezultatele sunt relativ mai bune decât în ultimele două cazuri (90 față de 192), comparabile cu cele pentru ora 21 a zilei de miercuri (subparagraful 7.3.2.2) – 90 față de 96.

### 7.3.2.6. Ultima zi de marți a fiecărei luni, ora 21

În tabelul 7.3.26 (Anexa 7.3), respectiv figura 7.3.21, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.27 (Anexa 7.3), respectiv figura 7.3.22, sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.3.21. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.22. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza datelor din tabelele 7.3.26 și 7.3.27 (Anexa 7.3), respectiv a figurilor 7.3.21 și 7.3.22, evidențiază următoarele concluzii:

- pentru perioada 2009-2016 se observă o tendință generală de scădere a consumului în primii 3 ani, urmată de o creștere în următorii 5 ani;
- pentru 2017-2018 tendința generală este de creștere (excepție lunii februarie);
- forma curbelor este destul de diferită, cu multe "intersecții" în primii 4 ani și cu o "stabilizare a formei" în următorii 6 ani;
- în consecință, gradul de corelare a curbelor de sarcină este relativ mai bun decât în celelalte cazuri analizate pentru stația Bucovina, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor pentru stația Bucovina, situația de față pare a fi cea mai avantajoasă pentru realizarea unei prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.28 (RNA bayesiană, curba de sarcină) și 7.3.29 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.23 (anul 2017) și figura 7.3.24 (anul 2018).

În tabelul 7.3.30 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.23. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.24. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.30. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	39.49	43.23	82.72
RNA bayesiană, lunar	4.61	5.61	10.22

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă în totalitate constatările și observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 10, față de 83), explicabile prin gradul de corelare a formei curbelor de sarcină;
- prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime, ceva mai mari cele pentru 2018 (comparativ cu 2017);
- s-a obținut cea mai bună prognoză lunară dintre toate situațiile analizate pentru stația Bucovina (indice global de performanță 10, față de 27-45 în celelalte cazuri) și cel mai mare raport de reducere față de cea a ansamblului curbei de sarcină (8 față de 2,5-4,5 în celelalte cazuri).

### 7.3.3. Stația IMT

#### 7.3.3.1. Prima zi de miercuri a fiecărei luni, ora 9

În tabelul 7.3.31, respectiv figura 7.3.25 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.32, respectiv figura 7.3.26 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază următoarele concluzii:

- pentru perioada 2009-2016 se observă o tendință generală de scădere a consumului în primii 4 ani, urmată de o evoluție contradictorie în următorii 4 ani;
- în perioada 2017-2018 continuă același trend contradictoriu (creștere la unele luni, scădere la alte luni);
- forma curbelor de sarcină este destul de diferită, cu multe "intersecții";
- în consecință, gradul de corelare este relativ redus, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față (și celelalte referitoare la stația IMT) se situează, din acest punct de vedere, în zona cea mai defavorabilă a posibilității obținerii unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.33 (RNA bayesiană, curba de sarcină) și 7.3.34 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.27 (anul 2017) și figura 7.3.28 (anul 2018).

În tabelul 7.3.35 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.27. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.28. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.35. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	169.34	143.45	312.79
RNA bayesiană, lunar	30.75	28.28	59.03

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță mai mic de 5.3 ori – 59 față de 313), explicabilă prin slaba corelare a formei curbelor de sarcină;
- comparativ, se poate afirma că prognoza lunară (curba verde) reușește să "prindă" mai bine forma curbelor de sarcină reale (curba albastră), în condițiile în care, totuși, valoarea indicelui global de performanță este relativ ridicată;
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime.

### 7.3.3.2. Prima zi de miercuri a fiecărei luni, ora 21

În tabelul 7.3.36, respectiv figura 7.3.29 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.37, respectiv figura 7.3.30 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii similare cu cele pentru ora 9.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.38 (RNA bayesiană, curba de sarcină) și 7.3.39 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.31 (anul 2017) și figura 7.3.32 (anul 2018).

În tabelul 7.3.40 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.

Tabelul 7.3.40. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	67.33	66.72	134.05
RNA bayesiană, lunar	20.58	19.80	40.38




Figura 7.3.31. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.32. Analiza comparativă a rezultatelor pentru anul 2018

Analiza comparativă a rezultatelor evidențiază concluzii asemănătoare cu cele din subparagraful anterior (ora 9 a aceleiași zile). Se apreciază, totuși, că sunt puțin mai bune, pe baza comparării valorilor indicilor de performanță.

### 7.3.3.3. A doua zi de joi a fiecărei luni, ora 9

În tabelul 7.3.41, respectiv figura 7.3.33 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.42, respectiv figura 7.3.34 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor conduce la concluzii similare cu cele pentru prima zi de miercuri, prezentate în subparagrafele precedente.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.43 (RNA bayesiană, curba de sarcină) și 7.3.44 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.35 (anul 2017) și figura 7.3.36 (anul 2018).

În tabelul 7.3.45 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.35. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.36. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.45. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	112.14	90.22	202.36
RNA bayesiană, lunar	20.91	21.94	42.85

Analiza comparativă a rezultatelor obținute evidențiază concluzii similare cu cele prezentate în subparagraful anterior, pentru ziua de miercuri (ora 21).

#### 7.3.3.4. A doua zi de joi a fiecărei luni, ora 21

În tabelul 7.3.46, respectiv figura 7.3.37 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.47, respectiv figura 7.3.38 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor conduce la concluzii asemănătoare cu cele din subparagrafele precedente, aferente stației IMT.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.48 (RNA bayesiană, curba de sarcină) și 7.3.49 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.39 (anul 2017) și figura 7.3.40 (anul 2018).

În tabelul 7.3.50 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.39. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.40. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.50. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	61.37	67.82	129.19
RNA bayesiană, lunar	15.71	16.63	32.34

Analiza comparativă a rezultatelor obținute evidențiază concluzii asemănătoare cu cele prezentate în subparagraful anterior, pentru ora 9 a zilei de joi. Totuși, pe baza valorilor indicilor de performanță și a imaginilor din figurile aferente, se apreciază o calitate ușor mai bună a prognozelor obținute.



### 7.3.3.5. Ultima zi de marți a fiecărei luni, ora 9

În tabelul 7.3.51, respectiv figura 7.3.41 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.52, respectiv figura 7.3.42 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor conduce la concluzii asemănătoare cu cele din subparagraful aferent orei 9 a zilei de joi (stația IMT).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.53 (RNA bayesiană, curba de sarcină) și 7.3.54 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.43 (anul 2017) și figura 7.3.44 (anul 2018).

În tabelul 7.3.55 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.43. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.44. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.55. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	74,79	75,26	150,05
RNA bayesiană, lunar	22,16	23,40	45,56

Analiza comparativă a rezultatelor obținute evidențiază concluzii similare (calitativ și cantitativ) cu cele prezentate în subparagraful aferent zilei de joi, ora 9.

### 7.3.3.6. Ultima zi de marți a fiecărei luni, ora 21

În tabelul 7.3.56, respectiv figura 7.3.45 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.57, respectiv figura 7.3.46 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor conduce la concluzii asemănătoare cu cele din subparagrafele anterioare referitoare la stația IMT, cu observația că, totuși, pentru ultimii 2 ani din

perioada de antrenare și pentru cei 2 ani următori, pentru care se efectuează prognoza, tendința de creștere a consumului este clară (în anii anteriori era scădere, întreruptă de salturi momentane de creștere pentru anumite ore).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.58 (RNA bayesiană, curba de sarcină) și 7.3.59 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.47 (anul 2017) și figura 7.3.48 (anul 2018).

În tabelul 7.3.60 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.47. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.48. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.60. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$s_{2017}$	$s_{2018}$	$s_{total}$
RNA bayesiană, curba de sarcină	55.78	58.19	113.96
RNA bayesiană, lunar	18.07	20.25	38.32

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă în totalitate constatările de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 38, față de 114), explicabilă prin gradul de corelare a formei curbelor de sarcină;
- prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);
- indicii anuali de performanță ( $s_{2017}$ ,  $s_{2018}$ ) au valori de același ordin de mărime;
- s-a obținut cea mai bună prognoză lunară dintre toate situațiile analizate pentru stația IMT, dar valoarea indicelui de performanță (38) este mult mai proastă decât cea aferentă celui mai bun caz pentru stația Bucovina (10, cf. tabelului 7.2.30).

### 7.3.4. Stația Musicescu

#### 7.3.4.1. Prima zi de miercuri a fiecărei luni, ora 9

În tabelul 7.3.61, respectiv figura 7.3.49 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.62, respectiv figura 7.3.50 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază următoarele concluzii:

- pentru perioada 2009-2016 se observă o tendință generală de creștere a consumului, creștere care continuă și în anii 2017 și 2018 (asociată cu stagnare pentru anumite luni);
- forma curbelor de sarcină este destul de asemănătoare, cu puține "intersecții";
- la curbele din primii 3 ani apar două diferențe – un maxim accentuat pentru luna iulie, respectiv un minim pentru luna august sau septembrie;
- în consecință, gradul de corelare este acceptabil, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față (și celelalte referitoare la stația Musicescu) se situează, din acest punct de vedere, în zona favorabilă a posibilității obținerii unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.63 (RNA bayesiană, curba de sarcină) și 7.3.64 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.51 (anul 2017) și figura 7.3.52 (anul 2018).

În tabelul 7.3.65 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.51. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.52. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.65. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	59.17	56.81	115.98
RNA bayesiană, lunar	20.44	19.30	39.74

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă constatările și observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 40, față de 116);
- prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);

- prognoza ansamblului curbei de sarcină (curba roșie) este "deranjată" în zona minimelor și maximelor care apar în unii ani în lunile iunie – septembrie (situații menționate la comentarea curbelor de sarcină utilizate pentru antrenarea RNA);
- indicii anuali de performanță ( $s_{2017}$ ,  $s_{2018}$ ) au valori de același ordin de mărime.

#### 7.3.4.2. Prima zi de miercuri a fiecărei luni, ora 21

În tabelul 7.3.66, respectiv figura 7.3.53 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.67, respectiv figura 7.3.54 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii asemănătoare cu cele din subparagraful precedent (prima zi de miercuri, ora 9). Se remarcă un plus în ceea ce privește gradul de corelare a curbelor de sarcină, iar "sincopile" din lunile februarie și iulie sunt mai puțin semnificative față de cele de la ora 9. Există premisele pentru realizarea unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.68 (RNA bayesiană, curba de sarcină) și 7.3.69 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.55 (anul 2017) și figura 7.3.56 (anul 2018).

În tabelul 7.3.70 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.55. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.56. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.70. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$s_{2017}$	$s_{2018}$	$s_{total}$
RNA bayesiană, curba de sarcină	19.97	20.59	40.56
RNA bayesiană, lunar	3.85	4.08	7.93

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă în totalitate constatările și observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 8, față de 40);

- prognoza lunară (curba verde) reușește să "prindă" foarte bine forma curbelor de sarcină reale (curba albastră), cele două grafice fiind practic suprapuse;
- valoarea indicelui de performanță pentru prognoza lunară este cea mai bună dintre toate analizele efectuate până în acest moment;
- prognoza ansamblului curbei de sarcină (curba roșie) este "deranjată" în zona "sincopelor" menționate la analiza curbelor de sarcină cunoscute, dar și ea este cea mai bună dintre toate analizele efectuate până în acest moment;
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime.

#### 7.3.4.3. A doua zi de joi a fiecărei luni, ora 9

În tabelul 7.3.71, respectiv figura 7.3.57 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.72, respectiv figura 7.3.58 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii aproape similare cu cele de la ora 9 a primei zile de miercuri (subparagraful 7.3.4.1).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.73 (RNA bayesiană, curba de sarcină) și 7.3.74 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.59 (anul 2017) și figura 7.3.60 (anul 2018).

În tabelul 7.3.75 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.59. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.60. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.75. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	50.21	48.17	98.38
RNA bayesiană, lunar	27.28	26.80	54.08

Analiza comparativă a rezultatelor obținute evidențiază concluzii similare (calitativ și cantitativ) cu cele prezentate în subparagraful aferent zilei de miercuri, ora 9 (subparagraful 7.3.4.1), lucru de așteptat în condițiile în care și comentariile de la analiza datelor inițiale erau asemănătoare.

#### 7.3.4.4. A doua zi de joi a fiecărei luni, ora 21

În tabelul 7.3.76, respectiv figura 7.3.61 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.77, respectiv figura 7.3.62 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii similare cu cele de la ora 21 a zilei de miercuri (subparagraful 7.3.4.2), existând și acum premisele pentru realizarea unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.78 (RNA bayesiană, curba de sarcină) și 7.3.79 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.63 (anul 2017) și figura 7.3.64 (anul 2018).

În tabelul 7.3.80 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.63. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.64. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.80. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	19.91	20.26	40.17
RNA bayesiană, lunar	3.13	3.19	6.32

Analiza rezultatelor evidențiază concluzii similare cu cele de la ora 21 a zilei de miercuri (subparagraful 7.3.4.2), lucru de așteptat în condițiile în care și comentariile de la analiza datelor inițiale erau asemănătoare. Comparând cifrele din tabelul 7.3.80 cu cele din tabelul 7.3.70, se observă o calitate și mai bună a prognozei (indice global 6.32 față de 7.93). Anticipând și rezultatele de la stațiile care urmează, se poate afirma că s-a obținut cea mai bună valoare indicelui global de performanță.

#### 7.3.4.5. Ultima zi de marți a fiecărei luni, ora 9

În tabelul 7.3.81, respectiv figura 7.3.65 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.82, respectiv figura 7.3.66 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii asemănătoare cu cele de la analizele anterioare realizate pentru stația Musicescu. Se remarcă însă un "plus" în ceea ce privește forma curbelor de sarcină, în sensul unei grad de corelare mai bun.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.83 (RNA bayesiană, curba de sarcină) și 7.3.84 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.67 (anul 2017) și figura 7.3.68 (anul 2018).

În tabelul 7.3.85 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.67. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.68. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.85. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$s_{2017}$	$s_{2018}$	$s_{total}$
RNA bayesiană, curba de sarcină	13,33	14,36	27,69
RNA bayesiană, lunar	7,47	7,83	15,30

Analiza rezultatelor evidențiază concluzii asemănătoare cu cele de la ora 21 a zilei de miercuri (subparagraful 7.3.4.2) și a zilei de joi (subparagraful 7.3.4.4), lucru de așteptat în condițiile în care și comentariile de la analiza datelor inițiale semănau. Se remarcă în plus faptul că s-au obținut și cu prognoza ansamblului curbei de sarcină rezultate apropiate față de cele cu prognoza lunară, raportul de 1.81 dintre indicii globali fiind cel mai bun (luând în considerare toate stațiile, zilele și orele analizate). Același lucru se poate spune și despre valoarea indicelui total de performanță (27.69).

#### 7.3.4.6. Ultima zi de marți a fiecărei luni, ora 21

În tabelul 7.3.86, respectiv figura 7.3.69 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.87, respectiv figura 7.3.70 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii similare cu cele din subparagraful precedent (marți, ora 9). Se remarcă un ușor "minus" în ceea ce privește gradul de corelare a curbelor de sarcină, încă foarte bun comparativ cu celelalte cazuri studiate în acest subcapitol (în clasamentul alcătuit după acest criteriu – locul 4 din 30). Primele 4 poziții aparțin stației Musicescu, care alimentează o zonă cu consumatori predominant casnici.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.88 (RNA bayesiană, curba de sarcină) și 7.3.89 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.71 (anul 2017) și figura 7.3.72 (anul 2018).

În tabelul 7.3.90 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.71. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.72. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.90. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	20.39	22.52	42.91
RNA bayesiană, lunar	6.89	7.31	14.20

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagrafele 7.3.4.2 și 7.3.4.4 (ora 21, zilele de miercuri și joi).

### 7.3.5. Stația Deta

#### 7.3.5.1. Prima zi de miercuri a fiecărei luni, ora 9

În tabelul 7.3.91, respectiv figura 7.3.73 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.92, respectiv figura 7.3.74 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază următoarele concluzii:

- pentru anii 2009-2016 nu se poate stabili o tendință clară de evoluție a consumului – se observă perioade de creștere, de scădere sau de stagnare;
- se remarcă totuși faptul că variațiile sunt cuprinse într-o gamă destul de îngustă de valori;



- în anii 2017 și 2018 (pentru care se face prognoza) se observă o ușoară scădere;
- curbele de sarcină sunt destul de "grupate", cu două excepții – anii 2009 și 2010;
- în consecință, gradul de corelare este acceptabil, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față (și celelalte referitoare la stația Deta) se situează, din acest punct de vedere, în zona favorabilă a posibilității obținerii unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.93 (RNA bayesiană, curba de sarcină) și 7.3.94 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.75 (anul 2017) și figura 7.3.76 (anul 2018).

În tabelul 7.3.95 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.75. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.76. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.95. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	40.90	42.63	83.53
RNA bayesiană, lunar	5.18	5.62	10.80

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă constatările și observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 11, față de 84);
- prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);
- prognoza ansamblului curbei de sarcină (curba roșie) este "deranjată" de alternarea unor perioade de creștere, scădere și stagnare a consumului la datele de antrenare și de scăderea clară a consumului în anul 2018 față de 2017;
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime.

### 7.3.5.2. Prima zi de miercuri a fiecărei luni, ora 21

În tabelul 7.3.96, respectiv figura 7.3.77 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.97, respectiv figura 7.3.78 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii foarte asemănătoare cu cele pentru ora 9 (subparagraful anterior), cu deosebirea că pentru anul 2018 apare o ușoară creștere față de 2017 (la ora 9 era scădere).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.98 (RNA bayesiană, curba de sarcină) și 7.3.99 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $s_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.79 (anul 2017) și figura 7.3.80 (anul 2018).

În tabelul 7.3.100 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.79. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.80. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.100. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$s_{2017}$	$s_{2018}$	$s_{total}$
RNA bayesiană, curba de sarcină	46.16	47.67	93.83
RNA bayesiană, lunar	7.08	6.94	14.02

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagraful anterior, cu un ușor minus în ceea ce privește calitatea prognozei.

### 7.3.5.3. A doua zi de joi a fiecărei luni, ora 9

În tabelul 7.3.101, respectiv figura 7.3.81 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a celei de a doua zile de joi a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.102, respectiv figura 7.3.82 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii foarte asemănătoare cu cele pentru ora 9 a zilei de miercuri (subparagraful 7.3.5.1), cu o ușoară alterare a gradului de corelare a curbelor de sarcină.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.103

(RNA bayesiană, curba de sarcină) și 7.3.104 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.83 (anul 2017) și figura 7.3.84 (anul 2018).

În tabelul 7.3.105 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.83. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.84. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.105. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	44.31	49.79	94.10
RNA bayesiană, lunar	6.19	6.54	12.73

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagraful 7.3.5.1 (miercuri, ora 9, cu un ușor minus în ceea ce privește calitatea prognozei).

#### 7.3.5.4. A doua zi de joi a fiecărei luni, ora 21

În tabelul 7.3.106, respectiv figura 7.3.85 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a celei de a doua zile de joi a fiecărei luni. Ele au fost folosite pentru antrenarea RNA.

În tabelul 7.3.107, respectiv figura 7.3.86 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii asemănătoare cu cele din subparagraful anterior (joi, ora 9), de fapt cu toate cazurile considerate pentru stația Deta.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.108 (RNA bayesiană, curba de sarcină) și 7.3.109 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.87 (anul 2017) și figura 7.3.88 (anul 2018).

În tabelul 7.3.110 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.87. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.88. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.110. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	40,17	54,54	94,71
RNA bayesiană, lunar	5,28	6,38	11,66

Analiza rezultatelor conduce la concluzii similare cu cele din subparagraful anterior, de fapt cu toate cazurile considerate pentru stația Deta.

### 7.3.5.5. Ultima zi de marți a fiecărei luni, ora 9

În tabelul 7.3.111, respectiv figura 7.3.89 (Anexa 7.3), sunt prezentate datele pentru curbele de sarcină pentru 8 ani (2009-2016), aferente orei 9 a ultimei zile de marți a fiecărei luni. Ele au fost folosite pentru antrenarea RNA. În tabelul 7.3.112, respectiv figura 7.3.90 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor.

Analiza datelor evidențiază concluzii asemănătoare cu cele din toate cazurile considerate pentru stația Deta.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.113 (RNA bayesiană, curba de sarcină) și 7.3.114 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare. Grafic, aceste rezultate sunt prezentate comparativ în figura 7.3.91 (anul 2017) și figura 7.3.92 (anul 2018).

În tabelul 7.3.115 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.91. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.92. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.115. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	50.92	48.05	98.97
RNA bayesiană, lunar	6.11	5.90	12.01

Analiza rezultatelor conduce la concluzii similare cu cele din subparagraful anterior, de fapt cu toate cazurile considerate pentru stația Deta.

### 7.3.5.6. Ultima zi de marți a fiecărei luni, ora 21

În tabelul 7.3.116, respectiv figura 7.3.93 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a ultimei zile de marți a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.117, respectiv figura 7.3.94 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază următoarele concluzii asemănătoare cu analizele anterioare pentru stația Deta:

- pentru anii 2009-2016 nu se poate stabili o tendință clară de evoluție a consumului – se observă perioade de creștere, de scădere sau de stagnare;
- se remarcă totuși faptul că variațiile sunt cuprinse într-o gamă destul de îngustă;
- în anii 2017 și 2018 (pentru care se face prognoza) continuă același trend neclar;
- curbele de sarcină sunt destul de "grupate", cu două excepții – anii 2009 și 2010, în perioada lunilor aprilie și septembrie;
- în consecință, gradul de corelare este acceptabil, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față (și celelalte referitoare la stația Deta) se situează, din acest punct de vedere, în zona favorabilă a posibilității obținerii unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.118 (RNA bayesiană, curba de sarcină) și 7.3.119 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.95 (anul 2017) și figura 7.3.96 (anul 2018).

În tabelul 7.3.120 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.95. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.96. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.120. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	41,87	45,01	86,79
RNA bayesiană, lunar	4,26	4,76	9,02

Analiza rezultatelor evidențiază concluzii similare cu cele obținute pentru în subparagrafele anterioare pentru stația Deta:

- rezultatele confirmă constatările și observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 9, față de 87);
- prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);
- prognoza ansamblului curbei de sarcină (curba roșie) este "deranjată" de alternarea unor perioade de creștere, scădere și stagnare a consumului la datele de antrenare și la anii pentru care se face prognoza;
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime.

### 7.3.6. Stația Satchinez

#### 7.3.6.1. Prima zi de miercuri a fiecărei luni, ora 9

În tabelul 7.3.121, respectiv figura 7.3.97 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.122, respectiv figura 7.3.98 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază următoarele concluzii:

- pentru perioada 2009-2016 se remarcă o tendință generală de creștere a consumului în primii 5 ani, urmată de o scădere în următorii 3 ani (cu mici excepții punctuale);
- se remarcă totuși faptul că variațiile sunt cuprinse într-o gamă destul de îngustă de valori;
- în anii 2017 și 2018 (pentru care se face prognoza) continuă trendul de scădere;
- curbele de sarcină sunt destul de "grupate", cu excepția anului 2009;
- în consecință, gradul de corelare a curbelor de sarcină este acceptabil, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față (și celelalte referitoare la stația Deta) se situează, din acest punct de vedere, în zona favorabilă a posibilității obținerii unor prognoze de calitate.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.123 (RNA bayesiană, curba de sarcină) și 7.3.124 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.99 (anul 2017) și figura 7.3.100 (anul 2018).

În tabelul 7.3.125 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.

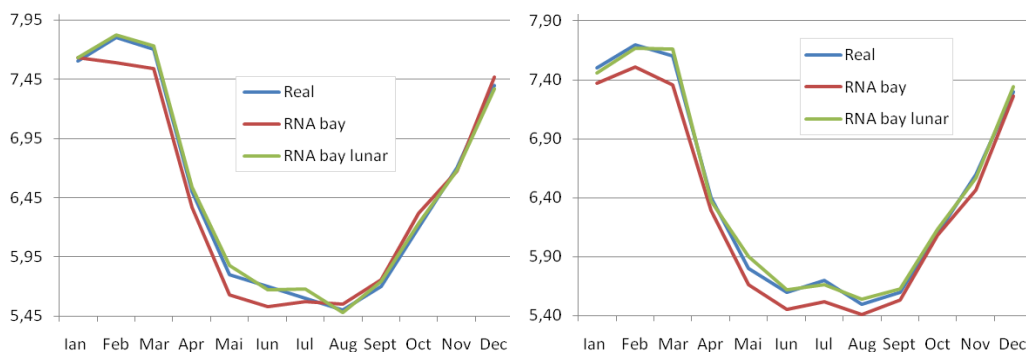


Figura 7.3.99. Analiza comparativă a rezultatelor pentru anul 2017

Figura 7.3.100. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.125. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	40.27	53.52	93.79
RNA bayesiană, lunar	6.08	6.44	12.52

- Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:
- rezultatele confirmă constatările și observațiile de la analiza curbelor de sarcină;
  - prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 12, față de 94);
  - prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);
  - prognoza ansamblului curbei de sarcină (curba roșie) este "deranjată" de alternarea unor perioade de creștere, scădere și stagnare a consumului la datele de antrenare, cu precădere în lunile ianuarie – martie și mai – iunie;
  - indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime, ușor mai mari pentru anul 2018.

### 7.3.6.2. Prima zi de miercuri a fiecărei luni, ora 21

În tabelul 7.3.126, respectiv figura 7.3.101 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a primei zile de miercuri a fiecărei luni. Ele au fost utilizate pentru antrenarea RNA.

În tabelul 7.3.127, respectiv figura 7.3.102 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii foarte asemănătoare cu cele pentru ora 9 (subparagraful anterior).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.128 (RNA bayesiană, curba de sarcină) și 7.3.129 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.103 (anul 2017) și figura 7.3.104 (anul 2018).

În tabelul 7.3.130 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.103. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.104. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.130. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	44.50	46.97	91.47
RNA bayesiană, lunar	4.19	4.82	9.01

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagraful anterior, cu un ușor plus în ceea ce privește calitatea prognozei.

### 7.3.6.3. A doua zi de joi a fiecărei luni, ora 9

În tabelul 7.3.131, respectiv figura 7.3.105 (Anexa 7.3), sunt prezentate datele pentru curbele de sarcină pentru 8 ani (2009-2016), aferente orei 9 a celei de a doua zile de joi a fiecărei luni. Ele au fost folosite pentru antrenarea RNA. În tabelul 7.3.132, respectiv figura 7.3.106 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor.

Analiza datelor evidențiază concluzii asemănătoare cu cele din toate cazurile considerate pentru stația Satchinez.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.133 (RNA bayesiană, curba de sarcină) și 7.3.134 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare. Grafic, aceste rezultate sunt prezentate comparativ în figura 7.3.107 (anul 2017) și figura 7.3.108 (anul 2018).

În tabelul 7.3.135 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.107. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.108. Analiza comparativă a rezultatelor pentru anul 2018



Tabelul 7.3.135. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	48.47	58.82	107.29
RNA bayesiană, lunar	3.36	4.60	7.96

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagraful anterior, cu un ușor plus în ceea ce privește calitatea prognozei lunare.

#### 7.3.6.4. A doua zi de joi a fiecărei luni, ora 21

În tabelul 7.3.136, respectiv figura 7.3.109 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a celei de a doua zile de joi a fiecărei luni. Ele au fost folosite pentru antrenarea RNA.

În tabelul 7.3.137, respectiv figura 7.3.110 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii asemănătoare cu cele din subparagrafele anterioare referitoare la stația Satchinez, remarcându-se o formă ușor discrepantă a curbei de sarcină din anul 2009 (valori neobișnuit de scăzute pentru consum în prima jumătate a anului).

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.138 (RNA bayesiană, curba de sarcină) și 7.3.139 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.111 (anul 2017) și figura 7.3.112 (anul 2018).

În tabelul 7.3.140 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.111. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.112. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.140. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	S <sub>2017</sub>	S <sub>2018</sub>	S <sub>total</sub>
RNA bayesiană, curba de sarcină	35.88	42.88	78.76
RNA bayesiană, lunar	5.22	5.73	10.95

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagraful anterior, cu un ușor minus în privința calității prognozei lunare.

### 7.3.6.5. Ultima zi de marți a fiecărei luni, ora 9

În tabelul 7.3.141, respectiv figura 7.3.113 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 9 a ultimei zile de marți a fiecărei luni. Ele au fost folosite pentru antrenarea RNA.

În tabelul 7.3.142, respectiv figura 7.3.114 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii asemănătoare cu cele din subparagrafele anterioare referitoare la stația Satchinez, remarcându-se o formă ușor discrepantă a curbelor de sarcină din anii 2009 și 2012.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.143 (RNA bayesiană, curba de sarcină) și 7.3.144 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.115 (anul 2017) și figura 7.3.116 (anul 2018).

În tabelul 7.3.145 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.115. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.116. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.145. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	53.09	55.88	108.97
RNA bayesiană, lunar	5.40	6.08	11.48

Analiza rezultatelor conduce la concluzii asemănătoare cu cele formulate în subparagraful 7.3.6.3 (joi, ora 9), cu un ușor minus în privința calității prognozei lunare.

### 7.3.6.6. Ultima zi de marți a fiecărei luni, ora 21

În tabelul 7.3.146, respectiv figura 7.3.117 (Anexa 7.3), sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), aferente orei 21 a ultimei zile de marți a fiecărei luni. Ele au fost folosite pentru antrenarea RNA.

În tabelul 7.3.147, respectiv figura 7.3.118 (Anexa 7.3), sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.

Analiza datelor evidențiază concluzii asemănătoare cu cele din subparagrafele anterioare, remarcându-se o formă ușor discrepantă a curbei de sarcină din anul 2013.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (procentual) și abaterea pătratică relativă – sunt prezentate în tabelele 7.3.148 (RNA bayesiană, curba de sarcină) și 7.3.149 (RNA bayesiană, lunar), Anexa 7.3. În ultima linie a fiecărui tabel este dată valoarea indicelui global de performanță ( $S_{total}$ ), obținut prin însumarea indicilor parțiali anuali ( $S_{2017}$ ,  $S_{2018}$ ) – suma pătratelor abaterilor (procentuale) pentru cele 12 valori lunare aferente anului în cauză.

Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figura 7.3.119 (anul 2017) și figura 7.3.120 (anul 2018).

În tabelul 7.3.150 s-au reunit indicii de performanță pentru cele două metode de prognoză utilizate.




Figura 7.3.119. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.120. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.150. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	40.99	47.23	88.22
RNA bayesiană, lunar	5.50	6.05	11.55

Analiza comparativă a rezultatelor evidențiază următoarele concluzii:

- rezultatele confirmă constatările și observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate mult mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 11, față de 88);
- prognoza lunară (curba verde) reușește să "prindă" mult mai bine forma curbelor de sarcină reale (curba albastră);
- prognoza ansamblului curbei de sarcină (curba roșie) este "deranjată" de scăderea mai puțin accentuată a consumului în anii prognozați (2017 și 2018) comparativ cu ultimii doi ani ai perioadei de antrenare (2015 și 2016);
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime, ușor mai mari pentru anul 2018.

### 7.3.7. Analiza comparativă a rezultatelor

În acest paragraf se efectuează o analiză comparativă a rezultatelor obținute pentru toate stațiile analizate, având la bază valoarea indicelui global de performanță. Pentru fiecare prognoză se iau în considerare cele mai bune rezultate, obținute de regulă prin prognoza lunară. Analiza se efectuează atât exhaustiv, cât și în parte pentru fiecare stație, fiecare zi și fiecare oră.

În tabelul 7.3.151 se prezintă rezultatele analizei exhaustive. Clasamentul a rezultat pe baza valorii indicelui specific de performanță, obținut prin împărțirea valorii indicelui global la 24 (2 ani x 12 luni = 24). Indicele specific permite compararea

calității rezultatelor obținute pentru stații (subcapitolul 7.3) cu cele obținute pentru UTR (subcapitolul 7.2).

Tabelul 7.3.151. Indicii specifici de performanță – analiză exhaustivă

Nr. crt.	Stația, ziua, ora	RNB curbă de sarcină		RNB lunar	
		Total	Specific	Total	Specific
1	Musicescu, joi, 21	40.17	1.67	6.32	0.26
2	Musicescu, miercuri, 21	40.56	1.69	7.93	0.33
3	Satchinez, joi, 9	107.3	4.47	7.96	0.33
4	Deta, marți, 21	86.79	3.62	9.02	0.38
5	Satchinez, miercuri, 21	91.47	3.81	9.01	0.38
6	Bucovina, marți, 21	82.72	3.45	10.22	0.43
7	Deta, miercuri, 9	83.53	3.48	10.80	0.45
8	Satchinez, joi, 21	78.76	3.28	10.95	0.46
9	Satchinez, marți, 9	109.0	4.54	11.48	0.48
10	Satchinez, marți, 21	88.22	3.68	11.55	0.48
11	Deta, joi, 21	94.71	3.95	11.66	0.49
12	Deta, marți, 9	98.97	4.12	12.01	0.50
13	Satchinez, miercuri, 9	93.79	3.91	12.52	0.52
14	Deta, joi, 9	94.10	3.92	12.73	0.53
15	Deta, miercuri, 21	93.83	3.91	14.02	0.58
16	Musicescu, marți, 21	42.91	1.79	14.20	0.59
17	Musicescu, marți, 9	27.69	1.15	15.30	0.64
18	Bucovina, miercuri, 21	96.39	4.02	27.33	1.14
19	Bucovina, miercuri, 9	77.62	3.23	30.87	1.29
20	IMT, joi, 21	129.2	5.38	32.34	1.35
21	IMT, marți, 21	114.0	4.75	38.32	1.60
22	Musicescu, miercuri, 9	116.0	4.83	39.74	1.66
23	IMT, miercuri, 21	134.1	5.59	40.38	1.68
24	IMT, joi, 9	202.4	8.43	42.85	1.79
25	Bucovina, joi, 21	192.0	8.00	43.12	1.80
26	Bucovina, joi, 9	116.1	4.84	45.08	1.88
27	Bucovina, marți, 9	89.67	3.74	45.12	1.88
28	IMT, marți, 9	150.1	6.25	45.56	1.90
29	Musicescu, joi, 9	98.38	4.10	54.08	2.25
30	IMT, miercuri, 9	312.8	13.03	59.03	2.46

În tabelele 7.3.152 – 7.3.156 (Anexa 7.3) se prezintă rezultatele pentru fiecare stație în parte, ierarhizarea fiind obținută tot pe baza valorii indicelui specific de performanță. S-au extras din tabelul 7.3.151 liniile aferente unei anumite stații, coloana a 2-a indicând poziția liniei respective în tabelul 7.3.151. Ultima linie a fiecărui tabel însumează valorile indicilor specifici, oferind baza pentru realizarea clasamentului stațiilor (tabelul 7.3.157). Coloana a 2-a a tabelului 7.3.157 oferă un indicator relativ de calitate suplimentar – suma pozițiilor ocupate de stația respectivă în tabelul 7.3.151.

Tabelul 7.3.157. Clasament stații

Nr. crt.	Sumă poziții	Stația	RNB curbă de sarcină		RNB lunar	
			Total	Specific	Total	Specific
1	48	Satchinez	568.54	23.69	63.47	2.65
2	63	Deta	551.93	23.00	70.24	2.93
3	87	Musicescu	365.71	15.23	137.57	5.73
4	121	Bucovina	654.50	27.28	201.74	8.42
5	146	IMT	1042.60	43.43	258.48	10.78

În tabelele 7.3.158 – 7.3.160 (Anexa 7.3) se prezintă rezultatele pentru fiecare zi în parte, ierarhizarea fiind obținută tot pe baza valorii indicelui specific de performanță. S-au extras din tabelul 7.3.151 liniile aferente unei anumite zile, coloana a 2-a indicând poziția liniei respective în tabel. Ultima linie a fiecărui tabel însumează valorile indicilor specifici, oferind baza pentru realizarea clasamentului pentru zile (tabelul 7.3.161). Coloana a 2-a a tabelului 7.3.161 furnizează un indicator relativ de calitate suplimentar – suma pozițiilor ocupate de ziua respectivă în tabelul 7.3.151.

Tabelul 7.3.161. Clasament zile

Nr. crt.	Sumă poziții	Ziua	RNB curbă de sarcină		RNB lunar	
			Total	Specific	Total	Specific
1	150	Martți	890.07	37.09	212.78	8.88
2	154	Miercuri	1140.09	47.50	251.63	10.49
3	161	Joi	1153.12	48.04	267.09	11.14

În tabelele 7.3.162 – 7.3.163 (Anexa 7.3) se prezintă rezultatele pentru fiecare oră în parte, ierarhizarea fiind obținută tot pe baza valorii indicelui specific de performanță. S-au extras din tabelul 7.3.151 liniile aferente unei anumite ore, coloana a 2-a indicând poziția liniei respective în tabel. Ultima linie a fiecărui tabel însumează valorile indicilor specifici, oferind baza pentru realizarea clasamentului pentru ore (tabelul 7.3.164). Coloana a 2-a a tabelului 7.3.164 furnizează un indicator relativ de calitate suplimentar – suma pozițiilor ocupate de ziua respectivă în tabelul 7.3.151.

Tabelul 7.3.164. Clasament ore

Nr. crt.	Sumă poziții	Ora	RNB curbă de sarcină		RNB lunar	
			Total	Specific	Total	Specific
1	185	21	1405.83	58.59	286.37	11.95
2	280	9	1777.45	74.04	445.13	18.56

Analiza ierarhizărilor prezentate mai sus oferă o serie de concluzii, atât cu caracter particular cât și cu caracter general:

- indicii specifici de performanță pentru prognozele lunare (care au stat la baza realizării clasamentelor) acoperă o plajă de valori cuprinsă între 0.26 și 2.46, cu observația că sunt de același ordin de mărime ca cei de la UTR (ceea ce înseamnă curbe de sarcină cu grad de corelare asemănător);
- indicele specific de performanță depinde de datele de consum inițiale (perioada 2009-2016), de gradul de corelare a curbelor de sarcină, de consumul real din anii 2017 și 2018 (pentru care s-a realizat compararea cu valorile prognozate) și de păstrarea formei curbelor de sarcină (din perioada 2009-2016);
- valorile mari ale indicelui specific de performanță, cumulativ pentru prognoza lunară (peste 1,5) și cea a ansamblului curbei de sarcină (peste 4) semnalează posibilitatea existenței unor valori eronate ("discrepante") de consum, prin eliminarea ("corectarea") cărora s-ar ajunge la o prognoză mai bună;
- valorile respective pot fi și reale, datorate unor situații de avarie în alimentarea consumatorilor sau de nefuncționare reală a unor consumatori importanți;
- în contextul celor două comentarii anterioare, un clasament întocmit în funcție de valoarea indicelui specific de performanță pentru prognoza ansamblului curbei de sarcină ar diferi de cel întocmit după prognoza lunară (așa cum se observă urmărind datele din tabelul 7.3.151);
- explicația pentru concluziile de mai sus – gradul de corelare a curbelor de sarcină din punctul de vedere al formei, respectiv trendului valorilor, constituie elemente distincte, cu influențe diferite asupra rezultatelor prognozei;

- totuși, pentru prima poziție din clasamentul prezentat în tabelul 7.3.151 (stația Musicescu, joi, ora 21) și valoarea indicelui specific pentru RNA curbă de sarcină este foarte bună (a doua în ierarhia aferentă), iar pentru ultima poziție din clasament (stația IMT, miercuri, ora 9) și valoarea indicelui specific pentru RNA curbă de sarcină este cea mai proastă (ultima în ierarhia aferentă);
- clasamentul pe stații (tabelul 7.3.157) situează pe primul loc stația Satchinez, cu observația că pentru primele două stații (Satchinez și Deta) valorile sunt relativ apropiate (fără "accidentul" pentru prognoza de joi, ora 9 – poziția 29, tabelul 7.3.151 – și stația Musicescu ar face parte din grupul respectiv);
- criteriul indicelui specific pentru prognoza lunară și al celui pentru prognoza ansamblului curbei de sarcină conduc la un rezultat ușor diferit – stația Musicescu ar fi pe primul loc, urmată foarte aproape de Deta și Satchinez (ceea ce este în spiritul observației anterioare), ultimele două poziții rămânând nemodificate;
- clasamentul general (tabelul 7.3.151) și cel pe stații (tabelul 7.3.157) conduc la o concluzie interesantă: pe primul loc se situează o stație care alimentează în principal o exploatare petrolieră (Satchinez), urmează apoi 3 stații cu consum preponderent rezidențial (Deta, Musicescu și Bucovina), ultimul loc fiind ocupat de o stație care alimentează o zonă cu consum preponderent industrial (IMT);
- clasamentul pe zile (tabelul 7.3.161) furnizează rezultate foarte apropiate, ierarhia fiind marți, miercuri, joi;
- în privința zilelor, criteriul indicelui de performanță specific lunar și cel pentru ansamblul curbei de sarcină conduc la același ierarhie;
- clasamentul pe ore (tabelul 7.3.164) are pe primul loc ora 21, cu observația că diferența dintre ora 21 și ora 9 este foarte clară;
- în privința orelor, criteriul indicelui de performanță specific lunar și cel pentru ansamblul curbei de sarcină conduc la același ierarhie.

### 7.3.8. Previzionarea calității prognozelor pentru stații

În acest paragraf se prezintă o estimare (previzionare) a calității prognozelor pentru stații în funcție de calitatea datelor cunoscute (gradul de corelare) pentru o anumită perioadă trecută (un anumit număr de ani). Acest instrument are la bază calculul unor diferențe finite [Kilyeni2015], [Deacu2015], cu ajutorul cărora se determină o serie de indici globali caracteristici.

Toate mărimile discutate se exprimă atât în unități absolute, cât și în unități relative. Pentru aprecierea comparativă a unei game largi de curbe de sarcină, exprimarea în unități relative are un grad sporit de relevanță (este eliminată dependența de nivelul consumului).

Se cunosc curbele de sarcină lunare aferente unei anumite ore a unei zile anume, pentru o perioadă de  $n$  ani. Se notează cu  $P_i^j$ ,  $i = 1, 2, \dots, n$ ;  $j = 1, 2, \dots, 12$ , puterea aferentă lunii  $j$  a curbei de sarcină din anul  $i$ .

Se definesc diferențele finite anuale absolute de ordinul 1 aferente lunii 1 (ianuarie):

$$\Delta_a^1 P_i^1 = P_{i+1}^1 - P_i^1, \quad i = 1, 2, \dots, n-1 \quad (7.3.1)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^1 P_i^1 = \frac{P_{i+1}^1 - P_i^1}{P_i^1} = \frac{\Delta_a^1 P_i^1}{P_i^1}, \quad i = 1, 2, \dots, n-1 \quad (7.3.2)$$

Diferențele finite absolute de ordinul  $k$ ,  $k = 2, 3, \dots, n-1$ , în număr de  $(n - k)$ , se determină cu relația:

$$\Delta_a^k P_i^1 = \Delta_a^{k-1} P_{i+1}^1 - \Delta_a^{k-1} P_i^1, \quad i = 1, 2, \dots, n - k \quad (7.3.3)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^k P_i^1 = \Delta_{ar}^{k-1} P_{i+1}^1 - \Delta_{ar}^{k-1} P_i^1, \quad i = 1, 2, \dots, n - k \quad (7.3.4)$$

Evident, pentru ordinul  $n-1$  rezultă o singură valoare:

$$\Delta_a^{n-1} P_1^1 = \Delta_a^{n-2} P_2^1 - \Delta_a^{n-2} P_1^1 \quad (7.3.5)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^{n-1} P_1^1 = \Delta_{ar}^{n-2} P_2^1 - \Delta_{ar}^{n-2} P_1^1 \quad (7.3.6)$$

Generalizând relațiile anterioare, se poate scrie expresia diferențelor finite anuale absolute de ordinul  $k$ ,  $k = 1, 2, \dots, n-1$ , aferente lunii  $j$ ,  $j = 1, 2, \dots, 11$ :

$$\Delta_a^k P_i^j = \Delta_a^{k-1} P_{i+1}^j - \Delta_a^{k-1} P_i^j, \quad i = 1, 2, \dots, n - k \quad (7.3.7)$$

Evident:

$$\Delta_a^0 P_i^j = P_i^j, \quad i = 1, 2, \dots, n; j = 1, 2, \dots, 12 \quad (7.3.8)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{ar}^k P_i^j = \Delta_{ar}^{k-1} P_{i+1}^j - \Delta_{ar}^{k-1} P_i^j, \quad i = 1, 2, \dots, n - k \quad (7.3.9)$$

Se definește în final indicele global de calitate anual  $IC_a$  pentru setul de date inițiale menționate la începutul paragrafului:

$$IC_a = \sum_{j=1}^{11} (\Delta_a^{n-1} P_1^j)^2 \quad (7.3.10)$$

În exprimare relativă indicele global de calitate anual  $IC_{ar}$  are expresia:

$$IC_{ar} = \sum_{j=1}^{11} (\Delta_{ar}^{n-1} P_1^j)^2 \quad (7.3.11)$$

În continuare se procedează analog în privința diferențelor finite lunare. Se definesc diferențele finite lunare absolute de ordinul 1 aferente lunii 1 (ianuarie):

$$\Delta_l^1 P_i^1 = P_i^2 - P_i^1, \quad i = 1, 2, \dots, n \quad (7.3.12)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{lr}^1 P_i^1 = \frac{P_i^2 - P_i^1}{P_i^1} = \frac{\Delta_l^1 P_i^1}{P_i^1}, \quad i = 1, 2, \dots, n \quad (7.3.13)$$

Diferențele finite absolute de ordinul  $k$ ,  $k = 2, 3, \dots, n$  - în număr de  $n - (k - 1)$  - se determină cu relația:

$$\Delta_l^k P_i^1 = \Delta_l^{k-1} P_{i+1}^1 - \Delta_l^{k-1} P_i^1, \quad i = 1, 2, \dots, n - k + 1 \quad (7.3.14)$$

Pentru diferența finită relativă rezultă:

$$\Delta_{lr}^k P_i^1 = \Delta_{lr}^{k-1} P_{i+1}^1 - \Delta_{lr}^{k-1} P_i^1, \quad i = 1, 2, \dots, n - k + 1 \quad (7.3.15)$$

Diferența finită de ordinul  $n$  (evident, una singură) este cea care ne interesează:  $\Delta_{lr}^n P_1^1$ , respectiv  $\Delta_{lr}^n P_1^1$ .

Generalizând relațiile anterioare, se poate scrie expresia diferențelor finite lunare absolute de ordinul  $k$ ,  $k = 1, 2, \dots, n$ , aferente lunii  $j$ ,  $j = 1, 2, \dots, 11$ :

$$\Delta_o^k P_i^j = \Delta_o^{k-1} P_{i+1}^j - \Delta_o^{k-1} P_i^j, \quad i = 1, 2, \dots, n - k + 1 \quad (7.3.16)$$

În exprimare relativă (raportată) înseamnă:

$$\Delta_{or}^k P_i^j = \Delta_{or}^{k-1} P_{i+1}^j - \Delta_{or}^{k-1} P_i^j, \quad i = 1, 2, \dots, n - k + 1 \quad (7.3.17)$$

Se definește în final indicele global de calitate lunar  $IC_l$  pentru setul de date inițiale menționate la începutul paragrafului:

$$IC_l = \sum_{j=1}^{11} (\Delta_{lr}^n P_1^j)^2 \quad (7.3.18)$$

În exprimare relativă indicele global de calitate lunar  $IC_{lr}$  are expresia:

$$IC_{lr} = \sum_{j=1}^{11} (\Delta_{lr}^n P_1^j)^2 \quad (7.3.19)$$

Pentru aprecierea comparativă a unei game largi de curbe de sarcină, exprimarea în unități relative are un grad sporit de relevanță (este eliminată dependența de nivelul consumului), cu alte cuvinte prezintă interes  $IC_{ar}$ , determinat cu relația (7.3.11), respectiv  $IC_{lr}$ , determinat cu relația (7.3.19).

Pentru fiecare stație, fiecare zi și fiecare oră s-au calculat valorile indicilor pătratici globali caracteristici  $IC_a, IC_{ar}, IC_l, IC_{lr}$ , conform relațiilor (7.3.10), (7.3.11), (7.3.18), (7.3.19). Rezultatele sunt centralizate în tabelul 7.3.165, cu mențiunea că pentru o apreciere comparativă, valorile relative ale indicilor sunt relevante (valorile absolute depind și de nivelul consumului). S-a întocmit și câte un clasament pentru fiecare indice în parte și pentru suma lor, apoi s-a calculat o medie a locurilor ocupate în cele trei clasamente, pe baza căruia a rezultat clasamentul final din ultima coloană a tabelului.

Tabelul 7.3.165. Valorile indicilor pătratici globali caracteristici

Nr. crt.	Stația, ziua, ora	$IC_{ar}$	Clasament $IC_{ar}$	$IC_{lr}$	Clasament $IC_{lr}$	$IC_{ar} + IC_{lr}$	Clasament $IC_{ar} + IC_{lr}$	Medie clasament	Clasament final
1	Bucovina, mi, 9	660.1	13	748.3	16	1408.4	15	14.67	15
2	Bucovina, mi, 21	1213.2	23	1410.6	23	2623.8	23	23.00	23
3	Bucovina, joi, 9	1389.3	24	1438.1	24	2827.4	24	24.00	24
4	Bucovina, joi, 21	1495.5	25	1972.1	27	3467.6	25	25.67	25
5	Bucovina, ma, 9	880.0	19	1096.6	20	1976.6	21	20.00	21



Nr. crt.	Stația, ziua, ora	$IC_{ar}$	Clasament $IC_{ar}$	$IC_{lr}$	Clasament $IC_{lr}$	$IC_{ar} + IC_{lr}$	Clasament $IC_{ar} + IC_{lr}$	Medie clasament	Clasament final
6	Bucovina, ma, 21	544.8	12	204.9	1	749.7	4	5.67	5
7	IMT, mi, 9	1796.5	27	1973.4	28	3769.9	28	27.67	28
8	IMT, mi, 21	2495.2	29	2064.1	29	4559.3	29	29.00	29
9	IMT, joi, 9	1581.9	26	1917.9	26	3499.8	26	26.00	26
10	IMT, joi, 21	1813.8	28	1875.0	25	3688.8	27	26.67	27
11	IMT, ma, 9	2600.4	30	2419.6	30	5020.0	30	30.00	30
12	IMT, ma, 21	767.2	18	1035.8	19	1803.0	19	18.67	19
13	Musicescu, mi, 9	761.7	17	1115.6	21	1877.3	20	19.33	20
14	Musicescu, mi, 21	353.1	4	380.3	4	733.4	3	3.67	3
15	Musicescu, joi, 9	892.5	21	1284.0	22	2176.5	22	21.67	22
16	Musicescu, joi, 21	268.5	1	303.2	2	571.7	1	1.33	1
17	Musicescu, ma, 9	380.1	6	587.2	11	967.3	10	9.00	9
18	Musicescu, ma, 21	336.5	3	454.9	6	791.4	5	4.67	4
19	Deta, mi, 9	481.1	11	465.9	7	947.0	8	8.67	8
20	Deta, mi, 21	673.3	14	633.4	14	1306.7	14	14.00	14
21	Deta, joi, 9	713.5	16	919.1	17	1632.6	18	17.00	17
22	Deta, joi, 21	426.7	8	655.7	15	1082.4	11	11.33	11
23	Deta, ma, 9	891.3	20	627.0	13	1518.3	16	16.33	16
24	Deta, ma, 21	430.6	9	509.7	9	940.3	7	8.33	7
25	Satchinez, mi, 9	468.9	10	493.4	8	962.3	9	9.00	10
26	Satchinez, mi, 21	395.2	7	404.4	5	799.6	6	6.00	6
27	Satchinez, joi, 9	373.9	5	926.0	18	1299.9	13	12.00	12
28	Satchinez, joi, 21	298.8	2	317.3	3	616.1	1	2.00	2
29	Satchinez, ma, 9	938.6	22	607.2	12	1545.8	17	17.00	18
30	Satchinez, ma, 21	695.6	15	562.0	10	1257.6	12	12.33	13

În tabelul 7.3.166 se prezintă o apreciere comparativă a valorii indicilor specifici (echivalenți) de performanță, preluați din tabelul 7.3.151, rezultând clasamentele obținute pe baza acestui criteriu.

Tabelul 7.3.166. Clasamente pe baza indicilor specifici (echivalenți) de performanță

Nr. crt.	Stația, ziua, ora	RNA bayesiană, curbă de sarcină			RNA bayesiană, lunar			Sumă $S_{specific}$	Clasament	Medie clasament	Clasament final
		$S_{total}$	$S_{specific}$	Clasament	$S_{total}$	$S_{specific}$	Clasament				
1	Bucovina, mi, 9	77.62	3.23	5	30.87	1.29	19	4.52	15	13.00	12
2	Bucovina, mi, 21	96.39	4.02	17	27.33	1.14	18	5.16	19	18.00	19
3	Bucovina, joi, 9	116.1	4.84	24	45.08	1.88	27	6.72	24	25.00	25
4	Bucovina, joi, 21	192.0	8.00	28	43.12	1.80	25	9.80	28	27.00	27
5	Bucovina, ma, 9	89.67	3.74	11	45.12	1.88	26	5.62	20	19.00	20
6	Bucovina, ma, 21	82.72	3.45	7	10.22	0.43	6	3.87	6	6.33	3
7	IMT, mi, 9	312.8	13.03	30	59.03	2.46	30	15.49	30	30.00	30
8	IMT, mi, 21	134.1	5.59	26	40.38	1.68	23	7.27	26	25.00	26

Nr. crt.	Stația, ziua, ora	RNA bayesiană, curbă de sarcină			RNA bayesiană, lunar			Sumă $S_{specific}$	Clasament	Medie clasament	Clasament final
		$S_{total}$	$S_{specific}$	Clasament	$S_{total}$	$S_{specific}$	Clasament				
9	IMT, joi, 9	202.4	8.43	29	42.85	1.79	24	10.22	29	27.33	28
10	IMT, joi, 21	129.2	5.38	25	32.34	1.35	20	6.73	25	23.33	24
11	IMT, ma, 9	150.1	6.25	27	45.56	1.90	28	8.15	27	27.33	29
12	IMT, ma, 21	114.0	4.75	22	38.32	1.60	21	6.35	21	21.33	21
13	Musicescu, mi, 9	116.0	4.83	23	39.74	1.66	22	6.49	23	22.67	22
14	Musicescu, mi, 21	40.56	1.69	4	7.93	0.33	2	2.02	3	3.00	2
15	Musicescu, joi, 9	98.38	4.10	18	54.08	2.25	29	6.35	22	23.00	23
16	Musicescu, joi, 21	40.17	1.67	2	6.32	0.26	1	1.94	2	1.67	1
17	Musicescu, ma, 9	27.69	1.15	1	15.30	0.64	17	1.79	1	6.33	4
18	Musicescu, ma, 21	42.91	1.79	4	14.20	0.59	16	2.38	4	8.00	8
19	Deta, mi, 9	83.53	3.48	8	10.80	0.45	7	3.93	7	7.33	7
20	Deta, mi, 21	93.83	3.91	13	14.02	0.58	15	4.49	14	14.00	15
21	Deta, joi, 9	94.10	3.92	15	12.73	0.53	14	4.45	13	14.00	16
22	Deta, joi, 21	94.71	3.95	16	11.66	0.49	11	4.43	12	13.00	13
23	Deta, ma, 9	98.97	4.12	19	12.01	0.50	12	4.62	16	15.67	17
24	Deta, ma, 21	86.79	3.62	9	9.02	0.38	4	3.99	8	7.00	6
25	Satchinez, mi, 9	93.79	3.91	14	12.52	0.52	13	4.43	11	12.67	11
26	Satchinez, mi, 21	91.47	3.81	12	9.01	0.38	5	4.19	10	9.00	9
27	Satchinez, joi, 9	107.3	4.47	20	7.96	0.33	3	4.80	17	13.33	14
28	Satchinez, joi, 21	78.76	3.28	6	10.95	0.46	8	3.74	5	6.33	5
29	Satchinez, ma, 9	109.0	4.54	21	11.48	0.48	10	5.02	18	16.33	18
30	Satchinez, ma, 21	88.22	3.68	10	11.55	0.48	9	4.16	9	9.33	10

În tabelul 7.3.167 s-au reunit clasamentele din tabellele și 7.3.165 și 7.3.166.

Tabelul 7.3.167. Comparație clasamente

Nr. crt.	Stația, ziua, ora	Clasament Indici caracteristici				Clasament Indici specifici de performanță			
		$IC_{ar}$	$IC_{lr}$	Sumă	Final	RNB curbă sarcină	RNB lunar	Sumă	Final
1	Bucovina, mi, 9	13	16	15	15	5	19	15	12
2	Bucovina, mi, 21	23	23	23	23	17	18	19	19
3	Bucovina, joi, 9	24	24	24	24	24	27	24	25
4	Bucovina, joi, 21	25	27	25	25	28	25	28	27
5	Bucovina, ma, 9	19	20	21	21	11	26	20	20
6	Bucovina, ma, 21	12	1	4	5	7	6	6	3
7	IMT, mi, 9	27	28	28	28	30	30	30	30
8	IMT, mi, 21	29	29	29	29	26	23	26	26
9	IMT, joi, 9	26	26	26	26	29	24	29	28
10	IMT, joi, 21	28	25	27	27	25	20	25	24
11	IMT, ma, 9	30	30	30	30	27	28	27	29
12	IMT, ma, 21	18	19	19	19	22	21	21	21
13	Musicescu, mi, 9	17	21	20	20	23	22	23	22

Nr. crt.	Stația, ziua, ora	Clasament Indici caracteristici				Clasament Indici specifici de performanță			
		$IC_{ar}$	$IC_{lr}$	Sumă	Final	RNB curbă sarcină	RNB lunar	Sumă	Final
14	Musicescu, mi, 21	4	4	3	3	4	2	3	2
15	Musicescu, joi, 9	21	22	22	22	18	29	22	23
16	Musicescu, joi, 21	1	2	1	1	2	1	2	1
17	Musicescu, ma, 9	6	11	10	9	1	17	1	4
18	Musicescu, ma, 21	3	6	5	4	4	16	4	8
19	Deta, mi, 9	11	7	8	8	8	7	7	7
20	Deta, mi, 21	14	14	14	14	13	15	14	15
21	Deta, joi, 9	16	17	18	17	15	14	13	16
22	Deta, joi, 21	8	15	11	11	16	11	12	13
23	Deta, ma, 9	20	13	16	16	19	12	16	17
24	Deta, ma, 21	9	9	7	7	9	4	8	6
25	Satchinez, mi, 9	10	8	9	10	14	13	11	11
26	Satchinez, mi, 21	7	5	6	6	12	5	10	9
27	Satchinez, joi, 9	5	18	13	12	20	3	17	14
28	Satchinez, joi, 21	2	3	1	2	6	8	5	5
29	Satchinez, ma, 9	22	12	17	18	21	10	18	18
30	Satchinez, ma, 21	15	10	12	13	10	9	9	10

În tabelul 7.3.168 s-a realizat o ierarhizare pe baza acordării unor note calculate cu relația:

$$Nota = \frac{\text{Valoare maxima indice} - \text{Valoare curenta indice}}{\text{Valoare maxima indice} - \text{Valoare minima indice}} \cdot 10 \quad (7.3.20)$$

Tabelul 7.3.168. Comparație note

Nr. crt.	Stația, ziua, ora	Note Indici caracteristici					Note Indici specifici de performanță				
		$IC_{ar}$	$IC_{lr}$	$IC_{ar} + IC_{lr}$	Medie	Clasament	RNB, curbă de sarcină	RNB, lunar	Sumă	Medie	Clasament
1	Bucovina, mi, 9	8.29	7.55	8.12	7.98	15	8.25	5.32	8.01	7.19	18
2	Bucovina, mi, 21	5.93	4.56	5.39	5.29	23	7.58	6.00	7.54	7.04	19
3	Bucovina, joi, 9	5.17	4.43	4.93	4.84	24	6.89	2.64	6.40	5.31	24
4	Bucovina, joi, 21	4.72	2.02	3.49	3.41	25	4.23	3.00	4.15	3.80	28
5	Bucovina, ma, 9	7.35	5.97	6.84	6.72	21	7.82	2.64	7.20	5.89	21
6	Bucovina, ma, 21	8.78	10.00	9.60	9.46	4	8.06	9.23	8.48	8.59	6
7	IMT, mi, 9	3.43	2.01	2.81	2.75	28	0.00	0.00	0.00	0.00	30
8	IMT, mi, 21	0.45	1.61	1.04	1.03	29	6.26	3.55	6.00	5.27	25
9	IMT, joi, 9	4.35	2.27	3.42	3.34	26	3.87	3.05	3.85	3.59	29
10	IMT, joi, 21	3.36	2.46	2.99	2.94	27	6.44	5.05	6.39	5.96	20
11	IMT, ma, 9	0.00	0.00	0.00	0.00	30	5.71	2.55	5.36	4.54	27
12	IMT, ma, 21	7.83	6.25	7.23	7.10	19	6.97	3.91	6.67	5.85	22
13	Musicescu, mi, 9	7.85	5.89	7.06	6.94	20	6.90	3.64	6.57	5.70	23
14	Musicescu, mi, 21	9.60	9.21	9.64	9.48	3	9.55	9.68	9.83	9.69	2

Nr. crt.	Stația, ziua, ora	Note Indici caracteristici					Note Indici specifici de performanță				
		$IC_{ar}$	$IC_{lr}$	$IC_{ar} + IC_{lr}$	Medie	Clasament	RNB, curbă de sarcină	RNB, lunar	Sumă	Medie	Clasament
15	Musicescu, joi, 9	7.30	5.13	6.39	6.27	22	7.52	0.95	6.67	5.05	26
16	Musicescu, joi, 21	9.96	9.56	10.00	9.84	1	9.56	10.00	9.89	9.82	1
17	Musicescu, ma, 9	9.48	8.27	9.11	8.96	10	10.00	8.27	10.00	9.42	3
18	Musicescu, ma, 21	9.67	8.87	9.51	9.35	5	9.46	8.50	9.57	9.18	4
19	Deta, mi, 9	9.05	8.82	9.16	9.01	8	8.04	9.14	8.44	8.54	8
20	Deta, mi, 21	8.23	8.07	8.35	8.22	13	7.68	8.55	8.03	8.08	16
21	Deta, joi, 9	8.06	6.78	7.62	7.48	18	7.67	8.77	8.06	8.17	14
22	Deta, joi, 21	9.29	7.96	8.85	8.70	11	7.64	8.95	8.07	8.22	12
23	Deta, ma, 9	7.30	8.09	7.87	7.76	16	7.50	8.91	7.93	8.11	15
24	Deta, ma, 21	9.27	8.62	9.17	9.02	7	7.92	9.45	8.39	8.59	7
25	Satchinez, mi, 9	9.11	8.70	9.12	8.97	9	7.68	8.82	8.07	8.19	13
26	Satchinez, mi, 21	9.42	9.10	9.49	9.34	6	7.76	9.45	8.25	8.49	9
27	Satchinez, joi, 9	9.51	6.74	8.36	8.21	14	7.21	9.68	7.80	8.23	11
28	Satchinez, joi, 21	9.83	9.49	9.90	9.74	2	8.21	9.09	8.58	8.62	5
29	Satchinez, ma, 9	7.10	8.18	7.81	7.70	17	7.15	9.00	7.64	7.93	17
30	Satchinez, ma, 21	8.14	8.39	8.46	8.33	12	7.87	9.00	8.27	8.38	10

Pentru a compara calitatea prognozelor realizate cu valorile indicilor caracteristici calculați pe baza diferențelor finite, în tabelele 7.3.169 și 7.3.170 s-au reunit clasamentele realizate mai sus (referitoare la indicii caracteristici, respectiv la indicii de performanță). Tabelul 7.3.169 utilizează suma indicilor (anuali și lunari), iar tabelul 7.3.170 – separat indicii anual și lunar.

Tabelul 7.3.169. Analiza corelării calității prognozei cu indicii de caracteristici (anual + lunar)

Nr. crt.	Stația, ziua, ora	Loc clasament indici caracteristici		Loc clasament indici de performanță		Diferență loc (valoare absolută)		Loc clasament note indici caracteristici		Loc clasament note indici de performanță		Diferență loc (valoare absolută)	
		Loc clasament indici caracteristici	Loc clasament indici de performanță	Loc clasament indici caracteristici	Loc clasament indici de performanță	Loc clasament note indici caracteristici	Loc clasament note indici de performanță	Loc clasament indici caracteristici	Loc clasament indici de performanță	Loc clasament note indici caracteristici	Loc clasament note indici de performanță	Loc clasament indici caracteristici	Loc clasament indici de performanță
1	Bucovina, mi, 9	15	12	3	15	18	3	15	5	10	15	19	4
2	Bucovina, mi, 21	23	19	4	23	19	4	23	17	6	23	18	5
3	Bucovina, joi, 9	24	25	1	24	24	0	24	24	0	24	27	3
4	Bucovina, joi, 21	25	27	2	25	28	3	25	28	3	25	25	0
5	Bucovina, ma, 9	21	20	1	21	21	0	21	11	10	21	26	5
6	Bucovina, ma, 21	5	3	2	4	6	2	4	7	3	4	6	2
7	IMT, mi, 9	28	30	2	28	30	2	28	30	2	28	30	2
8	IMT, mi, 21	29	26	3	29	25	4	29	26	3	29	23	6
9	IMT, joi, 9	26	28	2	26	29	3	26	29	3	26	24	2
10	IMT, joi, 21	27	24	3	27	20	7	27	25	2	27	20	7

Nr. crt.	Stația, ziua, ora	Indicii de caracteristici											
		Loc clasament indici caracteristici	Loc clasament indici de performanță	Diferență loc (valoare absolută)	Loc clasament note indici caracteristici	Loc clasament note indici de performanță	Diferență loc (valoare absolută)	Loc clasament note indici caracteristici	Loc clasament indici de performanță RNB CS	Diferență loc (valoare absolută)	Loc clasament note indici caracteristici	Loc clasament indici de performanță RNB lunar	Diferență loc (valoare absolută)
11	IMT, ma, 9	30	29	1	30	27	3	30	27	3	30	28	2
12	IMT, ma, 21	19	21	2	19	22	3	19	22	3	19	21	2
13	Musicescu, mi, 9	20	22	2	20	23	3	20	23	3	20	22	2
14	Musicescu, mi, 21	3	2	1	3	2	1	3	4	1	3	2	1
15	Musicescu, joi, 9	22	23	1	22	26	4	22	18	4	22	29	7
16	Musicescu, joi, 21	1	1	0	1	1	0	1	2	1	1	1	0
17	Musicescu, ma, 9	9	4	5	10	3	7	10	1	9	10	17	7
18	Musicescu, ma, 21	4	8	4	5	4	1	5	4	1	5	16	11
19	Deta, mi, 9	8	7	1	8	8	0	8	8	0	8	7	1
20	Deta, mi, 21	14	15	1	13	16	3	13	13	0	13	15	2
21	Deta, joi, 9	17	16	1	18	14	4	18	15	3	18	14	4
22	Deta, joi, 21	11	13	2	11	12	1	11	16	5	11	11	0
23	Deta, ma, 9	16	17	1	16	15	1	16	19	3	16	12	4
24	Deta, ma, 21	7	6	1	7	7	0	7	9	2	7	4	3
25	Satchinez, mi, 9	10	11	1	9	13	4	9	14	5	9	13	4
26	Satchinez, mi, 21	6	9	3	6	9	3	6	12	6	6	5	1
27	Satchinez, joi, 9	12	14	2	14	11	3	14	20	6	14	3	11
28	Satchinez, joi, 21	2	5	3	2	5	3	2	6	4	2	8	6
29	Satchinez, ma, 9	18	18	0	17	17	0	17	21	4	17	10	7
30	Satchinez, ma, 21	13	10	3	12	10	2	12	10	2	12	9	3
		Suma	58		Suma	74		Suma	107		Suma	114	

Tabelul 7.3.170. Analiza corelării calității prognozei cu indicii de caracteristici (anual, lunar)

Nr. crt.	Stația, ziua, ora	Indicii de caracteristici											
		Loc clasament indici caracteristici anuali	Loc clasament indici de performanță RNB CS	Diferență loc (valoare absolută)	Loc clasament indici caracteristici anuali	Loc clasament indici de performanță RNB lunar	Diferență loc (valoare absolută)	Loc clasament indici caracteristici lunari	Loc clasament indici de performanță RNB CS	Diferență loc (valoare absolută)	Loc clasament indici caracteristici lunari	Loc clasament indici de performanță RNB lunar	Diferență loc (valoare absolută)
1	Bucovina, mi, 9	13	5	8	13	19	6	16	5	11	16	19	3
2	Bucovina, mi, 21	23	17	6	23	18	5	23	17	6	23	18	5
3	Bucovina, joi, 9	24	24	0	24	27	3	24	24	0	24	27	3
4	Bucovina, joi, 21	25	28	3	25	25	0	27	28	1	27	25	2
5	Bucovina, ma, 9	19	11	8	19	26	7	20	11	9	20	26	6
6	Bucovina, ma, 21	12	7	5	12	6	6	1	7	6	1	6	5
7	IMT, mi, 9	27	30	3	27	30	3	28	30	2	28	30	2
8	IMT, mi, 21	29	26	3	29	23	6	29	26	3	29	23	6

Nr. crt.	Stația, ziua, ora	Loc clasament indici caracteristici anuali			Loc clasament indici caracteristici anuali			Loc clasament indici caracteristici lunari			Loc clasament indici caracteristici lunari		
		Loc clasament indici caracteristici anuali	Loc clasament indici de performanță RNB CS	Diferență loc (valoare absolută)	Loc clasament indici caracteristici anuali	Loc clasament indici de performanță RNB lunar	Diferență loc (valoare absolută)	Loc clasament indici caracteristici lunari	Loc clasament indici de performanță RNB CS	Diferență loc (valoare absolută)	Loc clasament indici caracteristici lunari	Loc clasament indici de performanță RNB lunar	Diferență loc (valoare absolută)
9	IMT, joi, 9	26	29	3	26	24	2	26	29	3	26	24	2
10	IMT, joi, 21	28	25	3	28	20	8	25	25	0	25	20	5
11	IMT, ma, 9	30	27	3	30	28	2	30	27	3	30	28	2
12	IMT, ma, 21	18	22	4	18	21	3	19	22	3	19	21	2
13	Musicescu, mi, 9	17	23	6	17	22	5	21	23	2	21	22	1
14	Musicescu, mi, 21	4	4	0	4	2	2	4	4	0	4	2	2
15	Musicescu, joi, 9	21	18	3	21	29	8	22	18	4	22	29	7
16	Musicescu, joi, 21	1	2	1	1	1	0	2	2	0	2	1	1
17	Musicescu, ma, 9	6	1	5	6	17	11	11	1	10	11	17	6
18	Musicescu, ma, 21	3	4	1	3	16	13	6	4	2	6	16	10
19	Deta, mi, 9	11	8	3	11	7	4	7	8	1	7	7	0
20	Deta, mi, 21	14	13	1	14	15	1	14	13	1	14	15	1
21	Deta, joi, 9	16	15	1	16	14	2	17	15	2	17	14	3
22	Deta, joi, 21	8	16	8	8	11	3	15	16	1	15	11	4
23	Deta, ma, 9	20	19	1	20	12	8	13	19	6	13	12	1
24	Deta, ma, 21	9	9	0	9	4	5	9	9	0	9	4	5
25	Satchinez, mi, 9	10	14	4	10	13	3	8	14	6	8	13	5
26	Satchinez, mi, 21	7	12	5	7	5	2	5	12	7	5	5	0
27	Satchinez, joi, 9	5	20	15	5	3	2	18	20	2	18	3	15
28	Satchinez, joi, 21	2	6	4	2	8	6	3	6	3	3	8	5
29	Satchinez, ma, 9	22	21	1	22	10	12	12	21	9	12	10	2
30	Satchinez, ma, 21	15	10	5	15	9	6	10	10	0	10	9	1
		Suma	113		Suma	144		Suma	103		Suma	112	

Analiza rezultatelor prezentate conduce la următoarele concluzii:

- comparând rezultatele cu cele din subcapitolul 7.2, se apreciază că gradul de corelare a datelor de consum (curbelor de sarcină) pentru stații este de același ordin de mărime cu cel de la UTR;
- indicii specifici de performanță pentru prognozele referitoare la ansamblul curbei de sarcină sunt cuprinși în gama (2.23÷15.33) pentru UTR, respectiv (1.15÷13.03) pentru stații;
- indicii specifici de performanță pentru prognozele orare (lunare) sunt cuprinși în gama (0.52÷2.64) pentru UTR, respectiv (0.26÷2.46) pentru stații;
- clasamentele absolute și comparative (tabelele 7.3.165 - 7.3.170) reflectă clar existența unei corespondențe (corelări) între valorile indicilor pătratici globali caracteristici (obținuți pe baza calculului diferențelor finite anuale și lunare) și cele ale indicilor specifici de performanță ai prognozelor ;
- primele două comparații din tabelul 7.3.169 arată o corespondență acceptabilă spre bună între calitatea prognozei și indicii caracteristici calculați cu diferențe finite (gradul de corespondență se poate urmări atât pe baza diferenței dintre locurile ocupate în clasament, cât și pe baza sumei valorilor absolute ale acestor diferențe – ultima linie a tabelului);

- cel mai bun grad de corelare a rezultat la confruntarea clasamentelor obținute prin ierarhizarea indicilor caracteristici și a indicilor de performanță (prima comparație din tabelul 7.3.169), suma valorilor absolute ale diferențelor dintre locurile ocupate în clasament fiind 58;
- valoarea de 58 semnifică de fapt o diferență medie mai mică de 2 locuri într-un clasament cu 30 de poziții (se observă că există 1 diferență de 5 locuri, 2 de 4 locuri, 6 de 3 locuri, 8 de 2 locuri, 11 de 1 loc și 2 coincidențe de loc);
- ultimele două comparații din tabelul 7.3.169 arată un grad de corelare mai bun între calitatea prognozelor obținute cu RNA folosind curbele de sarcină față de cele obținute cu RNA folosind consumurile lunare (107 față de 114);
- cele 4 comparații din tabelul 7.4.170, unde în loc de suma indicilor caracteristici s-au utilizat separat indicii anuali și cei lunari, confirmă concluziile de mai sus, cu observația că totuși este recomandată folosirea sumei indicilor.

În final se apreciază că concluzia de la finele subcapitolului 7.2 (referitor la UTR) rămâne valabilă (cu nuanțele precizate mai sus): indicii de calitate determinați pe baza diferențelor finite pot ajuta foarte bine la previzionarea calității prognozelor.

## 7.4. Concluzii

Capitolul 7 constituie principala parte aplicativă a tezei de doctorat. Se prezintă rezultatele obținute privind prognoza puterii consumate și a curbelor de sarcină utilizând tehnici de inteligență artificială – RNA bayesiene. S-a pornit de la cazuri simple și de la baze de date test, în scopul validării metodelor propuse și "calibrării" instrumentelor soft. În același scop au fost realizate și o serie de studii comparative cu cele din [Deacu2015] și [Chiș2015]. În continuare s-au analizat situații reale, referitoare la operatori de distribuție din România: Enel, Electrica, Delgaz Grid etc.

Din motive de spațiu, pentru acest capitol s-au selectat doar o serie de studii de caz vizând Enel Distribuție Banat. Rezultatele obținute și pentru alte sisteme de distribuție a energiei electrice au fost utilizate în cadrul contractelor derulate în ultimii ani prin Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor SEE din cadrul Universității Politehnica Timișoara, beneficiarii fiind operatori de distribuție din România (Enel Distribuție Banat și Dobrogea, Electrica Muntenia Nord, Delgaz Grid) și agenți economici cu preocupări în domeniul implementării surselor regenerabile de energie.

În prima parte a capitolului s-au validat modelele de calcul și instrumentele soft elaborate prin realizarea unor comparații cu rezultatele din [Deacu2015] și [Chiș2015] și s-au demonstrat calitățile superioare ale metodelor utilizând RNA bayesiene.

A doua parte prezintă o serie de studii de prognoză realizate atât pentru ansamblul rețelei de distribuție din cadrul Enel Distribuție Banat cât și pentru UTR componente: Arad, Deva, Reșița și Timișoara.

A treia parte este dedicată stațiilor de transformare de 110 kV / m.t. din cadrul UTR Timișoara. Pentru prezentarea rezultatelor în extenso au fost selectate 5 stații de 110 / 20 kV (3 din municipiul Timișoara, una dintr-o localitate importantă a jud. Timiș și una care alimentează o exploatare petrolieră): Bucovina, IMT, Musicescu, Deta și Satchinez.

La finele fiecărui subcapitol în parte și al ansamblului capitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau vizând aspecte de natură mai generală, vizând atât rezultatele prognozelor realizate cât și metodele și modelele utilizate. Ele sunt extrem de utile nu numai operatorilor de distribuție ci și tuturor celor interesați de evoluția viitoare a consumului de energie electrică.

În continuare se prezintă o sinteză a contribuțiilor personale, în contextul în care întregul capitol este original, reprezentând principala parte aplicativă a tezei:

- realizarea unor baze de date cuprinzătoare privind consumurile de energie electrică (putere) la nivelul Enel Distribuție Banat, al UTR componente și al stațiilor de distribuție de 110 kV / m.t.;
- realizarea unor comparații edificatoare cu alte lucrări având un subiect asemănător, în scopul demonstrării calității superioare a metodelor elaborate în cadrul tezei;
- realizarea unor studii extinse de prognoză pentru Enel Distribuție Banat și pentru alți operatori de distribuție și agenți economici;
- testarea unei tehnici de analiză a datelor de consum, în scopul formulării unei previziuni privind calitatea așteptată a prognozei;
- formularea unor concluzii utile operatorilor de distribuție și operatorului național de transport și de sistem (C.N.T.E.E. Transelectrica S.A.), atât în ceea ce privește tehnica de realizare a prognozelor și instrumentelor soft cât și rezultatele obținute pentru situațiile concrete abordate.



## 8. CONCLUZII GENERALE. CONTRIBUȚII PERSONALE

Acest ultim capitol sintetizează o serie de concluzii cu caracter mai general, rezultate în urma elaborării tezei de doctorat, contribuțiile originale aduse în cadrul tezei, modul de valorificare a rezultatelor și direcțiile posibile de continuare și aprofundare a cercetărilor în domeniul prognozei consumului de energie electrică (putere) și al curbelor de sarcină.

Dezvoltările teoretice și rezultatele practice prezentate în cadrul tezei de doctorat evidențiază următoarele concluzii și comentarii cu caracter mai general:

- Pe baza analizei evoluției sectorului energetic, cu referire și la sistemul electroenergetic al României, se pot afirma următoarele:
  - necesitatea dezvoltării unui sistem electroenergetic puternic și fiabil, care să respecte cerințele legate de mediu și să asigure accesul consumatorilor la sursele de energie la prețuri accesibile, în condiții de siguranță în alimentare și de calitate corespunzătoare a energiei furnizate;
  - prognoza consumului trebuie să reprezinte o preocupare de prim rang, atât în contextul planificării dezvoltării rețelei de transport și a celei de distribuție a energiei electrice cât și în cel al pieței complet liberalizate a energiei, atât la nivelul României cât și al Uniunii Europene;
  - rezultatele privind prognoza evoluției consumului, la modul general, acoperă o plajă largă de valori, cu diferențe sensibile între valorile "pesimiste" și cele "optimiste"; în cazul noilor capacități "verzi" de producere a energiei electrice, unele prognoze sunt mai realiste, altele mai puțin realiste.
- Elaborarea modelului matematic al prognozei consumului de energie (putere) electrică și a curbelor de sarcină și utilizarea lui permite formularea următoarelor concluzii:
  - s-a realizat un modelul matematic eficient al prognozei consumului de energie electrică și al curbelor de sarcină, utilizând rețele neuronale artificiale bayesiene, cu algoritm de antrenare de tip "backpropagation";
  - gradul relativ scăzut de corelare a datelor utilizate pentru antrenarea și testare RNB poate ridica uneori semne de întrebare în privința gradului de credibilitate a rezultatelor obținute;
  - testarea metodelor elaborate pentru un număr foarte mare de aplicații practice este extrem de importantă, rezultând o serie de concluzii privind posibilitățile de îmbunătățire;
  - din punctul de vedere al aprecierii calității modelului elaborat, la fel de utilă este și compararea rezultatelor obținute cu cele din alte lucrări (teze de doctorat) cu preocupări similare, care au utilizat alte tipuri de RNA;
  - completarea modelului RNB cu o serie de tehnici de optimizare neliniară (metoda gradientului conjugat scalat) este binevenită pentru ameliorarea convergenței tehnicilor de calcul iterativ și creșterea acurateții rezultatelor;
  - se impune o analiză atentă a datelor de consum disponibile, pentru eliminarea unor informații clar eronate și pentru a aprecia de la bun început așteptările legate de calitatea prognozelor elaborate.

- În privința instrumentelor soft elaborate pentru scopul propus, se pot evidenția următoarele constatări și observații:
- există o mare diversitate de preocupări legate de prognoza consumului, pe termen scurt, mediu și lung, așa cum rezultă din analiza lucrărilor publicate în literatura de specialitate;
  - la ora actuală majoritatea programelor de calcul utilizează tehnici de inteligență artificială și, eventual, abordări fuzzy;
  - performanțele sistemelor de calcul actuale și ale mediilor de programare permit implementarea unor modele din ce în ce mai sofisticate pentru soluționarea tuturor aspectelor legate de prognoză;
  - majoritatea programelor de calcul folosesc și instrumente standard ale mediilor de programare, de regulă de utilitate mai generală, fără a ține cont întotdeauna de elementele specifice prognozei consumului de energie electrică;
  - în cadrul tezei de doctorat s-a preferat elaborarea unor instrumente soft proprii, pentru cazul particular al prognozei consumului de energie electrică (putere) și a curbelor de sarcină, care permit optimizarea performanțelor rețelei neuronale utilizate, chiar în condițiile utilizării unor funcții din toolbox-ul Matlab [Nabney2002] al mediului Matlab.

În continuare se prezintă o sinteză a principalelor contribuții originale, de natură teoretică și aplicativă, aduse în cadrul tezei de doctorat (așa cum au fost prezentate și la finele fiecărui capitol).

- Obiectivul capitolului 2 constă în prezentarea principalelor noțiuni teoretice legate de abordarea bayesiană, de rețelele bayesiene, de rețelele neuronale bayesiene și de o serie de elemente conexe. Se evidențiază următoarele contribuții:
- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a elementelor teoretice legate de abordarea bayesiană și de RNA bayesiene, în contextul înțelegerii exemplurilor de utilizare prezentate în capitolele următoare;
  - evidențierea aspectelor esențiale necesare la elaborarea modelului matematic utilizat pentru prognoza consumului de energie electrică, a puterii și a curbelor de sarcină;
  - schițarea algoritmului de învățare (antrenare) bayesiană a RNA, care va fi dezvoltat în capitolul 6.
- Obiectivul capitolului 3 constă în prezentarea sistematizată a unor aplicații ale rețelelor bayesiene în domeniul electroenergeticii (fiabilitatea rețelelor electrice, estimarea stării și analiza stabilității SEE, diagnoza și localizarea defectelor în rețelele electrice și a defectelor legate de transformatoare și generatoare etc.), mai puțin cele legate de prognoză (care apar în capitolul 4). Contribuțiile aduse sunt următoarele:
- identificarea domeniilor din cadrul ingineriei sistemelor electroenergetice în care utilizarea avantajelor oferite de RB este benefică, numărul din ce în ce mai mare de lucrări publicate în ultima perioadă (practic ultimii 10-15 ani) constituind o dovadă clară a interesului manifestat față de abordarea specifică, în manieră bayesiană, a unui număr din ce în ce mai mare de aplicații;
  - realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a problemelor din domeniile identificate, unde utilizarea RB aduce avantaje incontestabile;
  - evidențierea subdomeniilor în care, pe baza numărului de lucrări publicate în ultima perioadă, abordarea bayesiană se va extinde în continuare.

- Obiectivul capitolului 4 constă în prezentarea problemelor legate de prognoza consumului de energie electrică (putere de vârf, putere orară, energie consumată, curbe de sarcină etc.) și a metodelor utilizate pentru obținerea prognozei. Se pot enumera următoarele contribuții:
- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a metodelor utilizate pentru prognoza consumului de energie electrică (putere de vârf sau orară, energie consumată, curbe de sarcină etc.), atât cele care la ora actuală pot fi considerate "clasice" (bazate pe modelarea matematică), cât și cele "moderne", utilizând tehnici de inteligență artificială, logică fuzzy, sisteme expert, "support vector machine" (SVM) etc.;
  - prezentarea aspectelor caracteristice abordărilor actuale, în condițiile pieței libere a energiei electrice, a dereglementării și a pătrunderii pe scară largă a surselor regenerabile de energie;
  - focalizarea unei atenții speciale asupra metodelor de prognoză care utilizează rețele neuronale bayesiene (utilizate în cadrul acestei teze);
  - pregătirea elementelor pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.
- Capitolul 5 este destinat prezentării RNA, oferind baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică (putere) și a curbelor de sarcină (capitolul 6). Contribuțiile aduse sunt următoarele:
- realizarea unei sinteze documentate asupra unei game largi de aspecte legate de rețelele neuronale artificiale;
  - pregătirea elementelor teoretice necesare pentru modelul de prognoză utilizat în cadrul tezei;
  - evidențierea parametrilor "reglabili" ai perceptronului cu mai multe straturi, în scopul ameliorării performanțelor de aplicare în problema prognozei consumului de energie electrică.
- Obiectivul capitolului 6 constă în prezentarea atât a modelului matematic al prognozei consumului de energie electrică și de putere (inclusiv curbe de sarcină) utilizând RNB cât și a instrumentului soft realizat pe baza modelului respectiv. Se evidențiază următoarele contribuții:
- utilizarea eficientă a elementelor teoretice referitoare la RNA bayesiene pentru elaborarea unui model matematic destinat prognozei consumului de energie electrică și de putere (inclusiv curbe de sarcină);
  - implementarea unor tehnici de optimizare neliniară (metoda gradientului conjugat scalat) în scopul ameliorării performanțelor RNA bayesiene;
  - realizarea unei aplicații soft performante, care exploatează în mod eficient posibilitățile oferite de mediul Matlab, cu multiple posibilități de utilizare în domeniul prognozei consumului de energie electrică și putere, inclusiv a curbelor de sarcină.
- Capitolul 7 este în întregime original, constituind principala parte aplicativă a tezei. Prima parte validează modelele de calcul și instrumentele soft, prin realizarea unor comparații cu rezultatele obținute în [Deacu2015], [Chiș2015], în scopul demonstrării calităților superioare ale metodelor utilizând RNB. A doua parte prezintă o serie de studii de prognoză realizate atât pentru ansamblul rețelei de distribuție din cadrul Enel Distribuție Banat cât și pentru UTR componente: Arad, Deva, Reșița și Timișoara. A treia parte este dedicată stațiilor de transformare de 110 kV / m.t. din cadrul UTR Timișoara. Au fost selectate 5 stații semnificative de 110 / 20 kV (3 din municipiul Timișoara, una dintr-o localitate importantă a jud. Timiș și una care alimentează o exploatare petroliferă): Bucovina, IMT, Musicescu, Deta și Satchinez. Se evidențiază următoarele contribuții:

- realizarea unor baze de date cuprinzătoare privind consumurile de energie electrică (putere) la nivelul Enel Distribuție Banat, al UTR componente și al stațiilor de distribuție de 110 kV / m.t.;
- realizarea unor comparații edificatoare cu alte lucrări având un subiect asemănător, în scopul demonstrării calității superioare a metodelor elaborate în cadrul tezei;
- realizarea unor studii extinse de prognoză pentru Enel Distribuție Banat și pentru alți operatori de distribuție și agenți economici;
- testarea unei tehnici de analiză a datelor de consum, în scopul formulării unei previziuni privind calitatea așteptată a prognozei;
- formularea unor concluzii utile operatorilor de distribuție și operatorului național de transport și de sistem (C.N.T.E.E. Transelectrica S.A.), atât în ceea ce privește tehnica de realizare a prognozelor și instrumentelor soft cât și rezultatele obținute pentru situațiile concrete abordate.

Rezultatele obținute au fost și vor fi valorificate în cadrul unor contracte de cercetare științifică și asistență tehnică derulate prin Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor de Funcționare a Sistemelor Electroenergetice din cadrul Universității Politehnica Timișoara (director prof.dr.ing. Ștefan Kilyeni), beneficiarii fiind Enel Distribuție Banat și Dobrogea, Electrica Muntenia Nord, Delgaz Grid Iași, (operatori importanți de distribuție a energiei electrice în România) și entități economice cu preocupări în domeniul implementării resurselor regenerabile de energie [UPT2017], [UPT2018], [UPT2019], [UPT2020a], [UPT 2020b].

Așa cum rezultă din lista lucrărilor proprii de la finele tezei, activitatea de pregătire prealabilă a doctorandei și rezultatele obținute în perioada de elaborare a lucrării au fost valorificate prin 5 lucrări indexate ISI (2 în reviste, 3 în volumele unor conferințe) [Bucerzan2010], [Crăciun2013], [Bărbulescu2018], [Crăciun2018a], [Csorba2018], 2 lucrări indexate în alte baze de date internaționale (BDI) (1 în revistă, 1 într-un volum de conferință, în curs de indexare ISI) [Crăciun2017], [Bărbulescu 2021] și 2 rapoarte științifice.

Analizele teoretice realizate în cadrul tezei de doctorat, precum și rezultatele practice obținute, deschid o serie de perspective clare de continuare și aprofundare a cercetărilor atât în domeniul prognozei consumului de energie electrică (putere) și a curbelor de sarcină cât și în ceea ce privește utilizarea RB la soluționarea unor alte probleme din domeniul electroenergeticii:

- rafinarea metodelor de soluționare bazate pe utilizarea RNB, în scopul creșterii eficienței și ameliorării performanțelor acestora;
- corelarea istoricului evoluției consumului cu o serie de alți factori (climatici, economici, gradul de implementare a producătorilor neconvenționali), în măsura disponibilității acestora;
- utilizarea RNB în studii de prognoză legate de sursele de energie regenerabilă (puterea sau energia generată, viteza vântului pentru centralele eoliene, iradianța pentru cele fotovoltaice etc.);
- elaborarea unor metode care să elimine sau să corecteze unele date evidente eronate în istoricul consumului;
- utilizarea RB în studii legate de fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a SEE în ansamblu, estimarea stării SEE, analiza stabilității SEE, diagnoza și localizarea defectelor în rețelele electrice, diagnoza defectelor legate de transformatoare și generatoare etc.

## BIBLIOGRAFIE

1. [Ahmadi2020] S. Ahmadi, A.H. Fakehi, A. Vakili, M. Haddadi, S.H. Iranmanesh, A hybrid stochastic model based Bayesian approach for long term energy demand managements, *Energy Strategy Reviews*, vol.28, 2020, pp.1-13
2. [Akarslan2018] E. Akarslan, F.O. Hocaoglu, A novel short-term load forecasting approach using Adaptive Neuro-Fuzzy Inference System, 6th International Istanbul Smart Grids and Cities Congress and Fair (ICSG), 2018, pp.160-163
3. [Amjady2008] N. Amjady, F. Keynia, Mid-term load forecasting of power systems by a new prediction method, *Energy Conversion and Management*, vol.49, nr.10, 2008, pp.2678-2687
4. [Amini2015] M.H. Amini, M.D. Ilic, O. Karabasoglu, DC Power Flow Estimation Utilizing Bayesian-based LMMSE Estimator, *IEEE Power & Energy Society General Meeting*, 2015, pp.1-5
5. [Angioni2016] A. Angioni, M. Pau, F. Ponci, A. Monti, Bayesian distribution system state estimation in presence of non-Gaussian pseudo-measurements, *IEEE International Workshop on Applied Measurements for Power Systems (AMPS)*, 2016, pp.1-6
6. [Augutis2012] J. Augutis, I. Zutautaitė, V. Radziukynas, R. Krikstolaitis, S. Kadisa, Application of Bayesian method for electrical power system transient stability assessment, *International Journal of Electrical Power & Energy Systems*, vol.42, nr.1, 2012, pp.465-472
7. [Azad2018] M.K. Azad, S. Uddin, M. Takruri, Support vector regression based electricity peak load forecasting, 11th International Symposium on Mechatronics and its Applications (ISMA), 2018, pp.1-5
8. [Bakirtzis1997] A. Bakirtzis, S. Kiartzis, V. Petridis, A. Kehagias, A Bayesian Combination Method for Short Term Load Forecasting, *International Journal of Electrical Power & Energy Systems*, vol.19, nr.3, 1997, pp.171-177
9. [Balint2006] S. Balint, E. Kaslik, S. Maris, *Probabilități. Note de curs*, Universitatea de Vest Timișoara, 2006
10. [Barber2012] D. Barber, *Bayesian Reasoning and Machine Learning*, Cambridge University Press, 2012
11. [Barman2018] M. Barman, N.B. Dev, S. Sutradhar, A regional hybrid GOA-SVM model based on similar day approach for short-term load forecasting in Assam, India, *Energy*, vol.145, 2018, pp.710-720
12. [Bassamzadeh2017] N. Bassamzadeh, R. Ghanem, Multiscale stochastic prediction of electricity demand in smart grids using Bayesian networks, *Applied Energy*, vol.193, 2017, pp.369-380
13. [Bărbulescu2016] C. Bărbulescu, Șt. Kilyeni, A. Deacu, Artificial Neural Network based Monthly Load Curves Forecasting, 11th IEEE International Symposium on Applied Computational Intelligence and Informatics (SACI), 2016, pp.237-242
14. [Bărbulescu2018] C. Bărbulescu, Șt. Kilyeni, A. Deacu, A. Simo, M. Crăciun, Power Consumption Forecast Quality Assessment, 7th International Conference on Computers Communications and Control (ICCCC), 2018, p.103-110
15. [Bărbulescu2021] C. Bărbulescu, Șt. Kilyeni, V. Chiș, M. Crăciun, A. Simo, Daily Load Curve Forecasting. Comparative Analysis: Conventional vs. Unconventional Methods. In: Balas V., Jain L., Balas M., Shahbazova S. (eds.) *Soft Computing Applications, SOFA 2018, Advances in Intelligent Systems and Computing*, vol. 1221, 2021, Springer, pp.3-18

16. [Bessani2020] M. Bessani, J.A.D. Massignan, T.M.O. Santos, J.B.A. London Jr., C.D. Maciel, Multiple households very short-term load forecasting using bayesian networks, *Electric Power Systems Research*, vol.189, pp.1-7
17. [Bishop2006] C.M. Bishop, *Pattern recognition and Machine Learning*, Springer, 2006
18. [Bolturk2012] E. Bolturk, B. Oztay, I.U. Sari, Electricity Consumption Forecasting Using Fuzzy, Time Seris, 13th IEEE International Symposium on Computational Intelligence and Informatics, 2012, pp.245-249
19. [Bolstad2004] W.M. Bolstad, *Introduction to Bayesian Statistics*, John Wiley&Sons, 2004
20. [Borges2016] C.L.T. Borges, J.A.S. Dias, A Model to Represent Correlated Time Series in Reliability Evaluation by Non-SequentialMonte Carlo Simulation, *IEEE Transactions on Power Systems*, vol.32, nr.2, 2017, pp.1511-1519
21. [Bracale2016] A. Bracale, G. Carpinelli, P. De Falco, A Bayesian-based approach for the short-term forecasting of electrical loads in smart grids. Part I: theoretical aspects, *IEEE International Symposium on Power Electronics, Electrical Drives, Automation and Motion*, 2016, pp.121-128
22. [Bracale2016a] A. Bracale, G. Carpinelli, P. De Falco, A Bayesian-based approach for the short-term forecasting of electrical loads in smart grids. Part II: numerical applications, *IEEE International Symposium on Power Electronics, Electrical Drives, Automation and Motion*, 2016, pp.129-136
23. [Brusaferri2019] A. Brusaferri, M. Matteucci, P. Portolani, A. Vitali, Bayesian deep learning based method for probabilistic forecast of day-ahead electricity prices, *Applied Energy*, vol.250, 2019, pp.1158-1175
24. [Bucerzan2010] D. Bucerzan, M. Crăciun, V. Chis, C. Rațiu, Stream Ciphers Analysis Methods, *International Journal of Computers Communications & Control*, vol.5, nr.4, 2010, pp.483-489
25. [Cai2011] Y. Cai, Q. Xie, C. Wang, F. Lü, Short-term load forecasting for city holidays based on genetic support vector machines, *International Conference on Electrical and Control Engineering*, 2011, pp.3144-3147
26. [Căbulea2013] L. Căbulea, R. Luca-Tudorache, G. Zbăganu, A. Pitea, I. Rasa, N. Breaz, *Probabilități și statistică*, StudIS, 2013
27. [Chen2002] B.J. Chen, M.W. Chang, C.J. Lin, Load Forecasting using Support Vector Machines: A Study on EUNITE Competition 2001, Technical report, Department of Computer Science and Information Engineering, National Taiwan University, 2002, pp.1-6
28. [Chen2004] B.J. Chen, M.W. Chang, C.J. Lin, Load forecasting using support vector machines: A study on EUNITE competition 2001, *IEEE Transactions on Power Systems*, nr.4, 2004, pp.1821-1830
29. [Chen2010] Y. Chen, P.B. Luh, C. Guan, Y. Ahao, L.D. Michel, A. Coolbeth, Short Term Load Forecasting: Similar Day-Based Wavelet Neural Networks, *IEEE Transactions on Power Systems*, vol.25, nr.1, 2010, pp.322-330
30. [Chen2012] Y. Chen, F. Liu, G. He, S. Mei, A Seidel-Type Recursive Bayesian Approach and its Applications to Power Systems, *IEEE Transactions on Power Systems*, vol.27, nr.3, 2012, pp.1710-1711
31. [Chen2013] Y. Chen, F. Liu, S. Mei, G. He, Q. Lu, Y. Fu, An Improved Recursive Bayesian Approach for Transformer Tap Position Estimation, *IEEE Transactions on Power Systems*, vol.28, nr.3, 2013, pp.2830-2841
32. [Cheng2019] H. Cheng, X. Dingb, W. Zhoua, R. Ding, A hybrid electricity price forecasting model with Bayesian optimization for German energy exchange, *Electrical Power and Energy Systems*, vol.110, 2019, pp.653-666
33. [Chevalier2019] S. Chevalier, P. Vorobev, K. Turitsyn, A Bayesian Approach to Forced Oscillation Source Location Given Uncertain Generator Parameters, *IEEE Transactions on Power Systems*, vol.34, nr.2, 2019, pp.1641-1649

34. [Chiş2015] V. Chiş, Tehnici de inteligență artificială utilizate în studiile de prognoză din domeniul ingineriei energetice, Teză de doctorat, Universitatea Politehnica Timișoara (Conducător științific: Prof.univ.dr.ing. Ștefan Kilyeni)
35. [Chiş2018] V. Chiş, C. Bărbulescu, Șt. Kilyeni, S. Dzitac, ANN based Short-Term Load Curve Forecasting, International Journal of Computers Communications & Control, vol.13, nr.6, 2018, p.938-955
36. [Chow2005] J.H. Chow, F.F. Wu, J.A. Momoh (Eds.), Applied mathematics for restructured electric power systems, Optimization, Control and Computational Intelligence, Springer, 2005
37. [Ciobanu2019] A. Ciobanu (Aionoai), Utilizarea rețelelor bayesiene și a diagramelelor de influență în analiza disponibilității în electroenergetică, Teză de doctorat, Universitatea Tehnică "Gh. Asachi" Iași, 2019
38. [Crăciun2013] M. Crăciun, D. Bucerzan, C. Rațiu, A. Manolescu, Actuality of Bankruptcy Prediction Models used in Decision Support System, International Journal of Computers Communications & Control, vol.8, nr.3, 2013, pp.375-383
39. [Crăciun2017] M. Crăciun, Șt. Kilyeni, C. Bărbulescu, Bayesian network applications in power systems engineering. A review, Journal of Sustainable Energy, nr.3, 2017, p. 99-105
40. [Crăciun2018a] M. Crăciun, L.M. Csorba, Application of the Fuzzy-Pay-Off Method in the Valuation of a Financial Instrument. In: Balas V., Jain L., Balas M. (eds.), Soft Computing Applications, SOFA 2016, Advances in Intelligent Systems and Computing, Springer, vol.634, 2018, pp.235-250
41. [Csorba2018] L.M. Csorba, M. Crăciun, An Application of the Multi Period Decision Trees in the Sustainable Medical Waste Investments. In: Balas V., Jain L., Balas M. (eds.), Soft Computing Applications, SOFA 2016, Advances in Intelligent Systems and Computing, Springer, vol.634, 2018, pp.540-556
42. [Daemi2012] T. Daemi, A. Ebrahimi, M. Fotuhi-Firuzabad, Constructing the Bayesian Network for components reliability importance ranking in composite power systems, International Journal of Electrical Power & Energy Systems, vol.43, nr.1, 2012, pp.474-480
43. [Dagdougui2019] H. Dagdougui, F. Bagheri, H. Le, L. Dessaint, Neural network model for short-term and very-short-term load forecasting in district buildings, Energy and buildings, vol.203, pp.1-10
44. [Dai2020] Y.Dai, P. Zhao, A hybrid load forecasting model based on support vector machine with intelligent methods for feature selection and parameter optimization, vol.279, 2020
45. [Deacu2015] A. Deacu, Prognoza consumului de energie electrică utilizând rețele neuronale artificiale, Teză de doctorat, Universitatea Politehnica Timișoara (Conducător științific: Prof.univ.dr.ing. Ștefan Kilyeni)
46. [Dehghanpour2016] K. Dehghanpour, M.H. Nehrir, J.W. Sheppard, N.C. Kelly, Agent-Based Modeling in Electrical Energy Markets Using Dynamic Bayesian Networks, IEEE Transactions on Power Systems, vol.31, nr.6, 2016, pp.4744-4754
47. [Dong2014] Z. Dong, Y. Wang, J. Zhao, Variational Bayesian inference for the probabilistic model of power load, IET Generation, Transmission and Distribution, vol.8, nr.11, 2014, pp.1860-1868
48. [Douglas1998] A.P. Douglas, A.M. Breip, F.N. Lee, R. Adapa, The Impacts of Temperature Forecast Uncertainty on Bayesian Load Forecasting, IEEE Transactions on Power Systems, vol.13, nr.4, 1998, pp.1507-1513
49. [Eapen2019] R.R. Eapen, S.P. Simon, Performance Analysis of Combined Similar Day and Day Ahead Short Term Electrical Load Forecasting using Sequential Hybrid Neural Networks, IETE Journal of Research, vol.65, nr.2, pp.216-226

50. [Ebrahimi2010] A. Ebrahimi, T. Daemi, A Novel Method for Constructing the Bayesian Network for Detailed Reliability Assessment of Power Systems, International Conference on Electric Power and Energy Conversion Systems, (EPECS), 2010, pp.1-6
51. [Eliassi2015] M. Eliassi, H. Seifi, M.R. Haghifam, Incorporation of protection system failures into bulk power system reliability assessment by Bayesian networks, IET Generation, Transmission and Distribution, vol.9, nr.11, 2015, pp.1226-1234
52. [Eliassi2015a] M. Eliassi, A.K. Dashtaki, H. Seifi, M.R. Haghifam, C. Singh, Application of Bayesian networks in composite power system reliability assessment and reliability-based analysis, IET Generation, Transmission and Distribution, vol.9, nr.13, 2015, pp.1755-1764
53. [Enăchescu2008] Calculul neuronal, Casa Cărții de Știință, 2008
54. [Eremia2006] Eremia M., Cârțină G., Petrică D., Bulac A.I., Bulac C., Triștiu I., Grigoraș G., Tehnici de inteligență artificială în conducerea sistemelor electroenergetice, Agir, 2006
55. [Fahiman2018] F. Fahiman, S. Disano, S.M. Erfani, P. Mancarella, C. Leckie, Data-Driven Dynamic Probabilistic Reserve Sizing Based on Dynamic Bayesian Belief Networks, IEEE Transactions on Power Systems, vol.34, nr.3, pp.2281-2291
56. [Fan2009] Y. Fan, X. Zai, H. Qian, X. Yang, L. Liu, Transient Stability Analysis of Power System Based on Bayesian Networks and Main Electrical Wiring, IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), 2009, pp.1-6
57. [Ferreira2009] V.H. Ferreira, S.M. de Rocco, A.R. Aoki, Demand Forecasting for Control of the Use of Transmission System for Electric Distribution Utilities, 15th International Conference on Intelligent System Applications to Power Systems, 2009, pp.1-6
58. [Ferreira2009a] V.H. Ferreira, A.P.A. da Silva, Automatic Kernel Based Models for Short Term Load Forecasting, 15th International Conference on Intelligent System Applications to Power Systems, 2009, pp.1-6
59. [Fu2003] C.W.Fu, T. Nguyen, Models for Long-Term Energy Forecasting, Power Engineering Society General Meeting, Vol.1, 2003, pp.1-6
60. [Gaber2015] A. Gaber, K.G. Seddik, A.Y. Elezabi, Joint Estimation-Detection of Cyber Attacks in Smart Grids: Bayesian and Non-Bayesian Formulations, IEEE Wireless Communications and Networking Conference (WCNC), 2015, pp.1-6
61. [Ganguly2018] A. Ganguly, K. Goswami, A.K. Sil, ANN technique based Mid Term Load Forecasting as a case study for Peak Load Reduction, IEEE Applied Signal Processing Conference (ASPCON), 2018, pp.262-266
62. [Ghahramani2013] Z. Ghahramani, Bayesian nonparametrics and the probabilistic approach to modeling, Philosophical Transactions of the Royal Society, vol.371, nr.1984, 2013, pp.1-27
63. [Ghayekhloo2015] M. Ghayekhloo, M.B. Menhaj, M. Ghofrani, A hybrid short-term load forecasting with a new data preprocessing framework, Electric Power Systems Research, vol.119, 2015, pp.138-148
64. [Ghayekhloo2019] M. Ghayekhloo, R. Azimi, M. Ghofrani, M.B. Menhaj, E. Shekari, A combination approach based on a novel data clustering method and Bayesian recurrent neural network for day-ahead price forecasting of electricity markets, Electric Power Systems Research, vol.168, 2019, pp.184-199
65. [Ghelardoni2013] L. Ghelardoni, A. Ghio, D. Anguita, Energy Load Forecasting Using Empirical Mode Decomposition and Support Vector Regression, IEEE Transaction on Smart Grid, vol.4, no.1, 2013, pp.549-556
66. [Gilanifar2020] M. Gilanifar, H. Wang, L.M.K. Sriram, E.E. Ozguven, R. Arghandeh, Multitask Bayesian Spatiotemporal Gaussian Processes for Short-Term Load Forecasting, IEEE Transactions on Industrial Electronics, vol.67, nr.6, 2020, pp.5132-5143



67. [Goia2010] A. Goia, C. May, G. Fusai, Functional clustering and linear regression for peak load forecasting, *International Journal of Forecasting*, vol.26, nr.4, 2010, pp.700-711
68. [Gui2010] M. Gui, A. Pahwa, S. Das, Classification of Input and Output Variables for a Bayesian Model to Analyze Animal-Related Outages in Overhead Distribution Systems, *IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*, pp.469-474
69. [Gutierrez2020] D.D. Gutierrez, How Bayesian Machine Learning Works, *Open Data Science*, October 2020
70. [Hahn2009] H. Hahn, S. Meyer-Nieberg, S. Pickl, Electric Load Forecasting methods: Tools for decision making, *European Journal of Operational Research*, vol.199, nr.3, 2009, pp.902-907
71. [Hajek2019] A. Hajek, Interpretations of Probability, *Stanford Encyclopedia of Philosophy*, Fall 2019 Edition
72. [He2006] Y.J. He, Y.C. Zhu, D.X. Duan, W. Sun, Application of Neural Network Model Based on combination of Fuzzy Classification and Input Selection in Short Term Load Forecasting, *IEEE International Conference on Machine Learning and Cybernetics*, 2006, pp.3152-3156
73. [HeY2018] Y. He, B. Lin, Forecasting China's total energy demand and its structure using ADL-MIDAS model, *Energy*, vol.151, 2018, pp.420-429
74. [He2019] F. He, J. Zhou, Z. Feng, G. Liu, Y. Yang, A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm, *Applied Energy*, vol.237, 2019, pp.103-116
75. [Hippert2010] H.S. Hippert, J.W. Taylor, An evaluation of Bayesian techniques for controlling model complexity and selecting inputs in a neural network for short-term load forecasting, *Neural Networks*, vol.23, 2010, pp.386-395
76. [Hor2005] C.L. Hor, S.J. Watson, S. Majithia, Analyzing the Impact of Weather Variables on Monthly Electricity Demands, *IEEE Transactions on Power Systems*, vol.20, nr.4, pp.2078-2085
77. [Hsu2018] Y.Y. Hsu, T.T. Tung, H.C. Yeh, C.N. Lu, Two-Stage Artificial Neural Network Model for Short-Term Load Forecasting, *IFAC PapersOnLine*, vol.51, nr.28, 2018, pp.678-683
78. [Hu2009] Y. Hu Y., H. Ji, X. Song, To Forecast Short-term Load in Electric Power System Based on FNN, *IEEE 6<sup>th</sup> International Conference on Fuzzy Systems and Knowledge Discovery*, 2009, pp.474-478
79. [Hu2011] Y. Hu, A. Kuh, A. Kavcic, T. Yang, A Belief Propagation Based Power Distribution System State Estimator, *2011 IEEE Computational Intelligence Magazine*, vol.6, nr.3, 2011, pp.36-46
80. [Iesmantas2014] T. Iesmantas, R. Alzbutas, Bayesian assessment of electrical power transmission grid outage risk, *Electrical Power & Energy Systems*, vol.58, 2014, pp.85-90
81. [Ismail2013] M.M. Ismail, M.A. Hassan, Artificial Neural Network Based Approach Compared with Stochastic Modelling for Electrical Load Forecasting, *International Conference on Modelling, Identification & Control*, 2013, pp.112-118
82. [Izudheen2019] S. Izudheen, A.M. Joykutty, A methodology for Short-term Electric Power Load Forecasting, *9th International Conference on Advanced Computer Control (ICACC)*, pp.322-325
83. [Jarndal2018] A. Jarndal, S. Hussein, Forecasting of Electric Peak Load Using ANN Cascaded, ANN-NARX and GPR Techniques, *International Conference on Communications, Computing, Cybersecurity, and Informatics (CCCI)*, 2020, pp.1-5
84. [Ji2021] C. Ji, Z. Yina, Y. Zhanga, M. Wang, X. Zhanga, C. Zhanga, D. Wang, Real-time robust forecasting-aided state estimation of power system based on data-driven models, *Electrical Power and Energy Systems*, vol.125, 2021, pp.1-11

85. [Jian2008] C. Jian, G. Ju'E, L. Hu, Forecasting energy demand of China using Bayesian Combination model, *China Population, Resources and Environment*, vol.18, nr.4, 2008, pp.50-55
86. [Jiang2017] Y. Jiang, H. Long, Z. Zhang, Z. Song, Day-Ahead Prediction of Bihourly Solar Radiance with a Markov Switch Approach, *IEEE Transactions on Sustainable Energy*, vol.8, nr.4, 2017, pp.1536-1547
87. [Jin2010] X. Jin, Z. Dong, J. Wu, J. Wang, An Improved Combined Forecasting Method for Electric Power Load Based on Autoregressive Integrated Moving Average Model, *IEEE International Conference of Information Science and Management Engineering*, vol.2, 2010, pp.476-480
88. [Jing2019] Z. Jing, M. Cai, M. Pipattanasomporn, S. Rahman, Commercial Building Load Forecasts with Artificial Neural Network, *IEEE Innovative Smart Grid Technologies (ISGT)*, pp.1-5
89. [Khatoon2015] S. Khatoon, I. Arunesh, S. Priti, ANN based Electric Load Forecasting Applied to Real Time Data, *Annual IEEE India Conference (INDICON)*, 2015, pp.1-5
90. [Kocadagli2014] O. Kocadagli, B. Asikgil, Nonlinear time series forecasting with Bayesian neural networks, *Expert Systems with Applications*, vol.41, 2014, pp.6596-6610
91. [Kilyeni2014] S. Kilyeni, Metode numerice. Algoritme, programe de calcul, aplicații în energetică, *Orizonturi Universitare*, 2014
92. [Kilyeni2015] S. Kilyeni, Tehnici de optimizare în ingineria energetică, *Orizonturi Universitare*, 2015
93. [Kilyeni2015a] S. Kilyeni, Tehnici numerice de analiză asistată de calculator a regimurilor de funcționare a sistemelor electroenergetice, *Orizonturi Universitare*, 2015
94. [Koch2007] K.R. Koch, *Introduction to Bayesian Statistics*, Springer, 2007
95. [Konig2010] J. König, L. Nordström, M. Ekstedt, Probabilistic Relational Models for Assessment of Reliability of Active Distribution Management Systems, *IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*, 2010, pp.454-459
96. [Konig2011] J. König, P. Närman, U. Franke, L. Nordström, An Extended Framework for Reliability Analysis of ICT for Power Systems, *IEEE Trondheim PowerTech*, 2011, pp.1-6
97. [Kumar2016] S. Kumar, S. Mishra, S. Gupta, Short Term Load Forecasting Using ANN and Multiple Linear Regression, *2nd International Conference on Computational Intelligence & Communication Technology (CICT)*, 2016, pp.184-186
98. [Kyriakides2007] E. Kyriakides, M. Polycarpou, Short Term Electric Load Forecasting: A tutorial, in Chen, K., Wang, L. (Eds.), *Trends in Neural Computation, Studies in Computational Intelligence*, vol.35, 2007, Springer
99. [Lauret2008] P. Lauret, E. Fock, R.N. Randrianarivony, J.F. Manicom-Ramsamy, Bayesian neural network approach to short time load forecasting, *Energy Conversion and Management*, vol.49, 2008, pp.1156-1166
100. [Lauret2012] P. Laureta, M. David, D. Calogine, Nonlinear Models for Short-time Load Forecasting, *2nd International Conference on Advances in Energy Engineering (ICAEE)*, *Energy Procedia*, vol.14, 2012, pp.1404-1409
101. [Lee2011] Y.S. Lee, L.I. Tong, Forecasting time series using a methodology based on autoregressive integrated moving average and genetic programming, *Knowledge Based Systems*, vol.24, nr.1, 2011, pp.66-72
102. [Lei2018] C. Lei, B. Fang, H. Gao, W. Jia, W. Pan, Short-term power load forecasting based on Least Squares Support Vector Machine optimized bare Bones Fireworks algorithm, *IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 2018, pp.2231-2235

103. [Leon2012] F. Leon, *Inteligență artificială: raționament probabilistic, tehnici de clasificare*, Tehnopress, 2012
104. [Li2014] G. Li, H. Wu, F. Wang, Bayesian network approach based on fault isolation for power system fault diagnosis, *International Conference on Power System Technology (Powercon)*, 2014, pp.601-606
105. [Liang2019] Y. Liang, D. Niu, W. Hong, Short term load forecasting based on feature extraction and improved general regression neural network model, *Energy*, vol.166, nr.C, 2019, pp.653-663
106. [Lihua2009] H. Lihua, H. Chenwei, W. Hui, H. Limin, Assessment of Distribution System Reliability Based on Bayesian Network and Time Sequence Simulation, *IEEE 6th International Conference on Fuzzy Systems and Knowledge Discovery*, 2009, pp.481-486
107. [Lilja2011] K.K. Lilja, K. Laakso, J. Polomaki, Using the Delphi Method, *IEEE Technology Management in the Energy Smart World*, 2011, pp.1-10
108. [Limei2017] L. Limei, H. Xuan, Study of electricity load forecasting based on multiple kernels learning and weighted support vector regression machine, *29th Chinese Control And Decision Conference (CCDC)*, 2017, pp.1421-1424
109. [Lin2019] Y. Lin, M. Yang, C. Wan, J. Wang, Y. Song, A Multi-Model Combination Approach for Probabilistic Wind Power Forecasting, *IEEE Transactions on Sustainable Energy*, vol.10, nr.1, 2019, pp.2226-2237
110. [Liu2017] B. Liu, J. Nowotarski, T. Hong, R. Weron, Probabilistic Load Forecasting via Quantile Regression Averaging on Sister Forecasts, *IEEE Transactions on Smart Grid*, vol.8, nr.2, 2017, pp.730-737
111. [Liu2020] Y. Liu, H. Qin, Z. Zhang, S. Pei, Z. Jiang, Z. Feng, J. Zhou, Probabilistic spatiotemporal wind speed forecasting based on a variational Bayesian deep learning model, *Applied Energy*, vol.260, 2020, pp.1-10
112. [Lopez2019] J.C. Lopez, M.J. Rider, Q. Wu, Parsimonious Short-Term Load Forecasting for Optimal Operation Planning of Electrical Distribution Systems, *IEEE Transactions on Power Systems*, vol.34, nr.2, 2019, pp.1427-1437
113. [Luștrea2001] B. Luștrea, *Prognoza consumului de energie*, Agir, 2001
114. [Luștrea2004] B. Luștrea, *Elemente de inteligență artificială cu aplicații în energetică*, Universitatea Politehnica Timișoara, 2004
115. [Lorencin2017] I. Lorencin, M. Pantos, Evaluating Generating Unit Unavailability Using Bayesian Power Priors, *IEEE Transactions on Power Systems*, vol.32, nr.3, 2017, pp.2315-2323
116. [Ma2013] H. Ma, H. Li, Analysis of Frequency Dynamics in Power Grid: A Bayesian Structure Learning Approach, 2013, *IEEE Transactions on Smart Grid*, vol.4, nr.1, March 2013, pp.457-466
117. [MacKay2003] D.J.C. MacKay, *Information Theory, Inference, and Learning Algorithms*, Cambridge University Press 2003
118. [Massignan2019] J.A.D. Massignan, J.B.A. London, C.D. Maciel, M. Bessani, V. Miranda, PMUs and SCADA Measurements in Power System State Estimation through Bayesian Inference, *IEEE PowerTech*, 2019, pp.1-6
119. [Matlab] Mathworks, *Matlab Users guide*, <http://www.mathworks.com/>
120. [Mestav2019] K.R. Mestav, J.L. Rozas, L. Tong, Bayesian State Estimation for Unobservable Distribution Systems via Deep Learning, *IEEE Transactions on Power Systems*, vol.34, nr.6, 2019, pp.4910-4920
121. [Mitchell1997] T.M. Mitchell, *Machine learning*, McGraw-Hill, 1997
122. [Mitchell2017] G. Mitchell, S. Bahadoorsingh, N. Ramsamooj, C. Sharma, A comparison of artificial neural networks and support vector machines for short-term load forecasting using various load types, *IEEE Manchester PowerTech*, 2017, pp.1-4

123. [Mitridati2018] L. Mitridati, P. Pinson, A Bayesian Inference Approach to Unveil Supply Curves in Electricity Markets, *IEEE Transactions on Power Systems*, vol.33, nr.3, 2018, pp.2610-2620
124. [Moller1993] M.F. Moller, A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, vol.6, 1993, pp.525-533
125. [Monteiro2018] R.V.A. Monteiro, G.C. Guimaraes, F.B. Silva, R.F.S.Teixeira, B.C. Carvalho, A.P. Finazzi, A.B. Vasconcellos, A medium-term analysis of the reduction in technical losses on distribution systems with variable demand using artificial neural networks: An Electrical Energy Storage approach, *Energy*, vol.164, 2018, pp.1216-1228
126. [Montenegro2012] D. Montenegro, G.A. Ramos, Smart Diagnosis of Power Quality Disturbances Using Bayesian Networks, 6th IEEE/PES Transmission and Distribution Conference and Exposition Latin America, 2012, pp.1-5
127. [Mori2005] H. Mori, M. Ohmi, Probabilistic Short-term Load Forecasting with Gaussian Processes, *International Conference on Intelligent Systems Applications to Power Systems (ISAP)*, 2005, pp.452-457
128. [Mori2009] H. Mori, D. Kanaoka, GP-based temperature forecasting for electric load forecasting, *IEEE Region 10 TENCON Conference*, 2009, pp.1-5
129. [Mori2011] H. Mori, A. Takahashi, Hybrid Intelligent Method of Relevant Vector Machine and Regression Tree for Probabilistic Load Forecasting, 2nd IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe), 2011, pp.1-6
130. [Mukherjee2019] S. Mukherjee, C.R. Vineeth, R. Nateghi, Evaluating regional climate-electricity demand nexus: A composite Bayesian predictive framework, *Applied Energy*, vol.235, 2019, pp.1561-1582
131. [Mukhopadhyay2017] P. Mukhopadhyay, G. Mitra, S. Banerjee, G. Mukherjee, Electricity load forecasting using fuzzy logic: Short term load forecasting factoring weather parameter, 7th International Conference on Power Systems (ICPS), 2017, pp.812-819
132. [Nabney2002] I.T. Nabley, *Algorithms for pattern recognition*, Springer, 2002
133. [Nadimi2017] R. Nadim, K. Tokimatsu, Analyzing of Renewable and Non-Renewable Energy Consumption via Bayesian Inference, *Energy Procedia*, vol.142, 2017, pp.2773-2778
134. [Neal1995] R.M.Neal, *Bayesian Learning for Neural Networks*, PhD Thesis, University of Toronto, 1995
135. [Neumayer2014] M. Neumayer, T. Bretterkieber, H. Zang, Bayesian Estimation of Electrical Transformer Parameters, *IEEE Instrumentation and Measurement Technology Conference*, 2014, pp.1-6
136. [Ning2010] Y. Ning, Y. Liu, Q. Ji, Bayesian - BP Neural Network Based Short-term Load Forecasting for Power System, 3rd IEEE International Conference on Advanced Computer Theory and Engineering, 2010, vol.2, pp.89-93
137. [Panamtash2020] H. Panamtash, Q. Zhou, T. Hong, Z. Qu, K.O. Davis, A copula-based Bayesian method for probabilistic solar power forecasting, *Solar Energy*, vol.196, 2020, pp.336-345
138. [Pandey2014] A.K. Pandey, K.H. Sahay, M.M. Tripathi, D. Chandra, Short-Term Load Forecasting of UPPCL using ANN, 6th IEEE Power India International Conference (PIICON), 2014, pp.1-6
139. [Pegoraro2017], P.A. Pegoraro, A. Angioni, M. Pau, A. Monti, C. Muscas, F. Ponci, S. Sulis, Bayesian Approach for Distribution System State Estimation with Non-Gaussian Uncertainty Models, *IEEE Transactions on Instrumentation and Measurement*, vol.66, no. 11, 2017, pp.2957-2966
140. [Peng1992] Peng T.M., Hubele N.F., Karady G.G., Advancement in the Application of Neural Networks for Short-Term Load Forecasting, *IEEE Transactions on Power Systems*, vol.7, no.1, 1992, pp.250-257

141. [Petra2017] N. Petra, C.G. Petra, Z. Zhang, E.M. Constantinescu, M. Anitescu, A Bayesian Approach for Parameter Estimation With Uncertainty for Dynamic Power Systems, *IEEE Transactions on Power Systems*, vol.32, nr.4, 2017, pp.2735-3743
142. [Petrehus2005] V. Petrehuş, S. Popescu, *Probabilităţi şi statistică*, Universitatea Tehnică de Construcţii Bucureşti, 2005
143. [Qingle2010] P. Qingle, Z. Min, Very Short-Term Load Forecasting Based on Neural Network and Rough Set, *International Conference on Intelligent Technology and Automation*, 2010, pp.1132-1135
144. [Rashidi2010] M.R. Rashidi, K.M. El-Naggar, Long term electric load forecasting based on particle swarm optimization, *Applied Energy*, vol.87, nr.10, 2010, pp.320-326
145. [Rivero2015] C.R. Rivero, V. Sauchelli, H.D. Patino, J.A. Pucheta, S. Laboret, Long-term Power Consumption Demand Prediction: a comparison of Energy associated and Bayesian modeling approach, *Latin America Congress on Computational Intelligence (LA-CCI)*, 2015, pp.1-6
146. [Russell2010] S.J. Russell, P. Norvig, *Artificial Intelligence. A Modern Approach*, Pearson, 2010
147. [Ruzic2003] S. Ruzic, A. Vuckovic, N. Nikolic, Weather Sensitive Method for Short Term Load Forecasting in Electric Power Utilitz of Serbia, *IEEE Transaction on Power Systems*, vol.18, nr.4, 2003, pp.1581-1586
148. [Sadaei2019] H.J. Sadaeia, P.C.L. Silva, F.G. Guimarães, M.H. Lee, Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series, *Energy*, vol.175, pp.365-377
149. [Sahay2106] K.B. Sahay, S. Sahu, P. Singh, Short-Term Load Forecasting of Toronto Canada by Using Different ANN Algorithms, *6th IEEE International Conference on Power Systems (ICPS)*, 2016, pp.1-6
150. [Sahu2019] M.K. Sahu, B. Sahoo, M. Khatoi, S. Behera, Short-term Wind and PV Generation Forecasting of time-series using ANN, *International Conference on Intelligent Computing and Control Systems (ICICCS)*, 2019, pp.1328-1333
151. [Saini2008] L.M Saini, Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks, *Electric Power Systems Research*, vol.78, 2008, pp.1302-1310
152. [Sarajcev2020] P. Sarajcev, D. Jakus, J. Vasilj, Ensemble learning with time-series clustering for aggregated short-term load forecasting, *20th IEEE Mediterranean Electrotechnical Conference (MELECON)*, 2020, pp.553-558
153. [Schenato2014] L. Schenato, G. Barchi, D. Macii, R. Arghandeh, Bayesian Linear State Estimation using Smart Meters and PMUs Measurements in Distribution Grids, *IEEE International Conference on Smart Grid Communications*, 2014, pp.572-577
154. [Senjyu1998] T. Senjyu, S. Higa, K. Uezato, Future Load Curve Shaping Based on Similarity Using Fuzzy Logic Approach, *IEE Proceedings – Generation, Transmission and Distribution*, vol.145, nr.4, 1998, pp.375-380
155. [Senjyu2004] T. Senjyu, P. Mandal, K. Uezato, T. Funabashi, Next Day Load Curve Forecasting using Recurent Neural Network Structure, *IEE Proceedings – Generation, Transmission and Distribution*, vol.151, nr.3, 2004, pp.388-394
156. [Seppanen2016] J. Seppanen, S.K. Au, J. Turunen, L. Haarla, Bayesian Approach in the Modal Analysis of Electromechanical Oscillations, *IEEE Transactions on Power Systems*, vol.32, nr.1, 2017, pp.316-325
157. [Shi2010] H.F. Shi, Y. Lu, Short-Term Load Forecasting Based on Bayesian Neural Networks Learned by Hybrid Monte Carlo Method, *IEEE 9th International Conference on Machine Learning and Cybernetics*, 2010, pp.1494-1499
158. [SilvaT2017] T.V. da Silva, R.V.A. Monteiro, G.C. Guimaraes, F.A.M. Moura, R.M.C. Albertini, M.A. Tamashiro, Performance Analysis of Neural Network Training Algorithms and Support Vector Machine for Power Generation Forecast of Photovoltaic Panel, *IEEE Latin America Transactions*, Vol.15, nr.6, 2017, pp.1091-1100

159. [Silva2019] FL.C. Silva, F.L.C. Oliveira, R.C. Souza, A bottom-up bayesian extension for long term electricity consumption forecasting, *Energy*, vol.167, 2019, pp.198-210
160. [Singh2010] R. Singh, E. Manitsas, B.C. Pal, G.Strbac, A Recursive Bayesian Approach for Identification of Network Configuration Changes in Distribution System State Estimation, *IEEE Transactions on Power Systems*, vol.25, nr.3, 2010, pp.1329-1336
161. [Singh2017] S. Singh, S. Hussain, M.A. Bazaz, Short term load forecasting using artificial neural network, 4th International Conference on Image Information Processing (ICIIP), 2017, pp.1-5
162. [Soltan2018] S. Soltan, P. Mittal, H.V. Poor, Bayesian Regression for Robust Power Grid State Estimation Following a Cyber-Physical Attack, *IEEE Power & Energy Society General Meeting (PESGM)*, 2018, pp.1-6
163. [Sun2019] M. Sun, C. Feng, J. Zhang, Conditional aggregated probabilistic wind power forecasting based on spatio-temporal correlation, *Applied Energy*, vol.256, 2019, pp.1-11
164. [Sun2019a] M. Sun, M. Ghorbani, E.K.P. Chong, S. Suryanarayanan, A Comparison of Multiple Methods for Short-Term Load Forecasting, *North American Power Symposium (NAPS)*, 2019, pp.1-5
165. [Song2009] Q. Song, A. Wang, The Prediction of the Medium term power Load Based on Combined Model of the Bayes Theory and LS-SVM, 6th IEEE International Conference on Natural Computation (ICNC), 2010, pp.940-944
166. [Sykora2016] M. Sykora, J. Markova, D. Diamantidis, Bayesian Network Application for the Risk Assessment of Existing Energy Production Units, 2nd IEEE International Symposium on Stochastic Models in Reliability Engineering, Life Science and Operations Management, 2010, pp.656-664
167. [TangJ2013] J. Tang, Y. Bao, L. Wang, H. Lu, Y. Wang, C. Guo, J. Liu, B. Zhou, A Bayesian Network Approach for Human Reliability Analysis of Power System, *IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 2013, pp.1-6
168. [Tang2019] L. Tang, X. Wang, X. Wang, C. Shao, S. Liu, S. Tian, Long-term electricity consumption forecasting based on expert prediction and fuzzy Bayesian theory, *Energy*, vol.167, 2019, pp.1144-1154
169. [Tao2013] Z. Tao, T. Zhong, R. Shuyan, Medium and Long Term Load Forecasting Based on Fuzzy Times Series, *IEEE International Conference on Advanced Mechatronic Systems*, 2013, pp.671-673
170. [Tao2016] L. Tao, J. He, Y. Wang, P. Zhang, H. Zhang, H. Wang, Y. Miao, J. Wang, Operational risk assessment of distribution network with consideration of PV output uncertainties, *China International Conference on Electricity Distribution (CICED)*, 2016, pp.1-6
171. [Teive2011] R.C.G. Teive, J. Coelho, C.C.B. Camargo, P.C. Charles, T.Lange, L. Cimino Jr., A Bayesian Network Approach to Fault Diagnosis and Prognosis in Power Transmission Systems, 6th International Conference on Intelligent Systems Applications to Power Systems (ISAP), 2011, pp.1-6
172. [Theocharides2020] S. Theocharides, G. Makrides, A. Livera, P. Kaimakis, G.E. Georghiou, Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing, *Applied Energy*, vol.268, 2020, pp.1-14
173. [Tiponuş2002] Tiponuş V., Căleanu C.D., *Reţele neuronale Arhitecturi şi Algoritmi*, Ed.Politehnica, Timişoara, 2002
174. [Tudor2012] Tudor N. L., *Reţele neuronale artificial, Aplicaţii Matlab*, Matrix Rom, Bucureşti, 2012

175. [UPT2017] Contract UPT 21/2017, Elaborare modele de calcul și aplicarea lor pentru prognoza consumului propriu tehnologic în rețelele electrice de distribuție, Electrica Muntenia Nord
176. [UPT2018] Contract UPT 59/2018, Analiza și optimizarea regimurilor de funcționare pentru rețeaua electrică de distribuție, Electrica Muntenia Nord
177. [UPT2019] Contract UPT 63/2019, Analiza regimurilor de funcționare în vederea determinării post-calcul a consumului propriu tehnologic, Electrica Muntenia Nord
178. [UPT2020a] Contract UPT 14/2020, Prognoza consumului propriu tehnologic în rețelele electrice de distribuție, DelGaz Grid Moldova
179. [UPT2020b] Contract UPT 75/2020, Evaluarea consumului propriu tehnologic prin metode de tip post-calcul în rețele de distribuție, Electrica Muntenia Nord
180. [Ursianu2013] V. Ursianu, F. Moldoveanu, R. Ursianu, E. Ursianu, Bayesian Networks Applications in the Reliability of Software Systems for Monitoring Electrical Substations, 19th IEEE International Conference on Control Systems and Computer Science, 2013, pp.353-358
181. [Vakili2015] S. Vakili, Q. Zhao, L. Tong, Bayesian Quickest Short-term Voltage Instability Detection in Power Systems, 54th IEEE Annual Conference on Decision and Control (CDC), 2015, pp.7214-7219
182. [Vapnik1995] V.N. Vapnik, The Nature of Statistical Learning Theory, Springer, 1995
183. [WangG2020] G. Wang, R. Jia, J. Liu, H. Zhang, A hybrid wind power forecasting approach based on Bayesian model averaging and ensemble learning, Renewable Energy, vol.145, 2020, pp.2426-2434
184. [WangT2015] T. Wang, Y. Zhu, Z. Gao, Fault Diagnosis for Power System Based on a Special Bayesian Network, IEEE Region 10 TTENCON Conference, 2015, pp.58-63
185. [WangY2011] Y. Wang, Q. Xie, A. Ammari, M. Pedram, Deriving a Near-optimal Power Management Policy Using Model-Free Reinforcement Learning and Bayesian Classification, 48th ACM/EDAC IEEE Design Automation Conference (DAC), 2011, pp.41-46
186. [WangY2019] Y. Wang, Q. Hu, D. Srinivasan, Z. Wang, Wind Power Curve Modeling and Wind Power Forecasting with Inconsistent Data, IEEE Transactions on Sustainable Energy, vol.10, nr.1, 2019, pp.16-25
187. [WangY2019a] Y. Wang, H. Wang, D. Srinivasan, Q. Hu, Robust functional regression for wind speed forecasting based on Sparse Bayesian learning, Renewable Energy, vol.132, 2019, pp.43-60
188. [Wi2012] Y.M. Wi, S.K. Joo, K.B. Song, Holiday Load Forecasting Using Fuzzy Polynomial Regression with Weather Feature Selection and Adjustment, IEEE Transactions on Power Systems, vol.27, nr.2, 2012, pp.596-603
189. [WuChao2009] C. Wu, C. Lu, T. Wang, T. Yu, Ambient Signals based Power System Oscillation Modes Identification considering Model Order Selection, IEEE Power & Energy Society General Meeting, 2009, pp.1-6
190. [WuCheng2011] C. Wu, F. Jiang Q. Wang, J. Liu, Bayesian network methods for Fault Diagnosis of Power Systems, IEEE Transactions on Power Delivery, vo.21, nr.2, pp.634-639
191. [XieW2019] W. Xie, P. Zhang, R. Chen, Z. Zhou, A Nonparametric Bayesian Framework for Short-Term Wind Power Probabilistic Forecast, IEEE Transactions on Power Systems, vol.34, nr.1, 2019, pp.371-379
192. [XieZ2019] Z. Xie, R. Wang, Z. Wu, T. Liu, Short-Term Power Load Forecasting Model Based on Fuzzy Neural Network using Improved Decision Tree, IEEE Sustainable Power and Energy Conference (iSPEC), 2019, pp.482-486

193. [Xinhui2010] D. Xinhui, W. Liang, S. Jiancheng, Z. Yan, Application of Neural Network and Support Vector Machines to Power System Short-term Load Forecasting, IEEE International Conference on Computational Aspects of Social Networks, 2010, pp.729-732
194. [XuB2019] B. Xu, H. Li, W. Pang, D.Chen, Y. Tian, X. Lei, X Gao, C. Wu, Bayesian network approach to fault diagnosis of a hydroelectric generation system, Energy Science & Engineering, vol.7, nr.5, 2019, pp.1669-1677
195. [XuT2010] T. Xu, Y. Zhou, Y. Zhang, Study and Implementation of Rural Distribution Network Fault Location Method Based on Bayesian Reference, 2nd International Conference on Information Science and Engineering, 2010, pp.1-6
196. [XuQ2016] Q. Xu, N. Zhang, C. Kang, Q. Xia, D. He, C. Liu, Y. Huang, L. Cheng, J. Bai, A Game Theoretical Pricing Mechanism for Multi-Area Spinning Reserve Trading Considering Wind Power Uncertainty, IEEE Transactions on Power Systems, vol.31, nr.2, 2016, pp.1084-1095
197. [Yang2013] M. Yang, S. Fan, J. Lee, Probabilistic Short-Term Wind Power Forecast Using Componential Sparse Bayesian Learning, IEEE Transactions on Industry Applications, vol.49, nr.6, 2013, pp.2783-2792
198. [Yang2015] M. Yang, Y. Lin, X. Han, Probabilistic Wind Generation Forecast Based on Sparse Bayesian Classification and Dempster-Shafer Theory, IEEE Industry Applications Society Annual Meeting, 2015, pp.1-6
199. [Yang2020] Y. Yang, W. Li, T.A. Gulliver, S. Li, Bayesian Deep Learning-Based Probabilistic Load Forecasting in Smart Grids, IEEE Transactions on industrial informatics, vol.16, nr.7, 2020, pp.4703-4713
200. [Yi2014] Z. Yi, Z. Feng, Z. Bingquan, A novel ultra-short term load forecasting method based on load trend and fuzzy c-means clustering algorithm, International Conference on Power System Technology, 2014, pp.1-7
201. [Yuan2017] X.C. Yuan, X. Sun, W. Zhao, Z. Mi, B. Wang, Y.M. Wei, Forecasting China's regional energy demand by 2030: A Bayesian approach, Resources, Conservation & Recycling, vol.127, 2017, pp.85-95
202. [Zhang2014] Y. Zhang, Y. Xiang, L. Wang, Reliability Analysis of Power Grids with Cyber Vulnerability in SCADA System, IEEE PES General Meeting, 2014, pp.1-6
203. [Zhao2010] W.Q. Zhao, S.L. Zhang, D.X. Niu, Multi-Agent and Bayesian Network applied in Transformer Faults Diagnosis, 9th International Conference on Machine Learning and Cybernetics, 2010, pp.43-46
204. [Zheng2010] G. Zheng, Z. Yongli, Research of Transformer Fault Diagnosis Based on Bayesian Network Classifiers, International Conference on Computer Design and Applications (ICCD), 2010, vol.3, pp.382-385
205. [Zehani2017] R.Zehani, M. Houabes, N. Zehani, Etude de la fiabilité des systèmes électriques par l'approche de Bayes, Revue des Sciences et de la Technologie, vol.34, pp.151-162
206. [Zhou2012] D. Zhou, C. Li, Z. Wang, Power Transformer Lifetime Modeling, Prognostics & System Health Management IEEE Conference (PHM), 2012, pp.1-6
207. [Zuluaga2018] C.D. Zuluaga, M.A. Alvarez, Bayesian Probabilistic Power Flow Analysis Using Jacobian Approximate Bayesian Computation, IEEE Transactions on Power Systems, vol.33, nr.5, 2018, pp.5217-5225



## SINTEZĂ PRIVIND LUCRĂRILE PROPRII

1. [Bucerzan2010] Bucerzan D., **Crăciun M.**, Chis V., Rațiu C., Stream Ciphers Analysis Methods, International Journal of Computers Communications & Control, vol.5, nr.4, 2010, pp.483-489 **(ISI)**
2. [Crăciun2013] **Crăciun M.**, Bucerzan D., Rațiu C., Manolescu A., Actuality of Bankruptcy Prediction Models used in Decision Support System, International Journal of Computers Communications & Control, vol.8, nr.3, 2013, pp.375-383 **(ISI)**
3. [Crăciun2017] **Crăciun M.**, Kilyeni Șt., Bărbulescu C., Meszaros R., Bayesian network applications in power systems engineering. A review, Journal of Sustainable Energy, nr.3, 2017, p. 99-105 **(BDI)**
4. [UPT2017] Contract UPT 21/2017, Elaborare modele de calcul și aplicarea lor pentru prognoza consumului propriu tehnologic în rețelele electrice de distribuție, Electrica Muntenia Nord & Servelect
5. [Bărbulescu2018] Bărbulescu C., Kilyeni Șt., Deacu A., Simo A., **Crăciun M.**, Power Consumption Forecast Quality Assessment, Proceedings of the 7th International Conference on Computers Communications and Control (ICCCC 2018), May 8-12, 2018, Oradea, Romania, p.103-110 **(ISI)**
6. [Crăciun2018a] **Crăciun M.**, Csorba L.M., Application of the Fuzzy-Pay-Off Method in the Valuation of a Financial Instrument. In: Balas V., Jain L., Balas M. (eds.), Soft Computing Applications, SOFA 2016, Advances in Intelligent Systems and Computing, Springer, vol.634, 2018, pp.235-250 **(ISI)**
7. [Crăciun2018b] **Crăciun M.**, Raport științific nr.1 cu rezultate intermediare ale cercetării, Universitatea Politehnica Timișoara, Facultatea de Electrotehnică și Electroenergetică, Departamentul de Electroenergetică, Timișoara, 2018
8. [Csorba2018] Csorba L.M., **Crăciun M.**, An Application of the Multi Period Decision Trees in the Sustainable Medical Waste Investments. In: Balas V., Jain L., Balas M. (eds.), Soft Computing Applications, SOFA 2016, Advances in Intelligent Systems and Computing, Springer, vol.634, 2018, pp.540-556 **(ISI)**
9. [UPT2018] Contract UPT 59/2018, Analiza și optimizarea regimurilor de funcționare pentru rețeaua electrică de distribuție, Electrica Muntenia Nord & Servelect
10. [Crăciun2019] **Crăciun M.**, Raport științific nr.2 cu rezultate intermediare ale cercetării, Universitatea Politehnica Timișoara, Facultatea de Electrotehnică și Electroenergetică, Departamentul de Electroenergetică, Timișoara, 2019
11. [UPT2019] Contract UPT 63/2019, Analiza regimurilor de funcționare în vederea determinării post-calcul a consumului propriu tehnologic, Electrica Muntenia Nord & Servelect
12. [UPT2020a] Contract UPT 14/2020, Prognoza consumului propriu tehnologic în rețelele electrice de distribuție, DelGaz Grid Moldova & Servelect

13. [UPT2020b] Contract UPT 75/2020, Evaluarea consumului propriu tehnologic prin metode de tip post-calcul în rețele de distribuție, Electrica Muntenia Nord & Servelect
14. [Bărbulescu2021] Bărbulescu C., Kilyeni Șt., Chiș V., **Crăciun M.**, Simo A., Daily Load Curve Forecasting. Comparative Analysis: Conventional vs. Unconventional Methods. In: Balas V., Jain L., Balas M., Shahbazova S. (eds.) Soft Computing Applications, SOFA 2018, Advances in Intelligent Systems and Computing, vol. 1221, 2021, Springer, pp.3-18 (**BDI, în curs de indexare ISI**)

## ANEXA 7.1. COMPARAȚII PROGNOZE

### A7.1.2.2. UTR Reșița

Tabelul 7.1.1. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

Anul / Ora	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
1	80.20	71.20	96.60	77.40	68.90	62.70	73.80	69.10	60.40	56.10
2	67.20	76.60	94.60	79.60	78.00	55.40	59.90	70.50	59.20	54.20
3	63.80	71.70	78.20	77.70	81.50	54.70	61.90	66.90	57.70	54.10
4	57.20	87.40	91.90	80.40	74.50	55.20	68.20	52.30	59.70	54.00
5	70.30	82.10	99.20	79.90	76.80	56.30	69.10	60.20	61.70	53.10
6	78.80	70.30	91.60	82.60	71.90	56.50	64.30	69.00	59.50	52.30
7	76.20	85.00	93.10	80.30	68.40	55.80	50.80	62.60	58.90	51.60
8	81.50	94.60	66.50	101.1	72.10	63.10	71.90	62.10	58.90	63.10
9	86.60	100.4	31.00	111.7	92.40	67.20	73.00	60.00	59.10	68.40
10	73.30	112.3	38.00	104.7	90.40	68.50	67.70	57.20	59.90	66.40
11	74.60	108.7	31.50	103.5	94.00	69.80	63.30	58.40	58.40	62.90
12	72.80	98.70	89.20	100.7	83.90	72.60	71.90	59.00	58.60	63.20
13	70.00	100.3	98.70	98.00	81.40	70.60	57.10	61.30	58.70	63.90
14	80.30	115.5	98.00	87.50	79.50	69.60	50.00	62.40	58.10	65.00
15	77.70	107.4	91.50	95.50	81.50	69.10	50.50	58.50	58.20	61.30
16	68.70	90.20	81.50	95.50	74.50	72.40	59.00	49.60	58.70	60.80
17	84.20	75.00	90.10	94.40	72.80	76.30	64.10	58.40	55.60	59.70
18	73.40	87.70	89.50	94.60	62.00	77.30	66.60	57.20	58.20	57.00
19	72.50	81.00	89.60	89.10	55.80	80.70	56.90	58.10	60.10	57.20
20	61.30	70.00	75.60	85.10	52.30	79.30	48.50	45.60	60.20	57.90
21	70.90	76.60	81.70	83.90	56.80	71.70	50.00	50.40	59.90	56.30
22	79.10	79.90	84.00	90.90	67.00	78.80	57.20	52.00	59.80	56.10
23	92.70	95.00	105.80	90.50	79.70	87.90	78.70	57.30	56.30	57.60
24	89.10	87.30	95.30	89.00	81.70	88.10	56.30	57.80	58.40	56.30

Tabelul 7.1.2. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Anul / Ora	2011	2012	2013	Anul / Ora	2011	2012	2013
1	59.40	56.80	54.20	13	59.50	60.10	58.10
2	57.70	55.60	54.90	14	58.60	62.40	57.80
3	57.90	56.80	56.10	15	60.50	58.30	55.20
4	57.60	55.30	56.10	16	53.80	54.70	57.30
5	60.40	58.60	57.80	17	59.40	60.60	62.60
6	53.60	52.00	53.20	18	59.80	58.40	57.60
7	53.30	49.90	53.20	19	55.30	54.40	51.90
8	60.10	55.10	53.40	20	49.30	48.30	47.10
9	59.20	57.90	56.20	21	50.20	51.40	54.10
10	62.50	60.70	57.20	22	58.10	56.90	53.60
11	62.50	61.10	61.80	23	64.60	65.80	66.10
12	62.20	60.90	61.80	24	64.10	62.80	60.40

Tabelul 7.1.3. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

Ora	2011				2012				2013					
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	59.4	57.7	-2.9	8.5	1	56.8	55.7	-1.9	3.4	1	54.2	53.8	-0.7	0.5
2	57.7	58.2	0.9	0.8	2	55.6	56.5	1.6	2.5	2	54.9	54.7	-0.3	0.1
3	57.9	59.9	3.5	11.9	3	56.8	58.6	3.1	9.7	3	56.1	57.2	2.0	4.0
4	57.6	57.4	-0.3	0.1	4	55.3	55.6	0.5	0.2	4	56.1	53.7	-4.3	18.2

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
5	60.4	61.1	1.1	1.2	5	58.6	59.3	1.2	1.5	5	57.8	57.6	-0.4	0.1
6	53.6	53.6	0.1	0.0	6	52.0	51.4	-1.1	1.2	6	53.2	49.2	-7.5	55.9
7	53.3	55.1	3.4	11.5	7	49.9	53.3	6.7	45.1	7	53.2	51.4	-3.4	11.3
8	60.1	63.9	6.3	39.8	8	55.1	62.3	13.1	170.4	8	53.4	60.7	13.7	186.7
9	59.2	61.2	3.4	11.6	9	57.9	59.3	2.5	6.0	9	56.2	57.4	2.2	4.7
10	62.5	60.7	-2.9	8.6	10	60.7	58.3	-3.9	15.0	10	57.2	56.0	-2.0	4.1
11	62.5	62.1	-0.6	0.4	11	61.1	60.9	-0.3	0.1	11	61.8	59.6	-3.5	12.3
12	62.2	65.7	5.6	31.3	12	60.9	63.5	4.2	17.8	12	61.8	61.3	-0.9	0.8
13	59.5	58.2	-2.1	4.4	13	60.1	55.9	-6.9	48.2	13	58.1	53.7	-7.7	58.5
14	58.6	61.7	5.3	27.9	14	62.4	59.5	-4.6	21.4	14	57.8	57.3	-0.8	0.7
15	60.5	58.2	-3.8	14.1	15	58.3	56.0	-4.0	15.7	15	55.2	53.8	-2.6	6.6
16	53.8	59.5	10.7	114.2	16	54.7	58.0	6.1	37.3	16	57.3	56.5	-1.4	1.9
17	59.4	63.1	6.2	38.2	17	60.6	61.5	1.5	2.2	17	62.6	59.9	-4.3	18.2
18	59.8	59.6	-0.3	0.1	18	58.4	57.8	-1.0	1.1	18	57.6	56.0	-2.8	7.9
19	55.3	55.2	-0.2	0.1	19	54.4	53.0	-2.5	6.2	19	51.9	50.9	-1.8	3.4
20	49.3	51.7	4.9	24.4	20	48.3	50.2	3.9	15.4	20	47.1	48.7	3.3	10.9
21	50.2	55.9	11.4	130.8	21	51.4	54.4	5.8	33.5	21	54.1	52.8	-2.4	5.7
22	58.1	57.2	-1.5	2.4	22	56.9	55.1	-3.2	10.1	22	53.6	53.0	-1.1	1.3
23	64.6	66.8	3.4	11.8	23	65.8	64.6	-1.8	3.2	23	66.1	62.5	-5.5	30.1
24	64.1	63.1	-1.6	2.6	24	62.8	60.9	-3.0	9.0	24	60.4	58.8	-2.6	7.0
S <sub>2011</sub>	496.58				S <sub>2012</sub>	476.33				S <sub>2013</sub>	450.67			
S <sub>total</sub> = 1423.59														

Tabelul 7.1.4. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	59.4	57.4	-3.3	11.1	1	56.8	56.4	-0.7	0.5	1	55.4	53.8	2.2	4.8
2	57.7	56.5	-2.0	4.0	2	55.6	55.7	0.1	0.0	2	54.8	54.7	-0.1	0.0
3	57.9	57.7	-0.3	0.1	3	56.8	57.1	0.5	0.2	3	56.5	57.2	0.6	0.4
4	57.6	57.0	-1.0	1.1	4	55.3	56.4	2.0	3.9	4	55.8	53.7	-0.6	0.3
5	60.4	59.5	-1.5	2.2	5	58.6	58.8	0.3	0.1	5	58.0	57.6	0.4	0.2
6	53.6	53.2	-0.8	0.6	6	52.0	53.0	1.8	3.4	6	52.7	49.2	-0.9	0.8
7	53.3	52.2	-2.1	4.5	7	49.9	52.1	4.4	19.1	7	52.0	51.4	-2.3	5.2
8	60.1	57.3	-4.7	22.2	8	55.1	56.2	2.0	4.1	8	55.2	60.7	3.3	11.0
9	59.2	59.6	0.6	0.4	9	57.9	57.8	-0.2	0.0	9	56.1	57.4	-0.3	0.1
10	62.5	60.8	-2.7	7.1	10	60.7	59.7	-1.7	2.8	10	58.5	56.0	2.4	5.5
11	62.5	62.7	0.2	0.1	11	61.1	61.9	1.3	1.6	11	61.1	59.6	-1.1	1.2
12	62.2	61.8	-0.6	0.4	12	60.9	61.7	1.2	1.5	12	61.5	61.3	-0.5	0.2
13	59.5	60.1	1.0	0.9	13	60.1	59.3	-1.3	1.6	13	58.6	53.7	0.9	0.7
14	58.6	60.2	2.8	7.7	14	62.4	59.7	-4.4	19.2	14	59.1	57.3	2.3	5.2
15	60.5	59.2	-2.1	4.6	15	58.3	57.9	-0.7	0.5	15	56.6	53.8	2.6	6.5
16	53.8	55.2	2.5	6.4	16	54.7	55.4	1.2	1.4	16	55.6	56.5	-3.0	9.2
17	59.4	60.1	1.1	1.3	17	60.6	60.8	0.3	0.1	17	61.5	59.9	-1.7	3.1
18	59.8	59.5	-0.5	0.3	18	58.4	58.7	0.4	0.2	18	57.8	56.0	0.4	0.2
19	55.3	55.1	-0.4	0.2	19	54.4	53.9	-0.9	0.7	19	52.8	50.9	1.8	3.1
20	49.3	48.8	-1.0	1.0	20	48.3	48.1	-0.4	0.1	20	47.5	48.7	0.7	0.6
21	50.2	51.6	2.7	7.3	21	51.4	52.2	1.6	2.5	21	52.9	52.8	-2.3	5.2
22	58.1	57.1	-1.8	3.2	22	56.9	56.1	-1.5	2.2	22	55.1	53.0	2.8	7.6

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
23	64.6	65.6	1.5	2.3	23	65.8	65.6	-0.3	0.1	23	65.6	62.5	-0.8	0.6
24	64.1	63.4	-1.0	1.1	24	62.8	62.3	-0.8	0.7	24	61.1	58.8	1.2	1.4
$S_{2011}$	89.87				$S_{2012}$	66.56				$S_{2013}$	73.09			
$S_{total} = 229.52$														

Tabelul 7.1.5. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	59.40	58.65	-1.26	1.59	1	56.80	55.89	-1.60	2.55	1	54.20	56.10	3.50	12.25
2	57.70	57.65	-0.09	0.01	2	55.60	56.02	0.75	0.56	2	54.90	57.09	4.00	15.97
3	57.90	57.65	-0.43	0.19	3	56.80	55.84	-1.69	2.86	3	56.10	57.35	2.24	5.00
4	57.60	57.65	0.09	0.01	4	55.30	56.06	1.37	1.87	4	56.10	56.85	1.33	1.77
5	60.40	59.02	-2.28	5.22	5	58.60	56.16	-4.16	17.33	5	57.80	57.06	-1.27	1.62
6	53.60	56.92	6.19	38.37	6	52.00	55.73	7.18	51.56	6	53.20	56.68	6.53	42.67
7	53.30	56.14	5.33	28.39	7	49.90	55.09	10.40	108.1	7	53.20	56.35	5.92	35.03
8	60.10	57.65	-4.08	16.65	8	55.10	57.05	3.53	12.46	8	53.40	56.75	6.27	39.33
9	59.20	57.65	-2.62	6.87	9	57.90	57.03	-1.49	2.23	9	56.20	57.86	2.95	8.68
10	62.50	59.43	-4.91	24.13	10	60.70	57.08	-5.96	35.49	10	57.20	57.82	1.09	1.18
11	62.50	60.22	-3.65	13.31	11	61.10	57.27	-6.27	39.35	11	61.80	57.92	-6.28	39.49
12	62.20	57.65	-7.32	53.52	12	60.90	57.42	-5.71	32.58	12	61.80	57.61	-6.77	45.87
13	59.50	57.82	-2.82	7.97	13	60.10	57.46	-4.39	19.29	13	58.10	57.51	-1.01	1.02
14	58.60	58.32	-0.48	0.23	14	62.40	56.25	-9.85	97.08	14	57.80	57.44	-0.63	0.40
15	60.50	57.65	-4.71	22.19	15	58.30	57.34	-1.64	2.70	15	55.20	57.54	4.24	17.98
16	53.80	56.30	4.65	21.59	16	54.70	56.46	3.21	10.32	16	57.30	57.17	-0.23	0.05
17	59.40	57.92	-2.49	6.21	17	60.60	57.02	-5.91	34.95	17	62.60	57.07	-8.84	78.16
18	59.80	57.65	-3.59	12.92	18	58.40	56.99	-2.41	5.79	18	57.60	55.99	-2.80	7.85
19	55.30	55.22	-0.14	0.02	19	54.40	54.65	0.45	0.20	19	51.90	55.12	6.21	38.55
20	49.30	53.27	8.05	64.85	20	48.30	49.73	2.96	8.76	20	47.10	53.64	13.89	192.8
21	50.20	56.14	11.83	140.0	21	51.40	49.00	-4.68	21.89	21	54.10	55.46	2.51	6.32
22	58.10	57.65	-0.78	0.60	22	56.90	55.10	-3.17	10.03	22	53.60	56.73	5.85	34.19
23	64.60	58.35	-9.67	93.60	23	65.80	57.41	-12.75	162.5	23	66.10	57.59	-12.88	165.8
24	64.10	57.65	-10.06	101.2	24	62.80	55.77	-11.19	125.2	24	60.40	57.67	-4.52	20.47
$S_{2011}$	659.6				$S_{2012}$	805.6				$S_{2013}$	812.5			
$S_{total} = 2277.7$														

### A7.1.2.3. Enel Banat

Tabelul 7.1.9. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

Anul / Ora	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
1	455.5	460.2	472.1	436.3	418.7	398.4	411.6	401.7	401.7	388.6
2	427.8	452.8	457.7	427.3	415.0	382.6	390.8	381.4	380.6	372.2
3	417.9	441.0	436.1	421.0	410.6	378.5	394.7	386.6	389.0	387.8
4	413.9	454.8	447.6	418.4	393.8	365.7	382.7	374.7	385.8	384.1
5	434.4	456.8	459.3	424.5	404.1	380.7	403.8	391.4	389.8	376.5
6	459.4	465.2	469.0	441.7	411.6	388.1	403.5	404.8	382.1	358.6
7	477.9	503.0	489.1	455.6	422.1	396.2	395.5	404.5	393.6	377.7
8	534.9	570.2	517.9	525.6	473.9	449.2	464.4	446.3	437.0	432.3
9	554.1	607.2	529.7	574.0	525.4	479.5	481.7	489.0	483.4	486.0

Anul / Ora	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
10	536.9	604.8	530.5	564.6	530.8	492.4	490.5	506.5	494.3	479.4
11	519.1	583.5	499.0	549.3	529.6	483.5	472.7	492.0	490.5	487.8
12	512.3	557.3	527.7	531.5	514.1	477.6	465.7	469.2	472.6	474.8
13	496.2	551.3	539.4	525.2	500.5	468.6	445.1	467.3	464.9	460.9
14	502.0	567.3	547.0	518.9	495.3	473.4	452.3	489.4	472.0	456.7
15	491.1	546.9	529.1	518.6	488.2	462.2	438.2	463.9	467.6	458.5
16	452.2	505.2	485.6	487.7	451.3	450.6	447.0	451.2	451.7	428.9
17	462.9	490.6	492.0	479.3	439.1	442.8	440.0	449.3	443.6	426.8
18	448.5	502.7	490.6	476.5	424.6	443.0	445.4	445.5	440.9	414.9
19	440.4	495.6	488.9	464.3	405.2	432.4	419.4	453.3	443.5	413.5
20	436.8	476.2	445.0	442.2	393.6	418.9	392.2	418.8	427.2	409.2
21	510.1	534.7	496.2	479.5	426.3	421.5	386.5	405.2	432.0	424.6
22	545.3	561.3	534.7	528.4	494.5	478.9	432.7	429.4	445.7	453.3
23	562.8	580.5	573.5	540.3	524.9	518.9	498.9	475.3	463.7	480.3
24	536.7	538.0	524.1	501.8	488.1	482.1	443.3	444.7	437.5	438.7

Tabelul 7.1.10. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Anul / Ora	2011	2012	2013	Anul / Ora	2011	2012	2013
1	389.4	384.8	384.2	13	449.0	442.3	450.7
2	374.7	370.3	364.6	14	459.8	454.9	450.5
3	377.4	380.9	373.9	15	453.0	450.5	441.4
4	370.8	364.9	363.3	16	433.3	431.1	430.0
5	370.6	367.4	372.5	17	437.5	440.2	433.8
6	368.2	358.1	364.3	18	427.2	418.0	423.0
7	382.0	381.3	380.1	19	419.9	409.6	415.9
8	430.4	421.4	422.7	20	408.3	402.2	405.6
9	464.1	450.9	449.9	21	410.9	411.6	406.0
10	482.8	472.9	471.2	22	450.0	439.8	436.4
11	490.3	486.2	481.9	23	472.6	474.6	467.7
12	460.6	453.9	452.7	24	438.6	439.4	434.6

Tabelul 7.1.11. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	389.4	394.9	1.40	1.95	1	384.8	390.1	1.37	1.87	1	384.2	385.5	0.34	0.12
2	374.7	381.1	1.71	2.91	2	370.3	375.8	1.46	2.15	2	364.6	370.5	1.63	2.64
3	377.4	382.8	1.42	2.03	3	380.9	378.9	-0.53	0.28	3	373.9	375.1	0.32	0.10
4	370.8	371.0	0.07	0.00	4	364.9	366.0	0.30	0.09	4	363.3	361.2	-0.58	0.33
5	370.6	379.3	2.35	5.50	5	367.4	374.2	1.85	3.41	5	372.5	369.4	-0.84	0.71
6	368.2	370.1	0.52	0.27	6	358.1	362.5	1.21	1.47	6	364.3	355.2	-2.49	6.22
7	382.0	385.0	0.77	0.60	7	381.3	378.2	-0.82	0.67	7	380.1	371.9	-2.16	4.67
8	430.4	431.8	0.31	0.10	8	421.4	423.5	0.49	0.24	8	422.7	415.7	-1.65	2.71
9	464.1	471.5	1.60	2.57	9	451.0	463.4	2.77	7.65	9	449.9	455.9	1.32	1.74
10	482.8	493.9	2.29	5.26	10	472.9	487.8	3.14	9.89	10	471.2	481.8	2.24	5.02
11	490.3	488.8	-0.31	0.09	11	486.2	485.6	-0.12	0.01	11	481.9	482.7	0.18	0.03
12	460.6	460.8	0.05	0.00	12	453.9	453.7	-0.06	0.00	12	452.7	446.9	-1.28	1.64
13	449.0	452.5	0.78	0.61	13	442.3	445.9	0.80	0.63	13	450.7	439.6	-2.47	6.09
14	459.8	464.0	0.93	0.86	14	454.9	458.7	0.82	0.67	14	450.5	453.5	0.66	0.44
15	453.0	457.6	1.02	1.03	15	450.6	453.4	0.64	0.41	15	441.4	449.6	1.87	3.50
16	433.3	446.5	3.03	9.21	16	431.1	444.5	3.11	9.68	16	430.0	442.8	2.97	8.83
17	437.5	433.1	-1.00	1.01	17	440.2	429.4	-2.45	5.99	17	433.8	425.9	-1.81	3.28
18	427.2	425.0	-0.51	0.26	18	418.0	420.4	0.58	0.34	18	423.0	416.1	-1.63	2.65
19	419.9	425.8	1.39	1.93	19	409.6	421.8	2.98	8.88	19	415.9	417.9	0.49	0.24
20	408.3	409.7	0.34	0.12	20	402.2	407.7	1.38	1.89	20	405.6	405.9	0.07	0.01
21	410.9	407.5	-0.84	0.70	21	411.6	401.0	-2.58	6.67	21	406.0	395.0	-2.69	7.24

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
22	450.0	437.6	-2.74	7.52	22	439.8	429.4	-2.36	5.57	22	436.4	421.5	-3.40	11.5
23	472.6	473.3	0.15	0.02	23	474.6	465.8	-1.85	3.43	23	467.7	458.7	-1.93	3.72
24	438.6	438.2	-0.08	0.01	24	439.4	431.7	-1.75	3.08	24	434.6	425.6	-2.07	4.27
$S_{2011}$	44.58				$S_{2012}$	74.98				$S_{2013}$	77.74			
$S_{total} = 197.30$														

Tabelul 7.1.12. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	389.4	388.9	-0.14	0.02	1	384.8	385.3	0.13	0.02	1	384.2	381.7	-0.63	0.40
2	374.7	374.6	-0.02	0.00	2	370.3	370.0	-0.09	0.01	2	364.6	365.5	0.24	0.06
3	377.4	379.3	0.49	0.24	3	380.9	377.4	-0.93	0.86	3	373.9	375.5	0.41	0.17
4	370.8	370.0	-0.22	0.05	4	364.9	365.6	0.18	0.03	4	363.3	361.2	-0.59	0.34
5	370.6	374.6	1.09	1.19	5	367.4	370.6	0.87	0.75	5	372.5	366.5	-1.61	2.59
6	368.2	369.6	0.39	0.15	6	358.1	363.3	1.44	2.08	6	364.3	357.3	-1.93	3.72
7	382.0	387.2	1.36	1.85	7	381.3	382.1	0.20	0.04	7	380.1	377.6	-0.64	0.41
8	430.4	428.8	-0.38	0.15	8	421.4	424.2	0.67	0.45	8	422.7	420.3	-0.56	0.31
9	464.1	462.7	-0.29	0.08	9	451.0	455.3	0.97	0.94	9	449.9	448.7	-0.28	0.08
10	482.8	481.4	-0.30	0.09	10	472.9	475.3	0.51	0.26	10	471.2	469.4	-0.38	0.15
11	490.3	490.3	0.01	0.00	11	486.2	486.0	-0.05	0.00	11	481.9	481.7	-0.02	0.00
12	460.6	460.1	-0.10	0.01	12	453.9	455.6	0.37	0.14	12	452.7	451.2	-0.33	0.11
13	449.0	453.5	0.99	0.97	13	442.3	448.2	1.33	1.76	13	450.7	443.0	-1.70	2.89
14	459.8	460.0	0.06	0.00	14	454.9	455.0	0.02	0.00	14	450.5	450.1	-0.08	0.01
15	453.0	454.4	0.31	0.09	15	450.6	448.5	-0.45	0.20	15	441.4	442.6	0.29	0.09
16	433.3	434.1	0.19	0.04	16	431.1	432.2	0.26	0.07	16	430.0	430.3	0.06	0.00
17	437.5	438.5	0.23	0.05	17	440.2	436.8	-0.76	0.58	17	433.8	435.1	0.30	0.09
18	427.2	426.1	-0.25	0.06	18	418.0	423.5	1.31	1.71	18	423.0	420.9	-0.51	0.26
19	419.9	418.4	-0.37	0.14	19	409.6	414.9	1.30	1.68	19	415.9	411.4	-1.06	1.13
20	408.3	406.5	-0.45	0.21	20	402.2	405.4	0.80	0.64	20	405.6	404.3	-0.33	0.11
21	410.9	412.1	0.28	0.08	21	411.6	409.3	-0.56	0.31	21	406.0	407.3	0.33	0.11
22	450.0	449.4	-0.12	0.01	22	439.8	442.0	0.51	0.26	22	436.4	435.2	-0.27	0.07
23	472.6	475.9	0.71	0.51	23	474.6	471.2	-0.71	0.51	23	467.7	466.8	-0.20	0.04
24	438.6	443.2	1.06	1.12	24	439.4	437.9	-0.34	0.11	24	434.6	432.8	-0.41	0.17
$S_{2011}$	7.12				$S_{2012}$	13.41				$S_{2013}$	13.30			
$S_{total} = 33.82$														

Tabelul 7.1.13. Curbele de sarcină prognozate pentru perioada 2011-2013 (puterile în MW)

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	389.4	387.7	-0.45	0.21	1	384.8	365.8	-4.94	24.38	1	384.2	379.9	-1.10	1.21
2	374.7	382.5	2.08	4.34	2	370.3	361.0	-2.52	6.37	2	364.6	366.1	0.42	0.17
3	377.4	386.1	2.30	5.30	3	380.9	367.3	-3.58	12.80	3	373.9	377.0	0.83	0.68
4	370.8	385.7	4.01	16.10	4	364.9	367.5	0.70	0.49	4	363.3	362.0	-0.35	0.12
5	370.6	384.1	3.66	13.37	5	367.4	369.8	0.64	0.41	5	372.5	364.7	-2.10	4.40

2011					2012					2013				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
6	368.2	380.6	3.37	11.37	6	358.1	368.5	2.90	8.41	6	364.3	356.2	-2.22	4.92
7	382.0	386.2	1.10	1.22	7	381.3	378.1	-0.84	0.71	7	380.1	379.0	-0.29	0.08
8	430.4	421.7	-2.02	4.09	8	421.4	411.1	-2.43	5.91	8	422.7	418.0	-1.12	1.26
9	464.1	477.3	2.85	8.14	9	450.9	446.8	-0.92	0.84	9	449.9	442.5	-1.65	2.74
10	482.8	472.0	-2.25	5.06	10	472.9	474.7	0.39	0.15	10	471.2	457.4	-2.94	8.63
11	490.3	476.4	-2.82	7.98	11	486.2	486.6	0.07	0.00	11	481.9	464.9	-3.52	12.39
12	460.6	468.5	1.73	3.00	12	453.9	457.1	0.69	0.48	12	452.7	445.8	-1.53	2.35
13	449.0	456.9	1.75	3.07	13	442.3	446.4	0.92	0.84	13	450.7	437.5	-2.93	8.56
14	459.8	454.4	-1.17	1.37	14	454.9	458.5	0.79	0.62	14	450.5	447.3	-0.72	0.51
15	453.0	454.4	0.31	0.09	15	450.5	451.7	0.25	0.06	15	441.4	444.6	0.73	0.53
16	433.3	419.7	-3.14	9.85	16	431.1	429.8	-0.30	0.09	16	430.0	430.0	0.00	0.00
17	437.5	419.2	-4.17	17.43	17	440.2	431.8	-1.90	3.63	17	433.8	437.9	0.96	0.92
18	427.2	409.9	-4.05	16.43	18	418.0	422.0	0.95	0.89	18	423.0	419.6	-0.82	0.67
19	419.9	409.2	-2.57	6.59	19	409.6	415.3	1.40	1.95	19	415.9	412.4	-0.83	0.69
20	408.3	402.5	-1.44	2.06	20	402.2	406.8	1.15	1.33	20	405.6	405.8	0.06	0.00
21	410.9	420.3	2.28	5.20	21	411.6	410.0	-0.39	0.15	21	406.0	414.8	2.19	4.78
22	450.0	454.9	1.10	1.22	22	439.8	443.8	0.92	0.84	22	436.4	438.6	0.51	0.26
23	472.6	485.9	2.81	7.92	23	474.6	464.1	-2.20	4.84	23	467.7	461.6	-1.32	1.73
24	438.6	439.7	0.26	0.07	24	439.4	432.2	-1.64	2.70	24	434.6	439.1	1.04	1.08
$S_{2011}$	151.50				$S_{2012}$	78.89				$S_{2013}$	58.72			
$S_{total} = 289.11$														

### A7.1.3.2. Stația Victoria

#### □ Ultima zi de joi a fiecărei luni, ora 9

Tabelul 7.1.17. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

Anul / Luna	2006	2007	2008	2009	2010	2011	Anul / Luna	2006	2007	2008	2009	2010	2011
Ian	16.00	16.00	12.00	16.00	14.00	14.50	Iul	10.00	15.00	14.50	14.00	12.00	10.00
Feb	15.50	17.00	15.00	16.00	11.50	8.00	Aug	9.50	12.50	11.00	11.50	10.50	8.50
Mar	12.00	19.50	15.00	15.50	8.50	10.50	Sep	16.50	13.00	13.00	10.00	11.00	12.00
Apr	10.50	17.00	10.50	6.50	9.00	8.00	Oct	18.00	15.00	10.50	12.50	10.50	11.50
Mai	9.50	10.00	13.50	11.50	14.50	12.50	Nov	21.50	15.50	15.00	14.50	14.50	8.50
Iun	11.00	15.50	14.50	9.00	6.50	6.50	Dec	12.00	11.00	7.00	6.00	5.50	7.50

Tabelul 7.1.18. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Anul / Luna	2012	2013	Anul / Luna	2012	2013	Anul / Luna	2012	2013
Ian	13.00	10.00	Mai	12.00	12.50	Sep	13.50	13.70
Feb	9.00	10.00	Iun	7.00	7.20	Oct	12.50	11.80
Mar	11.00	12.50	Iul	11.00	12.50	Nov	12.50	13.70
Apr	7.50	9.00	Aug	7.50	8.10	Dec	6.50	7.10

Tabelul 7.1.19. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	13.00	13.34	2.58	6.68	Ian	10.00	13.28	28.20	795.3
Feb	9.00	10.95	19.54	381.6	Feb	10.00	10.69	6.65	44.25
Mar	11.00	11.02	0.15	0.02	Mar	12.50	10.81	-14.54	211.5



2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Apr	7.50	8.71	14.93	223.1	Apr	9.00	8.65	-4.01	16.04
Mai	12.00	11.29	-6.07	36.90	Mai	12.50	11.28	-10.29	106.0
Iun	7.00	8.20	15.80	249.5	Iun	7.20	8.01	10.69	114.2
Iul	11.00	11.30	2.68	7.19	Iul	12.50	11.21	-10.88	118.3
Aug	7.50	9.55	24.04	578.0	Aug	8.10	9.46	15.48	239.7
Sep	13.50	12.26	-9.66	93.33	Sep	13.70	12.28	-10.96	120.2
Oct	12.50	11.41	-9.13	83.29	Oct	11.80	11.31	-4.24	18.01
Nov	12.50	12.62	0.95	0.90	Nov	13.70	12.41	-9.87	97.45
Dec	6.50	7.13	9.25	85.64	Dec	7.10	7.07	-0.48	0.23
$S_{2012}$	1746.15				$S_{2013}$	1881.18			
$S_{total} = 3627.33$									

Tabelul 7.1.20. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	13.00	11.50	-12.27	150.55	Ian	10.00	11.21	11.38	129.39
Feb	9.00	9.14	1.58	2.51	Feb	10.00	9.64	-3.70	13.68
Mar	11.00	11.66	5.79	33.54	Mar	12.50	12.16	-2.79	7.78
Apr	7.50	8.26	9.62	92.51	Apr	9.00	8.51	-5.58	31.09
Mai	12.00	12.16	1.32	1.75	Mai	12.50	12.54	0.28	0.08
Iun	7.00	6.98	-0.26	0.07	Iun	7.20	7.23	0.46	0.21
Iul	11.00	11.49	4.31	18.62	Iul	12.50	12.03	-3.83	14.66
Aug	7.50	7.65	1.95	3.80	Aug	8.10	7.88	-2.72	7.41
Sep	13.50	13.49	-0.08	0.01	Sep	13.70	13.68	-0.13	0.02
Oct	12.50	12.43	-0.56	0.31	Oct	11.80	12.02	1.84	3.37
Nov	12.50	12.86	2.84	8.07	Nov	13.70	13.36	-2.49	6.22
Dec	6.50	6.60	1.60	2.55	Dec	7.10	6.91	-2.71	7.33
$S_{2012}$	314.29				$S_{2013}$	221.24			
$S_{total} = 535.53$									

## □ Ultima zi de joi a fiecărei luni, ora 21

Tabelul 7.1.24. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

Anul / Luna	2006	2007	2008	2009	2010	2011	Anul / Luna	2006	2007	2008	2009	2010	2011
Ian	16.00	17.00	16.20	16.00	15.00	14.50	Iul	12.00	15.00	12.50	12.00	12.50	10.00
Feb	15.00	17.50	17.00	16.00	13.00	12.50	Aug	12.50	15.00	11.50	13.00	10.50	9.50
Mar	12.00	18.00	16.00	15.00	11.00	15.00	Sep	16.00	14.00	12.50	10.50	12.00	10.00
Apr	11.00	15.50	11.00	10.50	10.00	6.50	Oct	17.00	15.00	15.00	14.00	12.00	12.50
Mai	9.00	12.50	13.50	10.50	14.50	13.00	Nov	21.00	17.00	16.00	14.50	12.00	13.00
Iun	11.00	15.00	13.50	9.50	10.00	13.50	Dec	15.00	13.50	10.50	9.00	8.50	10.00

Tabelul 7.1.25. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Anul / Luna	2012	2013	Anul / Luna	2012	2013	Anul / Luna	2012	2013
Ian	12.60	11.50	Mai	13.20	13.60	Sep	12.00	12.20
Feb	12.40	12.10	Iun	12.80	13.10	Oct	14.00	14.40
Mar	14.00	16.00	Iul	11.00	11.80	Nov	12.50	13.10
Apr	8.50	9.00	Aug	9.00	9.70	Dec	9.00	9.70

Tabelul 7.1.26. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	12.60	12.22	-3.09	9.54	Ian	11.50	11.89	3.37	11.34
Feb	12.40	13.46	8.19	67.02	Feb	12.10	13.17	8.48	71.92
Mar	14.00	12.73	-9.52	90.65	Mar	16.00	12.50	-24.57	603.7
Apr	8.50	7.83	-8.23	67.71	Apr	9.00	7.66	-16.10	259.1
Mai	13.20	14.53	9.63	92.65	Mai	13.60	14.24	4.58	20.93
Iun	12.80	11.88	-7.45	55.50	Iun	13.10	11.67	-11.58	134.1
Iul	11.00	11.94	8.20	67.26	Iul	11.80	11.60	-1.75	3.06
Aug	9.00	10.03	10.79	116.5	Aug	9.70	9.81	1.10	1.21
Sep	12.00	11.01	-8.58	73.56	Sep	12.20	10.83	-11.90	141.6
Oct	14.00	14.29	2.02	4.07	Oct	14.40	13.78	-4.38	19.22
Nov	12.50	11.77	-6.01	36.15	Nov	13.10	11.36	-14.25	203.0
Dec	9.00	8.00	-11.82	139.7	Dec	9.70	7.75	-22.41	502.1
$S_{2012}$	820.31				$S_{2013}$	1971.28			
$S_{total} = 2791.59$									

Tabelul 7.1.27. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	12.60	12.39	-1.71	2.93	Ian	11.50	11.95	3.82	14.56
Feb	12.40	12.37	-0.26	0.07	Feb	12.10	12.14	0.31	0.10
Mar	14.00	14.82	5.68	32.27	Mar	16.00	15.49	-3.23	10.44
Apr	8.50	8.44	-0.70	0.50	Apr	9.00	8.92	-0.84	0.71
Mai	13.20	13.21	0.06	0.00	Mai	13.60	13.50	-0.73	0.54
Iun	12.80	12.80	-0.02	0.00	Iun	13.10	13.05	-0.37	0.14
Iul	11.00	11.14	1.31	1.71	Iul	11.80	11.59	-1.76	3.09
Aug	9.00	9.02	0.21	0.04	Aug	9.70	9.54	-1.65	2.74
Sep	12.00	12.03	0.22	0.05	Sep	12.20	12.21	0.11	0.01
Oct	14.00	14.02	0.13	0.02	Oct	14.40	14.49	0.59	0.35
Nov	12.50	12.59	0.74	0.55	Nov	13.10	13.06	-0.30	0.09
Dec	9.00	9.20	2.23	4.96	Dec	9.70	9.62	-0.84	0.70
$S_{2012}$	43.10				$S_{2013}$	33.46			
$S_{total} = 76.56$									

## □ Prima zi de marți a fiecărei luni, ora 9

Tabelul 7.1.31. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

Anul / Luna	2006	2007	2008	2009	2010	2011	Anul / Luna	2006	2007	2008	2009	2010	2011
Ian	10.00	11.50	10.50	6.50	8.00	8.00	Iul	11.00	16.00	12.00	11.00	12.00	11.00
Feb	14.50	15.00	17.00	16.00	15.00	14.00	Aug	14.50	12.00	11.00	11.50	5.50	9.20
Mar	14.00	15.00	11.00	15.00	15.00	15.00	Sep	8.50	12.50	11.50	11.00	9.00	11.00
Apr	13.00	16.00	15.50	15.00	11.00	12.00	Oct	17.00	15.50	12.50	10.00	9.00	10.00
Mai	12.00	13.00	8.00	5.50	4.50	5.00	Nov	18.00	13.00	9.50	12.00	12.00	8.00
Iun	7.50	11.00	14.00	12.50	14.00	13.00	Dec	14.00	15.50	5.50	14.00	11.50	10.00

Tabelul 7.1.32. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Anul / Luna	2012	2013	Anul / Luna	2012	2013	Anul / Luna	2012	2013
Ian	6.50	6.00	Mai	4.00	5.90	Sep	10.00	10.50
Feb	12.00	10.00	Iun	12.00	12.50	Oct	13.00	12.00
Mar	14.80	15.00	Iul	5.50		Nov	11.50	11.00
Apr	11.50	12.00	Aug	9.50		Dec	8.50	9.00

Tabelul 7.1.33. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	6.50	6.01	-7.89	62.23	Ian	6.00	5.95	-0.88	0.78
Feb	12.00	11.78	-1.82	3.31	Feb	10.00	11.68	15.51	240.7
Mar	14.80	13.47	-9.41	88.59	Mar	15.00	13.39	-11.32	128.2
Apr	11.50	11.83	2.80	7.81	Apr	12.00	11.72	-2.32	5.39
Mai	4.00	5.95	39.18	1535	Mai	5.90	5.89	-0.24	0.06
Iun	12.00	11.95	-0.40	0.16	Iun	12.50	11.88	-5.12	26.20
Iul	5.50	8.32	40.85	1669	Iul	10.00	8.24	-19.25	370.6
Aug	9.50	10.15	6.62	43.87	Aug	10.00	10.08	0.76	0.58
Sep	10.00	10.25	2.48	6.14	Sep	10.50	10.18	-3.11	9.66
Oct	13.00	11.56	-11.73	137.6	Oct	12.00	11.47	-4.50	20.21
Nov	11.50	9.50	-19.06	363.2	Nov	11.00	9.42	-15.52	240.8
Dec	8.50	11.58	30.69	942.1	Dec	9.00	11.52	24.55	602.5
$S_{2012}$	4859.01				$S_{2013}$	1645.68			
$S_{total} = 6504.69$									

Tabelul 7.1.34. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	6.50	6.35	-2.36	5.56	Ian	6.00	6.13	2.20	4.84
Feb	12.00	11.50	-4.29	18.38	Feb	10.00	11.00	9.50	90.20
Mar	14.80	14.77	-0.17	0.03	Mar	15.00	15.06	0.38	0.14
Apr	11.50	11.57	0.61	0.37	Apr	12.00	11.90	-0.84	0.71
Mai	4.00	4.86	19.31	373.00	Mai	5.90	5.07	-15.04	226.3
Iun	12.00	12.08	0.70	0.49	Iun	12.50	12.44	-0.52	0.27
Iul	5.50	7.69	33.23	1104	Iul	10.00	8.10	-21.05	443.3
Aug	9.50	9.64	1.48	2.20	Aug	10.00	9.98	-0.25	0.06
Sep	10.00	10.18	1.82	3.31	Sep	10.50	10.47	-0.29	0.08
Oct	13.00	12.69	-2.41	5.79	Oct	12.00	12.26	2.10	4.42
Nov	11.50	11.46	-0.34	0.12	Nov	11.00	11.02	0.17	0.03
Dec	8.50	8.39	-1.35	1.83	Dec	9.00	8.92	-0.86	0.73
$S_{2012}$	1515.08				$S_{2013}$	771.08			
$S_{total} = 2286.16$									

## □ Prima zi de marți a fiecărei luni, ora 21

Tabelul 7.1.38. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

Anul / Luna	2006	2007	2008	2009	2010	2011	Anul / Luna	2006	2007	2008	2009	2010	2011
Ian	12.50	15.00	13.00	10.50	9.00	10.00	Iul	11.00	15.00	12.00	10.50	11.50	12.00
Feb	15.00	17.00	15.50	15.00	15.00	13.50	Aug	13.50	13.50	10.50	10.50	9.00	9.20
Mar	14.00	15.50	15.00	15.50	15.00	15.00	Sep	10.00	12.00	11.50	5.00	11.50	10.50
Apr	13.00	14.50	16.00	16.00	13.00	12.50	Oct	17.00	15.50	14.50	10.00	13.00	10.80
Mai	12.50	11.00	10.50	10.00	5.00	8.50	Nov	17.50	15.50	11.50	14.00	10.50	11.00
Iun	10.50	13.00	13.00	12.00	11.50	12.00	Dec	17.50	17.00	15.50	12.00	13.00	12.50

Tabelul 7.1.39. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Anul / Luna	2012	2013	Anul / Luna	2012	2013	Anul / Luna	2012	2013
Ian	11.00	10.00	Mai	9.00	9.80	Sep	10.50	10.00
Feb	12.00	10.00	Iun	11.00	12.00	Oct	13.00	11.50
Mar	15.00	15.50	Iul	9.50	12.00	Nov	12.50	12.00
Apr	12.00	11.50	Aug	10.00	10.20	Dec	11.50	12.00

Tabelul 7.1.40. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.00	10.01	-9.43	88.94	Ian	10.00	9.65	-3.61	13.03
Feb	12.00	10.34	-14.84	220.3	Feb	10.00	9.82	-1.86	3.46
Mar	15.00	11.57	-25.81	666.3	Mar	15.50	11.15	-32.63	1064
Apr	12.00	11.23	-6.59	43.40	Apr	11.50	10.81	-6.18	38.20
Mai	9.00	8.92	-0.92	0.85	Mai	9.80	8.59	-13.20	174.1
Iun	11.00	9.40	-15.67	245.7	Iun	12.00	8.87	-29.96	897.3
Iul	9.50	9.37	-1.43	2.05	Iul	12.00	8.86	-30.10	905.7
Aug	10.00	10.02	0.22	0.05	Aug	10.20	9.49	-7.20	51.90
Sep	10.50	10.56	0.58	0.33	Sep	10.00	10.09	0.86	0.73
Oct	13.00	10.01	-26.01	676.3	Oct	11.50	9.44	-19.70	388.0
Nov	12.50	11.23	-10.72	114.9	Nov	12.00	10.73	-11.14	124.2
Dec	11.50	12.29	6.63	43.97	Dec	12.00	11.79	-1.75	3.05
$S_{2012}$	2103.09				$S_{2013}$	3663.67			
$S_{total} = 5766.76$									

Tabelul 7.1.41. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.00	10.70	-2.76	7.63	Ian	10.00	10.19	1.85	3.42
Feb	12.00	11.24	-6.56	43.06	Feb	10.00	10.82	7.85	61.67
Mar	15.00	15.02	0.12	0.01	Mar	15.50	15.40	-0.66	0.44
Apr	12.00	12.03	0.23	0.05	Apr	11.50	11.56	0.53	0.28
Mai	9.00	9.28	3.01	9.08	Mai	9.80	9.56	-2.51	6.31
Iun	11.00	11.30	2.69	7.23	Iun	12.00	11.64	-3.08	9.50
Iul	9.50	10.57	10.68	114.0	Iul	12.00	10.96	-9.08	82.47
Aug	10.00	10.02	0.25	0.06	Aug	10.20	10.20	0.01	0.00
Sep	10.50	10.36	-1.33	1.78	Sep	10.00	10.18	1.80	3.24
Oct	13.00	12.44	-4.43	19.64	Oct	11.50	12.08	4.90	23.97
Nov	12.50	12.39	-0.91	0.83	Nov	12.00	11.99	-0.12	0.01
Dec	11.50	11.60	0.87	0.75	Dec	12.00	12.02	0.20	0.04
$S_{2012}$	204.12				$S_{2013}$	191.35			
$S_{total} = 395.47$									

## □ A doua zi de miercuri a fiecărei luni, ora 9

Tabelul 7.1.45. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

Anul / Luna	2006	2007	2008	2009	2010	2011	Anul / Luna	2006	2007	2008	2009	2010	2011
Ian	11.00	18.00	18.00	17.50	14.50	16.00	Iul	8.50	9.50	12.00	7.00	11.00	10.00
Feb	13.00	19.00	17.00	14.00	15.00	15.00	Aug	13.00	13.00	12.00	11.00	8.00	9.00
Mar	13.00	16.50	16.00	8.50	8.00	15.00	Sep	16.50	11.00	10.00	11.00	10.50	8.00
Apr	5.50	10.50	15.00	10.50	11.00	11.00	Oct	12.00	15.00	16.00	14.00	15.00	14.00
Mai	11.50	16.00	14.50	15.00	14.00	13.50	Nov	19.00	15.50	9.00	8.00	9.50	15.50
Iun	10.50	15.50	11.50	12.00	8.00	12.00	Dec	20.50	19.00	7.00	14.50	13.50	16.00

Tabelul 7.1.46. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Anul / Luna	2012	2013	Anul / Luna	2012	2013	Anul / Luna	2012	2013
Ian	11.00	10.50	Mai	13.00	14.50	Sep	13.00	12.50
Feb	14.00	15.00	Iun	9.00	10.40	Oct	11.50	13.00
Mar	10.70	12.80	Iul	10.00	10.70	Nov	13.00	14.00
Apr	10.80	11.50	Aug	10.00	11.20	Dec	12.50	13.90

Tabelul 7.1.47. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.00	12.93	16.14	260.6	Ian	10.50	12.83	20.00	399.9
Feb	14.00	12.90	-8.19	67.06	Feb	15.00	12.82	-15.69	246.1
Mar	10.70	11.94	10.97	120.3	Mar	12.80	11.89	-7.41	54.86
Apr	10.80	10.33	-4.45	19.81	Apr	11.50	10.28	-11.20	125.4
Mai	13.00	13.72	5.38	28.93	Mai	14.50	13.65	-6.03	36.42
Iun	9.00	10.84	18.57	344.8	Iun	10.40	10.78	3.57	12.74
Iul	10.00	9.58	-4.28	18.32	Iul	10.70	9.53	-11.61	134.9
Aug	10.00	11.61	14.87	221.2	Aug	11.20	11.53	2.90	8.43
Sep	13.00	10.95	-17.12	293.2	Sep	12.50	10.88	-13.86	192.2
Oct	11.50	13.88	18.76	352.1	Oct	13.00	13.81	6.05	36.58
Nov	13.00	13.64	4.77	22.76	Nov	14.00	13.54	-3.31	10.97
Dec	12.50	13.04	4.19	17.59	Dec	13.90	12.95	-7.11	50.62
$S_{2012}$	1766.67				$S_{2013}$	1309.12			
$S_{total} = 3075.79$									

Tabelul 7.1.48. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	11.00	10.98	-0.19	0.04	Ian	10.50	10.53	0.24	0.06
Feb	14.00	14.19	1.37	1.89	Feb	15.00	14.68	-2.19	4.78
Mar	10.70	11.64	8.41	70.66	Mar	12.80	12.06	-5.99	35.94
Apr	10.80	10.84	0.32	0.10	Apr	11.50	11.17	-2.94	8.65
Mai	13.00	13.69	5.18	26.86	Mai	14.50	14.28	-1.54	2.39
Iun	9.00	9.68	7.31	53.38	Iun	10.40	10.05	-3.46	11.96
Iul	10.00	10.11	1.14	1.29	Iul	10.70	10.66	-0.40	0.16
Aug	10.00	10.45	4.40	19.33	Aug	11.20	10.89	-2.79	7.76
Sep	13.00	12.96	-0.28	0.08	Sep	12.50	12.47	-0.24	0.06
Oct	11.50	12.04	4.60	21.13	Oct	13.00	12.65	-2.74	7.50
Nov	13.00	13.05	0.39	0.15	Nov	14.00	13.59	-3.00	8.99
Dec	12.50	13.02	4.10	16.83	Dec	13.90	13.51	-2.88	8.29
$S_{2012}$	211.74				$S_{2013}$	96.48			
$S_{total} = 308.22$									

## □ A doua zi de miercuri a fiecărei luni, ora 21

Tabelul 7.1.52. Curbele de sarcină pentru perioada 2006-2011 (puterile în MW)

Anul / Luna	2006	2007	2008	2009	2010	2011	Anul / Luna	2006	2007	2008	2009	2010	2011
Ian	14.50	20.00	19.00	18.50	14.00	16.00	Iul	9.50	11.00	9.00	11.00	10.00	10.00
Feb	14.00	18.50	18.50	15.00	15.00	14.00	Aug	13.50	12.00	11.00	9.50	6.50	8.50
Mar	14.00	17.00	16.50	12.00	12.00	14.00	Sep	14.00	11.00	11.00	13.50	12.00	10.50
Apr	7.00	15.00	14.50	11.50	11.00	13.50	Oct	14.50	16.00	16.00	13.00	12.50	13.00
Mai	10.50	14.50	14.50	12.50	12.00	13.00	Nov	18.00	16.50	14.50	11.50	13.00	16.00
Iun	12.00	14.50	12.00	11.00	10.50	11.50	Dec	16.00	14.00	12.50	15.00	13.00	16.50

Tabelul 7.1.53. Curbele de sarcină pentru perioada 2012-2013 (puterile în MW)

Anul / Luna	2012	2013	Anul / Luna	2012	2013	Anul / Luna	2012	2013
Ian	15.00	12.00	Mai	12.80	13.40	Sep	13.00	12.00
Feb	12.50	13.90	Iun	10.00	12.90	Oct	11.00	13.50
Mar	13.00	14.00	Iul	8.00	9.00	Nov	15.00	14.00
Apr	11.50	12.70	Aug	9.50	10.00	Dec	13.00	14.50

Tabelul 7.1.54. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	15.00	13.60	-9.80	95.99	Ian	12.00	13.51	11.87	140.78
Feb	12.50	11.90	-4.92	24.21	Feb	13.90	11.84	-16.04	257.38
Mar	13.00	13.40	3.06	9.37	Mar	14.00	13.33	-4.93	24.30
Apr	11.50	11.68	1.54	2.37	Apr	12.70	11.64	-8.74	76.46
Mai	12.80	12.63	-1.37	1.88	Mai	13.40	12.58	-6.27	39.36
Iun	10.00	11.35	12.63	159.5	Iun	12.90	11.31	-13.10	171.68
Iul	8.00	9.39	15.97	255.1	Iul	9.00	9.35	3.78	14.25
Aug	9.50	9.40	-1.06	1.13	Aug	10.00	9.35	-6.72	45.09
Sep	13.00	11.50	-12.27	150.5	Sep	12.00	11.42	-4.95	24.48
Oct	11.00	13.62	21.26	452.1	Oct	13.50	13.56	0.43	0.19
Nov	15.00	14.31	-4.74	22.45	Nov	14.00	14.25	1.78	3.18
Dec	13.00	13.89	6.64	44.11	Dec	14.50	13.84	-4.69	21.98
$S_{2012}$	1218.71				$S_{2013}$	819.13			
$S_{total} = 2037.84$									

Tabelul 7.1.55. Curbele de sarcină prognozate pentru perioada 2012-2013 (puterile în MW)

2012					2013				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ian	15.00	13.83	-8.11	65.81	Ian	12.00	13.14	9.04	81.77
Feb	12.50	13.06	4.42	19.52	Feb	13.90	13.70	-1.46	2.15
Mar	13.00	13.33	2.50	6.26	Mar	14.00	13.94	-0.47	0.22
Apr	11.50	11.80	2.56	6.54	Apr	12.70	12.24	-3.68	13.54
Mai	12.80	12.86	0.44	0.19	Mai	13.40	13.27	-1.00	1.01
Iun	10.00	11.33	12.47	155.4	Iun	12.90	11.87	-8.29	68.70
Iul	8.00	8.20	2.45	6.01	Iul	9.00	8.60	-4.49	20.17
Aug	9.50	9.55	0.53	0.28	Aug	10.00	9.96	-0.37	0.14
Sep	13.00	12.66	-2.69	7.23	Sep	12.00	12.33	2.70	7.27
Oct	11.00	12.24	10.63	113.1	Oct	13.50	12.82	-5.16	26.64
Nov	15.00	14.88	-0.80	0.65	Nov	14.00	14.27	1.94	3.75
Dec	13.00	13.33	2.49	6.22	Dec	14.50	13.88	-4.34	18.82
$S_{2012}$	387.21				$S_{2013}$	244.18			
$S_{total} = 631.39$									

## ANEXA 7.2. PROGNOZE UNITĂȚI TERITORIALE REȚEA (UTR)

### A7.2.2. UTR Arad

*Tabelul 7.2.1. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)*

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
1	69.9	65.0	55.3	61.2	63.3	64.8	61.3	62.6	65.0	71.0
2	67.4	61.2	52.3	58.0	59.3	59.9	56.4	57.6	59.9	65.2
3	66.2	58.0	50.1	55.8	56.9	57.6	54.1	56.3	58.5	63.0
4	65.1	57.3	49.0	54.1	55.7	55.8	54.3	55.4	57.4	61.2
5	66.3	59.0	50.9	56.0	58.0	58.1	58.5	55.2	58.4	62.2
6	69.3	63.6	54.6	59.8	61.7	60.3	58.6	58.3	58.2	64.1
7	72.3	65.8	56.4	64.2	63.4	63.6	61.8	60.6	60.7	67.5
8	84.9	80.7	70.6	82.9	79.9	81.3	78.3	78.8	78.7	82.2
9	89.9	86.0	77.6	86.5	85.0	84.8	83.0	84.6	83.0	87.6
10	88.1	88.1	78.6	84.5	85.0	85.4	81.6	85.5	84.3	87.5
11	84.1	84.0	75.3	81.3	80.8	81.1	78.5	81.9	80.8	85.0
12	83.6	85.0	75.9	80.5	80.6	82.3	80.3	83.7	80.9	86.3
13	84.6	84.6	77.8	81.6	83.2	84.9	81.5	84.5	82.3	87.2
14	84.4	84.6	78.2	81.9	84.8	88.0	81.7	86.8	83.8	87.0
15	83.1	79.7	77.2	82.2	82.2	87.3	80.0	84.0	84.1	86.6
16	78.2	73.8	70.8	76.0	77.6	81.9	74.5	78.6	79.9	80.0
17	75.3	72.0	68.6	73.4	74.2	78.1	71.5	75.9	79.0	79.0
18	73.9	70.5	66.5	71.5	70.6	76.6	69.7	75.0	74.5	77.4
19	72.3	67.8	64.8	69.6	69.5	72.1	66.8	71.8	71.7	76.3
20	71.6	67.2	65.0	67.7	68.3	68.5	66.0	71.4	71.2	74.3
21	80.2	73.6	69.1	70.0	69.8	72.8	68.1	74.0	72.4	74.4
22	90.5	89.0	83.6	80.1	79.5	74.6	76.4	87.0	88.1	89.3
23	81.5	84.8	81.4	81.1	81.3	75.4	82.4	81.0	83.3	84.2
24	71.7	73.6	69.5	70.8	70.8	69.0	72.3	69.5	75.4	76.1

*Tabelul 7.2.2. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)*

Anul / Ora	2016	2017	2018	Anul / Ora	2016	2017	2018
1	69.3	72.1	76.5	13	91.6	89.9	94.2
2	64.4	65.7	69.9	14	93.8	91.5	94.1
3	63.5	66.2	71.3	15	90.9	91.0	93.4
4	62.3	64.8	69.1	16	85.6	86.9	87.0
5	62.2	65.3	69.6	17	82.7	85.9	85.9
6	65.0	66.1	71.0	18	81.9	81.5	84.5
7	67.7	68.9	73.0	19	78.6	78.7	83.4
8	85.7	85.7	89.3	20	78.2	78.0	81.2
9	91.6	90.8	94.5	21	81.0	79.3	81.3
10	92.6	91.3	94.4	22	93.9	95.1	96.5
11	89.1	87.8	91.8	23	88.4	90.6	91.4
12	90.8	88.8	93.3	24	76.6	82.5	83.0

RNA bayesiană, curba de sarcină

Tabelul 7.2.3. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	69.3	71.1	2.61	6.83	1	72.1	72.3	0.24	0.06	1	76.5	73.4	-3.99	15.91
2	64.4	64.0	-0.68	0.46	2	65.7	65.5	-0.25	0.06	2	69.9	67.1	-3.94	15.56
3	63.5	63.7	0.34	0.11	3	66.2	64.6	-2.41	5.82	3	71.3	67.9	-4.77	22.74
4	62.3	61.6	-1.18	1.40	4	64.8	62.9	-2.96	8.77	4	69.1	65.6	-5.07	25.66
5	62.2	61.0	-1.99	3.94	5	65.3	62.5	-4.26	18.15	5	69.6	65.3	-6.18	38.17
6	65.0	63.6	-2.11	4.45	6	66.1	65.1	-1.49	2.23	6	71.0	66.6	-6.17	38.02
7	67.7	71.2	5.18	26.83	7	68.9	72.1	4.60	21.19	7	73.0	72.7	-0.41	0.17
8	85.7	87.5	2.05	4.22	8	85.7	88.7	3.51	12.32	8	89.3	90.0	0.74	0.55
9	91.6	93.6	2.21	4.89	9	90.8	94.4	4.01	16.11	9	94.5	95.3	0.81	0.66
10	92.6	92.6	0.00	0.00	10	91.3	93.8	2.71	7.35	10	94.4	95.0	0.59	0.35
11	89.1	90.1	1.12	1.26	11	87.8	89.8	2.28	5.19	11	91.8	94.1	2.51	6.28
12	90.8	93.3	2.75	7.58	12	88.8	92.5	4.17	17.36	12	93.3	96.9	3.86	14.89
13	91.6	93.6	2.20	4.86	13	89.9	94.1	4.67	21.83	13	94.2	96.7	2.63	6.91
14	93.8	91.2	-2.75	7.59	14	91.5	92.4	0.95	0.90	14	94.1	93.5	-0.61	0.37
15	90.9	93.0	2.26	5.09	15	91.0	94.4	3.74	13.97	15	93.4	95.9	2.64	6.96
16	85.6	87.4	2.10	4.42	16	86.9	90.3	3.91	15.31	16	87.0	92.4	6.21	38.53
17	82.7	82.5	-0.23	0.05	17	85.9	83.6	-2.71	7.33	17	85.9	84.6	-1.46	2.13
18	81.9	83.7	2.21	4.89	18	81.5	84.7	3.93	15.43	18	84.5	85.7	1.41	2.00
19	78.6	75.7	-3.69	13.64	19	78.7	77.5	-1.50	2.26	19	83.4	79.4	-4.83	23.36
20	78.2	79.7	1.92	3.68	20	78.0	80.8	3.59	12.89	20	81.2	82.9	2.09	4.38
21	81.0	78.6	-2.98	8.88	21	79.3	79.8	0.66	0.44	21	81.3	81.1	-0.28	0.08
22	93.9	93.1	-0.83	0.69	22	95.1	94.2	-0.95	0.91	22	96.5	95.3	-1.28	1.64
23	88.4	90.7	2.60	6.77	23	90.6	92.6	2.21	4.87	23	91.4	93.9	2.74	7.48
24	76.6	79.0	3.11	9.65	24	82.5	80.8	-2.11	4.47	24	83.0	82.6	-0.53	0.28
$S_{2016}$	132.19				$S_{2017}$	215.21				$S_{2018}$	273.05			
$S_{total} = 620.45$														

RNA bayesiană, orar

Tabelul 7.2.4. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	69.3	71.1	2.54	6.44	1	72.1	73.1	1.45	2.09	1	76.5	75.3	-1.60	2.55
2	64.4	65.9	2.33	5.45	2	65.7	66.8	1.61	2.60	2	69.9	67.6	-3.26	10.63
3	63.5	64.3	1.30	1.68	3	66.2	66.7	0.70	0.49	3	71.3	69.1	-3.12	9.74
4	62.3	63.3	1.55	2.41	4	64.8	65.6	1.22	1.50	4	69.1	68.0	-1.60	2.57
5	62.2	63.7	2.40	5.78	5	65.3	65.7	0.64	0.42	5	69.6	67.8	-2.58	6.66
6	65.0	65.4	0.67	0.45	6	66.1	67.3	1.87	3.48	6	71.0	69.3	-2.43	5.89
7	67.7	68.2	0.71	0.51	7	68.9	70.1	1.71	2.94	7	73.0	72.0	-1.34	1.78
8	85.7	85.2	-0.64	0.41	8	85.7	86.9	1.35	1.81	8	89.3	88.6	-0.81	0.66



2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
9	91.6	90.6	-1.10	1.22	9	90.8	92.1	1.45	2.10	9	94.5	93.7	-0.89	0.79
10	92.6	91.7	-0.98	0.96	10	91.3	92.7	1.55	2.40	10	94.4	93.7	-0.69	0.48
11	89.1	88.3	-0.88	0.77	11	87.8	89.7	2.16	4.64	11	91.8	91.1	-0.78	0.60
12	90.8	89.4	-1.56	2.44	12	88.8	90.7	2.15	4.63	12	93.3	92.1	-1.33	1.77
13	91.6	90.3	-1.43	2.06	13	89.9	91.7	1.98	3.92	13	94.2	93.1	-1.18	1.39
14	93.8	92.8	-1.09	1.18	14	91.5	92.9	1.53	2.33	14	94.1	93.0	-1.16	1.34
15	90.9	90.6	-0.35	0.12	15	91.0	91.8	0.90	0.81	15	93.4	93.1	-0.36	0.13
16	85.6	85.7	0.16	0.03	16	86.9	86.5	-0.48	0.23	16	87.0	87.2	0.27	0.07
17	82.7	83.4	0.88	0.77	17	85.9	84.9	-1.22	1.48	17	85.9	86.3	0.47	0.22
18	81.9	81.4	-0.64	0.41	18	81.5	82.6	1.38	1.91	18	84.5	83.9	-0.72	0.52
19	78.6	78.0	-0.76	0.57	19	78.7	80.4	2.10	4.42	19	83.4	82.8	-0.77	0.59
20	78.2	77.8	-0.45	0.20	20	78.0	79.3	1.61	2.59	20	81.2	80.7	-0.64	0.41
21	81.0	80.4	-0.71	0.51	21	79.3	80.6	1.66	2.74	21	81.3	80.8	-0.61	0.37
22	93.9	94.2	0.32	0.10	22	95.1	95.3	0.21	0.04	22	96.5	96.3	-0.17	0.03
23	88.4	88.2	-0.23	0.05	23	90.6	89.9	-0.78	0.60	23	91.4	91.6	0.22	0.05
24	76.6	78.3	2.28	5.19	24	82.5	80.9	-1.97	3.88	24	83.0	83.5	0.57	0.32
S <sub>2016</sub>	39.72				S <sub>2017</sub>	54.04				S <sub>2018</sub>	49.57			
S <sub>total</sub> = 143.33														

### A7.2.3. UTR Deva

Tabelul 7.2.6. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
1	174.2	168.8	167.3	165.7	160.4	159.5	158.6	152.0	144.5	142.8
2	172.7	167.1	168.7	170.3	151.1	153.9	156.8	150.5	145.6	136.4
3	172.4	165.9	171.0	176.1	163.5	171.3	179.0	160.4	161.7	150.0
4	168.6	158.7	160.5	162.4	167.1	170.1	173.2	154.1	149.0	143.9
5	171.8	163.5	171.4	179.3	174.2	168.5	162.7	154.1	146.1	148.3
6	176.3	166.6	171.0	175.5	170.5	157.8	145.1	148.5	142.9	140.2
7	175.8	167.9	166.6	165.2	163.9	156.1	148.3	147.2	148.6	136.7
8	196.3	184.2	179.7	175.3	169.1	162.2	155.3	154.1	145.0	140.2
9	222.2	200.0	188.7	177.3	200.9	195.5	190.1	174.7	168.9	163.0
10	223.2	203.7	197.8	191.8	221.7	203.9	186.1	183.7	179.5	175.2
11	218.3	204.1	194.2	184.3	211.7	207.4	203.0	194.7	196.3	184.3
12	201.3	197.9	183.1	168.2	186.1	185.5	184.9	168.7	167.1	160.6
13	199.1	189.4	176.0	162.6	180.2	175.2	170.1	162.0	155.7	158.8
14	202.7	187.8	182.6	177.4	198.5	180.8	163.1	166.3	158.4	158.5
15	198.8	188.1	175.9	163.6	182.0	178.0	174.0	164.3	164.7	156.8
16	182.9	173.8	175.2	176.7	189.8	174.0	158.2	163.5	160.0	156.5
17	183.1	170.8	171.0	171.2	189.3	177.5	165.8	166.0	169.0	160.1
18	184.4	169.7	174.6	179.5	192.0	176.8	161.6	166.4	159.6	160.8
19	180.7	161.5	164.5	167.6	204.3	184.6	164.8	168.1	159.0	161.0
20	160.1	154.3	153.5	152.8	184.3	173.4	162.6	162.9	159.4	159.0
21	174.6	164.8	151.5	138.3	159.5	166.2	172.9	150.1	150.0	141.0
22	186.8	185.8	166.5	147.3	156.8	169.0	181.1	152.7	143.7	143.3
23	218.3	212.5	201.9	191.3	193.1	192.1	191.1	176.9	177.0	168.2
24	206.4	202.2	194.1	186.0	188.9	184.0	179.1	170.5	164.6	164.8

Tabelul 7.2.7. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Anul / Ora	2016	2017	2018	Anul / Ora	2016	2017	2018
1	142.5	135.1	133.4	13	149.9	145.4	150.4
2	137.0	133.6	125.8	14	156.5	149.1	149.9
3	149.0	150.4	139.0	15	152.1	153.3	146.2
4	143.6	139.0	134.3	16	153.3	150.3	147.3
5	143.5	135.6	137.8	17	155.3	158.5	149.7
6	137.8	133.9	132.8	18	156.7	149.9	151.0
7	134.2	137.8	128.1	19	157.2	148.8	151.3
8	156.2	151.5	151.1	20	152.9	149.2	148.7
9	164.3	159.2	154.3	21	138.0	139.9	130.0
10	170.6	167.3	164.0	22	141.6	133.3	133.5
11	183.6	186.1	175.0	23	165.5	167.8	161.1
12	158.4	157.8	152.2	24	158.6	154.3	156.1

□ RNA bayesiană, curba de sarcină

Tabelul 7.2.8. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	142.5	137.0	-3.89	15.12	1	135.1	134.6	-0.33	0.11	1	133.4	132.3	-0.83	0.68
2	137.0	135.9	-0.80	0.64	2	133.6	133.8	0.18	0.03	2	125.8	130.1	3.42	11.68
3	149.0	148.3	-0.45	0.21	3	150.4	146.6	-2.51	6.32	3	139.0	143.5	3.24	10.48
4	143.6	144.6	0.67	0.44	4	139.0	143.3	3.07	9.40	4	134.3	141.9	5.66	32.01
5	143.5	143.2	-0.24	0.06	5	135.6	140.1	3.32	11.01	5	137.8	139.2	1.01	1.02
6	137.8	137.4	-0.28	0.08	6	133.9	135.2	0.95	0.90	6	132.8	132.9	0.07	0.00
7	134.2	133.7	-0.38	0.15	7	137.8	133.0	-3.48	12.13	7	128.1	128.6	0.37	0.14
8	156.2	152.1	-2.62	6.89	8	151.5	147.8	-2.44	5.96	8	151.1	145.1	-3.97	15.77
9	164.3	160.0	-2.63	6.94	9	159.2	156.7	-1.57	2.47	9	154.3	153.4	-0.56	0.31
10	170.6	173.2	1.54	2.38	10	167.3	170.7	2.05	4.18	10	164.0	168.2	2.54	6.43
11	183.6	182.3	-0.73	0.53	11	186.1	180.6	-2.97	8.81	11	175.0	178.8	2.17	4.70
12	158.4	157.3	-0.70	0.49	12	157.8	154.8	-1.87	3.50	12	152.2	152.3	0.10	0.01
13	149.9	151.0	0.76	0.58	13	145.4	148.8	2.35	5.52	13	150.4	146.5	-2.56	6.56
14	156.5	153.9	-1.66	2.75	14	149.1	151.4	1.56	2.43	14	149.9	148.9	-0.66	0.44
15	152.1	151.9	-0.11	0.01	15	153.3	149.4	-2.53	6.40	15	146.2	146.8	0.44	0.19
16	153.3	152.3	-0.62	0.39	16	150.3	150.6	0.21	0.04	16	147.3	148.8	1.05	1.10
17	155.3	153.7	-1.06	1.11	17	158.5	153.9	-2.90	8.42	17	149.7	150.2	0.36	0.13
18	156.7	152.3	-2.81	7.89	18	149.9	150.3	0.27	0.07	18	151.0	148.2	-1.83	3.36
19	157.2	154.3	-1.82	3.30	19	148.8	152.9	2.75	7.58	19	151.3	151.6	0.20	0.04
20	152.9	148.2	-3.10	9.63	20	149.2	147.5	-1.17	1.36	20	148.7	146.6	-1.38	1.92
21	138.0	140.0	1.44	2.07	21	139.9	138.6	-0.92	0.85	21	130.0	135.1	3.92	15.39
22	141.6	140.4	-0.87	0.75	22	133.3	138.1	3.57	12.77	22	133.5	135.7	1.63	2.66
23	165.5	166.4	0.53	0.28	23	167.8	163.5	-2.56	6.55	23	161.1	160.6	-0.32	0.10
24	158.6	160.1	0.96	0.92	24	154.3	157.5	2.09	4.36	24	156.1	154.9	-0.77	0.59
S <sub>2016</sub>	63.63				S <sub>2017</sub>	121.20				S <sub>2018</sub>	115.72			
$S_{total} = 300.55$														

## □ RNA bayesiană, orar

Tabelul 7.2.9. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	142.5	138.1	-3.09	9.54	1	135.1	136.5	1.04	1.08	1	133.4	134.9	1.15	1.31
2	137.0	135.6	-1.03	1.07	2	133.6	133.4	-0.15	0.02	2	125.8	129.1	2.62	6.88
3	149.0	148.6	-0.30	0.09	3	150.4	146.8	-2.40	5.78	3	139.0	143.2	3.02	9.13
4	143.6	140.7	-2.00	3.99	4	139.0	138.9	-0.11	0.01	4	134.3	137.0	2.00	4.01
5	143.5	141.2	-1.59	2.52	5	135.6	138.4	2.06	4.26	5	137.8	138.1	0.22	0.05
6	137.8	136.1	-1.24	1.54	6	133.9	134.2	0.22	0.05	6	132.8	132.3	-0.36	0.13
7	134.2	135.3	0.79	0.63	7	137.8	134.4	-2.47	6.09	7	128.1	131.6	2.72	7.41
8	156.2	154.6	-1.00	1.00	8	151.5	153.4	1.29	1.66	8	151.1	152.3	0.79	0.63
9	164.3	164.1	-0.10	0.01	9	159.2	159.8	0.37	0.14	9	154.3	155.5	0.77	0.59
10	170.6	172.5	1.12	1.25	10	167.3	169.1	1.08	1.16	10	164.0	165.8	1.07	1.15
11	183.6	183.1	-0.27	0.07	11	186.1	181.8	-2.31	5.32	11	175.0	180.2	2.96	8.78
12	158.4	158.1	-0.20	0.04	12	157.8	155.8	-1.25	1.57	12	152.2	153.6	0.91	0.83
13	149.9	150.2	0.23	0.05	13	145.4	148.9	2.40	5.78	13	150.4	147.6	-1.89	3.56
14	156.5	155.3	-0.74	0.55	14	149.1	151.9	1.87	3.51	14	149.9	148.5	-0.93	0.86
15	152.1	154.3	1.44	2.07	15	153.3	151.9	-0.91	0.83	15	146.2	149.5	2.29	5.22
16	153.3	152.1	-0.81	0.66	16	150.3	150.5	0.12	0.01	16	147.3	148.9	1.09	1.19
17	155.3	156.4	0.69	0.48	17	158.5	154.7	-2.43	5.90	17	149.7	152.9	2.16	4.68
18	156.7	154.0	-1.70	2.89	18	149.9	152.5	1.71	2.94	18	151.0	150.7	-0.20	0.04
19	157.2	154.3	-1.86	3.45	19	148.8	152.8	2.70	7.29	19	151.3	151.7	0.26	0.07
20	152.9	151.9	-0.68	0.46	20	149.2	150.5	0.90	0.80	20	148.7	149.2	0.36	0.13
21	138.0	138.8	0.58	0.34	21	139.9	137.3	-1.88	3.53	21	130.0	134.2	3.23	10.44
22	141.6	140.0	-1.15	1.33	22	133.3	136.4	2.30	5.28	22	133.5	132.8	-0.51	0.26
23	165.5	166.4	0.54	0.29	23	167.8	164.6	-1.90	3.62	23	161.1	162.8	1.08	1.16
24	158.6	158.6	0.01	0.00	24	154.3	156.5	1.45	2.09	24	156.1	154.5	-1.05	1.11
$S_{2016}$	34.33				$S_{2017}$	68.72				$S_{2018}$	69.60			
$S_{total} = 172.65$														

## A7.2.4. UTR Reșița

Tabelul 7.2.11. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
1	77.4	68.9	62.7	73.8	69.1	60.4	56.1	59.4	56.8	54.2
2	79.6	78.0	55.4	59.9	70.5	59.2	54.2	57.7	55.6	54.9
3	77.7	81.5	54.7	61.9	66.9	57.7	54.1	57.9	56.8	56.1
4	80.4	74.5	55.2	68.2	52.3	59.7	54.0	57.6	55.3	56.1
5	79.9	76.8	56.3	69.1	60.2	61.7	53.1	60.4	58.6	57.8
6	82.6	71.9	56.5	64.3	69.0	59.5	52.3	53.6	52.0	53.2
7	80.3	68.4	55.8	50.8	62.6	58.9	51.6	53.3	49.9	53.2
8	101.1	72.1	63.1	71.9	62.1	58.9	63.1	60.1	55.1	53.4
9	111.7	92.4	67.2	73.0	60.0	59.1	68.4	59.2	57.9	56.2
10	104.7	90.4	68.5	67.7	57.2	59.9	66.4	62.5	60.7	57.2
11	103.5	94.0	69.8	63.3	58.4	58.4	62.9	62.5	61.1	61.8
12	100.7	83.9	72.6	71.9	59.0	58.6	63.2	62.2	60.9	61.8
13	98.0	81.4	70.6	57.1	61.3	58.7	63.9	59.5	60.1	58.1

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
14	87.5	79.5	69.6	50.0	62.4	58.1	65.0	58.6	62.4	57.8
15	95.5	81.5	69.1	50.5	58.5	58.2	61.3	60.5	58.3	55.2
16	95.5	74.5	72.4	59.0	49.6	58.7	60.8	53.8	54.7	57.3
17	94.4	72.8	76.3	64.1	58.4	55.6	59.7	59.4	60.6	62.6
18	94.6	62.0	77.3	66.6	57.2	58.2	57.0	59.8	58.4	57.6
19	89.1	55.8	80.7	56.9	58.1	60.1	57.2	55.3	54.4	51.9
20	85.1	52.3	79.3	48.5	45.6	60.2	57.9	49.3	48.3	47.1
21	83.9	56.8	71.7	50.0	50.4	59.9	56.3	50.2	51.4	54.1
22	90.9	67.0	78.8	57.2	52.0	59.8	56.1	58.1	56.9	53.6
23	90.5	79.7	87.9	78.7	57.3	56.3	57.6	64.6	65.8	66.1
24	89.0	81.7	88.1	56.3	57.8	58.4	56.3	64.1	62.8	60.4

Tabelul 7.2.12. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Anul / Ora	2016	2017	2018	Anul / Ora	2016	2017	2018
1	52.9	51.7	49.4	13	54.2	55.0	53.2
2	53.0	51.1	50.5	14	53.2	57.3	52.9
3	52.4	51.4	50.9	15	55.1	53.5	51.0
4	52.6	50.3	51.2	16	47.8	49.4	52.7
5	55.3	53.7	53.1	17	53.8	55.4	57.9
6	48.5	46.9	48.1	18	54.6	53.3	52.6
7	48.3	44.9	48.2	19	50.2	49.5	47.2
8	54.8	50.0	48.4	20	44.4	43.4	42.3
9	53.1	52.6	51.7	21	44.0	45.9	49.4
10	57.8	56.2	52.8	22	53.0	52.1	48.9
11	57.0	56.0	57.1	23	58.9	60.8	61.9
12	57.1	55.9	56.7	24	58.7	57.9	56.0

□ RNA bayesiană, curba de sarcină

Tabelul 7.2.13. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	52.9	53.5	1.21	1.46	1	51.7	52.8	2.17	4.71	1	49.4	52.1	5.44	29.61
2	53.0	52.1	-1.70	2.89	2	51.1	51.2	0.26	0.07	2	50.5	50.4	-0.28	0.08
3	52.4	50.7	-3.24	10.53	3	51.4	49.6	-3.50	12.26	3	50.9	48.9	-3.93	15.44
4	52.6	52.1	-1.03	1.07	4	50.3	51.7	2.84	8.05	4	51.2	51.4	0.36	0.13
5	55.3	55.3	-0.08	0.01	5	53.7	54.7	1.90	3.61	5	53.1	54.2	2.01	4.04
6	48.5	50.5	4.20	17.62	6	46.9	49.8	6.16	37.88	6	48.1	49.0	1.94	3.76
7	48.3	45.8	-5.18	26.79	7	44.9	42.7	-4.90	24.01	7	48.2	46.0	-4.56	20.83
8	54.8	50.3	-8.21	67.43	8	50.0	46.9	-6.29	39.60	8	48.4	46.1	-4.85	23.54
9	53.1	51.3	-3.34	11.18	9	52.6	51.0	-3.03	9.18	9	51.7	50.7	-2.01	4.05
10	57.8	60.1	3.98	15.83	10	56.2	58.7	4.45	19.79	10	52.8	55.6	5.30	28.12
11	57.0	59.8	4.91	24.13	11	56.0	59.1	5.54	30.64	11	57.1	59.9	4.90	24.05
12	57.1	58.8	2.98	8.86	12	55.9	58.6	4.83	23.33	12	56.7	58.6	3.35	11.23
13	54.2	56.4	4.07	16.57	13	55.0	55.7	1.31	1.73	13	53.2	55.0	3.44	11.83
14	53.2	51.4	-3.38	11.45	14	57.3	54.8	-4.36	19.04	14	52.9	50.4	-4.73	22.33
15	55.1	51.9	-5.81	33.73	15	53.5	50.6	-5.49	30.11	15	51.0	50.2	-1.59	2.53
16	47.8	50.2	5.02	25.21	16	49.4	51.3	3.85	14.79	16	52.7	52.1	-1.14	1.30

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
17	53.8	56.0	4.09	16.72	17	55.4	57.1	3.03	9.19	17	57.9	56.8	-1.96	3.83
18	54.6	55.3	1.28	1.64	18	53.3	55.1	3.38	11.40	18	52.6	54.9	4.37	19.12
19	50.2	50.2	-0.04	0.00	19	49.5	49.6	0.27	0.07	19	47.2	49.1	3.98	15.85
20	44.4	42.4	-4.50	20.29	20	43.4	41.5	-4.38	19.17	20	42.3	40.8	-3.57	12.74
21	44.0	44.4	0.82	0.67	21	45.9	44.0	-4.24	18.01	21	49.4	46.1	-6.68	44.62
22	53.0	50.4	-4.91	24.07	22	52.1	49.9	-4.22	17.83	22	48.9	48.0	-1.84	3.39
23	58.9	60.3	2.31	5.35	23	60.8	59.4	-2.38	5.69	23	61.9	58.4	-5.60	31.39
24	58.7	61.0	3.93	15.44	24	57.9	60.6	4.67	21.83	24	56.0	59.0	5.36	28.70
$S_{2016}$	358.93				$S_{2017}$	381.99				$S_{2018}$	362.50			
$S_{total} = 1103.42$														

RNA bayesiană, orar

Tabelul 7.2.14. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	52.9	52.0	-1.75	3.05	1	51.7	51.3	-0.75	0.56	1	49.4	50.7	2.54	6.46
2	53.0	52.3	-1.32	1.74	2	51.1	51.2	0.13	0.02	2	50.5	50.2	-0.59	0.35
3	52.4	52.3	-0.28	0.08	3	51.4	51.8	0.71	0.51	3	50.9	51.3	0.76	0.58
4	52.6	52.1	-0.99	0.97	4	50.3	51.5	2.35	5.51	4	51.2	50.9	-0.61	0.38
5	55.3	54.4	-1.55	2.41	5	53.7	53.9	0.36	0.13	5	53.1	53.4	0.48	0.23
6	48.5	48.1	-0.86	0.74	6	46.9	47.9	2.09	4.36	6	48.1	47.7	-0.89	0.79
7	48.3	47.2	-2.29	5.26	7	44.9	46.7	4.01	16.07	7	48.2	47.1	-2.38	5.65
8	54.8	53.7	-2.01	4.03	8	50.0	51.1	2.23	4.97	8	48.4	49.2	1.65	2.73
9	53.1	53.5	0.71	0.50	9	52.6	52.5	-0.16	0.03	9	51.7	51.6	-0.25	0.06
10	57.8	56.1	-2.89	8.35	10	56.2	55.2	-1.78	3.16	10	52.8	54.3	2.81	7.91
11	57.0	57.2	0.28	0.08	11	56.0	56.8	1.43	2.04	11	57.1	56.4	-1.16	1.35
12	57.1	56.8	-0.49	0.24	12	55.9	56.6	1.32	1.74	12	56.7	56.5	-0.44	0.19
13	54.2	54.8	1.20	1.43	13	55.0	54.3	-1.30	1.69	13	53.2	53.7	0.99	0.98
14	53.2	54.3	2.07	4.28	14	57.3	55.6	-2.97	8.80	14	52.9	54.3	2.56	6.56
15	55.1	53.9	-2.19	4.82	15	53.5	53.2	-0.61	0.38	15	51.0	52.5	2.87	8.24
16	47.8	48.7	1.88	3.55	16	49.4	50.1	1.46	2.14	16	52.7	51.1	-3.11	9.66
17	53.8	54.5	1.30	1.69	17	55.4	55.7	0.48	0.23	17	57.9	56.9	-1.81	3.26
18	54.6	54.3	-0.49	0.24	18	53.3	53.6	0.57	0.33	18	52.6	52.9	0.54	0.30
19	50.2	50.0	-0.42	0.18	19	49.5	49.1	-0.83	0.70	19	47.2	48.2	2.11	4.45
20	44.4	43.9	-1.02	1.05	20	43.4	43.3	-0.22	0.05	20	42.3	42.7	0.88	0.77
21	44.0	45.0	2.27	5.17	21	45.9	46.8	1.96	3.84	21	49.4	48.2	-2.41	5.81
22	53.0	52.0	-1.85	3.43	22	52.1	51.3	-1.62	2.62	22	48.9	49.7	1.64	2.68
23	58.9	59.9	1.76	3.09	23	60.8	60.7	-0.23	0.06	23	61.9	61.4	-0.83	0.69
24	58.7	58.1	-1.08	1.17	24	57.9	57.4	-0.82	0.67	24	56.0	56.8	1.41	1.99
$S_{2016}$	57.54				$S_{2017}$	60.61				$S_{2018}$	72.06			
$S_{total} = 190.21$														

**A7.2.5. UTR Timișoara**

Tabelul 7.2.16. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
1	114.9	116.0	113.1	110.9	108.9	117.0	112.6	115.4	118.5	116.2
2	107.7	108.7	106.2	102.6	100.6	107.5	104.8	108.9	109.2	108.1
3	104.8	105.2	102.7	100.9	99.2	102.4	100.6	102.8	103.9	104.8
4	104.3	103.3	101.0	98.0	99.7	100.2	102.6	103.7	103.2	102.1
5	106.5	104.8	102.1	99.4	99.0	101.5	102.2	100.9	104.3	104.2
6	113.5	109.5	106.0	103.9	103.6	104.6	102.6	107.8	105.0	106.8
7	127.2	119.9	117.4	115.3	114.6	115.0	116.0	120.9	122.1	122.7
8	143.3	137.0	135.8	134.4	135.2	134.7	135.7	137.4	142.6	146.9
9	150.1	147.0	146.0	144.9	143.1	144.0	144.5	145.6	141.2	143.1
10	148.5	148.6	147.5	146.5	142.6	145.1	145.3	151.1	148.4	151.3
11	143.4	147.5	144.2	143.9	141.1	143.7	143.3	151.2	148.0	150.8
12	145.9	147.3	146.0	145.1	143.5	146.2	146.4	146.0	145.0	144.0
13	143.5	145.1	144.2	143.8	142.6	146.2	145.4	143.0	144.2	146.6
14	144.3	143.4	143.0	143.0	143.6	145.1	146.9	148.1	150.3	147.2
15	141.1	138.9	140.0	141.9	141.3	144.1	143.1	144.2	143.5	142.8
16	131.1	129.2	132.2	135.3	134.2	137.0	135.4	137.4	136.5	136.2
17	126.5	123.5	126.9	131.3	127.4	132.3	129.7	136.2	131.6	132.1
18	123.6	122.4	124.6	127.8	125.7	129.3	126.7	126.0	125.5	127.2
19	122.3	120.1	122.4	125.3	121.4	126.7	124.7	124.7	124.5	126.7
20	125.4	119.8	121.1	123.3	120.6	125.0	122.7	124.7	123.3	125.2
21	140.8	131.0	129.2	128.3	125.5	133.0	127.3	136.6	137.8	136.5
22	160.2	152.8	150.0	148.2	141.0	142.3	139.7	152.2	151.1	150.2
23	150.0	147.9	147.7	147.8	143.6	139.9	149.3	150.1	148.5	149.0
24	134.8	130.6	130.4	130.2	127.2	126.0	131.0	134.5	133.6	133.3

Tabelul 7.2.17. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Anul / Ora	2016	2017	2018	Anul / Ora	2016	2017	2018
1	118.2	121.4	119.2	13	144.9	146.8	149.9
2	111.9	112.2	111.2	14	151.0	153.2	150.1
3	105.3	106.8	108.1	15	147.1	146.4	145.8
4	106.7	106.3	105.3	16	140.3	139.4	139.1
5	103.1	107.4	108.2	17	139.3	134.8	135.4
6	110.7	108.0	109.9	18	128.9	128.4	130.1
7	123.2	125.0	126.3	19	127.3	127.4	129.9
8	139.1	144.5	149.0	20	127.4	126.3	128.4
9	149.8	145.0	146.6	21	139.6	140.7	139.3
10	154.1	151.4	154.3	22	155.1	154.1	153.3
11	154.1	150.9	153.8	23	153.0	151.4	151.8
12	149.0	147.9	146.8	24	141.4	143.0	145.2

**□ RNA bayesiană, curba de sarcină**

Tabelul 7.2.18. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

Ora	2016				2017				2018			
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	118.2	119.6	1.19	1.41	121.4	120.4	-0.79	0.62	119.2	121.3	1.74	3.03
2	111.9	109.5	-2.13	4.54	112.2	110.3	-1.68	2.83	111.2	110.9	-0.27	0.07
3	105.3	104.9	-0.39	0.16	106.8	105.5	-1.24	1.55	108.1	106.1	-1.89	3.59

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
4	106.7	108.9	2.06	4.25	4	106.3	108.5	2.07	4.28	4	105.3	108.1	2.66	7.07
5	103.1	105.9	2.72	7.38	5	107.4	108.4	0.93	0.87	5	108.2	109.7	1.39	1.92
6	110.7	107.2	-3.13	9.79	6	108.0	108.3	0.28	0.08	6	109.9	108.7	-1.12	1.25
7	123.2	125.8	2.11	4.45	7	125.0	127.4	1.92	3.69	7	126.3	128.6	1.82	3.32
8	139.1	141.9	2.01	4.05	8	144.5	144.2	-0.21	0.04	8	149.0	145.9	-2.08	4.33
9	149.8	148.0	-1.22	1.49	9	145.0	149.1	2.81	7.92	9	146.6	150.2	2.44	5.97
10	154.1	157.1	1.92	3.69	10	151.4	155.8	2.91	8.45	10	154.3	158.5	2.69	7.25
11	154.1	153.3	-0.50	0.25	11	150.9	154.0	2.03	4.12	11	153.8	154.6	0.51	0.26
12	149.0	151.2	1.48	2.18	12	147.9	150.1	1.49	2.21	12	146.8	149.3	1.70	2.90
13	144.9	147.6	1.85	3.43	13	146.8	148.5	1.13	1.28	13	149.9	149.3	-0.38	0.15
14	151.0	148.6	-1.62	2.63	14	153.2	149.0	-2.77	7.69	14	150.1	149.3	-0.50	0.25
15	147.1	144.3	-1.90	3.62	15	146.4	143.2	-2.22	4.92	15	145.8	142.9	-1.99	3.96
16	140.3	141.3	0.73	0.54	16	139.4	142.0	1.85	3.42	16	139.1	142.6	2.53	6.40
17	139.3	139.0	-0.22	0.05	17	134.8	137.7	2.15	4.63	17	135.4	138.1	1.99	3.98
18	128.9	131.5	2.02	4.07	18	128.4	132.3	3.04	9.23	18	130.1	133.9	2.92	8.53
19	127.3	129.7	1.90	3.62	19	127.4	130.5	2.40	5.74	19	129.9	131.2	0.99	0.97
20	127.4	128.1	0.56	0.31	20	126.3	128.9	2.07	4.27	20	128.4	129.7	1.01	1.02
21	139.6	141.6	1.43	2.06	21	140.7	142.4	1.18	1.40	21	139.3	143.1	2.74	7.49
22	155.1	151.1	-2.58	6.65	22	154.1	150.3	-2.44	5.96	22	153.3	149.6	-2.41	5.83
23	153.0	148.4	-3.01	9.04	23	151.4	148.5	-1.89	3.57	23	151.8	148.7	-2.06	4.25
24	141.4	138.1	-2.33	5.45	24	143.0	139.1	-2.73	7.44	24	145.2	140.9	-2.96	8.77
S <sub>2016</sub>	85.10				S <sub>2017</sub>	96.19				S <sub>2018</sub>	92.54			
S <sub>total</sub> = 273.83														

 RNA bayesiană, orar

Tabelul 7.2.19. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	118.2	119.2	0.87	0.75	1	121.4	119.7	-1.40	1.97	1	119.2	120.6	1.17	1.38
2	111.9	112.1	0.21	0.04	2	112.2	111.8	-0.35	0.13	2	111.2	111.7	0.45	0.20
3	105.3	105.8	0.51	0.26	3	106.8	107.1	0.28	0.08	3	108.1	108.6	0.46	0.21
4	106.7	106.9	0.19	0.04	4	106.3	106.1	-0.18	0.03	4	105.3	105.7	0.38	0.14
5	103.1	104.2	1.11	1.24	5	107.4	106.1	-1.17	1.37	5	108.2	109.7	1.39	1.92
6	110.7	110.0	-0.61	0.38	6	108.0	109.6	1.45	2.10	6	109.9	108.5	-1.27	1.62
7	123.2	124.0	0.66	0.44	7	125.0	124.6	-0.32	0.10	7	126.3	125.8	-0.42	0.17
8	139.1	142.6	2.50	6.23	8	144.5	145.1	0.42	0.17	8	149.0	146.3	-1.84	3.38
9	149.8	147.3	-1.68	2.82	9	145.0	146.3	0.91	0.82	9	146.6	145.4	-0.85	0.72
10	154.1	153.2	-0.59	0.35	10	151.4	153.3	1.24	1.54	10	154.3	153.1	-0.78	0.60
11	154.1	153.2	-0.61	0.37	11	150.9	153.0	1.38	1.91	11	153.8	152.8	-0.65	0.42

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
12	149.0	149.2	0.13	0.02	12	147.9	149.0	0.74	0.55	12	146.8	148.2	0.95	0.91
13	144.9	145.6	0.51	0.26	13	146.8	147.4	0.43	0.18	13	149.9	149.2	-0.44	0.20
14	151.0	152.0	0.65	0.42	14	153.2	151.5	-1.11	1.24	14	150.1	151.3	0.80	0.64
15	147.1	147.3	0.14	0.02	15	146.4	146.5	0.08	0.01	15	145.8	146.4	0.41	0.17
16	140.3	140.0	-0.21	0.05	16	139.4	139.8	0.29	0.08	16	139.1	139.6	0.36	0.13
17	139.3	137.1	-1.55	2.41	17	134.8	136.4	1.17	1.37	17	135.4	136.9	1.11	1.23
18	128.9	128.6	-0.25	0.06	18	128.4	129.2	0.64	0.41	18	130.1	130.8	0.54	0.29
19	127.3	127.2	-0.09	0.01	19	127.4	128.2	0.64	0.40	19	129.9	129.2	-0.51	0.26
20	127.4	127.2	-0.19	0.03	20	126.3	127.4	0.89	0.79	20	128.4	127.6	-0.62	0.39
21	139.6	140.0	0.29	0.08	21	140.7	139.9	-0.59	0.34	21	139.3	139.8	0.36	0.13
22	155.1	155.3	0.13	0.02	22	154.1	154.5	0.26	0.07	22	153.3	153.9	0.39	0.15
23	153.0	152.6	-0.23	0.05	23	151.4	152.2	0.53	0.28	23	151.8	151.0	-0.53	0.28
24	141.4	141.1	-0.21	0.05	24	143.0	143.3	0.20	0.04	24	145.2	145.8	0.41	0.17
S <sub>2016</sub>	16.39				S <sub>2017</sub>	15.99				S <sub>2018</sub>	15.73			
S <sub>total</sub> = 48.11														

### A7.2.6. Enel Banat

Tabelul 7.2.21. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)

Anul / ora	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
1	436.4	418.7	398.4	411.6	401.7	401.7	388.6	389.4	384.8	384.2
2	427.4	415.0	382.6	390.8	381.5	380.5	372.2	374.7	370.3	364.6
3	421.1	410.6	378.5	394.7	386.5	389.0	387.8	377.4	380.9	373.9
4	418.4	393.8	365.7	382.7	374.8	385.8	384.1	370.8	364.9	363.3
5	424.5	404.1	380.7	403.8	391.4	389.8	376.5	370.6	367.4	372.5
6	441.7	411.6	388.1	403.5	404.8	382.2	358.6	368.2	358.1	364.3
7	455.6	422.0	396.2	395.5	404.5	393.6	377.7	382.0	381.3	380.1
8	525.6	474.0	449.2	464.5	446.3	437.1	432.4	430.4	421.4	422.7
9	573.9	525.4	479.5	481.7	489.0	483.4	486.0	464.1	451.0	449.9
10	564.5	530.8	492.4	490.5	506.5	494.3	479.4	482.8	472.9	471.2
11	549.3	529.6	483.5	472.8	492.0	490.6	487.7	490.3	486.2	481.9
12	531.5	514.1	477.6	465.7	469.2	472.6	474.8	460.6	453.9	452.7
13	525.2	500.5	468.6	445.1	467.3	465.0	460.9	449.0	442.3	450.7
14	518.9	495.3	473.4	452.3	489.3	472.0	456.7	459.8	454.9	450.5
15	518.5	488.2	462.2	438.2	464.0	467.6	458.4	453.0	450.6	441.4
16	487.7	451.3	450.6	447.0	451.2	451.6	428.9	433.3	431.1	430.0
17	479.3	439.1	442.8	440.0	449.3	443.5	426.7	437.5	440.2	433.8
18	476.5	424.6	443.0	445.4	445.5	440.9	415.0	427.2	418.0	423.0
19	464.4	405.2	432.4	419.4	453.3	443.5	413.5	419.9	409.6	415.9
20	442.2	393.6	418.9	392.3	418.8	427.1	409.2	408.3	402.2	405.6
21	479.5	426.2	421.5	386.6	405.2	431.9	424.6	410.9	411.6	406.0
22	528.4	494.6	478.9	432.8	429.3	445.7	453.3	450.0	439.8	436.4
23	540.3	524.9	518.9	498.9	475.3	463.7	480.4	472.6	474.6	467.5
24	501.9	488.1	482.1	443.3	444.7	437.4	438.7	438.6	436.4	434.6



Tabelul 7.2.22. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Anul / Ora	2016	2017	2018	Anul / Ora	2016	2017	2018
1	382.9	380.3	378.5	13	440.6	437.1	447.7
2	366.3	362.6	357.4	14	454.5	451.1	447.0
3	370.2	374.8	369.3	15	445.2	444.2	436.4
4	365.2	360.4	359.9	16	427.0	426.0	426.1
5	364.1	362.0	368.7	17	431.1	434.6	428.9
6	362.0	354.9	361.8	18	422.1	413.1	418.2
7	373.4	376.6	375.6	19	413.3	404.4	411.8
8	435.8	431.7	437.8	20	402.9	396.9	400.6
9	458.8	447.6	447.1	21	402.6	405.8	400.0
10	475.1	466.2	465.5	22	443.6	434.6	432.2
11	483.8	480.8	477.7	23	465.8	470.6	466.2
12	455.3	450.4	449.0	24	435.3	437.7	440.3

□ RNA bayesiană, curba de sarcină

Tabelul 7.2.23. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	382.9	390.7	2.03	4.14	1	380.3	386.6	1.64	2.71	1	378.5	382.4	1.04	1.08
2	366.3	371.6	1.45	2.09	2	362.6	369.0	1.77	3.12	2	357.4	365.4	2.24	5.01
3	370.2	377.1	1.86	3.47	3	374.8	376.6	0.49	0.24	3	369.3	375.2	1.61	2.59
4	365.2	368.5	0.92	0.84	4	360.4	368.3	2.19	4.81	4	359.9	368.1	2.27	5.14
5	364.1	371.6	2.06	4.24	5	362.0	370.9	2.46	6.04	5	368.7	369.7	0.28	0.08
6	362.0	368.4	1.77	3.13	6	354.9	363.1	2.31	5.34	6	361.8	360.9	-0.25	0.06
7	373.4	380.3	1.84	3.40	7	376.6	378.0	0.37	0.14	7	375.6	376.1	0.13	0.02
8	435.8	427.7	-1.85	3.43	8	431.7	424.3	-1.70	2.91	8	437.8	424.4	-3.06	9.37
9	458.8	465.1	1.37	1.89	9	447.6	457.1	2.12	4.50	9	447.1	456.9	2.19	4.80
10	475.1	478.3	0.67	0.45	10	466.2	476.0	2.09	4.39	10	465.5	473.7	1.75	3.07
11	483.8	482.6	-0.25	0.06	11	480.8	481.5	0.15	0.02	11	477.7	479.9	0.45	0.20
12	455.3	458.4	0.68	0.46	12	450.4	456.1	1.27	1.61	12	449.0	453.8	1.08	1.16
13	440.6	446.8	1.41	1.98	13	437.1	444.2	1.62	2.64	13	447.7	442.9	-1.08	1.16
14	454.5	456.8	0.50	0.25	14	451.1	454.8	0.81	0.66	14	447.0	452.7	1.28	1.65
15	445.2	450.5	1.18	1.40	15	444.2	446.3	0.47	0.22	15	436.4	442.1	1.31	1.72
16	427.0	435.4	1.97	3.87	16	426.0	434.3	1.96	3.83	16	426.1	430.9	1.13	1.27
17	431.1	431.4	0.07	0.00	17	434.6	431.3	-0.76	0.57	17	428.9	431.2	0.54	0.29
18	422.1	427.7	1.33	1.77	18	413.1	422.8	2.35	5.51	18	418.2	421.8	0.86	0.75
19	413.3	420.6	1.77	3.12	19	404.4	413.8	2.32	5.40	19	411.8	414.5	0.65	0.43
20	402.9	407.9	1.24	1.54	20	396.9	405.3	2.12	4.48	20	400.6	406.2	1.41	1.99
21	402.6	410.4	1.95	3.79	21	405.8	408.4	0.63	0.40	21	400.0	406.3	1.58	2.49
22	443.6	441.7	-0.42	0.17	22	434.6	439.3	1.07	1.15	22	432.2	436.8	1.06	1.13
23	465.8	473.9	1.73	2.99	23	470.6	469.9	-0.15	0.02	23	466.2	465.4	-0.17	0.03
24	435.3	434.7	-0.14	0.02	24	437.7	432.7	-1.14	1.30	24	440.3	430.7	-2.17	4.72
S <sub>2016</sub>	48.51				S <sub>2017</sub>	62.01				S <sub>2018</sub>	50.22			
S <sub>total</sub> = 160.74														

## □ RNA bayesiană, orar

Tabelul 7.2.24. Curbele de sarcină prognozate pentru perioada 2016-2018 (puterile în MW)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	382.9	386.4	0.90	0.82	1	380.3	384.0	0.96	0.93	1	378.5	381.6	0.82	0.67
2	366.3	369.7	0.93	0.86	2	362.6	365.1	0.69	0.48	2	357.4	359.8	0.67	0.45
3	370.2	373.4	0.86	0.75	3	374.8	377.0	0.60	0.36	3	369.3	373.4	1.12	1.25
4	365.2	366.3	0.29	0.09	4	360.4	364.1	1.03	1.05	4	359.9	361.9	0.56	0.32
5	364.1	367.0	0.80	0.63	5	362.0	366.4	1.22	1.48	5	368.7	369.2	0.14	0.02
6	362.0	363.8	0.49	0.24	6	354.9	356.2	0.37	0.13	6	361.8	360.5	-0.35	0.12
7	373.4	376.1	0.72	0.52	7	376.6	379.2	0.68	0.46	7	375.6	378.2	0.70	0.49
8	435.8	433.6	-0.50	0.25	8	431.7	430.0	-0.39	0.16	8	437.8	433.9	-0.89	0.79
9	458.8	459.8	0.22	0.05	9	447.6	450.9	0.74	0.54	9	447.1	446.1	-0.23	0.05
10	475.1	478.9	0.80	0.64	10	466.2	471.5	1.14	1.29	10	465.5	470.0	0.96	0.93
11	483.8	486.2	0.50	0.25	11	480.8	484.1	0.69	0.48	11	477.7	482.1	0.91	0.83
12	455.3	456.4	0.24	0.06	12	450.4	454.3	0.86	0.73	12	449.0	452.1	0.69	0.48
13	440.6	444.3	0.84	0.71	13	437.1	442.3	1.19	1.42	13	447.7	444.2	-0.78	0.60
14	454.5	455.4	0.19	0.04	14	451.1	452.7	0.35	0.12	14	447.0	450.0	0.66	0.44
15	445.2	448.0	0.63	0.40	15	444.2	445.4	0.26	0.07	15	436.4	440.1	0.85	0.72
16	427.0	431.2	0.98	0.96	16	426.0	429.6	0.84	0.71	16	426.1	428.0	0.44	0.20
17	431.1	435.1	0.93	0.86	17	434.6	435.5	0.20	0.04	17	428.9	433.4	1.05	1.10
18	422.1	422.8	0.17	0.03	18	413.1	416.1	0.73	0.53	18	418.2	418.8	0.15	0.02
19	413.3	415.0	0.40	0.16	19	404.4	409.2	1.19	1.41	19	411.8	411.0	-0.18	0.03
20	402.9	404.8	0.46	0.22	20	396.9	400.6	0.93	0.87	20	400.6	402.1	0.38	0.15
21	402.6	405.8	0.79	0.63	21	405.8	407.1	0.31	0.10	21	400.0	404.6	1.16	1.34
22	443.6	445.0	0.31	0.10	22	434.6	436.7	0.48	0.23	22	432.2	435.8	0.84	0.70
23	465.8	469.1	0.71	0.50	23	470.6	469.8	-0.17	0.03	23	466.2	468.1	0.41	0.17
24	435.3	436.9	0.38	0.14	24	437.7	435.4	-0.52	0.27	24	440.3	433.9	-1.45	2.11
S <sub>2016</sub>	9.91				S <sub>2017</sub>	13.89				S <sub>2018</sub>	13.98			
S <sub>total</sub> = 37.76														

## ANEXA 7.3. PROGNOZE STAȚII

### A7.3.2. Stația Bucovina

#### A7.3.2.1. Prima zi de miercuri a fiecărei luni, ora 9

Tabelul 7.3.1. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.7	8.1	9.0	8.8	7.7	8.1	8.3	8.9
Februarie	6.2	8.3	9.0	8.2	9.4	9.8	9.4	9.6
Martie	8.0	8.4	7.8	8.8	8.6	9.0	8.8	9.1
Aprilie	8.0	8.3	7.0	8.1	7.8	8.8	8.4	8.9
Mai	7.1	7.8	7.0	8.0	7.2	8.0	8.2	8.1
Iunie	6.6	7.4	7.8	7.5	7.2	9.0	9.1	8.8
Iulie	6.5	8.6	6.6	8.0	7.4	9.0	8.7	8.8
August	8.2	8.3	7.3	7.3	8.0	9.8	9.9	9.7
Septembrie	8.1	7.5	7.0	8.3	8.0	8.5	9.6	9.5
Octombrie	8.6	8.4	7.8	8.0	8.1	9.5	9.7	9.4
Noiembrie	9.1	9.5	7.0	6.5	9.1	9.7	9.8	9.9
Decembrie	10.9	10.8	8.7	8.7	9.4	9.2	9.6	9.2

Tabelul 7.3.2. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	9.1	9.2	Mai	8.3	8.5	Septembrie	9.6	9.7
Februarie	9.5	9.6	Iunie	8.7	8.8	Octombrie	9.7	9.8
Martie	9.2	9.1	Iulie	8.9	9.1	Noiembrie	9.8	9.9
Aprilie	8.8	8.9	August	9.6	9.5	Decembrie	9.4	9.6

#### RNA bayesiană, curba de sarcină

Tabelul 7.3.3. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	9.10	8.76	-3.74	13.96	Ianuarie	9.20	8.91	-3.15	9.94
Februarie	9.50	9.58	0.84	0.71	Februarie	9.60	9.64	0.42	0.17
Martie	9.20	9.15	-0.54	0.30	Martie	9.10	9.27	1.87	3.49
Aprilie	8.80	8.77	-0.34	0.12	Aprilie	8.90	8.85	-0.56	0.32
Mai	8.30	8.08	-2.65	7.03	Mai	8.50	8.21	-3.41	11.64
Iunie	8.70	8.87	1.95	3.82	Iunie	8.80	8.97	1.93	3.73
Iulie	8.90	8.84	-0.67	0.45	Iulie	9.10	8.95	-1.65	2.72
August	9.60	9.74	1.46	2.13	August	9.50	9.71	2.21	4.89
Septembrie	9.60	9.49	-1.15	1.31	Septembrie	9.70	9.66	-0.41	0.17
Octombrie	9.70	9.52	-1.86	3.44	Octombrie	9.80	9.64	-1.63	2.67
Noiembrie	9.80	9.86	0.61	0.37	Noiembrie	9.90	10.03	1.31	1.72
Decembrie	9.40	9.46	0.64	0.41	Decembrie	9.60	9.46	-1.46	2.13
$S_{2017}$	34.04				$S_{2018}$	43.58			
$S_{total} = 77.62$									

□ RNA bayesiană, lunar

Tabelul 7.3.4. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	9.10	9.28	1.98	3.91	Ianuarie	9.20	9.39	2.07	4.27
Februarie	9.50	9.55	0.53	0.28	Februarie	9.60	9.61	0.10	0.01
Martie	9.20	9.25	0.54	0.30	Martie	9.10	9.28	1.98	3.91
Aprilie	8.80	8.77	-0.34	0.12	Aprilie	8.90	8.87	-0.34	0.11
Mai	8.30	8.22	-0.96	0.93	Mai	8.50	8.36	-1.65	2.71
Iunie	8.70	8.90	2.30	5.28	Iunie	8.80	9.00	2.27	5.17
Iulie	8.90	8.88	-0.22	0.05	Iulie	9.10	9.05	-0.55	0.30
August	9.60	9.64	0.42	0.17	August	9.50	9.43	-0.74	0.54
Septembrie	9.60	9.53	-0.73	0.53	Septembrie	9.70	9.77	0.72	0.52
Octombrie	9.70	9.73	0.31	0.10	Octombrie	9.80	9.75	-0.51	0.26
Noiembrie	9.80	9.87	0.71	0.51	Noiembrie	9.90	9.86	-0.40	0.16
Decembrie	9.40	9.47	0.74	0.55	Decembrie	9.60	9.56	-0.42	0.17
$S_{2017}$	12.73				$S_{2018}$	18.14			
$S_{total} = 30.87$									

A7.3.2.2. Prima zi de miercuri a fiecărei luni, ora 21

Tabelul 7.3.6. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	10.0	11.2	11.0	10.0	9.8	10.1	10.4	10.2
Februarie	9.8	10.9	11.1	10.2	11.0	10.4	10.8	10.7
Martie	10.2	10.6	10.0	10.1	10.2	9.3	9.7	9.8
Aprilie	9.5	10.2	8.8	9.5	10.0	10.5	10.4	10.3
Mai	8.0	8.7	8.1	9.5	8.2	8.5	8.8	9.1
Iunie	8.2	9.6	8.0	8.5	8.6	9.3	9.4	9.2
Iulie	8.0	9.1	8.3	9.0	8.4	10.1	10.8	10.4
August	10.9	10.8	8.3	8.4	8.5	9.5	10.4	10.3
Septembrie	9.2	8.2	8.0	9.4	8.6	10.0	10.3	10.6
Octombrie	10.1	10.0	9.3	8.9	9.7	10.8	11.1	10.9
Noiembrie	10.3	10.1	9.2	9.2	10.3	11.1	11.6	11.8
Decembrie	12.5	12.0	10.5	9.8	11.1	10.5	10.2	10.6

Tabelul 7.3.7. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	10.2	10.1	Mai	9.0	9.1	Septembrie	10.5	10.4
Februarie	10.6	10.4	Iunie	9.3	9.2	Octombrie	10.8	10.6
Martie	9.7	9.6	Iulie	10.5	10.3	Noiembrie	11.5	11.2
Aprilie	10.1	9.9	August	10.4	10.2	Decembrie	10.5	10.4

□ RNA bayesiană, curba de sarcină

Tabelul 7.3.8. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	10.20	9.98	-2.16	4.65	Ianuarie	10.10	9.83	-2.67	7.15
Februarie	10.60	10.57	-0.28	0.08	Februarie	10.40	10.44	0.38	0.15
Martie	9.70	9.44	-2.68	7.18	Martie	9.60	9.30	-3.12	9.77

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Aprilie	10.10	10.25	1.49	2.21	Aprilie	9.90	10.11	2.12	4.50
Mai	9.00	8.75	-2.78	7.72	Mai	9.10	8.85	-2.75	7.55
Iunie	9.30	9.12	-1.94	3.75	Iunie	9.20	8.98	-2.39	5.72
Iulie	10.50	10.51	0.10	0.01	Iulie	10.30	10.37	0.68	0.46
August	10.40	10.13	-2.60	6.74	August	10.20	9.91	-2.84	8.08
Septembrie	10.50	10.36	-1.33	1.78	Septembrie	10.40	10.23	-1.63	2.67
Octombrie	10.80	10.74	-0.56	0.31	Octombrie	10.60	10.57	-0.28	0.08
Noiembrie	11.50	11.40	-0.87	0.76	Noiembrie	11.20	11.23	0.27	0.07
Decembrie	10.50	10.24	-2.48	6.13	Decembrie	10.40	10.09	-2.98	8.88
$S_{2017}$	41.31				$S_{2018}$	55.08			
$S_{total} = 96.39$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.9. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	10.20	10.16	-0.39	0.15	Ianuarie	10.10	10.14	0.40	0.16
Februarie	10.60	10.56	-0.38	0.14	Februarie	10.40	10.52	1.15	1.33
Martie	9.70	9.67	-0.31	0.10	Martie	9.60	9.63	0.31	0.10
Aprilie	10.10	10.21	1.09	1.19	Aprilie	9.90	10.05	1.52	2.30
Mai	9.00	9.03	0.33	0.11	Mai	9.10	9.07	-0.33	0.11
Iunie	9.30	9.23	-0.75	0.57	Iunie	9.20	9.30	1.09	1.18
Iulie	10.50	10.39	-1.05	1.10	Iulie	10.30	10.48	1.75	3.05
August	10.40	10.56	1.54	2.37	August	10.20	10.41	2.06	4.24
Septembrie	10.50	10.32	-1.71	2.94	Septembrie	10.40	10.53	1.25	1.56
Octombrie	10.80	10.86	0.56	0.31	Octombrie	10.60	10.71	1.04	1.08
Noiembrie	11.50	11.34	-1.39	1.94	Noiembrie	11.20	11.29	0.80	0.65
Decembrie	10.50	10.45	-0.48	0.23	Decembrie	10.40	10.47	0.67	0.45
$S_{2017}$	11.13				$S_{2018}$	16.20			
$S_{total} = 27.33$									

#### A7.3.2.3. A doua zi de joi a fiecărei luni, ora 9

Tabelul 7.3.11. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	8.1	9.5	8.5	9.0	8.7	10.0	10.5	11.2
Februarie	8.0	9.3	8.6	9.5	10.0	10.3	10.4	10.6
Martie	8.7	9.8	8.8	9.3	8.5	8.9	9.9	10.2
Aprilie	8.0	9.3	8.0	8.1	8.2	9.8	9.7	10.1
Mai	8.1	9.1	7.9	8.2	8.0	8.8	9.1	9.8
Iunie	8.3	9.5	7.8	7.9	7.6	9.0	8.8	9.3
Iulie	8.0	10.1	7.5	8.2	9.0	9.8	9.2	9.4
August	9.0	10.6	8.5	8.2	8.3	9.2	10.1	9.8
Septembrie	9.0	8.9	7.5	7.3	7.8	8.3	10.1	10.2
Octombrie	9.2	8.1	8.0	8.6	7.9	9.2	10.2	10.3
Noiembrie	10.4	9.1	9.0	9.5	9.4	9.5	10.6	10.8
Decembrie	10.1	9.6	8.5	9.0	9.5	10.0	10.9	10.7

Tabelul 7.3.12. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	10.8	10.7	Mai	9.7	9.5	Septembrie	9.9	9.8
Februarie	10.5	10.4	Iunie	9.4	9.3	Octombrie	10.2	10.1
Martie	10.1	10.1	Iulie	9.3	9.2	Noiembrie	10.7	10.5
Aprilie	10.0	9.9	August	9.6	9.5	Decembrie	10.6	10.5

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.13. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	10.80	10.84	0.37	0.14	Ianuarie	10.70	11.01	2.90	8.39
Februarie	10.50	10.81	2.95	8.72	Februarie	10.40	10.72	3.08	9.47
Martie	10.10	9.79	-3.07	9.42	Martie	10.10	9.84	-2.57	6.63
Aprilie	10.00	9.90	-1.00	1.00	Aprilie	9.90	10.08	1.82	3.31
Mai	9.70	9.44	-2.68	7.18	Mai	9.50	9.29	-2.21	4.89
Iunie	9.40	9.11	-3.09	9.52	Iunie	9.30	9.06	-2.58	6.66
Iulie	9.30	9.44	1.51	2.27	Iulie	9.20	9.49	3.15	9.94
August	9.60	9.51	-0.94	0.88	August	9.50	9.58	0.84	0.71
Septembrie	9.90	9.64	-2.63	6.90	Septembrie	9.80	9.56	-2.45	6.00
Octombrie	10.20	9.96	-2.35	5.54	Octombrie	10.10	9.99	-1.09	1.19
Noiembrie	10.70	10.47	-2.15	4.62	Noiembrie	10.50	10.42	-0.76	0.58
Decembrie	10.60	10.49	-1.04	1.08	Decembrie	10.50	10.61	1.05	1.10
$S_{2017}$	57.25				$S_{2018}$	58.85			
$S_{total} = 116.10$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.14. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	10.80	10.65	-1.39	1.93	Ianuarie	10.70	10.88	1.68	2.83
Februarie	10.50	10.58	0.76	0.58	Februarie	10.40	10.59	1.83	3.34
Martie	10.10	10.15	0.49	0.24	Martie	10.10	10.26	1.58	2.51
Aprilie	10.00	9.85	-1.50	2.25	Aprilie	9.90	9.98	0.81	0.65
Mai	9.70	9.48	-2.27	5.14	Mai	9.50	9.66	1.68	2.84
Iunie	9.40	9.30	-1.06	1.13	Iunie	9.30	9.32	0.22	0.05
Iulie	9.30	9.25	-0.54	0.29	Iulie	9.20	9.28	0.87	0.76
August	9.60	9.50	-1.04	1.09	August	9.50	9.56	0.63	0.40
Septembrie	9.90	10.12	2.22	4.93	Septembrie	9.80	10.01	2.14	4.59
Octombrie	10.20	10.27	0.69	0.47	Octombrie	10.10	10.27	1.68	2.83
Noiembrie	10.70	10.61	-0.84	0.71	Noiembrie	10.50	10.31	-1.81	3.27
Decembrie	10.60	10.47	-1.23	1.50	Decembrie	10.50	10.59	0.86	0.73
$S_{2017}$	20.28				$S_{2018}$	24.80			
$S_{total} = 45.08$									

**A7.3.2.4. A doua zi de joi a fiecărei luni, ora 21**

Tabelul 7.3.16. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	10.1	11.2	10.6	10.0	10.4	11.0	11.1	11.6
Februarie	9.5	9.8	10.3	9.6	10.5	10.9	11.1	11.3
Martie	10.0	10.4	9.7	10.0	10.3	11.0	10.8	11.1
Aprilie	9.6	10.1	10.2	10.0	9.8	9.7	10.3	10.6
Mai	9.0	10.1	9.2	9.0	8.8	10.0	9.6	10.2
Iunie	8.7	10.2	8.9	8.7	8.6	9.3	9.7	10.6
Iulie	8.8	10.3	8.6	9.0	9.2	10.2	10.6	10.8
August	10.1	10.2	8.9	9.0	9.3	9.6	10.8	11.0
Septembrie	9.7	9.2	8.8	9.8	9.0	9.8	11.1	11.3
Octombrie	11.1	10.5	10.0	9.5	10.1	10.8	11.6	11.9
Noiembrie	12.1	11.1	10.0	9.6	10.0	10.9	11.6	11.8
Decembrie	11.6	10.8	10.2	10.0	10.5	11.1	11.4	12.1

Tabelul 7.3.17. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	11.5	11.6	Mai	10.3	10.4	Septembrie	11.5	11.5
Februarie	11.4	11.4	Iunie	10.5	10.6	Octombrie	11.9	12.0
Martie	11.2	11.1	Iulie	10.7	10.9	Noiembrie	11.9	12.1
Aprilie	10.7	10.8	August	10.9	11.1	Decembrie	12.0	12.3

 RNA bayesiană, curba de sarcină

Tabelul 7.3.18. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	11.50	11.17	-2.87	8.23	Ianuarie	11.60	11.25	-3.02	9.10
Februarie	11.40	11.25	-1.32	1.73	Februarie	11.40	11.42	0.18	0.03
Martie	11.20	11.04	-1.43	2.04	Martie	11.10	11.15	0.45	0.20
Aprilie	10.70	10.28	-3.93	15.41	Aprilie	10.80	10.39	-3.80	14.41
Mai	10.30	9.95	-3.40	11.55	Mai	10.40	10.06	-3.27	10.69
Iunie	10.50	10.21	-2.76	7.63	Iunie	10.60	10.30	-2.83	8.01
Iulie	10.70	10.59	-1.03	1.06	Iulie	10.90	10.75	-1.38	1.89
August	10.90	10.61	-2.66	7.08	August	11.10	10.68	-3.78	14.32
Septembrie	11.50	11.17	-2.87	8.23	Septembrie	11.50	11.11	-3.39	11.50
Octombrie	11.90	11.51	-3.28	10.74	Octombrie	12.00	11.62	-3.17	10.03
Noiembrie	11.90	11.55	-2.94	8.65	Noiembrie	12.10	11.72	-3.14	9.86
Decembrie	12.00	11.61	-3.25	10.56	Decembrie	12.30	11.93	-3.01	9.05
$S_{2017}$	92.91				$S_{2018}$	99.10			
$S_{total} = 192.01$									

 RNA bayesiană, lunar

Tabelul 7.3.19. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	11.50	11.32	-1.57	2.45	Ianuarie	11.60	11.42	-1.55	2.41
Februarie	11.40	11.29	-0.96	0.93	Februarie	11.40	11.53	1.14	1.30
Martie	11.20	11.13	-0.62	0.39	Martie	11.10	11.26	1.44	2.08

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Aprilie	10.70	10.40	-2.80	7.86	Aprilie	10.80	10.49	-2.87	8.24
Mai	10.30	10.22	-0.78	0.60	Mai	10.40	10.28	-1.15	1.33
Iunie	10.50	10.65	1.43	2.04	Iunie	10.60	10.73	1.23	1.50
Iulie	10.70	10.76	0.56	0.31	Iulie	10.90	10.77	-1.19	1.42
August	10.90	11.00	0.92	0.84	August	11.10	11.03	-0.63	0.40
Septembrie	11.50	11.38	-1.04	1.09	Septembrie	11.50	11.72	1.91	3.66
Octombrie	11.90	12.00	0.84	0.71	Octombrie	12.00	12.04	0.33	0.11
Noiembrie	11.90	11.99	0.76	0.57	Noiembrie	12.10	12.24	1.16	1.34
Decembrie	12.00	12.14	1.17	1.36	Decembrie	12.30	12.35	0.41	0.17
$S_{2017}$	19.16				$S_{2018}$	23.96			
$S_{total} = 43.12$									

### A7.3.2.5. Ultima zi de marți a fiecărei luni, ora 9

Tabelul 7.3.21. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Januarie	8.3	11.1	10.0	9.2	9.6	10.0	10.8	11.7
Februarie	8.0	10.1	8.8	9.0	8.5	8.8	9.7	10.6
Martie	8.8	10.2	8.4	9.0	8.9	9.2	9.8	10.4
Aprilie	8.5	10.3	8.2	8.5	8.8	9.4	9.6	10.1
Mai	8.9	10.6	8.6	8.2	8.7	9.0	9.2	10.3
Iunie	8.8	10.7	8.7	7.9	9.6	10.1	9.8	10.4
Iulie	8.5	10.8	9.2	8.3	8.3	9.3	10.4	10.6
August	9.2	9.4	8.7	8.5	8.2	9.3	10.5	10.8
Septembrie	9.0	8.6	9.3	8.6	8.5	9.0	10.8	11.2
Octombrie	9.4	8.2	7.8	8.0	8.5	8.9	10.9	11.3
Noiembrie	9.5	9.0	8.4	8.7	9.2	8.7	10.1	10.9
Decembrie	9.8	9.4	8.6	8.3	8.0	9.6	10.8	11.1

Tabelul 7.3.22. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Januarie	11.4	11.4	Mai	10.1	10.3	Septembrie	11.0	11.2
Februarie	10.7	10.8	Iunie	10.3	10.5	Octombrie	11.2	11.4
Martie	10.3	10.5	Iulie	10.5	10.6	Noiembrie	11.0	11.2
Aprilie	9.9	10.2	August	10.7	10.8	Decembrie	11.3	11.4

### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.23. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Januarie	11.40	11.68	2.46	6.03	Januarie	11.40	11.7	2.63	6.93
Februarie	10.70	10.58	-1.12	1.26	Februarie	10.80	10.6	-1.85	3.43
Martie	10.30	10.58	2.72	7.39	Martie	10.50	10.59	0.86	0.73
Aprilie	9.90	10.05	1.52	2.30	Aprilie	10.20	10.3	0.98	0.96
Mai	10.10	10.06	-0.40	0.16	Mai	10.30	10.12	-1.75	3.05



2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iunie	10.30	10.39	0.87	0.76	Iunie	10.50	10.41	-0.86	0.73
Iulie	10.50	10.73	2.19	4.80	Iulie	10.60	10.74	1.32	1.74
August	10.70	10.98	2.62	6.85	August	10.80	11.14	3.15	9.91
Septembrie	11.00	11.31	2.82	7.94	Septembrie	11.20	11.48	2.50	6.25
Octombrie	11.20	11.42	1.96	3.86	Octombrie	11.40	11.55	1.32	1.73
Noiembrie	11.00	10.81	-1.73	2.98	Noiembrie	11.20	10.86	-3.04	9.22
Decembrie	11.30	11.28	-0.18	0.03	Decembrie	11.40	11.31	-0.79	0.62
$S_{2017}$	44.36				$S_{2018}$	45.31			
$S_{total} = 89.67$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.24. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	11.40	11.23	-1.49	2.22	Ianuarie	11.40	11.12	-2.46	6.03
Februarie	10.70	10.82	1.12	1.26	Februarie	10.80	10.85	0.46	0.21
Martie	10.30	10.40	0.97	0.94	Martie	10.50	10.43	-0.67	0.44
Aprilie	9.90	10.02	1.21	1.47	Aprilie	10.20	10.07	-1.27	1.62
Mai	10.10	10.16	0.59	0.35	Mai	10.30	10.37	0.68	0.46
Iunie	10.30	10.04	-2.52	6.37	Iunie	10.50	10.22	-2.67	7.11
Iulie	10.50	10.26	-2.29	5.22	Iulie	10.60	10.37	-2.17	4.71
August	10.70	10.66	-0.37	0.14	August	10.80	10.69	-1.02	1.04
Septembrie	11.00	11.10	0.91	0.83	Septembrie	11.20	11.11	-0.80	0.65
Octombrie	11.20	11.10	-0.89	0.80	Octombrie	11.40	11.50	0.88	0.77
Noiembrie	11.00	11.16	1.45	2.12	Noiembrie	11.20	11.22	0.18	0.03
Decembrie	11.30	11.35	0.44	0.20	Decembrie	11.40	11.44	0.35	0.12
$S_{2017}$	21.92				$S_{2018}$	23.20			
$S_{total} = 45.12$									

#### A7.3.2.6. Ultima zi de marți a fiecărei luni, ora 21

Tabelul 7.3.26. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	10.1	11.5	10.9	11.0	9.4	11.1	11.5	11.7
Februarie	9.2	11.4	9.6	10.1	10.2	10.8	11.1	11.6
Martie	10.0	11.2	9.9	9.8	9.5	11.0	10.9	11.4
Aprilie	9.1	10.9	8.8	9.3	8.9	9.9	10.4	10.9
Mai	8.3	10.5	8.0	9.6	8.9	9.8	10.2	10.4
Iunie	8.6	11.2	8.3	9.2	9.0	10.5	11.1	11.2
Iulie	9.4	10.8	8.1	8.5	9.1	11.0	11.5	11.6
August	10.3	9.2	8.8	8.7	10.0	9.9	11.8	11.4
Septembrie	10.5	9.6	9.0	9.4	9.0	9.5	11.2	10.9
Octombrie	11.1	9.7	8.8	9.0	9.8	10.4	11.4	11.2
Noiembrie	10.9	10.8	10.0	9.2	10.4	9.7	11.3	11.0
Decembrie	10.7	10.3	8.9	9.6	10.2	10.4	11.4	11.3

Tabelul 7.3.27. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	11.7	11.8	Mai	10.5	10.7	Septembrie	11.1	11.2
Februarie	11.6	11.5	Iunie	11.1	11.2	Octombrie	11.3	11.4
Martie	11.3	11.4	Iulie	11.7	11.8	Noiembrie	11.4	11.5
Aprilie	10.8	11.0	August	11.6	11.8	Decembrie	11.6	11.7

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.28. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	11.70	11.57	-1.11	1.23	Ianuarie	11.80	11.64	-1.36	1.84
Februarie	11.60	11.41	-1.64	2.68	Februarie	11.50	11.37	-1.13	1.28
Martie	11.30	11.07	-2.04	4.14	Martie	11.40	11.15	-2.19	4.81
Aprilie	10.80	10.57	-2.13	4.54	Aprilie	11.00	10.77	-2.09	4.37
Mai	10.50	10.41	-0.86	0.73	Mai	10.70	10.45	-2.34	5.46
Iunie	11.10	10.93	-1.53	2.35	Iunie	11.20	11.07	-1.16	1.35
Iulie	11.70	11.45	-2.14	4.57	Iulie	11.80	11.53	-2.29	5.24
August	11.60	11.36	-2.07	4.28	August	11.80	11.61	-1.61	2.59
Septembrie	11.10	10.83	-2.43	5.92	Septembrie	11.20	10.94	-2.32	5.39
Octombrie	11.30	11.21	-0.80	0.63	Octombrie	11.40	11.50	0.88	0.77
Noiembrie	11.40	11.19	-1.84	3.39	Noiembrie	11.50	11.27	-2.00	4.00
Decembrie	11.60	11.34	-2.24	5.02	Decembrie	11.70	11.41	-2.48	6.14
$S_{2017}$	39.49				$S_{2018}$	43.23			
$S_{total} = 82.72$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.29. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	11.70	11.67	-0.26	0.07	Ianuarie	11.80	11.77	-0.25	0.06
Februarie	11.60	11.65	0.43	0.19	Februarie	11.50	11.63	1.13	1.28
Martie	11.30	11.40	0.88	0.78	Martie	11.40	11.31	-0.79	0.62
Aprilie	10.80	10.70	-0.93	0.86	Aprilie	11.00	10.90	-0.91	0.83
Mai	10.50	10.46	-0.38	0.15	Mai	10.70	10.58	-1.12	1.26
Iunie	11.10	11.17	0.63	0.40	Iunie	11.20	11.25	0.45	0.20
Iulie	11.70	11.79	0.77	0.59	Iulie	11.80	11.85	0.42	0.18
August	11.60	11.51	-0.78	0.60	August	11.80	11.77	-0.25	0.06
Septembrie	11.10	11.03	-0.63	0.40	Septembrie	11.20	11.27	0.63	0.39
Octombrie	11.30	11.35	0.44	0.20	Octombrie	11.40	11.44	0.35	0.12
Noiembrie	11.40	11.36	-0.35	0.12	Noiembrie	11.50	11.42	-0.70	0.48
Decembrie	11.60	11.54	-0.52	0.27	Decembrie	11.70	11.74	0.34	0.12
$S_{2017}$	4.61				$S_{2018}$	5.61			
$S_{total} = 10.22$									

### A7.3.3. Stația IMT

#### A7.3.3.1. Prima zi de miercuri a fiecărei luni, ora 9

Tabelul 7.3.31. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	4.4	4.7	4.7	4.6	4.5	4.7	4.6	4.8
Februarie	5.4	5.9	5.8	6.3	5.8	5.1	4.8	4.9
Martie	5.7	5.6	5.2	4.9	4.8	4.6	4.5	4.6
Aprilie	6.0	5.9	4.5	4.4	4.4	4.9	4.7	4.4
Mai	5.8	4.9	4.2	3.9	4.4	4.6	4.2	4.3
Iunie	5.6	5.4	5.1	4.3	4.1	4.0	3.9	4.2
Iulie	5.1	5.4	5.5	4.1	3.9	3.9	4.0	4.1
August	4.5	5.2	5.3	4.4	4.2	3.8	3.9	3.9
Septembrie	5.1	5.6	5.2	4.8	4.5	4.0	4.0	4.1
Octombrie	5.3	5.7	5.3	4.9	4.8	4.6	4.1	4.2
Noiembrie	5.8	5.7	5.3	5.0	4.7	4.5	4.4	4.3
Decembrie	5.9	5.1	5.0	4.7	4.6	4.2	4.3	4.1

Tabelul 7.3.32. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	4.9	5.0	Mai	4.5	4.5	Septembrie	4.2	4.3
Februarie	5.1	5.1	Iunie	4.2	4.3	Octombrie	4.5	4.4
Martie	4.7	4.8	Iulie	4.2	4.3	Noiembrie	4.6	4.6
Aprilie	4.9	4.8	August	4.0	4.1	Decembrie	4.4	4.4




Figura 7.3.25. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.26. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

**□ RNA bayesiană, curba de sarcină**

Tabelul 7.3.33. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.90	4.64	-5.31	28.15	Ianuarie	5.00	4.75	-5.00	25.00
Februarie	5.10	5.13	0.59	0.35	Februarie	5.10	5.12	0.39	0.15
Martie	4.70	4.47	-4.89	23.95	Martie	4.80	4.69	-2.29	5.25
Aprilie	4.90	4.73	-3.47	12.04	Aprilie	4.80	4.68	-2.50	6.25
Mai	4.50	4.31	-4.22	17.83	Mai	4.50	4.29	-4.67	21.78
Iunie	4.20	4.05	-3.57	12.76	Iunie	4.30	4.16	-3.26	10.60
Iulie	4.20	4.06	-3.33	11.11	Iulie	4.30	4.18	-2.79	7.79
August	4.00	3.84	-4.00	16.00	August	4.10	3.95	-3.66	13.38
Septembrie	4.20	4.12	-1.90	3.63	Septembrie	4.30	4.18	-2.79	7.79
Octombrie	4.50	4.30	-4.44	19.75	Octombrie	4.40	4.25	-3.41	11.62
Noiembrie	4.60	4.43	-3.70	13.66	Noiembrie	4.60	4.40	-4.35	18.90
Decembrie	4.40	4.26	-3.18	10.12	Decembrie	4.40	4.23	-3.86	14.93
$S_{2017}$	169.34				$S_{2018}$	143.45			
$S_{total} = 312.79$									

**□ RNA bayesiană, lunar**

Tabelul 7.3.34. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.90	4.86	-0.82	0.67	Ianuarie	5.00	4.94	-1.20	1.44
Februarie	5.10	4.99	-2.16	4.65	Februarie	5.10	5.01	-1.76	3.11
Martie	4.70	4.76	1.28	1.63	Martie	4.80	4.82	0.42	0.17
Aprilie	4.90	4.81	-1.84	3.37	Aprilie	4.80	4.77	-0.63	0.39
Mai	4.50	4.47	-0.67	0.44	Mai	4.50	4.52	0.44	0.20
Iunie	4.20	4.16	-0.95	0.91	Iunie	4.30	4.25	-1.16	1.35
Iulie	4.20	4.23	0.71	0.51	Iulie	4.30	4.27	-0.70	0.49
August	4.00	4.03	0.75	0.56	August	4.10	4.07	-0.73	0.54
Septembrie	4.20	4.10	-2.38	5.67	Septembrie	4.30	4.18	-2.79	7.79
Octombrie	4.50	4.39	-2.44	5.98	Octombrie	4.40	4.28	-2.73	7.44
Noiembrie	4.60	4.51	-1.96	3.83	Noiembrie	4.60	4.55	-1.09	1.18
Decembrie	4.40	4.33	-1.59	2.53	Decembrie	4.40	4.31	-2.05	4.18
$S_{2017}$	30.75				$S_{2018}$	28.28			
$S_{total} = 59.03$									

**A7.3.3.2. Prima zi de miercuri a fiecărei luni, ora 21**

Tabelul 7.3.36. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	4.4	4.6	5.2	6.2	5.3	4.6	4.1	4.2
Februarie	4.0	4.5	5.1	6.0	4.9	4.3	4.0	4.3
Martie	3.9	4.6	5.4	5.8	4.6	3.8	3.9	4.0
Aprilie	3.8	4.3	4.9	4.6	4.1	3.5	3.6	3.9
Mai	3.6	4.1	4.9	4.2	3.8	3.4	3.2	3.7
Iunie	3.3	4.2	5.0	3.7	4.0	3.4	3.5	3.4
Iulie	4.1	3.9	4.9	3.5	3.7	3.4	3.6	3.6

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
August	4.0	4.3	5.1	3.2	3.5	2.8	3.2	3.4
Septembrie	4.2	4.1	4.9	3.6	3.2	2.9	3.0	3.1
Octombrie	3.9	4.0	4.6	3.3	2.9	3.0	3.1	2.9
Noiembrie	4.2	4.0	4.9	3.6	3.1	3.9	3.2	3.0
Decembrie	4.5	4.2	5.1	3.7	3.3	3.2	3.4	3.3

Tabelul 7.3.37. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	4.3	4.3	Mai	3.5	3.6	Septembrie	3.0	3.1
Februarie	4.2	4.3	Iunie	3.5	3.5	Octombrie	3.0	3.0
Martie	3.9	4.0	Iulie	3.6	3.5	Noiembrie	3.4	3.2
Aprilie	3.7	3.8	August	3.2	3.3	Decembrie	3.3	3.4




Figura 7.3.29. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.30. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.38. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.30	4.36	1.40	1.95	Ianuarie	4.30	4.38	1.86	3.46
Februarie	4.20	4.32	2.86	8.16	Februarie	4.30	4.39	2.09	4.38
Martie	3.90	3.96	1.54	2.37	Martie	4.00	4.05	1.25	1.56

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Aprilie	3.70	3.72	0.54	0.29	Aprilie	3.80	3.76	-1.05	1.11
Mai	3.50	3.39	-3.14	9.88	Mai	3.60	3.48	-3.33	11.11
Iunie	3.50	3.48	-0.57	0.33	Iunie	3.50	3.52	0.57	0.33
Iulie	3.60	3.49	-3.06	9.34	Iulie	3.50	3.43	-2.00	4.00
August	3.20	3.11	-2.81	7.91	August	3.30	3.18	-3.64	13.22
Septembrie	3.00	2.93	-2.33	5.44	Septembrie	3.10	3.01	-2.90	8.43
Octombrie	3.00	2.90	-3.33	11.11	Octombrie	3.00	2.92	-2.67	7.11
Noiembrie	3.40	3.34	-1.76	3.11	Noiembrie	3.20	3.22	-1.24	1.54
Decembrie	3.30	3.21	-2.73	7.44	Decembrie	3.40	3.29	-3.24	10.47
$S_{2017}$	67.33				$S_{2018}$	66.72			
$S_{total} = 134.05$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.39. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.30	4.24	-1.40	1.95	Ianuarie	4.30	4.21	-2.09	4.38
Februarie	4.20	4.30	2.38	5.67	Februarie	4.30	4.33	0.70	0.49
Martie	3.90	3.97	1.79	3.22	Martie	4.00	4.02	0.50	0.25
Aprilie	3.70	3.74	1.08	1.17	Aprilie	3.80	3.82	0.53	0.28
Mai	3.50	3.52	0.57	0.33	Mai	3.60	3.54	-1.67	2.78
Iunie	3.50	3.49	-0.29	0.08	Iunie	3.50	3.48	-0.57	0.33
Iulie	3.60	3.58	-0.56	0.31	Iulie	3.50	3.53	0.86	0.73
August	3.20	3.25	1.56	2.44	August	3.30	3.27	-0.91	0.83
Septembrie	3.00	3.05	1.67	2.78	Septembrie	3.10	3.06	-1.29	1.66
Octombrie	3.00	3.01	0.33	0.11	Octombrie	3.00	3.02	0.67	0.44
Noiembrie	3.40	3.35	-1.47	2.16	Noiembrie	3.20	3.28	2.50	6.25
Decembrie	3.30	3.28	-0.61	0.37	Decembrie	3.40	3.36	-1.18	1.38
$S_{2017}$	20.58				$S_{2018}$	19.80			
$S_{total} = 40.38$									

#### A7.3.3.3. A doua zi de joi a fiecărei luni, ora 9

Tabelul 7.3.41. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	4.5	4.7	5.3	5.4	4.6	4.5	4.4	4.7
Februarie	4.8	4.3	5.1	5.3	4.8	4.6	4.5	4.5
Martie	5.3	5.3	5.6	4.8	4.8	4.7	4.3	4.6
Aprilie	4.9	5.2	4.6	4.4	4.2	4.8	4.7	4.5
Mai	5.0	5.3	5.5	4.6	4.2	4.1	4.5	4.3
Iunie	5.2	5.1	5.1	4.6	3.6	4.0	4.2	4.1
Iulie	4.6	4.9	5.1	4.8	4.3	4.1	3.9	3.9
August	4.0	4.8	5.4	4.7	3.9	4.2	4.0	4.0
Septembrie	4.7	4.8	4.9	4.5	3.8	4.4	3.9	4.2
Octombrie	4.8	4.9	5.0	4.4	4.3	4.6	4.2	4.3
Noiembrie	4.7	5.1	5.2	4.6	4.2	4.7	4.4	4.3
Decembrie	5.3	5.2	5.2	4.9	4.5	4.4	4.5	4.5

Tabelul 7.3.42. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	4.5	4.5	Mai	4.3	4.3	Septembrie	4.1	4.0
Februarie	4.5	4.4	Iunie	4.1	4.1	Octombrie	4.4	4.2
Martie	4.5	4.4	Iulie	4.0	3.8	Noiembrie	4.4	4.3
Aprilie	4.7	4.5	August	4.1	3.9	Decembrie	4.4	4.5




Figura 7.3.33. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.34. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### RNA bayesiană, curba de sarcină

Tabelul 7.3.43. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.50	4.45	-1.11	1.23	Ianuarie	4.50	4.43	-1.56	2.42
Februarie	4.50	4.58	1.78	3.16	Februarie	4.40	4.54	3.18	10.12
Martie	4.50	4.34	-3.56	12.64	Martie	4.40	4.29	-2.50	6.25
Aprilie	4.70	4.52	-3.83	14.67	Aprilie	4.50	4.39	-2.44	5.98
Mai	4.30	4.14	-3.72	13.85	Mai	4.30	4.11	-4.42	19.52
Iunie	4.10	3.98	-2.93	8.57	Iunie	4.10	3.95	-3.66	13.38
Iulie	4.00	3.85	-3.75	14.06	Iulie	3.80	3.76	-1.05	1.11
August	4.10	3.96	-3.41	11.66	August	3.90	3.83	-1.79	3.22
Septembrie	4.10	3.99	-2.68	7.20	Septembrie	4.00	3.97	-0.75	0.56
Octombrie	4.40	4.29	-2.50	6.25	Octombrie	4.20	4.16	-0.95	0.91
Noiembrie	4.40	4.26	-3.18	10.12	Noiembrie	4.30	4.13	-3.95	15.63
Decembrie	4.40	4.27	-2.95	8.73	Decembrie	4.50	4.35	-3.33	11.11
$S_{2017}$		112.14			$S_{2018}$		90.22		
$S_{total} = 202.36$									

### □ RNA bayesiană, lunar

Tabelul 7.3.44. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.50	4.52	0.44	0.20	Ianuarie	4.50	4.47	-0.67	0.44
Februarie	4.50	4.44	-1.33	1.78	Februarie	4.40	4.45	1.14	1.29
Martie	4.50	4.47	-0.67	0.44	Martie	4.40	4.44	0.91	0.83
Aprilie	4.70	4.61	-1.91	3.67	Aprilie	4.50	4.60	2.22	4.94
Mai	4.30	4.28	-0.47	0.22	Mai	4.30	4.29	-0.23	0.05
Iunie	4.10	4.12	0.49	0.24	Iunie	4.10	4.14	0.98	0.95
Iulie	4.00	3.92	-2.00	4.00	Iulie	3.80	3.88	2.11	4.43
August	4.10	4.04	-1.46	2.14	August	3.90	3.98	2.05	4.21
Septembrie	4.10	4.07	-0.73	0.54	Septembrie	4.00	4.03	0.75	0.56
Octombrie	4.40	4.32	-1.82	3.31	Octombrie	4.20	4.27	1.67	2.78
Noiembrie	4.40	4.34	-1.36	1.86	Noiembrie	4.30	4.28	-0.47	0.22
Decembrie	4.40	4.47	1.59	2.53	Decembrie	4.50	4.55	1.11	1.23
$S_{2017}$	20.91				$S_{2018}$	21.94			
$S_{total} = 42.85$									

### A7.3.3.4. A doua zi de joi a fiecărei luni, ora 21

Tabelul 7.3.46. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	4.4	3.9	3.6	4.6	4.4	4.7	4.6	4.8
Februarie	4.7	4.6	4.2	4.8	4.6	3.9	4.4	4.7
Martie	4.9	4.6	5.0	4.4	4.3	3.8	4.2	4.3
Aprilie	4.8	4.5	4.4	4.6	4.4	4.5	4.1	4.2
Mai	5.0	4.6	4.9	5.0	4.6	4.3	4.4	4.3
Iunie	4.3	4.2	4.6	4.1	3.9	4.1	3.9	4.2
Iulie	4.3	4.5	5.0	3.9	4.2	3.8	3.9	4.1
August	4.7	4.3	4.9	4.2	4.2	3.9	3.8	3.9
Septembrie	4.8	4.0	4.9	4.0	4.2	4.0	4.1	4.0
Octombrie	3.3	4.2	5.1	4.3	4.4	3.9	4.2	4.3
Noiembrie	3.5	4.4	5.2	4.6	4.3	4.2	4.2	4.4
Decembrie	4.6	4.8	5.3	4.5	4.6	4.7	3.9	4.3




Figura 7.3.37. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)



Tabelul 7.3.47. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	4.8	4.9	Mai	4.5	4.6	Septembrie	4.2	4.2
Februarie	4.5	4.7	Iunie	4.2	4.3	Octombrie	4.3	4.4
Martie	4.2	4.4	Iulie	4.1	4.2	Noiembrie	4.4	4.5
Aprilie	4.4	4.4	August	4.0	4.0	Decembrie	4.5	4.6




Figura 7.3.38. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.48. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.80	4.74	-1.25	1.56	Ianuarie	4.90	4.79	-2.24	5.04
Februarie	4.50	4.35	-3.33	11.11	Februarie	4.70	4.54	-3.40	11.59
Martie	4.20	4.24	0.95	0.91	Martie	4.40	4.31	-2.05	4.18
Aprilie	4.40	4.29	-2.50	6.25	Aprilie	4.40	4.32	-1.82	3.31
Mai	4.50	4.39	-2.44	5.98	Mai	4.60	4.48	-2.61	6.81
Iunie	4.20	4.06	-3.33	11.11	Iunie	4.30	4.16	-3.26	10.60
Iulie	4.10	3.97	-3.17	10.05	Iulie	4.20	4.06	-3.33	11.11
August	4.00	3.92	-2.00	4.00	August	4.00	3.94	-1.50	2.25
Septembrie	4.20	4.10	-2.38	5.67	Septembrie	4.20	4.12	-1.90	3.63
Octombrie	4.30	4.23	-1.63	2.65	Octombrie	4.40	4.31	-2.05	4.18
Noiembrie	4.40	4.35	-1.14	1.29	Noiembrie	4.50	4.40	-2.22	4.94
Decembrie	4.50	4.54	0.89	0.79	Decembrie	4.60	4.58	-0.43	0.19
$S_{2017}$	61.37				$S_{2018}$	67.82			
$S_{total} = 129.19$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.49. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.80	4.78	-0.42	0.17	Ianuarie	4.90	4.89	-0.20	0.04
Februarie	4.50	4.58	1.78	3.16	Februarie	4.70	4.67	-0.64	0.41
Martie	4.20	4.27	1.67	2.78	Martie	4.40	4.31	-2.05	4.18
Aprilie	4.40	4.38	-0.45	0.21	Aprilie	4.40	4.35	-1.14	1.29

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Mai	4.50	4.52	0.44	0.20	Mai	4.60	4.53	-1.52	2.32
Iunie	4.20	4.22	0.48	0.23	Iunie	4.30	4.24	-1.40	1.95
Iulie	4.10	4.18	1.95	3.81	Iulie	4.20	4.22	0.48	0.23
August	4.00	3.94	-1.50	2.25	August	4.00	3.93	-1.75	3.06
Septembrie	4.20	4.21	0.24	0.06	Septembrie	4.20	4.24	0.95	0.91
Octombrie	4.30	4.36	1.40	1.95	Octombrie	4.40	4.35	-1.14	1.29
Noiembrie	4.40	4.43	0.68	0.46	Noiembrie	4.50	4.48	-0.44	0.20
Decembrie	4.50	4.53	0.67	0.44	Decembrie	4.60	4.56	-0.87	0.76
$S_{2017}$	15.71				$S_{2018}$	16.63			
$S_{total} = 32.34$									

### A7.3.3.5. Ultima zi de marți a fiecărei luni, ora 9

Tabelul 7.3.51. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	5.7	4.5	5.3	4.9	4.7	4.1	4.4	4.6
Februarie	5.4	5.3	4.7	4.8	4.8	4.3	4.5	4.4
Martie	5.2	4.9	5.0	4.5	4.4	3.9	4.4	4.5
Aprilie	4.9	4.9	4.6	4.2	4.5	4.0	3.9	4.3
Mai	4.5	4.5	4.6	4.3	4.4	4.2	4.0	4.3
Iunie	5.0	4.7	4.8	4.6	4.6	3.9	4.3	4.4
Iulie	5.0	4.8	4.9	4.4	4.6	4.0	4.3	4.2
August	4.6	5.1	4.6	4.2	4.5	3.9	4.1	3.9
Septembrie	5.0	4.8	4.7	4.2	4.7	3.8	4.2	4.0
Octombrie	4.4	5.2	4.8	4.7	4.8	4.8	4.5	4.4
Noiembrie	5.1	5.1	4.8	4.5	4.6	4.8	4.7	4.5
Decembrie	5.7	5.1	4.6	4.3	4.6	3.9	4.6	4.7

Tabelul 7.3.52. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	4.5	4.7	Mai	4.3	4.4	Septembrie	4.2	4.3
Februarie	4.6	4.7	Iunie	4.4	4.5	Octombrie	4.7	4.7
Martie	4.4	4.6	Iulie	4.3	4.4	Noiembrie	4.9	4.9
Aprilie	4.2	4.3	August	4.1	4.2	Decembrie	4.6	4.8




Figura 7.3.41. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.42. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.53. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.50	4.63	2.89	8.35	Ianuarie	4.70	4.72	0.43	0.18
Februarie	4.60	4.71	2.39	5.72	Februarie	4.70	4.80	2.13	4.53
Martie	4.40	4.49	2.05	4.18	Martie	4.60	4.52	-1.74	3.02
Aprilie	4.20	4.28	1.90	3.63	Aprilie	4.30	4.35	1.16	1.35
Mai	4.30	4.34	0.93	0.87	Mai	4.40	4.38	-0.45	0.21
Iunie	4.40	4.45	1.14	1.29	Iunie	4.50	4.48	-0.44	0.20
Iulie	4.30	4.46	3.72	13.85	Iulie	4.40	4.54	3.18	10.12
August	4.10	4.25	3.66	13.38	August	4.20	4.34	3.33	11.11
Septembrie	4.20	4.37	4.05	16.38	Septembrie	4.30	4.50	4.65	21.63
Octombrie	4.70	4.74	0.85	0.72	Octombrie	4.70	4.75	1.06	1.13
Noiembrie	4.90	4.78	-2.45	6.00	Noiembrie	4.90	4.74	-3.27	10.66
Decembrie	4.60	4.63	0.65	0.43	Decembrie	4.80	4.64	-3.33	11.11
$S_{2017}$	74.79				$S_{2018}$	75.26			
$S_{total} = 150.05$									

### □ RNA bayesiană, lunar

Tabelul 7.3.54. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.50	4.60	2.22	4.94	Ianuarie	4.70	4.66	-0.85	0.72
Februarie	4.60	4.58	-0.43	0.19	Februarie	4.70	4.64	-1.28	1.63
Martie	4.40	4.45	1.14	1.29	Martie	4.60	4.49	-2.39	5.72
Aprilie	4.20	4.16	-0.95	0.91	Aprilie	4.30	4.22	-1.86	3.46
Mai	4.30	4.28	-0.47	0.22	Mai	4.40	4.34	-1.36	1.86
Iunie	4.40	4.37	-0.68	0.46	Iunie	4.50	4.44	-1.33	1.78
Iulie	4.30	4.27	-0.70	0.49	Iulie	4.40	4.36	-0.91	0.83
August	4.10	4.09	-0.24	0.06	August	4.20	4.16	-0.95	0.91
Septembrie	4.20	4.16	-0.95	0.91	Septembrie	4.30	4.23	-1.63	2.65
Octombrie	4.70	4.77	1.49	2.22	Octombrie	4.70	4.74	0.85	0.72
Noiembrie	4.90	4.76	-2.86	8.16	Noiembrie	4.90	4.83	-1.43	2.04
Decembrie	4.60	4.67	1.52	2.32	Decembrie	4.80	4.75	-1.04	1.09
$S_{2017}$	22.16				$S_{2018}$	23.40			
$S_{total} = 45.56$									

**A7.3.3.6. Ultima zi de marți a fiecărei luni, ora 21**

Tabelul 7.3.56. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	5.1	4.7	4.6	5.0	4.9	4.8	4.6	4.8
Februarie	5.0	4.9	5.1	4.2	4.4	4.6	4.4	4.7
Martie	4.8	5.0	5.1	4.3	4.3	4.3	4.5	4.6
Aprilie	4.8	4.4	4.1	3.9	4.4	4.1	3.9	4.3
Mai	4.4	4.2	4.0	4.4	4.7	4.0	4.1	4.4
Iunie	4.7	4.8	4.3	4.5	4.7	4.2	4.0	4.3
Iulie	4.7	4.6	4.4	4.2	4.1	4.0	4.4	4.1
August	4.8	4.2	4.6	4.5	4.0	4.4	4.5	4.4
Septembrie	5.1	4.5	4.8	4.1	4.0	4.2	4.3	4.6
Octombrie	4.8	4.7	4.6	4.2	4.3	4.3	4.5	4.4
Noiembrie	4.6	4.8	4.9	4.6	4.6	4.7	4.8	4.7
Decembrie	5.0	5.1	4.8	4.5	4.8	4.8	4.6	4.9

Tabelul 7.3.57. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	4.9	4.9	Mai	4.3	4.4	Septembrie	4.5	4.6
Februarie	4.7	4.8	Iunie	4.3	4.4	Octombrie	4.5	4.7
Martie	4.6	4.7	Iulie	4.3	4.4	Noiembrie	4.9	5.0
Aprilie	4.2	4.3	August	4.6	4.7	Decembrie	4.9	5.0




Figura 7.3.45. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.46. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.58. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.90	4.85	-1.02	1.04	Ianuarie	4.90	4.87	-0.61	0.37
Februarie	4.70	4.68	-0.43	0.18	Februarie	4.80	4.75	-1.04	1.09
Martie	4.60	4.62	0.43	0.19	Martie	4.70	4.66	-0.85	0.72
Aprilie	4.20	4.18	-0.48	0.23	Aprilie	4.30	4.25	-1.16	1.35
Mai	4.30	4.26	-0.93	0.87	Mai	4.40	4.33	-1.59	2.53
Iunie	4.30	4.46	3.72	13.85	Iunie	4.40	4.57	3.86	14.93
Iulie	4.30	4.33	0.70	0.49	Iulie	4.40	4.37	-0.68	0.46
August	4.60	4.43	-3.70	13.66	August	4.70	4.56	-2.98	8.87
Septembrie	4.50	4.46	-0.89	0.79	Septembrie	4.60	4.52	-1.74	3.02
Octombrie	4.50	4.57	1.56	2.42	Octombrie	4.70	4.64	-1.28	1.63
Noiembrie	4.90	4.71	-3.88	15.04	Noiembrie	5.00	4.82	-3.60	12.96
Decembrie	4.90	4.77	-2.65	7.04	Decembrie	5.00	4.84	-3.20	10.24
$S_{2017}$	55.78				$S_{2018}$	58.19			
$S_{total} = 113.96$									

### □ RNA bayesiană, lunar

Tabelul 7.3.59. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	4.90	4.85	-1.02	1.04	Ianuarie	4.90	4.88	-0.41	0.17
Februarie	4.70	4.64	-1.28	1.63	Februarie	4.80	4.73	-1.46	2.13
Martie	4.60	4.62	0.43	0.19	Martie	4.70	4.68	-0.43	0.18
Aprilie	4.20	4.22	0.48	0.23	Aprilie	4.30	4.26	-0.93	0.87
Mai	4.30	4.33	0.70	0.49	Mai	4.40	4.38	-0.45	0.21
Iunie	4.30	4.34	0.93	0.87	Iunie	4.40	4.37	-0.68	0.46
Iulie	4.30	4.28	-0.47	0.22	Iulie	4.40	4.33	-1.59	2.53
August	4.60	4.48	-2.61	6.81	August	4.70	4.57	-2.77	7.65
Septembrie	4.50	4.52	0.44	0.20	Septembrie	4.60	4.58	-0.43	0.19
Octombrie	4.50	4.59	2.00	4.00	Octombrie	4.70	4.64	-1.28	1.63
Noiembrie	4.90	4.83	-1.43	2.04	Noiembrie	5.00	4.91	-1.80	3.24
Decembrie	4.90	4.93	0.61	0.37	Decembrie	5.00	4.95	-1.00	1.00
$S_{2017}$	18.07				$S_{2018}$	20.25			
$S_{total} = 38.32$									

## A7.3.4. Stația Musicescu

### A7.3.4.1. Prima zi de miercuri a fiecărei luni, ora 9

Tabelul 7.3.61. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	4.8	6.2	7.2	6.8	7.0	7.4	8.1	7.8
Februarie	4.8	5.3	6.4	6.6	6.8	7.2	7.4	7.6
Martie	4.8	5.0	5.3	6.0	6.4	6.7	6.8	7.0
Aprilie	4.4	4.5	5.0	5.3	5.2	5.8	5.6	5.8
Mai	3.8	4.0	4.2	4.5	4.5	5.1	5.4	5.6

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Iunie	3.2	3.8	4.0	4.6	4.7	5.0	5.3	5.4
Iulie	4.6	4.8	4.2	4.8	4.4	4.8	5.6	5.7
August	3.2	3.5	3.8	4.4	4.4	5.0	6.0	6.2
Septembrie	3.8	3.8	3.3	4.8	4.5	5.2	6.2	6.4
Octombrie	4.2	4.8	5.3	5.0	4.9	5.4	6.5	6.6
Noiembrie	5.6	5.8	5.8	5.4	6.4	7.5	7.2	7.3
Decembrie	6.2	7.0	6.2	6.8	7.3	8.0	8.1	8.2

Tabelul 7.3.62. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.0	8.1	Mai	5.5	5.6	Septembrie	6.1	6.4
Februarie	7.6	7.7	Iunie	5.4	5.5	Octombrie	6.4	6.6
Martie	7.0	7.1	Iulie	5.5	5.7	Noiembrie	7.6	7.5
Aprilie	5.9	5.9	August	5.9	6.2	Decembrie	8.3	8.4




Figura 7.3.49. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.50. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.63. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

Luna	2017				Luna	2018			
	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă		Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.00	7.96	-0.50	0.25	Ianuarie	8.10	7.94	-1.98	3.90
Februarie	7.60	7.43	-2.24	5.00	Februarie	7.70	7.49	-2.73	7.44
Martie	7.00	6.92	-1.14	1.31	Martie	7.10	6.90	-2.82	7.93

2017					2018				
Luna	Valoare cunoscută	Valoare prognostată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognostată	Abatere relativă [%]	Abatere pătratică relativă
Aprilie	5.90	5.75	-2.54	6.46	Aprilie	5.90	5.72	-3.05	9.31
Mai	5.50	5.56	1.09	1.19	Mai	5.60	5.54	-1.07	1.15
Iunie	5.40	5.28	-2.22	4.94	Iunie	5.50	5.32	-3.27	10.71
Iulie	5.50	5.62	2.18	4.76	Iulie	5.70	5.60	-1.75	3.08
August	5.90	6.14	4.07	16.55	August	6.20	6.12	-1.29	1.66
Septembrie	6.10	6.32	3.61	13.01	Septembrie	6.40	6.3	-1.56	2.44
Octombrie	6.40	6.46	0.94	0.88	Octombrie	6.60	6.43	-2.58	6.63
Noiembrie	7.60	7.45	-1.97	3.90	Noiembrie	7.50	7.42	-1.07	1.14
Decembrie	8.30	8.22	-0.96	0.93	Decembrie	8.40	8.30	-1.19	1.42
$S_{2017}$	59.17				$S_{2018}$	56.81			
$S_{total} = 115.98$									

RNA bayesiană, lunar

Tabelul 7.3.64. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognostată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognostată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.00	7.99	-0.12	0.02	Ianuarie	8.10	8.15	0.62	0.38
Februarie	7.60	7.66	0.79	0.62	Februarie	7.70	7.78	1.04	1.08
Martie	7.00	7.07	1.00	1.00	Martie	7.10	7.16	0.85	0.71
Aprilie	5.90	5.86	-0.68	0.46	Aprilie	5.90	5.97	1.19	1.41
Mai	5.50	5.57	1.27	1.62	Mai	5.60	5.66	1.07	1.15
Iunie	5.40	5.43	0.56	0.31	Iunie	5.50	5.54	0.73	0.53
Iulie	5.50	5.55	0.91	0.83	Iulie	5.70	5.61	-1.58	2.49
August	5.90	6.09	3.22	10.37	August	6.20	6.24	0.65	0.42
Septembrie	6.10	6.21	1.80	3.25	Septembrie	6.40	6.32	-1.25	1.56
Octombrie	6.40	6.38	-0.31	0.10	Octombrie	6.60	6.42	-2.73	7.44
Noiembrie	7.60	7.50	-1.32	1.73	Noiembrie	7.50	7.41	-1.20	1.44
Decembrie	8.30	8.27	-0.36	0.13	Decembrie	8.40	8.47	0.83	0.69
$S_{2017}$	20.44				$S_{2018}$	19.30			
$S_{total} = 39.74$									

**A7.3.4.2. Prima zi de miercuri a fiecărei luni, ora 21**

Tabelul 7.3.66. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.2	8.4	8.9	9.0	9.1	9.3	9.5	9.8
Februarie	7.0	6.5	8.6	8.3	9.0	9.1	9.2	9.5
Martie	6.8	7.2	7.6	7.2	8.6	8.8	8.6	9.1
Aprilie	6.2	7.0	7.2	6.9	7.6	8.2	8.3	8.5
Mai	5.3	4.7	5.0	5.6	6.0	6.1	7.4	6.8
Iunie	5.2	4.2	4.8	5.2	5.6	5.4	6.0	5.9
Iulie	5.0	4.9	4.6	5.3	5.0	5.2	6.5	6.0
August	5.2	5.2	4.8	5.0	6.3	6.1	7.1	6.3
Septembrie	5.5	5.3	6.0	6.2	6.5	7.2	8.2	7.5
Octombrie	6.2	6.0	6.8	7.2	7.2	7.9	8.6	8.4
Noiembrie	7.4	7.8	7.2	7.4	7.8	8.4	9.4	8.9
Decembrie	8.2	8.4	7.9	8.7	9.1	9.2	10.2	10.1

Tabelul 7.3.67. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	9.8	9.9	Mai	7.0	7.2	Septembrie	7.9	8.0
Februarie	9.5	9.6	Iunie	5.9	6.1	Octombrie	8.5	8.7
Martie	9.1	9.2	Iulie	6.1	6.3	Noiembrie	9.2	9.3
Aprilie	8.6	8.6	August	6.7	6.8	Decembrie	10.1	10.2




Figura 7.3.53. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.54. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.68. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	9.80	9.88	0.82	0.67	Ianuarie	9.90	9.93	0.30	0.09
Februarie	9.50	9.79	3.05	9.32	Februarie	9.60	9.81	2.19	4.79
Martie	9.10	9.07	-0.33	0.11	Martie	9.20	9.12	-0.87	0.76
Aprilie	8.60	8.58	-0.23	0.05	Aprilie	8.60	8.65	0.58	0.34
Mai	7.00	7.10	1.43	2.04	Mai	7.20	7.16	-0.56	0.31
Iunie	5.90	5.97	1.19	1.41	Iunie	6.10	6.00	-1.64	2.69
Iulie	6.10	6.04	-0.98	0.97	Iulie	6.30	6.16	-2.22	4.94
August	6.70	6.77	1.04	1.09	August	6.80	6.82	0.29	0.09
Septembrie	7.90	7.85	-0.63	0.40	Septembrie	8.00	7.91	-1.13	1.27
Octombrie	8.50	8.55	0.59	0.35	Octombrie	8.70	8.61	-1.03	1.07
Noiembrie	9.20	9.03	-1.85	3.41	Noiembrie	9.30	9.11	-2.04	4.17
Decembrie	10.10	10.14	0.40	0.16	Decembrie	10.20	10.17	-0.29	0.09
$S_{2017}$		19.97			$S_{2018}$		20.59		
$S_{total} = 40.56$									



### □ RNA bayesiană, lunar

Tabelul 7.3.69. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	9.80	9.83	0.31	0.09	Ianuarie	9.90	9.92	0.20	0.04
Februarie	9.50	9.53	0.32	0.10	Februarie	9.60	9.63	0.31	0.10
Martie	9.10	9.13	0.33	0.11	Martie	9.20	9.23	0.33	0.11
Aprilie	8.60	8.56	-0.47	0.22	Aprilie	8.60	8.63	0.35	0.12
Mai	7.00	6.92	-1.14	1.31	Mai	7.20	7.13	-0.97	0.95
Iunie	5.90	5.92	0.34	0.11	Iunie	6.10	6.06	-0.66	0.43
Iulie	6.10	6.14	0.66	0.43	Iulie	6.30	6.24	-0.95	0.91
August	6.70	6.74	0.60	0.36	August	6.80	6.83	0.44	0.19
Septembrie	7.90	7.86	-0.51	0.26	Septembrie	8.00	8.03	0.37	0.14
Octombrie	8.50	8.54	0.47	0.22	Octombrie	8.70	8.74	0.46	0.21
Noiembrie	9.20	9.15	-0.54	0.30	Noiembrie	9.30	9.24	-0.65	0.42
Decembrie	10.10	10.04	-0.59	0.35	Decembrie	10.20	10.13	-0.69	0.47
$S_{2017}$	3.85				$S_{2018}$	4.08			
$S_{total} = 7.93$									

### A7.3.4.3. A doua zi de joi a fiecărei luni, ora 9

Tabelul 7.3.71. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	5.0	6.3	6.5	6.8	6.9	7.1	7.9	9.0
Februarie	4.9	5.1	5.3	6.0	6.7	7.0	7.1	8.0
Martie	4.5	5.0	4.8	5.8	6.3	5.9	6.5	6.8
Aprilie	4.0	4.4	4.7	5.4	5.1	5.7	6.1	6.4
Mai	3.7	3.8	4.1	5.1	5.0	5.0	5.6	5.9
Iunie	3.2	3.6	3.9	4.6	4.8	4.9	5.2	5.8
Iulie	3.8	3.6	4.4	4.5	4.7	5.0	5.5	5.9
August	4.0	3.4	4.0	4.4	4.5	4.6	5.9	5.6
Septembrie	4.2	3.9	4.2	4.1	4.5	4.9	6.3	5.9
Octombrie	4.4	4.6	5.0	5.3	5.4	5.6	6.4	6.6
Noiembrie	5.5	5.2	6.1	6.4	6.2	6.9	7.5	7.8
Decembrie	6.8	6.3	8.3	7.2	7.4	8.1	9.2	9.2




Figura 7.3.57. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Tabelul 7.3.72. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.5	8.8	Mai	5.8	6.0	Septembrie	6.0	6.3
Februarie	7.8	7.9	Iunie	5.6	5.7	Octombrie	6.6	6.8
Martie	6.8	6.9	Iulie	5.8	5.9	Noiembrie	7.8	8.0
Aprilie	6.4	6.5	August	5.7	5.9	Decembrie	9.1	9.2




Figura 7.3.58. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.73. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.50	8.62	1.41	1.99	Ianuarie	8.80	8.66	1.41	1.99
Februarie	7.80	7.68	-1.54	2.37	Februarie	7.90	7.71	-1.54	2.37
Martie	6.80	6.61	-2.79	7.81	Martie	6.90	6.64	-2.79	7.81
Aprilie	6.40	6.35	-0.78	0.61	Aprilie	6.50	6.39	-0.78	0.61
Mai	5.80	5.88	1.38	1.90	Mai	6.00	5.91	1.38	1.90
Iunie	5.60	5.69	1.61	2.58	Iunie	5.70	5.77	1.61	2.58
Iulie	5.80	5.88	1.38	1.90	Iulie	5.90	5.97	1.38	1.90
August	5.70	5.86	2.81	7.88	August	5.90	5.96	2.81	7.88
Septembrie	6.00	6.14	2.33	5.44	Septembrie	6.30	6.18	2.33	5.44
Octombrie	6.60	6.71	1.67	2.78	Octombrie	6.80	6.73	1.67	2.78
Noiembrie	7.80	7.83	0.38	0.15	Noiembrie	8.00	7.87	0.38	0.15
Decembrie	9.10	9.45	3.85	14.79	Decembrie	9.20	9.48	3.85	14.79
$S_{2017}$	50.21				$S_{2018}$	48.17			
$S_{total} = 98.38$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.74. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.50	8.92	4.94	24.42	Ianuarie	8.80	9.21	4.66	21.71
Februarie	7.80	7.83	0.38	0.15	Februarie	7.90	7.94	0.51	0.26
Martie	6.80	6.83	0.44	0.19	Martie	6.90	6.93	0.43	0.19
Aprilie	6.40	6.38	-0.31	0.10	Aprilie	6.50	6.52	0.31	0.09

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă
Mai	5.80	5.82	0.34	0.12	Mai	6.00	5.96	-0.67	0.44
Iunie	5.60	5.56	-0.71	0.51	Iunie	5.70	5.67	-0.53	0.28
Iulie	5.80	5.78	-0.34	0.12	Iulie	5.90	5.97	1.19	1.41
August	5.70	5.73	0.53	0.28	August	5.90	5.94	0.68	0.46
Septembrie	6.00	6.05	0.83	0.69	Septembrie	6.30	6.25	-0.79	0.63
Octombrie	6.60	6.56	-0.61	0.37	Octombrie	6.80	6.77	-0.44	0.19
Noiembrie	7.80	7.77	-0.38	0.15	Noiembrie	8.00	7.94	-0.75	0.56
Decembrie	9.10	9.06	-0.44	0.19	Decembrie	9.20	9.27	0.76	0.58
$S_{2017}$	27.28				$S_{2018}$	26.80			
$S_{total} = 54.08$									

#### A7.3.4.4. A doua zi de joi a fiecărei luni, ora 21

Tabelul 7.3.76. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	8.2	8.7	8.9	9.0	9.5	10.1	10.6	8.2
Februarie	7.2	8.4	8.5	8.9	9.0	9.2	9.3	7.2
Martie	7.1	8.2	8.6	8.6	7.9	8.5	8.4	7.1
Aprilie	6.7	7.4	7.0	7.2	7.6	7.8	7.9	6.7
Mai	4.9	5.3	5.5	6.0	6.2	6.8	6.7	4.9
Iunie	4.8	5.0	5.1	5.6	5.5	5.7	5.8	4.8
Iulie	4.6	4.6	5.0	5.0	5.4	6.2	5.9	4.6
August	4.7	5.2	5.6	5.7	5.8	6.4	6.3	4.7
Septembrie	4.8	6.0	6.1	6.6	7.0	7.5	7.4	4.8
Octombrie	6.8	7.2	7.5	7.3	7.6	8.2	8.3	6.8
Noiembrie	7.5	8.0	8.3	8.2	9.2	9.8	9.7	7.5
Decembrie	9.0	9.4	9.0	9.2	9.8	10.7	10.6	9.0

Tabelul 7.3.77. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	10.5	10.6	Mai	6.8	6.9	Septembrie	7.6	7.6
Februarie	9.5	9.5	Iunie	5.9	5.9	Octombrie	8.4	8.5
Martie	8.6	8.7	Iulie	6.1	6.2	Noiembrie	9.9	10.0
Aprilie	8.1	8.1	August	6.4	6.5	Decembrie	10.8	10.9




Figura 7.3.61. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.62. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.78. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	10.50	10.53	0.29	0.08	Ianuarie	10.60	10.68	0.75	0.57
Februarie	9.50	9.57	0.74	0.54	Februarie	9.50	9.65	1.58	2.49
Martie	8.60	8.72	1.40	1.95	Martie	8.70	8.79	1.03	1.07
Aprilie	8.10	8.15	0.62	0.38	Aprilie	8.10	8.20	1.23	1.52
Mai	6.80	6.89	1.32	1.75	Mai	6.90	6.99	1.30	1.70
Iunie	5.90	5.85	-0.85	0.72	Iunie	5.90	5.92	0.34	0.11
Iulie	6.10	5.99	-1.80	3.25	Iulie	6.20	6.11	-1.45	2.11
August	6.40	6.46	0.94	0.88	August	6.50	6.54	0.62	0.38
Septembrie	7.60	7.68	1.05	1.11	Septembrie	7.60	7.75	1.97	3.90
Octombrie	8.40	8.35	-0.60	0.35	Octombrie	8.50	8.46	-0.47	0.22
Noiembrie	9.90	9.98	0.81	0.65	Noiembrie	10.00	10.07	0.70	0.49
Decembrie	10.80	10.49	-2.87	8.24	Decembrie	10.90	10.64	-2.39	5.69
$S_{2017}$	19.91				$S_{2018}$	20.26			
$S_{total} = 40.17$									

### □ RNA bayesiană, lunar

Tabelul 7.3.79. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	10.50	10.54	0.38	0.15	Ianuarie	10.60	10.56	-0.38	0.14
Februarie	9.50	9.46	-0.42	0.18	Februarie	9.50	9.55	0.53	0.28
Martie	8.60	8.65	0.58	0.34	Martie	8.70	8.67	-0.34	0.12
Aprilie	8.10	8.04	-0.74	0.55	Aprilie	8.10	8.06	-0.49	0.24
Mai	6.80	6.77	-0.44	0.19	Mai	6.90	6.95	0.72	0.53
Iunie	5.90	5.87	-0.51	0.26	Iunie	5.90	5.93	0.51	0.26
Iulie	6.10	6.07	-0.49	0.24	Iulie	6.20	6.16	-0.65	0.42

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
August	6.40	6.45	0.78	0.61	August	6.50	6.53	0.46	0.21
Septembrie	7.60	7.57	-0.39	0.16	Septembrie	7.60	7.63	0.39	0.16
Octombrie	8.40	8.43	0.36	0.13	Octombrie	8.50	8.52	0.24	0.06
Noiembrie	9.90	9.85	-0.51	0.26	Noiembrie	10.00	9.95	-0.50	0.25
Decembrie	10.80	10.77	-0.28	0.08	Decembrie	10.90	10.82	-0.73	0.54
$S_{2017}$	3.13				$S_{2018}$	3.19			
$S_{total} = 6.32$									

#### A7.3.4.5. Ultima zi de marți a fiecărei luni, ora 9

Tabelul 7.3.81. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	6.4	6.6	7.0	6.9	7.2	7.8	8.7	9.0
Februarie	5.2	5.2	6.5	7.1	7.0	7.2	7.6	8.1
Martie	4.8	5.4	5.4	5.8	5.9	6.4	6.8	6.9
Aprilie	4.3	4.9	5.0	4.9	5.4	5.6	5.7	6.1
Mai	3.7	4.0	4.3	4.5	4.8	5.0	5.4	5.7
Iunie	3.3	4.2	4.2	4.4	4.2	4.7	4.9	5.2
Iulie	3.6	4.0	4.2	4.0	4.0	4.2	5.4	5.8
August	3.8	4.1	4.2	4.1	4.3	4.8	5.5	5.6
Septembrie	4.5	4.6	4.9	4.8	5.2	5.2	5.8	5.8
Octombrie	5.0	5.0	5.4	5.5	5.6	5.8	7.0	6.7
Noiembrie	5.4	5.2	6.0	6.0	6.8	7.2	8.2	8.1
Decembrie	7.0	7.1	6.8	6.7	7.4	8.5	8.9	9.2

Tabelul 7.3.82. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.9	9.1	Mai	5.6	5.7	Septembrie	5.9	5.9
Februarie	8.0	8.1	Iunie	5.2	5.2	Octombrie	6.8	7.0
Martie	7.0	7.0	Iulie	5.6	5.7	Noiembrie	8.2	8.3
Aprilie	6.1	6.1	August	5.6	5.7	Decembrie	9.3	9.3




Figura 7.3.65. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.66. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.83. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.90	8.99	1.01	1.02	Ianuarie	9.10	9.00	-1.10	1.21
Februarie	8.00	7.97	-0.38	0.14	Februarie	8.10	8.04	-0.74	0.55
Martie	7.00	7.05	0.71	0.51	Martie	7.00	7.05	0.71	0.51
Aprilie	6.10	5.98	-1.97	3.87	Aprilie	6.10	5.99	-1.80	3.25
Mai	5.60	5.57	-0.54	0.29	Mai	5.70	5.59	-1.93	3.72
Iunie	5.20	5.16	-0.77	0.59	Iunie	5.20	5.17	-0.58	0.33
Iulie	5.60	5.62	0.36	0.13	Iulie	5.70	5.63	-1.23	1.51
August	5.60	5.68	1.43	2.04	August	5.70	5.74	0.70	0.49
Septembrie	5.90	5.93	0.51	0.26	Septembrie	5.90	5.92	0.34	0.11
Octombrie	6.80	6.88	1.18	1.38	Octombrie	7.00	6.90	-1.43	2.04
Noiembrie	8.20	8.34	1.71	2.91	Noiembrie	8.30	8.36	0.72	0.52
Decembrie	9.30	9.34	0.43	0.18	Decembrie	9.30	9.33	0.32	0.10
$S_{2017}$	13.33				$S_{2018}$	14.36			
$S_{total} = 27.69$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.84. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.90	8.98	0.90	0.81	Ianuarie	9.10	9.01	-0.99	0.98
Februarie	8.00	7.97	-0.38	0.14	Februarie	8.10	8.13	0.37	0.14
Martie	7.00	6.98	-0.29	0.08	Martie	7.00	7.05	0.71	0.51
Aprilie	6.10	6.12	0.33	0.11	Aprilie	6.10	6.16	0.98	0.97
Mai	5.60	5.65	0.89	0.80	Mai	5.70	5.80	1.75	3.08
Iunie	5.20	5.22	0.38	0.15	Iunie	5.20	5.23	0.58	0.33
Iulie	5.60	5.71	1.96	3.86	Iulie	5.70	5.74	0.70	0.49

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
August	5.60	5.65	0.89	0.80	August	5.70	5.68	-0.35	0.12
Septembrie	5.90	5.92	0.34	0.11	Septembrie	5.90	5.95	0.85	0.72
Octombrie	6.80	6.82	0.29	0.09	Octombrie	7.00	7.04	0.57	0.33
Noiembrie	8.20	8.24	0.49	0.24	Noiembrie	8.30	8.32	0.24	0.06
Decembrie	9.30	9.25	-0.54	0.29	Decembrie	9.30	9.33	0.32	0.10
$S_{2017}$	7.47				$S_{2018}$	7.83			
$S_{total} = 15.30$									

#### A7.3.4.6. Ultima zi de marți a fiecărei luni, ora 21

Tabelul 7.3.86. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	8.4	9.1	8.9	8.6	9.1	9.5	9.9	10.8
Februarie	7.3	7.6	8.0	8.4	8.7	9.0	8.9	9.3
Martie	6.8	7.3	7.9	8.0	7.9	8.8	8.5	8.9
Aprilie	6.2	6.7	6.2	6.2	6.4	6.5	7.1	7.6
Mai	4.9	5.3	4.8	5.2	5.5	6.0	6.4	6.5
Iunie	4.8	5.2	4.8	4.8	5.2	5.8	6.1	6.2
Iulie	5.0	4.8	4.6	4.7	5.3	5.7	6.0	5.9
August	5.2	5.5	5.6	6.0	6.2	6.7	7.0	6.9
Septembrie	5.8	6.2	6.2	7.1	6.8	7.1	7.8	7.8
Octombrie	7.0	7.6	7.5	7.8	7.6	8.2	8.6	8.7
Noiembrie	8.2	8.0	7.4	7.8	8.5	9.3	9.8	9.6
Decembrie	9.5	9.1	8.6	8.8	9.2	9.7	10.2	10.5

Tabelul 7.3.87. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	10.6	10.6	Mai	6.6	6.6	Septembrie	7.9	8.0
Februarie	9.5	9.4	Iunie	6.3	6.3	Octombrie	8.9	8.9
Martie	9.2	9.0	Iulie	6.2	6.1	Noiembrie	10.0	10.0
Aprilie	7.4	7.5	August	7.2	7.2	Decembrie	10.6	10.7




Figura 7.3.69. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.70. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.88. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă
Ianuarie	10.60	10.42	-1.70	2.88	Ianuarie	10.60	10.46	-1.32	1.74
Februarie	9.50	9.32	-1.89	3.59	Februarie	9.40	9.24	-1.70	2.90
Martie	9.20	8.97	-2.50	6.25	Martie	9.00	8.93	-0.78	0.60
Aprilie	7.40	7.36	-0.54	0.29	Aprilie	7.50	7.43	-0.93	0.87
Mai	6.60	6.67	1.06	1.12	Mai	6.60	6.75	2.27	5.17
Iunie	6.30	6.29	-0.16	0.03	Iunie	6.30	6.37	1.11	1.23
Iulie	6.20	6.14	-0.97	0.94	Iulie	6.10	6.22	1.97	3.87
August	7.20	7.08	-1.67	2.78	August	7.20	7.15	-0.69	0.48
Septembrie	7.90	7.93	0.38	0.14	Septembrie	8.00	7.96	-0.50	0.25
Octombrie	8.90	8.94	0.45	0.20	Octombrie	8.90	8.98	0.90	0.81
Noiembrie	10.00	10.04	0.40	0.16	Noiembrie	10.00	10.12	1.20	1.44
Decembrie	10.60	10.45	-1.42	2.00	Decembrie	10.70	10.51	-1.78	3.15
$S_{2017}$	20.39				$S_{2018}$	22.52			
$S_{total} = 42.91$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.89. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă
Ianuarie	10.60	10.63	0.28	0.08	Ianuarie	10.60	10.67	0.66	0.44
Februarie	9.50	9.41	-0.95	0.90	Februarie	9.40	9.47	0.74	0.55
Martie	9.20	9.08	-1.30	1.70	Martie	9.00	9.12	1.33	1.78
Aprilie	7.40	7.34	-0.81	0.66	Aprilie	7.50	7.42	-1.07	1.14
Mai	6.60	6.62	0.30	0.09	Mai	6.60	6.64	0.61	0.37
Iunie	6.30	6.28	-0.32	0.10	Iunie	6.30	6.35	0.79	0.63
Iulie	6.20	6.11	-1.45	2.11	Iulie	6.10	6.06	-0.66	0.43
August	7.20	7.14	-0.83	0.69	August	7.20	7.14	-0.83	0.69



2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Septembrie	7.90	7.93	0.38	0.14	Septembrie	8.00	8.05	0.63	0.39
Octombrie	8.90	8.93	0.34	0.11	Octombrie	8.90	8.95	0.56	0.32
Noiembrie	10.00	9.96	-0.40	0.16	Noiembrie	10.00	10.06	0.60	0.36
Decembrie	10.60	10.56	-0.38	0.14	Decembrie	10.70	10.65	-0.47	0.22
$S_{2017}$	6.89				$S_{2018}$	7.31			
$S_{total} = 14.20$									

### A7.3.5. Stația Deta

#### A7.3.5.1. Prima zi de miercuri a fiecărei luni, ora 9

Tabelul 7.3.91. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	4.8	5.4	5.2	5.5	5.4	5.6	5.5	5.3
Februarie	4.6	5.2	5.4	5.3	5.4	5.4	5.3	5.3
Martie	4.3	4.1	5.1	5.0	5.2	5.4	5.1	5.0
Aprilie	4.2	4.8	4.9	4.8	5.0	4.9	5.0	4.8
Mai	4.2	4.6	4.8	4.4	4.9	4.8	4.7	4.7
Iunie	4.6	4.7	4.8	4.6	4.8	4.6	4.5	4.4
Iulie	4.8	4.4	4.6	4.5	4.5	4.3	4.6	4.3
August	4.9	4.5	4.4	4.3	4.2	4.2	4.5	4.2
Septembrie	5.2	5.0	4.8	4.5	4.4	4.6	4.4	4.3
Octombrie	5.4	5.1	4.9	4.6	4.8	4.7	4.6	4.5
Noiembrie	5.4	5.6	5.4	4.9	5.0	5.0	5.1	4.9
Decembrie	5.8	6.0	5.7	5.6	5.5	5.4	5.4	5.5

Tabelul 7.3.92. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	5.2	5.1	Mai	4.5	4.5	Septembrie	4.3	4.2
Februarie	5.1	5.0	Iunie	4.3	4.2	Octombrie	4.4	4.3
Martie	5.0	4.8	Iulie	4.2	4.2	Noiembrie	4.8	4.7
Aprilie	4.7	4.6	August	4.1	4.1	Decembrie	5.4	5.3




Figura 7.3.73. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.74. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.93. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Januarie	5.20	5.31	2.12	4.47	Januarie	5.10	5.18	1.57	2.46
Februarie	5.10	5.17	1.37	1.88	Februarie	5.00	5.06	1.20	1.44
Martie	5.00	4.96	-0.80	0.64	Martie	4.80	4.87	1.46	2.13
Aprilie	4.70	4.82	2.55	6.52	Aprilie	4.60	4.70	2.17	4.73
Mai	4.50	4.66	3.56	12.64	Mai	4.50	4.62	2.67	7.11
Iunie	4.30	4.37	1.63	2.65	Iunie	4.20	4.24	0.95	0.91
Iulie	4.20	4.13	-1.67	2.78	Iulie	4.20	4.15	-1.19	1.42
August	4.10	4.09	-0.24	0.06	August	4.10	4.02	-1.95	3.81
Septembrie	4.30	4.22	-1.86	3.46	Septembrie	4.20	4.15	-1.19	1.42
Octombrie	4.40	4.37	-0.68	0.46	Octombrie	4.30	4.22	-1.86	3.46
Noiembrie	4.80	4.77	-0.63	0.39	Noiembrie	4.70	4.63	-1.49	2.22
Decembrie	5.40	5.28	-2.22	4.94	Decembrie	5.30	5.12	-3.40	11.53
$S_{2017}$	40.90				$S_{2018}$	42.63			
$S_{total} = 83.53$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.94. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Januarie	5.20	5.23	0.58	0.33	Januarie	5.10	5.14	0.78	0.62
Februarie	5.10	5.09	-0.20	0.04	Februarie	5.00	4.98	-0.40	0.16
Martie	5.00	4.98	-0.40	0.16	Martie	4.80	4.82	0.42	0.17
Aprilie	4.70	4.73	0.64	0.41	Aprilie	4.60	4.62	0.43	0.19
Mai	4.50	4.55	1.11	1.23	Mai	4.50	4.46	-0.89	0.79
Iunie	4.30	4.27	-0.70	0.49	Iunie	4.20	4.22	0.48	0.23

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	4.20	4.23	0.71	0.51	Iulie	4.20	4.17	-0.71	0.51
August	4.10	4.12	0.49	0.24	August	4.10	4.07	-0.73	0.54
Septembrie	4.30	4.26	-0.93	0.87	Septembrie	4.20	4.23	0.71	0.51
Octombrie	4.40	4.42	0.45	0.21	Octombrie	4.30	4.34	0.93	0.87
Noiembrie	4.80	4.83	0.63	0.39	Noiembrie	4.70	4.74	0.85	0.72
Decembrie	5.40	5.37	-0.56	0.31	Decembrie	5.30	5.33	0.57	0.32
$S_{2017}$	5.18				$S_{2018}$	5.62			
$S_{total} = 10.80$									

### A7.3.5.2. Prima zi de miercuri a fiecărei luni, ora 21

Tabelul 7.3.96. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	6.1	6.6	6.9	6.2	6.0	6.2	6.0	6.2
Februarie	5.6	5.8	6.4	6.0	5.8	5.9	5.7	5.8
Martie	5.4	5.6	6.0	5.8	5.7	5.8	5.6	5.6
Aprilie	5.3	5.3	5.8	5.6	5.5	5.4	5.4	5.4
Mai	4.8	4.6	5.0	4.9	5.2	4.7	4.9	5.0
Iunie	4.8	4.7	4.6	4.4	4.8	4.8	4.7	4.7
Iulie	4.5	4.4	4.1	4.4	4.5	4.3	4.6	4.5
August	4.2	4.0	4.1	4.0	4.0	4.3	4.4	4.3
Septembrie	5.0	4.5	4.7	4.6	5.1	5.3	5.2	4.9
Octombrie	5.3	5.0	5.4	5.0	5.4	5.6	5.6	5.4
Noiembrie	5.8	5.9	5.7	5.5	5.8	5.6	6.0	5.7
Decembrie	6.5	6.8	6.4	5.9	6.1	6.2	6.3	6.1

Tabelul 7.3.97. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	6.1	6.2	Mai	4.9	5.0	Septembrie	5.1	5.2
Februarie	5.8	5.9	Iunie	4.7	4.8	Octombrie	5.5	5.6
Martie	5.7	5.7	Iulie	4.5	4.6	Noiembrie	5.8	5.9
Aprilie	5.4	5.5	August	4.3	4.4	Decembrie	6.2	6.3




Figura 7.3.77. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.78. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.98. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	6.10	6.21	1.80	3.25	Ianuarie	6.20	6.26	0.97	0.94
Februarie	5.80	5.96	2.76	7.61	Februarie	5.90	5.99	1.53	2.33
Martie	5.70	5.77	1.23	1.51	Martie	5.70	5.81	1.93	3.72
Aprilie	5.40	5.51	2.04	4.15	Aprilie	5.50	5.57	1.27	1.62
Mai	4.90	4.97	1.43	2.04	Mai	5.00	5.04	0.80	0.64
Iunie	4.70	4.61	-1.91	3.67	Iunie	4.80	4.69	-2.29	5.25
Iulie	4.50	4.39	-2.44	5.98	Iulie	4.60	4.48	-2.61	6.81
August	4.30	4.21	-2.09	4.38	August	4.40	4.31	-2.05	4.18
Septembrie	5.10	5.01	-1.76	3.11	Septembrie	5.20	5.06	-2.69	7.25
Octombrie	5.50	5.44	-1.09	1.19	Octombrie	5.60	5.48	-2.14	4.59
Noiembrie	5.80	5.64	-2.76	7.61	Noiembrie	5.90	5.73	-2.88	8.30
Decembrie	6.20	6.12	-1.29	1.66	Decembrie	6.30	6.21	-1.43	2.04
$S_{2017}$	46.16				$S_{2018}$	47.67			
$S_{total} = 93.83$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.99. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	6.10	6.12	0.33	0.11	Ianuarie	6.20	6.16	-0.65	0.42
Februarie	5.80	5.78	-0.34	0.12	Februarie	5.90	5.83	-1.19	1.41
Martie	5.70	5.69	-0.18	0.03	Martie	5.70	5.67	-0.53	0.28
Aprilie	5.40	5.48	1.48	2.19	Aprilie	5.50	5.46	-0.73	0.53
Mai	4.90	4.96	1.22	1.50	Mai	5.00	4.98	-0.40	0.16
Iunie	4.70	4.74	0.85	0.72	Iunie	4.80	4.76	-0.83	0.69
Iulie	4.50	4.55	1.11	1.23	Iulie	4.60	4.59	-0.22	0.05

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
August	4.30	4.32	0.47	0.22	August	4.40	4.36	-0.91	0.83
Septembrie	5.10	5.12	0.39	0.15	Septembrie	5.20	5.15	-0.96	0.92
Octombrie	5.50	5.53	0.55	0.30	Octombrie	5.60	5.55	-0.89	0.80
Noiembrie	5.80	5.83	0.52	0.27	Noiembrie	5.90	5.86	-0.68	0.46
Decembrie	6.20	6.23	0.48	0.23	Decembrie	6.30	6.26	-0.63	0.40
$S_{2017}$	7.08				$S_{2018}$	6.94			
$S_{total} = 14.02$									

### A7.3.5.3. A doua zi de joi a fiecărei luni, ora 9

Tabelul 7.3.101. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	6.0	6.2	6.1	5.9	5.7	5.4	5.7	5.8
Februarie	5.5	6.1	5.9	5.6	5.3	5.2	5.1	5.2
Martie	5.4	5.4	5.8	5.3	5.1	5.0	4.9	4.8
Aprilie	5.4	5.0	5.3	4.9	5.0	4.8	4.7	4.6
Mai	5.0	5.0	5.2	4.8	4.9	4.6	4.5	4.5
Iunie	5.0	4.8	5.1	4.7	4.8	4.6	4.4	4.3
Iulie	4.3	4.0	4.7	4.4	5.2	4.6	4.5	4.3
August	4.0	4.2	4.3	4.3	4.0	4.1	4.3	4.1
Septembrie	4.9	4.8	4.6	4.3	4.1	4.1	4.3	4.1
Octombrie	5.0	4.7	4.8	5.0	4.8	4.3	4.5	4.2
Noiembrie	5.6	5.3	5.2	5.2	5.0	4.9	5.2	4.9
Decembrie	6.0	6.2	5.9	5.6	5.5	5.9	6.0	5.9

Tabelul 7.3.102. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	5.6	5.5	Mai	4.4	4.3	Septembrie	4.1	4.0
Februarie	5.1	5.0	Iunie	4.3	4.2	Octombrie	4.2	4.2
Martie	4.8	4.7	Iulie	4.4	4.3	Noiembrie	4.9	4.9
Aprilie	4.6	4.5	August	4.1	4.0	Decembrie	5.8	5.7




Figura 7.3.81. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.82. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.103. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	5.60	5.58	-0.36	0.13	Ianuarie	5.50	5.56	1.09	1.19
Februarie	5.10	5.17	1.37	1.88	Februarie	5.00	5.09	1.80	3.24
Martie	4.80	4.93	2.71	7.34	Martie	4.70	4.84	2.98	8.87
Aprilie	4.60	4.69	1.96	3.83	Aprilie	4.50	4.61	2.44	5.98
Mai	4.40	4.51	2.50	6.25	Mai	4.30	4.43	3.02	9.14
Iunie	4.30	4.4	2.33	5.41	Iunie	4.20	4.31	2.62	6.86
Iulie	4.40	4.51	2.50	6.25	Iulie	4.30	4.43	3.02	9.14
August	4.10	4.12	0.49	0.24	August	4.00	4.05	1.25	1.56
Septembrie	4.10	3.99	-2.68	7.20	Septembrie	4.00	3.94	-1.50	2.25
Octombrie	4.20	4.28	1.90	3.63	Octombrie	4.20	4.24	0.95	0.91
Noiembrie	4.90	4.97	1.43	2.04	Noiembrie	4.90	4.93	0.61	0.37
Decembrie	5.80	5.78	-0.34	0.12	Decembrie	5.70	5.73	0.53	0.28
$S_{2017}$	44.31				$S_{2018}$	49.79			
$S_{total} = 94.10$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.104. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	5.60	5.57	-0.54	0.29	Ianuarie	5.50	5.52	0.36	0.13
Februarie	5.10	5.06	-0.78	0.62	Februarie	5.00	5.03	0.60	0.36
Martie	4.80	4.77	-0.63	0.39	Martie	4.70	4.73	0.64	0.41
Aprilie	4.60	4.56	-0.87	0.76	Aprilie	4.50	4.48	-0.44	0.20
Mai	4.40	4.37	-0.68	0.46	Mai	4.30	4.28	-0.47	0.22
Iunie	4.30	4.33	0.70	0.49	Iunie	4.20	4.22	0.48	0.23

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	4.40	4.44	0.91	0.83	Iulie	4.30	4.34	0.93	0.87
August	4.10	4.13	0.73	0.54	August	4.00	4.04	1.00	1.00
Septembrie	4.10	4.13	0.73	0.54	Septembrie	4.00	4.06	1.50	2.25
Octombrie	4.20	4.23	0.71	0.51	Octombrie	4.20	4.22	0.48	0.23
Noiembrie	4.90	4.94	0.82	0.67	Noiembrie	4.90	4.92	0.41	0.17
Decembrie	5.80	5.78	-0.34	0.12	Decembrie	5.70	5.74	0.70	0.49
$S_{2017}$	6.19				$S_{2018}$	6.54			
$S_{total} = 12.73$									

#### A7.3.5.4. A doua zi de joi a fiecărei luni, ora 21

Tabelul 7.3.106. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	6.5	6.8	7.0	6.5	6.4	6.2	6.2	6.3
Februarie	5.8	6.4	6.6	6.1	6.0	5.8	5.9	5.7
Martie	5.5	6.0	6.3	5.8	5.9	5.7	5.6	5.6
Aprilie	5.4	5.7	5.7	5.6	5.8	5.6	5.4	5.3
Mai	5.0	4.8	5.0	5.0	4.7	4.8	4.7	4.6
Iunie	5.0	4.7	4.8	4.7	4.8	5.1	4.8	4.5
Iulie	4.9	4.5	4.4	4.5	4.3	4.4	4.2	4.3
August	4.7	4.3	4.5	4.5	4.3	4.2	4.4	4.6
Septembrie	5.0	4.8	5.0	5.2	5.3	4.7	5.1	5.0
Octombrie	5.8	5.8	5.6	5.6	5.4	5.2	5.3	5.2
Noiembrie	6.4	6.6	5.9	6.0	6.1	5.6	5.8	5.6
Decembrie	6.9	7.0	6.4	6.4	6.3	6.1	6.2	6.1

Tabelul 7.3.107. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	6.1	6.0	Mai	4.6	4.5	Septembrie	4.8	4.8
Februarie	5.7	5.6	Iunie	4.7	4.5	Octombrie	5.1	5.1
Martie	5.5	5.4	Iulie	4.2	4.1	Noiembrie	5.6	5.5
Aprilie	5.3	5.2	August	4.3	4.3	Decembrie	6.0	5.9




Figura 7.3.85. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.86. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.108. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	6.10	6.21	1.80	3.25	Ianuarie	6.00	6.17	2.83	8.03
Februarie	5.70	5.75	0.88	0.77	Februarie	5.60	5.69	1.61	2.58
Martie	5.50	5.65	2.73	7.44	Martie	5.40	5.57	3.15	9.91
Aprilie	5.30	5.41	2.08	4.31	Aprilie	5.20	5.35	2.88	8.32
Mai	4.60	4.65	1.09	1.18	Mai	4.50	4.57	1.56	2.42
Iunie	4.70	4.75	1.06	1.13	Iunie	4.50	4.64	3.11	9.68
Iulie	4.20	4.24	0.95	0.91	Iulie	4.10	4.18	1.95	3.81
August	4.30	4.4	2.33	5.41	August	4.30	4.37	1.63	2.65
Septembrie	4.80	4.97	3.54	12.54	Septembrie	4.80	4.91	2.29	5.25
Octombrie	5.10	5.16	1.18	1.38	Octombrie	5.10	5.13	0.59	0.35
Noiembrie	5.60	5.54	-1.07	1.15	Noiembrie	5.50	5.52	0.36	0.13
Decembrie	6.00	6.05	0.83	0.69	Decembrie	5.90	5.97	1.19	1.41
$S_{2017}$	40.17				$S_{2018}$	54.54			
$S_{total} = 94.71$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.109. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	6.10	6.07	-0.49	0.24	Ianuarie	6.00	6.02	0.33	0.11
Februarie	5.70	5.67	-0.53	0.28	Februarie	5.60	5.64	0.71	0.51
Martie	5.50	5.5	0.00	0.00	Martie	5.40	5.42	0.37	0.14
Aprilie	5.30	5.28	-0.38	0.14	Aprilie	5.20	5.23	0.58	0.33
Mai	4.60	4.58	-0.43	0.19	Mai	4.50	4.54	0.89	0.79
Iunie	4.70	4.63	-1.49	2.22	Iunie	4.50	4.55	1.11	1.23



2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	4.20	4.22	0.48	0.23	Iulie	4.10	4.14	0.98	0.95
August	4.30	4.34	0.93	0.87	August	4.30	4.33	0.70	0.49
Septembrie	4.80	4.83	0.63	0.39	Septembrie	4.80	4.76	-0.83	0.69
Octombrie	5.10	5.12	0.39	0.15	Octombrie	5.10	5.13	0.59	0.35
Noiembrie	5.60	5.62	0.36	0.13	Noiembrie	5.50	5.54	0.73	0.53
Decembrie	6.00	6.04	0.67	0.44	Decembrie	5.90	5.93	0.51	0.26
$S_{2017}$	5.28				$S_{2018}$	6.38			
$S_{total} = 11.66$									

### A7.3.5.5. Ultima zi de marți a fiecărei luni, ora 9

Tabelul 7.3.111. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	5.9	6.1	6.3	6.1	6.0	5.9	5.8	5.9
Februarie	5.5	5.6	6.0	5.8	5.7	5.6	5.6	5.4
Martie	5.1	5.4	5.5	5.4	5.5	5.3	5.2	5.1
Aprilie	5.0	5.0	4.8	4.6	4.6	4.4	4.3	4.6
Mai	5.0	4.5	5.0	4.4	4.3	4.2	4.1	4.2
Iunie	4.2	4.1	4.6	4.1	4.2	4.0	4.1	4.0
Iulie	4.0	4.0	4.2	3.9	4.0	4.1	4.3	4.0
August	4.5	4.5	4.5	4.2	4.2	4.1	4.4	4.2
Septembrie	5.2	4.8	4.6	4.3	4.4	4.2	4.3	4.3
Octombrie	5.6	5.0	5.1	4.8	4.6	4.5	4.8	4.6
Noiembrie	5.8	5.6	5.3	5.3	5.1	4.8	5.2	5.3
Decembrie	6.2	6.4	6.0	5.9	5.8	5.7	5.8	5.7

Tabelul 7.3.112. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	5.8	5.7	Mai	4.1	4.0	Septembrie	4.2	4.1
Februarie	5.5	5.4	Iunie	4.0	3.9	Octombrie	4.6	4.5
Martie	5.1	5.0	Iulie	4.1	4.0	Noiembrie	5.0	5.0
Aprilie	4.4	4.4	August	4.2	4.1	Decembrie	5.7	5.6




Figura 7.3.89. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.90. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.113. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	5.80	5.89	1.55	2.41	Ianuarie	5.70	5.79	1.58	2.49
Februarie	5.50	5.6	1.82	3.31	Februarie	5.40	5.51	2.04	4.15
Martie	5.10	5.24	2.75	7.54	Martie	5.00	5.19	3.80	14.44
Aprilie	4.40	4.28	-2.73	7.44	Aprilie	4.40	4.31	-2.05	4.18
Mai	4.10	3.99	-2.68	7.20	Mai	4.00	3.93	-1.75	3.06
Iunie	4.00	4.05	1.25	1.56	Iunie	3.90	3.99	2.31	5.33
Iulie	4.10	4.14	0.98	0.95	Iulie	4.00	4.08	2.00	4.00
August	4.20	4.11	-2.14	4.59	August	4.10	4.01	-2.20	4.82
Septembrie	4.20	4.13	-1.67	2.78	Septembrie	4.10	4.06	-0.98	0.95
Octombrie	4.60	4.48	-2.61	6.81	Octombrie	4.50	4.44	-1.33	1.78
Noiembrie	5.00	4.89	-2.20	4.84	Noiembrie	5.00	4.92	-1.60	2.56
Decembrie	5.70	5.63	-1.23	1.51	Decembrie	5.60	5.57	-0.54	0.29
$S_{2017}$	50.92				$S_{2018}$	48.05			
$S_{total} = 98.97$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.114. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	5.80	5.78	-0.34	0.12	Ianuarie	5.70	5.73	0.53	0.28
Februarie	5.50	5.46	-0.73	0.53	Februarie	5.40	5.43	0.56	0.31
Martie	5.10	5.08	-0.39	0.15	Martie	5.00	5.04	0.80	0.64
Aprilie	4.40	4.43	0.68	0.46	Aprilie	4.40	4.37	-0.68	0.46
Mai	4.10	4.07	-0.73	0.54	Mai	4.00	4.02	0.50	0.25
Iunie	4.00	3.97	-0.75	0.56	Iunie	3.90	3.93	0.77	0.59

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	4.10	4.07	-0.73	0.54	Iulie	4.00	4.03	0.75	0.56
August	4.20	4.16	-0.95	0.91	August	4.10	4.13	0.73	0.54
Septembrie	4.20	4.16	-0.95	0.91	Septembrie	4.10	4.13	0.73	0.54
Octombrie	4.60	4.56	-0.87	0.76	Octombrie	4.50	4.53	0.67	0.44
Noiembrie	5.00	4.97	-0.60	0.36	Noiembrie	5.00	4.95	-1.00	1.00
Decembrie	5.70	5.67	-0.53	0.28	Decembrie	5.60	5.63	0.54	0.29
$S_{2017}$	6.11				$S_{2018}$	5.90			
$S_{total} = 12.01$									

### A7.3.5.6. Ultima zi de marți a fiecărei luni, ora 21

Tabelul 7.3.116. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	6.8	6.9	7.1	6.7	6.6	6.5	6.6	6.6
Februarie	5.8	6.3	6.6	6.4	6.2	5.9	6.0	5.9
Martie	5.4	5.7	6.0	5.8	5.5	5.6	5.5	5.4
Aprilie	5.0	5.1	5.3	5.0	5.0	4.8	4.9	4.8
Mai	4.8	5.0	4.5	4.4	4.3	4.4	4.3	4.2
Iunie	4.6	4.4	4.2	4.0	4.2	4.1	4.4	4.2
Iulie	4.2	4.1	3.9	4.0	4.1	4.2	4.3	4.1
August	4.6	4.4	4.2	4.1	4.5	4.2	4.4	4.3
Septembrie	5.4	4.8	5.1	4.8	5.0	4.8	5.0	4.9
Octombrie	5.8	5.4	5.6	5.5	5.6	5.4	5.8	5.6
Noiembrie	6.6	6.4	6.2	5.9	6.1	6.0	6.3	6.2
Decembrie	7.0	7.0	6.9	6.8	6.7	6.6	6.7	6.8

Tabelul 7.3.117. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	6.4	6.3	Mai	4.2	4.1	Septembrie	4.8	4.7
Februarie	5.8	5.7	Iunie	4.1	4.0	Octombrie	5.5	5.4
Martie	5.4	5.3	Iulie	4.1	4.0	Noiembrie	6.0	6.0
Aprilie	4.7	4.6	August	4.2	4.2	Decembrie	6.6	6.5




Figura 7.3.93. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.94. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.118. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	6.40	6.56	2.50	6.25	Ianuarie	6.30	6.45	2.38	5.67
Februarie	5.80	5.92	2.07	4.28	Februarie	5.70	5.83	2.28	5.20
Martie	5.40	5.36	-0.74	0.55	Martie	5.30	5.32	0.38	0.14
Aprilie	4.70	4.86	3.40	11.59	Aprilie	4.60	4.76	3.48	12.10
Mai	4.20	4.28	1.90	3.63	Mai	4.10	4.21	2.68	7.20
Iunie	4.10	4.17	1.71	2.91	Iunie	4.00	4.09	2.25	5.06
Iulie	4.10	4.05	-1.22	1.49	Iulie	4.00	3.98	-0.50	0.25
August	4.20	4.15	-1.19	1.42	August	4.20	4.11	-2.14	4.59
Septembrie	4.80	4.72	-1.67	2.78	Septembrie	4.70	4.66	-0.85	0.72
Octombrie	5.50	5.38	-2.18	4.76	Octombrie	5.40	5.31	-1.67	2.78
Noiembrie	6.00	5.94	-1.00	1.00	Noiembrie	6.00	5.96	-0.67	0.44
Decembrie	6.60	6.53	-1.06	1.12	Decembrie	6.50	6.44	-0.92	0.85
$S_{2017}$	41.78				$S_{2018}$	45.01			
$S_{total} = 86.79$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.119. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	6.40	6.37	-0.47	0.22	Ianuarie	6.30	6.26	-0.63	0.40
Februarie	5.80	5.76	-0.69	0.48	Februarie	5.70	5.73	0.53	0.28
Martie	5.40	5.38	-0.37	0.14	Martie	5.30	5.33	0.57	0.32
Aprilie	4.70	4.67	-0.64	0.41	Aprilie	4.60	4.62	0.43	0.19
Mai	4.20	4.18	-0.48	0.23	Mai	4.10	4.12	0.49	0.24
Iunie	4.10	4.06	-0.98	0.95	Iunie	4.00	4.03	0.75	0.56
Iulie	4.10	4.08	-0.49	0.24	Iulie	4.00	4.04	1.00	1.00
August	4.20	4.22	0.48	0.23	August	4.20	4.23	0.71	0.51

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Septembrie	4.80	4.77	-0.63	0.39	Septembrie	4.70	4.73	0.64	0.41
Octombrie	5.50	5.46	-0.73	0.53	Octombrie	5.40	5.43	0.56	0.31
Noiembrie	6.00	6.03	0.50	0.25	Noiembrie	6.00	6.04	0.67	0.44
Decembrie	6.60	6.57	-0.45	0.21	Decembrie	6.50	6.52	0.31	0.09
$S_{2017}$	4.26				$S_{2018}$	4.76			
$S_{total} = 9.02$									

### A7.3.6. Stația Satchinez

#### A7.3.6.1. Prima zi de miercuri a fiecărei luni, ora 9

Tabelul 7.3.121. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.2	8.0	8.0	8.8	8.1	8.2	7.8	7.5
Februarie	6.8	7.6	7.8	8.0	8.2	8.3	7.9	7.9
Martie	6.2	7.4	7.2	7.5	8.0	8.2	7.7	7.8
Aprilie	6.0	6.8	6.4	6.6	7.6	6.9	6.7	6.6
Mai	5.2	5.8	6.0	5.4	6.1	6.0	5.9	6.1
Iunie	5.4	5.8	5.9	6.0	6.2	6.1	5.6	5.8
Iulie	6.0	6.2	6.0	6.4	6.0	5.9	5.8	5.7
August	6.1	6.0	6.2	6.5	6.0	5.8	5.6	5.7
Septembrie	6.7	6.4	6.4	6.8	6.8	6.2	5.8	5.6
Octombrie	6.8	6.2	7.2	7.4	7.2	6.6	6.3	6.2
Noiembrie	7.2	7.4	7.5	7.2	7.5	7.0	6.8	6.8
Decembrie	7.0	8.0	8.5	7.6	8.0	7.7	7.5	7.6

Tabelul 7.3.122. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	7.6	7.5	Mai	5.8	5.8	Septembrie	5.7	5.6
Februarie	7.8	7.7	Iunie	5.7	5.6	Octombrie	6.2	6.1
Martie	7.7	7.6	Iulie	5.6	5.7	Noiembrie	6.7	6.6
Aprilie	6.5	6.4	August	5.5	5.5	Decembrie	7.4	7.3




Figura 7.3.97. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.98. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.123. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	7.60	7.63	0.39	0.16	Ianuarie	7.50	7.37	-1.73	3.00
Februarie	7.80	7.59	-2.69	7.25	Februarie	7.70	7.51	-2.47	6.09
Martie	7.70	7.54	-2.08	4.32	Martie	7.60	7.36	-3.16	9.97
Aprilie	6.50	6.37	-2.00	4.00	Aprilie	6.40	6.29	-1.72	2.95
Mai	5.80	5.63	-2.93	8.59	Mai	5.80	5.66	-2.41	5.83
Iunie	5.70	5.53	-2.98	8.90	Iunie	5.60	5.45	-2.68	7.17
Iulie	5.60	5.57	-0.54	0.29	Iulie	5.70	5.52	-3.16	9.97
August	5.50	5.55	0.91	0.83	August	5.50	5.41	-1.64	2.68
Septembrie	5.70	5.76	1.05	1.11	Septembrie	5.60	5.53	-1.25	1.56
Octombrie	6.20	6.32	1.94	3.75	Octombrie	6.10	6.08	-0.33	0.11
Noiembrie	6.70	6.67	-0.45	0.20	Noiembrie	6.60	6.47	-1.97	3.88
Decembrie	7.40	7.47	0.95	0.89	Decembrie	7.30	7.26	-0.55	0.30
$S_{2017}$	40.27				$S_{2018}$	53.52			
$S_{total} = 93.79$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.124. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	7.60	7.63	0.39	0.16	Ianuarie	7.50	7.46	-0.53	0.28
Februarie	7.80	7.82	0.26	0.07	Februarie	7.70	7.67	-0.39	0.15
Martie	7.70	7.73	0.39	0.15	Martie	7.60	7.66	0.79	0.62
Aprilie	6.50	6.54	0.62	0.38	Aprilie	6.40	6.37	-0.47	0.22
Mai	5.80	5.88	1.38	1.90	Mai	5.80	5.9	1.72	2.97
Iunie	5.70	5.67	-0.53	0.28	Iunie	5.60	5.62	0.36	0.13

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	5.60	5.68	1.43	2.04	Iulie	5.70	5.66	-0.70	0.49
August	5.50	5.48	-0.36	0.13	August	5.50	5.54	0.73	0.53
Septembrie	5.70	5.74	0.70	0.49	Septembrie	5.60	5.63	0.54	0.29
Octombrie	6.20	6.23	0.48	0.23	Octombrie	6.10	6.13	0.49	0.24
Noiembrie	6.70	6.68	-0.30	0.09	Noiembrie	6.60	6.57	-0.45	0.21
Decembrie	7.40	7.37	-0.41	0.16	Decembrie	7.30	7.34	0.55	0.30
$S_{2017}$	6.08				$S_{2018}$	6.44			
$S_{total} = 12.52$									

### A7.3.6.2. Prima zi de miercuri a fiecărei luni, ora 21

Tabelul 7.3.126. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.7	8.5	8.5	8.8	8.5	8.6	8.5	8.4
Februarie	7.5	8.4	8.6	8.3	8.4	8.5	8.3	8.0
Martie	7.0	8.3	7.9	8.2	8.3	7.9	7.8	7.7
Aprilie	7.0	7.5	7.7	6.9	8.1	7.8	7.3	7.4
Mai	5.8	5.8	6.0	5.6	6.2	6.0	6.1	5.9
Iunie	6.0	6.3	6.1	5.8	6.2	6.2	6.0	5.8
Iulie	6.4	6.5	6.2	6.0	6.0	6.1	6.0	5.7
August	6.5	6.4	6.7	6.8	6.5	6.6	6.4	6.1
Septembrie	6.4	6.5	6.9	7.1	7.4	6.8	6.7	6.6
Octombrie	6.1	6.0	7.1	7.6	7.8	7.4	7.0	7.1
Noiembrie	7.2	6.9	7.8	7.8	7.6	7.5	7.2	7.3
Decembrie	8.0	8.5	8.1	8.6	8.7	8.4	8.2	8.1

Tabelul 7.3.127. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.3	8.2	Mai	5.9	5.8	Septembrie	6.6	6.5
Februarie	8.1	8.0	Iunie	5.9	5.8	Octombrie	7.0	6.9
Martie	7.6	7.6	Iulie	5.8	5.7	Noiembrie	7.2	7.1
Aprilie	7.4	7.2	August	6.2	6.1	Decembrie	8.1	8.0




Figura 7.3.101. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.102. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.128. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.30	8.22	-0.96	0.93	Ianuarie	8.20	8.05	-1.83	3.35
Februarie	8.10	8.02	-0.99	0.98	Februarie	8.00	7.83	-2.13	4.52
Martie	7.60	7.77	2.24	5.00	Martie	7.60	7.63	0.39	0.16
Aprilie	7.40	7.21	-2.57	6.59	Aprilie	7.20	7.04	-2.22	4.94
Mai	5.90	5.72	-3.05	9.31	Mai	5.80	5.63	-2.93	8.59
Iunie	5.90	5.69	-3.56	12.67	Iunie	5.80	5.59	-3.62	13.11
Iulie	5.80	5.66	-2.41	5.83	Iulie	5.70	5.55	-2.63	6.93
August	6.20	6.23	0.48	0.23	August	6.10	6.05	-0.82	0.67
Septembrie	6.60	6.56	-0.61	0.37	Septembrie	6.50	6.43	-1.08	1.16
Octombrie	7.00	7.1	1.43	2.04	Octombrie	6.90	6.99	1.30	1.70
Noiembrie	7.20	7.17	-0.42	0.17	Noiembrie	7.10	7.01	-1.27	1.61
Decembrie	8.10	8.05	-0.62	0.38	Decembrie	8.00	7.96	-0.50	0.25
$S_{2017}$	44.50				$S_{2018}$	46.97			
$S_{total} = 91.47$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.129. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.30	8.25	-0.60	0.36	Ianuarie	8.20	8.16	-0.49	0.24
Februarie	8.10	8.06	-0.49	0.24	Februarie	8.00	8.03	0.37	0.14
Martie	7.60	7.64	0.53	0.28	Martie	7.60	7.56	-0.53	0.28
Aprilie	7.40	7.34	-0.81	0.66	Aprilie	7.20	7.27	0.97	0.95
Mai	5.90	5.87	-0.51	0.26	Mai	5.80	5.76	-0.69	0.48
Iunie	5.90	5.87	-0.51	0.26	Iunie	5.80	5.84	0.69	0.48
Iulie	5.80	5.76	-0.69	0.48	Iulie	5.70	5.74	0.70	0.49



2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
August	6.20	6.24	0.65	0.42	August	6.10	6.14	0.66	0.43
Septembrie	6.60	6.64	0.61	0.37	Septembrie	6.50	6.45	-0.77	0.59
Octombrie	7.00	6.97	-0.43	0.18	Octombrie	6.90	6.93	0.43	0.19
Noiembrie	7.20	7.16	-0.56	0.31	Noiembrie	7.10	7.06	-0.56	0.32
Decembrie	8.10	8.15	0.62	0.38	Decembrie	8.00	8.04	0.50	0.25
$S_{2017}$	4.19				$S_{2018}$	4.82			
$S_{total} = 9.01$									

### A7.3.6.3. A doua zi de joi a fiecărei luni, ora 9

Tabelul 7.3.131. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.0	8.0	8.2	8.5	8.6	8.4	8.5	8.4
Februarie	6.8	7.8	7.6	7.9	8.2	7.9	8.0	7.8
Martie	6.2	7.4	7.3	7.6	7.8	7.7	7.6	7.4
Aprilie	6.0	6.8	6.9	6.6	6.7	6.8	7.1	6.9
Mai	5.4	5.5	5.9	6.0	6.6	6.4	6.3	6.2
Iunie	5.2	5.7	6.0	6.1	6.3	5.9	5.8	5.7
Iulie	5.2	5.5	5.6	6.4	6.2	6.3	5.7	5.8
August	6.0	6.2	6.2	6.0	6.4	6.0	5.8	5.9
Septembrie	6.2	6.2	6.6	6.8	6.8	6.5	6.6	6.4
Octombrie	6.5	6.9	7.3	7.2	6.9	6.8	6.6	6.9
Noiembrie	6.8	7.1	7.8	7.8	7.7	7.2	7.1	7.3
Decembrie	7.5	8.0	8.5	8.6	8.3	8.4	8.3	8.2

Tabelul 7.3.132. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.3	8.2	Mai	6.2	6.1	Septembrie	6.4	6.3
Februarie	7.7	7.8	Iunie	5.7	5.6	Octombrie	6.6	6.5
Martie	7.4	7.3	Iulie	5.8	5.7	Noiembrie	7.1	7.1
Aprilie	6.8	6.8	August	5.8	5.7	Decembrie	8.1	8.0




Figura 7.3.105. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.106. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.133. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.30	8.41	1.33	1.76	Ianuarie	8.20	8.36	1.95	3.81
Februarie	7.70	7.81	1.43	2.04	Februarie	7.80	7.85	0.64	0.41
Martie	7.40	7.52	1.62	2.63	Martie	7.30	7.44	1.92	3.68
Aprilie	6.80	6.85	0.74	0.54	Aprilie	6.80	6.84	0.59	0.35
Mai	6.20	6.14	-0.97	0.94	Mai	6.10	6.13	0.49	0.24
Iunie	5.70	5.85	2.63	6.93	Iunie	5.60	5.79	3.39	11.51
Iulie	5.80	5.87	1.21	1.46	Iulie	5.70	5.83	2.28	5.20
August	5.80	6.01	3.62	13.11	August	5.70	5.90	3.51	12.31
Septembrie	6.40	6.51	1.72	2.95	Septembrie	6.30	6.44	2.22	4.94
Octombrie	6.60	6.77	2.58	6.63	Octombrie	6.50	6.67	2.62	6.84
Noiembrie	7.10	7.26	2.25	5.08	Noiembrie	7.10	7.24	1.97	3.89
Decembrie	8.10	8.27	2.10	4.40	Decembrie	8.00	8.19	2.37	5.64
$S_{2017}$	48.47				$S_{2018}$	58.82			
$S_{total} = 107.29$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.134. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.30	8.33	0.36	0.13	Ianuarie	8.20	8.22	0.24	0.06
Februarie	7.70	7.78	1.04	1.08	Februarie	7.80	7.72	-1.03	1.05
Martie	7.40	7.44	0.54	0.29	Martie	7.30	7.35	0.68	0.47
Aprilie	6.80	6.84	0.59	0.35	Aprilie	6.80	6.76	-0.59	0.35
Mai	6.20	6.17	-0.48	0.23	Mai	6.10	6.06	-0.66	0.43
Iunie	5.70	5.68	-0.35	0.12	Iunie	5.60	5.63	0.54	0.29

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	5.80	5.78	-0.34	0.12	Iulie	5.70	5.73	0.53	0.28
August	5.80	5.83	0.52	0.27	August	5.70	5.74	0.70	0.49
Septembrie	6.40	6.43	0.47	0.22	Septembrie	6.30	6.27	-0.48	0.23
Octombrie	6.60	6.58	-0.30	0.09	Octombrie	6.50	6.53	0.46	0.21
Noiembrie	7.10	7.14	0.56	0.32	Noiembrie	7.10	7.05	-0.70	0.50
Decembrie	8.10	8.13	0.37	0.14	Decembrie	8.00	8.04	0.50	0.25
$S_{2017}$	3.36				$S_{2018}$	4.60			
$S_{total} = 7.96$									

### 7.3.6.4. A doua zi de joi a fiecărei luni, ora 21

Tabelul 7.3.136. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.8	8.5	8.5	8.9	9.0	8.7	8.6	8.5
Februarie	7.8	8.5	8.3	8.4	8.5	8.4	8.3	8.1
Martie	8.0	8.8	8.6	8.5	8.6	8.4	8.0	7.9
Aprilie	7.0	7.8	7.4	7.3	7.6	7.6	7.5	7.3
Mai	6.1	6.5	6.8	7.0	7.2	6.9	6.8	6.6
Iunie	6.0	7.2	6.6	6.4	7.0	6.6	6.5	6.4
Iulie	5.8	6.0	6.1	6.2	6.5	6.2	6.4	6.1
August	6.7	6.2	6.8	6.9	7.0	6.7	6.0	6.1
Septembrie	6.4	6.8	6.5	7.0	7.1	6.8	6.5	6.3
Octombrie	7.2	8.0	8.0	7.8	7.7	7.3	7.1	6.9
Noiembrie	7.8	8.2	7.7	8.5	8.0	7.6	7.6	7.5
Decembrie	8.4	9.0	8.6	8.9	8.8	8.7	8.8	8.6

Tabelul 7.3.137. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.4	8.3	Mai	6.6	6.5	Septembrie	6.4	6.2
Februarie	8.1	7.9	Iunie	6.4	6.2	Octombrie	7.0	6.8
Martie	7.9	7.8	Iulie	6.1	6.0	Noiembrie	7.4	7.3
Aprilie	7.3	7.2	August	6.1	6.0	Decembrie	8.5	8.4




Figura 7.3.109. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.110. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### RNA bayesiană, curba de sarcină

Tabelul 7.3.138. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.40	8.35	-0.60	0.35	Ianuarie	8.30	8.27	-0.36	0.13
Februarie	8.10	8.05	-0.62	0.38	Februarie	7.90	7.97	0.89	0.79
Martie	7.90	7.97	0.89	0.79	Martie	7.80	7.85	0.64	0.41
Aprilie	7.30	7.19	-1.51	2.27	Aprilie	7.20	7.13	-0.97	0.95
Mai	6.60	6.57	-0.45	0.21	Mai	6.50	6.53	0.46	0.21
Iunie	6.40	6.37	-0.47	0.22	Iunie	6.20	6.27	1.13	1.27
Iulie	6.10	5.95	-2.46	6.05	Iulie	6.00	5.88	-2.00	4.00
August	6.10	6.33	3.77	14.22	August	6.00	6.19	3.17	10.03
Septembrie	6.40	6.49	1.41	1.98	Septembrie	6.20	6.4	3.23	10.41
Octombrie	7.00	7.19	2.71	7.37	Octombrie	6.80	7.04	3.53	12.46
Noiembrie	7.40	7.48	1.08	1.17	Noiembrie	7.30	7.4	1.37	1.88
Decembrie	8.50	8.42	-0.94	0.89	Decembrie	8.40	8.35	-0.60	0.35
$S_{2017}$	35.88				$S_{2018}$	42.88			
$S_{total} = 78.76$									

#### RNA bayesiană, lunar

Tabelul 7.3.139. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.40	8.42	0.24	0.06	Ianuarie	8.30	8.27	-0.36	0.13
Februarie	8.10	8.07	-0.37	0.14	Februarie	7.90	7.94	0.51	0.26
Martie	7.90	7.87	-0.38	0.14	Martie	7.80	7.84	0.51	0.26
Aprilie	7.30	7.33	0.41	0.17	Aprilie	7.20	7.24	0.56	0.31
Mai	6.60	6.66	0.91	0.83	Mai	6.50	6.58	1.23	1.51
Iunie	6.40	6.36	-0.63	0.39	Iunie	6.20	6.25	0.81	0.65

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	6.10	6.12	0.33	0.11	Iulie	6.00	6.03	0.50	0.25
August	6.10	6.03	-1.15	1.32	August	6.00	5.97	-0.50	0.25
Septembrie	6.40	6.37	-0.47	0.22	Septembrie	6.20	6.26	0.97	0.94
Octombrie	7.00	6.91	-1.29	1.65	Octombrie	6.80	6.86	0.88	0.78
Noiembrie	7.40	7.38	-0.27	0.07	Noiembrie	7.30	7.27	-0.41	0.17
Decembrie	8.50	8.53	0.35	0.12	Decembrie	8.40	8.44	0.48	0.23
$S_{2017}$	5.22				$S_{2018}$	5.73			
$S_{total} = 10.95$									

#### A7.3.6.5. Ultima zi de marți a fiecărei luni, ora 9

Tabelul 7.3.141. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	7.5	7.4	8.3	8.2	8.5	8.4	8.5	8.2
Februarie	6.9	7.0	7.4	7.8	8.0	8.0	7.9	7.6
Martie	6.6	6.5	7.2	7.0	7.4	6.9	7.2	7.0
Aprilie	6.0	6.2	6.1	6.0	6.8	6.4	6.4	6.6
Mai	6.8	6.2	6.2	6.0	6.5	6.2	6.3	6.0
Iunie	6.4	6.1	6.0	6.1	6.0	6.0	5.9	6.0
Iulie	6.0	5.8	6.2	6.5	6.4	6.1	6.0	5.9
August	6.0	5.8	6.4	6.5	6.8	5.9	5.7	6.0
Septembrie	7.2	6.4	6.5	6.4	7.1	6.3	6.2	6.3
Octombrie	6.6	6.7	6.6	6.4	7.3	6.5	6.5	6.7
Noiembrie	6.8	7.4	7.1	7.4	7.6	7.2	7.2	7.1
Decembrie	7.4	8.0	8.1	8.3	8.5	8.4	8.1	7.9

Tabelul 7.3.142. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.2	8.1	Mai	6.0	5.9	Septembrie	6.1	6.1
Februarie	7.6	7.5	Iunie	5.8	5.8	Octombrie	6.5	6.4
Martie	6.9	6.9	Iulie	5.9	5.8	Noiembrie	7.0	7.2
Aprilie	6.4	6.3	August	5.8	5.7	Decembrie	8.0	7.8




Figura 7.3.113. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.114. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.143. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.20	8.15	-0.61	0.37	Ianuarie	8.10	8.08	-0.25	0.06
Februarie	7.60	7.63	0.39	0.16	Februarie	7.50	7.56	0.80	0.64
Martie	6.90	6.99	1.30	1.70	Martie	6.90	6.93	0.43	0.19
Aprilie	6.40	6.27	-2.03	4.13	Aprilie	6.30	6.22	-1.27	1.61
Mai	6.00	6.09	1.50	2.25	Mai	5.90	6.04	2.37	5.63
Iunie	5.80	5.94	2.41	5.83	Iunie	5.80	5.88	1.38	1.90
Iulie	5.90	6.01	1.86	3.48	Iulie	5.80	5.96	2.76	7.61
August	5.80	6.03	3.97	15.73	August	5.70	5.99	5.09	25.88
Septembrie	6.10	6.25	2.46	6.05	Septembrie	6.10	6.21	1.80	3.25
Octombrie	6.50	6.62	1.85	3.41	Octombrie	6.40	6.56	2.50	6.25
Noiembrie	7.00	7.21	3.00	9.00	Noiembrie	7.20	7.15	-0.69	0.48
Decembrie	8.00	8.08	1.00	1.00	Decembrie	7.80	7.92	1.54	2.37
$S_{2017}$	53.09				$S_{2018}$	55.88			
$S_{Total} = 108.97$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.144. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Ianuarie	8.20	8.23	0.37	0.13	Ianuarie	8.10	8.14	0.37	0.13
Februarie	7.60	7.63	0.39	0.16	Februarie	7.50	7.47	0.39	0.16
Martie	6.90	6.94	0.58	0.34	Martie	6.90	6.84	0.58	0.34
Aprilie	6.40	6.37	-0.47	0.22	Aprilie	6.30	6.36	-0.47	0.22
Mai	6.00	5.97	-0.50	0.25	Mai	5.90	5.95	-0.50	0.25
Iunie	5.80	5.82	0.34	0.12	Iunie	5.80	5.76	0.34	0.12

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abateră relativă [%]	Abateră pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abateră relativă [%]	Abateră pătratică relativă
Iulie	5.90	5.86	-0.68	0.46	Iulie	5.80	5.78	-0.68	0.46
August	5.80	5.78	-0.34	0.12	August	5.70	5.66	-0.34	0.12
Septembrie	6.10	6.15	0.82	0.67	Septembrie	6.10	6.06	0.82	0.67
Octombrie	6.50	6.47	-0.46	0.21	Octombrie	6.40	6.36	-0.46	0.21
Noiembrie	7.00	7.11	1.57	2.47	Noiembrie	7.20	7.12	1.57	2.47
Decembrie	8.00	7.96	-0.50	0.25	Decembrie	7.80	7.83	-0.50	0.25
$S_{2017}$	5.40				$S_{2018}$	6.08			
$S_{total} = 11.48$									

### A7.3.6.6. Ultima zi de marți a fiecărei luni, ora 21

Tabelul 7.3.146. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)

Anul / Luna	2009	2010	2011	2012	2013	2014	2015	2016
Ianuarie	8.2	8.6	8.9	8.6	9.0	9.1	8.9	8.7
Februarie	7.5	7.8	8.1	8.0	8.5	8.4	8.3	8.2
Martie	7.8	8.0	8.2	7.9	8.6	8.0	8.0	7.9
Aprilie	7.0	7.1	6.8	6.8	8.0	7.2	7.4	7.1
Mai	5.9	6.0	5.8	6.6	7.2	6.7	6.8	6.5
Iunie	6.8	6.5	6.2	6.3	7.0	6.4	6.3	6.2
Iulie	6.4	6.5	6.4	6.4	7.0	6.4	6.4	6.3
August	6.8	6.4	6.5	6.8	7.8	6.7	6.9	6.7
Septembrie	6.4	6.0	6.6	6.9	7.2	6.8	6.6	6.8
Octombrie	6.5	6.4	7.0	7.5	8.5	7.6	7.0	7.2
Noiembrie	7.5	7.6	7.6	7.9	8.2	8.2	7.9	8.0
Decembrie	8.3	8.6	8.5	8.5	8.6	8.7	8.5	8.6

Tabelul 7.3.147. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Anul / Luna	2017	2018	Anul / Luna	2017	2018	Anul / Luna	2017	2018
Ianuarie	8.7	8.6	Mai	6.5	6.3	Septembrie	6.6	6.5
Februarie	8.1	8.0	Iunie	6.2	6.1	Octombrie	7.1	7.0
Martie	7.8	7.7	Iulie	6.2	6.3	Noiembrie	7.9	7.8
Aprilie	7.1	7.0	August	6.6	6.5	Decembrie	8.4	8.3




Figura 7.3.117. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.118. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

#### □ RNA bayesiană, curba de sarcină

Tabelul 7.3.148. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă
Ianuarie	8.65	8.65	-0.56	0.32	Ianuarie	8.60	8.66	0.70	0.49
Februarie	8.21	8.21	1.36	1.84	Februarie	8.00	8.14	1.75	3.06
Martie	7.84	7.84	0.51	0.26	Martie	7.70	7.81	1.43	2.04
Aprilie	7.23	7.23	1.80	3.23	Aprilie	7.00	7.20	2.86	8.16
Mai	6.46	6.46	-0.62	0.38	Mai	6.30	6.42	1.90	3.63
Iunie	6.04	6.04	-2.58	6.66	Iunie	6.10	6.01	-1.48	2.18
Iulie	6.02	6.02	-2.90	8.43	Iulie	6.30	6.09	-3.33	11.11
August	6.47	6.47	-1.97	3.88	August	6.50	6.44	-0.92	0.85
Septembrie	6.51	6.51	-1.36	1.86	Septembrie	6.50	6.48	-0.31	0.09
Octombrie	6.85	6.85	-3.52	12.40	Octombrie	7.00	6.74	-3.71	13.80
Noiembrie	7.84	7.84	-0.76	0.58	Noiembrie	7.80	7.82	0.26	0.07
Decembrie	8.49	8.49	1.07	1.15	Decembrie	8.30	8.41	1.33	1.76
$S_{2017}$	40.99				$S_{2018}$	47.23			
$S_{total} = 88.22$									

#### □ RNA bayesiană, lunar

Tabelul 7.3.149. Curbele de sarcină prognozate pentru perioada 2017-2018 (puterile în MW)

2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abateri relativă [%]	Abateri pătratică relativă
Ianuarie	8.70	8.67	-0.34	0.12	Ianuarie	8.60	8.56	-0.47	0.22
Februarie	8.10	8.12	0.25	0.06	Februarie	8.00	8.05	0.63	0.39
Martie	7.80	7.83	0.38	0.15	Martie	7.70	7.74	0.52	0.27
Aprilie	7.10	7.14	0.56	0.32	Aprilie	7.00	6.96	-0.57	0.33
Mai	6.50	6.45	-0.77	0.59	Mai	6.30	6.27	-0.48	0.23
Iunie	6.20	6.17	-0.48	0.23	Iunie	6.10	6.13	0.49	0.24



2017					2018				
Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Luna	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
Iulie	6.20	6.30	1.61	2.60	Iulie	6.30	6.35	0.79	0.63
August	6.60	6.56	-0.61	0.37	August	6.50	6.56	0.92	0.85
Septembrie	6.60	6.64	0.61	0.37	Septembrie	6.50	6.58	1.23	1.51
Octombrie	7.10	7.05	-0.70	0.50	Octombrie	7.00	6.94	-0.86	0.73
Noiembrie	7.90	7.93	0.38	0.14	Noiembrie	7.80	7.85	0.64	0.41
Decembrie	8.40	8.38	-0.24	0.06	Decembrie	8.30	8.26	-0.48	0.23
$S_{2017}$	5.50				$S_{2018}$	6.05			
$S_{total} = 11.55$									

### A7.3.7. Analiza comparativă a rezultatelor

Tabelul 7.3.152. Indicii specifici de performanță – stația Bucovina

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	6	Bucovina, marți, 21	82.72	3.45	10.22	0.43
2	18	Bucovina, miercuri, 21	96.39	4.02	27.33	1.14
3	19	Bucovina, miercuri, 9	77.62	3.23	30.87	1.29
4	25	Bucovina, joi, 21	192.0	8.00	43.12	1.80
5	26	Bucovina, joi, 9	116.1	4.84	45.08	1.88
6	27	Bucovina, marți, 9	89.67	3.74	45.12	1.88
<b>Total</b>	121		654.50	27.28	201.74	8.42

Tabelul 7.3.153. Indicii specifici de performanță – stația IMT

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	20	IMT, joi, 21	129.2	5.38	32.34	1.35
2	21	IMT, marți, 21	114.0	4.75	38.32	1.60
3	23	IMT, miercuri, 21	134.1	5.59	40.38	1.68
4	24	IMT, joi, 9	202.4	8.43	42.85	1.79
5	28	IMT, marți, 9	150.1	6.25	45.56	1.90
6	30	IMT, miercuri, 9	312.8	13.03	59.03	2.46
<b>Total</b>	146		1042.6	43.43	258.48	10.78

Tabelul 7.3.154. Indicii specifici de performanță – stația Musicescu

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	1	Musicescu, joi, 21	40.17	1.67	6.32	0.26
2	2	Musicescu, miercuri, 21	40.56	1.69	7.93	0.33
3	16	Musicescu, marți, 21	42.91	1.79	14.20	0.59
4	17	Musicescu, marți, 9	27.69	1.15	15.30	0.64
5	22	Musicescu, miercuri, 9	116.0	4.83	39.74	1.66
6	29	Musicescu, joi, 9	98.38	4.10	54.08	2.25
<b>Total</b>	87		365.71	15.23	137.57	5.73

Tabelul 7.3.155. Indicii specifici de performanță – stația Deta

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	4	Deta, marți, 21	86.79	3.62	9.02	0.38
2	7	Deta, miercuri, 9	83.53	3.48	10.80	0.45
3	11	Deta, joi, 21	94.71	3.95	11.66	0.49
4	12	Deta, marți, 9	98.97	4.12	12.01	0.50
5	14	Deta, joi, 9	94.10	3.92	12.73	0.53
6	15	Deta, miercuri, 21	93.83	3.91	14.02	0.58
<b>Total</b>	63		551.93	23.00	70.24	2.93

Tabelul 7.3.156. Indicii specifici de performanță – stația Satchinez

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	3	Satchinez, joi, 9	107.3	4.47	7.96	0.33
2	5	Satchinez, miercuri, 21	91.47	3.81	9.01	0.38
3	8	Satchinez, joi, 21	78.76	3.28	10.95	0.46
4	9	Satchinez, marți, 9	109.0	4.54	11.48	0.48
5	10	Satchinez, marți, 21	88.22	3.68	11.55	0.48
6	13	Satchinez, miercuri, 9	93.79	3.91	12.52	0.52
<b>Total</b>	48		568.54	23.69	63.47	2.65

Tabelul 7.3.158. Clasament zile – marți

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	4	Deta, marți, 21	86.79	3.62	9.02	0.38
2	6	Bucovina, marți, 21	82.72	3.45	10.22	0.43
3	9	Satchinez, marți, 9	109.0	4.54	11.48	0.48
4	10	Satchinez, marți, 21	88.22	3.68	11.55	0.48
5	12	Deta, marți, 9	98.97	4.12	12.01	0.50
6	16	Musicescu, marți, 21	42.91	1.79	14.20	0.59
7	17	Musicescu, marți, 9	27.69	1.15	15.30	0.64
8	21	IMT, marți, 21	114.0	4.75	38.32	1.60
9	27	Bucovina, marți, 9	89.67	3.74	45.12	1.88
10	28	IMT, marți, 9	150.1	6.25	45.56	1.90
<b>Total</b>	150		890.07	37.09	212.78	8.88

Tabelul 7.3.159. Clasament zile – miercuri

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	2	Musicescu, miercuri, 21	40.56	1.69	7.93	0.33
2	5	Satchinez, miercuri, 21	91.47	3.81	9.01	0.38
3	7	Deta, miercuri, 9	83.53	3.48	10.80	0.45
4	13	Satchinez, miercuri, 9	93.79	3.91	12.52	0.52
5	15	Deta, miercuri, 21	93.83	3.91	14.02	0.58
6	18	Bucovina, miercuri, 21	96.39	4.02	27.33	1.14
7	19	Bucovina, miercuri, 9	77.62	3.23	30.87	1.29
8	22	Musicescu, miercuri, 9	116.0	4.83	39.74	1.66
9	23	IMT, miercuri, 21	134.1	5.59	40.38	1.68
10	30	IMT, miercuri, 9	312.8	13.03	59.03	2.46
<b>Total</b>	154		1140.09	47.50	251.63	10.49

Tabelul 7.3.160. Clasament zile – joi

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	1	Mucescu, joi, 21	40.17	1.67	6.32	0.26
2	3	Satchinez, joi, 9	107.3	4.47	7.96	0.33
3	8	Satchinez, joi, 21	78.76	3.28	10.95	0.46
4	11	Deta, joi, 21	94.71	3.95	11.66	0.49
5	14	Deta, joi, 9	94.10	3.92	12.73	0.53
6	20	IMT, joi, 21	129.2	5.38	32.34	1.35
7	24	IMT, joi, 9	202.4	8.43	42.85	1.79
8	25	Bucovina, joi, 21	192.0	8.00	43.12	1.80
9	26	Bucovina, joi, 9	116.1	4.84	45.08	1.88
10	29	Mucescu, joi, 9	98.38	4.10	54.08	2.25
<b>Total</b>	161		1153.12	48.04	267.09	11.14

Tabelul 7.3.162. Clasament ore – ora 9

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	3	Satchinez, joi, 9	107.3	4.47	7.96	0.33
2	7	Deta, miercuri, 9	83.53	3.48	10.80	0.45
3	9	Satchinez, marți, 9	109.0	4.54	11.48	0.48
4	12	Deta, marți, 9	98.97	4.12	12.01	0.50
5	13	Satchinez, miercuri, 9	93.79	3.91	12.52	0.52
6	14	Deta, joi, 9	94.10	3.92	12.73	0.53
7	17	Mucescu, marți, 9	27.69	1.15	15.30	0.64
8	19	Bucovina, miercuri, 9	77.62	3.23	30.87	1.29
9	22	Mucescu, miercuri, 9	116.0	4.83	39.74	1.66
10	24	IMT, joi, 9	202.4	8.43	42.85	1.79
11	26	Bucovina, joi, 9	116.1	4.84	45.08	1.88
12	27	Bucovina, marți, 9	89.67	3.74	45.12	1.88
13	28	IMT, marți, 9	150.1	6.25	45.56	1.90
14	29	Mucescu, joi, 9	98.38	4.10	54.08	2.25
15	30	IMT, miercuri, 9	312.8	13.03	59.03	2.46
<b>Total</b>	280		1777.45	74.04	445.13	18.56

Tabelul 7.3.163. Clasament ore – ora 21

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
1	1	Mucescu, joi, 21	40.17	1.67	6.32	0.26
2	2	Mucescu, miercuri, 21	40.56	1.69	7.93	0.33
3	4	Deta, marți, 21	86.79	3.62	9.02	0.38
4	5	Satchinez, miercuri, 21	91.47	3.81	9.01	0.38
5	6	Bucovina, marți, 21	82.72	3.45	10.22	0.43
6	8	Satchinez, joi, 21	78.76	3.28	10.95	0.46
7	10	Satchinez, marți, 21	88.22	3.68	11.55	0.48
8	11	Deta, joi, 21	94.71	3.95	11.66	0.49
9	15	Deta, miercuri, 21	93.83	3.91	14.02	0.58
10	16	Mucescu, marți, 21	42.91	1.79	14.20	0.59
11	18	Bucovina, miercuri, 21	96.39	4.02	27.33	1.14

Nr. crt.	Poziție clasament	Stația, ziua, ora	RNA curbă de sarcină		RNA lunar	
			Total	Specific	Total	Specific
12	20	IMT, joi, 21	129.2	5.38	32.34	1.35
13	21	IMT, marți, 21	114.0	4.75	38.32	1.60
14	23	IMT, miercuri, 21	134.1	5.59	40.38	1.68
15	25	Bucovina, joi, 21	192.0	8.00	43.12	1.80
<b>Total</b>	185		1405.83	58.59	286.37	11.95