

TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ UTILIZATE ÎN STUDIILE DE PROGNOZĂ DIN DOMENIUL INGINERIEI ENERGETICE

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

Ing. Violeta Eugenia Chiș

Președinte:	Prof.univ.dr.ing. Petru Andea
Conducător științific:	Prof.univ.dr.ing. Ștefan Kilyeni
Referenți științifici:	Prof.univ.dr.ing. Ioan Felea Prof.univ.dr.ing. Mariana Nagy Conf.univ.dr.ing. Gheorghe Vuc

Data susținerii tezei: 07.XII.2015

Seriile Teze de doctorat ale UPT sunt:

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

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, 2015

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, 300159 Timișoara, Bd. Republicii 9,
tel. 0256 403823, fax. 0256 403221
e-mail: editura@edipol.upt.ro

PREFAȚĂ

Teza de doctorat este rodul activității desfășurate 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 și să mă încurajeze în momentele dificile.

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. În mod cu totul deosebit, doresc să subliniez ajutorul extrem de consistent oferit de Dr.ing. Antheia Deacu la elaborarea studiilor de caz, motiv pentru care îi sunt extrem de recunoscătoare.

Pentru sprijinul acordat în vederea finalizării tezei, doresc să adresez cele mai calde mulțumiri directorului Departamentului de Electroenergetică, Conf.dr.ing. Gheorghe Vuc.

Mulțumesc cadrelor didactice din cadrul Universității Politehnica Timișoara, care au contribuit la formarea și dezvoltarea mea profesională. În mod special îmi exprim gratitudinea față de cei din Departamentul de Electroenergetică – m-au încurajat și mi-au oferit un real ajutor. Doresc să evidențiez în mod special colaborarea profitabilă pentru mine cu Prof.dr.ing. Corneliu Velicescu, Prof.dr.ing. Bucur Luștea, Prof.dr.ing. Flavius Dan Șurianu, Șef lucr.dr.ing. Ioan Borlea, Asist.dr.ing. Attila Simó.

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.

De asemenea, mulțumesc colegilor din cadrul Departamentului de Matematică – Informatică din cadrul Universității "Aurel Vlaicu" Arad, în cadrul căreia îmi desfășor activitatea, pentru atmosfera de reală prietenie și colegialitate fără de care elaborarea acestei lucrări ar fi fost mai dificilă.

Mulțumesc în mod deosebit, și pe această cale, membrilor comisiei de analiză a tezei de doctorat, Prof.dr.ing. Ioan Felea (Universitatea din Oradea), Prof.dr.ing. Mariana Nagy (Universitatea "Aurel Vlaicu" din Arad), și Conf.dr.ing. Gheorghe Vuc (Universitatea Politehnica Timișoara), pentru atenția cu care au parcurs teza de doctorat, pentru criticile 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, noiembrie 2015

Violeta Chiș

Chiș, Violeta Eugenia

**TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ ÎN STUDIILE DE PROGNOZĂ
DIN DOMENIUL INGINERIEI ENERGETICE**

Teze de doctorat ale UPT, Seria 13, Nr. 13, Editura Politehnica, 2015,
184 pagini, 82 figuri, 90 tabele

ISSN: 2069-8208

ISSN-L: 2069-8208

ISBN: 978-606-35-0026-8

Cuvinte cheie: tehnici de inteligență artificială, inginerie energetică, consum de energie electrică, curbe de sarcină, prognoză, rețele neuronale artificiale

Rezumat: Tematica tezei se încadrează în preocupările actuale legate de utilizarea tehnicilor de inteligență artificială în soluționarea unor probleme din domeniul ingineriei energetice.

Teza are ca obiectiv principal elaborarea unei metode eficiente de prognoză a consumului de energie (putere) electrică și a curbelor de sarcină. S-au elaborat o serie de metode de prognoză utilizând metode euristice și meta-euristice, cu un accent special pe cele care fac uz de rețele neuronale artificiale.

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, utilizând și o serie de facilități oferite de toolbox-urile aferente tehnicilor de inteligență artificială utilizate.

Aplicațiile concrete se referă prognoza curbelor de sarcină, atât la ansamblul Enel Distribuție Banat cât și pentru principalele unități teritoriale rețea componente: Timișoara, Arad, Deva și Reșița. Rezultatele obținute au fost confruntate cu situația reală a consumului pentru anii prognozați.

CUPRINS

CUPRINS	5
ACRONIME	9
LISTA DE FIGURI	11
LISTA DE TABELE	15
1. INTRODUCERE	19
2. TENDINȚE ȘI DIRECȚII PRIVIND SECTORUL ENERGETIC	25
2.1. Evoluția consumului de energie	25
2.1.1. Obiectivele politicii energetice la nivelul Uniunii Europene	25
2.1.2. Evoluția consumului de energie pe plan mondial	26
2.1.3. Evoluția consumului de energie în Europa	27
2.1.4. Evoluția consumului de energie în România	28
2.2. Piața energetică	29
2.2.1. Piața energetică europeană	29
2.2.2. Piața energetică internă	30
2.3. Sursele regenerabile de energie	34
2.3.1. Situația pe plan european	34
2.3.2. Producția din surse regenerabile în România	36
2.4. Smart Grid	37
2.4.1. Considerații preliminare	37
2.4.2. Actorii implicați în implementarea Smart Grids. Rol și responsabilități	38
2.4.3. Evoluția actualelor sisteme spre Smart Grids.....	40
2.4.4. Modelul conceptual european de Smart Grid	42
2.5. Concluzii	43
3. DINAMICA CERCETĂRILOR ÎN DOMENIUL PROGNOZEI CONSUMULUI DE ENERGIE ELECTRICĂ	45
3.1. Metode de prognoză a consumului de energie electrică	46
3.1.1. Prezentare generală	46
3.1.2. Metode statistice	47
3.1.3. Metode bazate pe tehnici ale inteligenței artificiale.....	48
3.1.3.1. Metode utilizând Rețelele Neuronale Artificiale (RNA)	48
3.1.3.2. Metode utilizând logica fuzzy	50

3.1.3.3. Metode utilizând sisteme expert.....	51
3.1.3.4. Metode care utilizează SVM (Support Vector Machines)	51
3.1.3.5. Metode hibride	52
3.1.3.6. Metode ce utilizează tehnici de tip Data Mining.....	54
3.2. Metode de amplasare și dimensionare optimă a surselor de generare distribuită	55
3.3. Concluzii	58
4. TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ UTILIZATE ÎN ELECTROENERGETICĂ	59
4.1. Considerații generale	59
4.1.1. Istoricul tehnicilor de inteligență artificială.....	59
4.1.2. Aplicații în electroenergetică	60
4.2. Prezentarea metodelor de inteligență artificială.....	62
4.2.1. Considerații preliminare.....	62
4.2.2. Algoritmi genetici	62
4.2.3. Inteligența de tip roi	63
4.2.4. Rețele neuronale artificiale (RNA).....	64
4.2.5. Sisteme expert (SE).....	65
4.2.6. Logica fuzzy. Sisteme fuzzy.....	67
4.2.7. Sisteme hibrid.....	70
4.3. Rețele neuronale artificiale	71
4.3.1. Scurt istoric al RNA	71
4.3.2. Neuronul formal. Modelul McCulloch-Pitts	71
4.3.3. Perceptronul	72
4.3.4. Structura rețelei neuronale artificiale	73
4.3.5. Caracteristicile principale și clasificarea RNA	74
4.3.6. Perceptronul multistrat	76
4.3.7. Algoritmul BackPropagation.....	77
4.3.8. Algoritmul Resilient Propagation.....	81
4.4. Concluzii	82
5. MODELE MATEMATICE UTILIZATE.....	83
5.1. Modelul Regresiei Liniare Multiple (RLM)	83
5.1.1. Considerații teoretice	83
5.1.2. Prezentarea modelului utilizat.....	87
5.2. Modelul Arborilor de Decizie (AD)	88
5.2.1. Considerații teoretice	88
5.2.2. Prezentarea modelului utilizat.....	92

5.3. Modelul Curve Fitting (CF)	93
5.3.1. Considerații teoretice	93
5.3.2. Prezentarea modelului utilizat.....	96
5.4. Modelul RNA.....	97
5.4.1. Considerații teoretice	97
5.4.2. Prezentarea modelului utilizat.....	101
5.5. Concluzii	103
6. INSTRUMENTUL SOFT.....	105
6.1. Structura instrumentului soft	105
6.2. Interfața aplicației	106
6.3. Concluzii	112
7. STUDII DE CAZ ȘI REZULTATE	113
7.1. Prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară....	113
7.1.1. Considerații preliminare	113
7.1.2. UTR Arad	114
7.1.3. UTR Deva	119
7.1.4. UTR Reșița	124
7.1.5. UTR Timișoara	129
7.1.6. Ansamblul Enel Distribuție Banat.....	134
7.1.7. Analiza comparativă a rezultatelor	139
7.2. Prognoza curbelor de sarcină pentru ziua de 1 septembrie.....	141
7.2.1. Considerații preliminare	141
7.2.2. UTR Arad	141
7.2.2.1. Anul 2012.....	141
7.2.2.2. Anul 2013.....	143
7.2.3. UTR Deva	145
7.2.3.1. Anul 2012.....	145
7.2.3.2. Anul 2013.....	147
7.2.4. UTR Reșița	149
7.2.4.1. Anul 2012.....	149
7.2.4.2. Anul 2013.....	151
7.2.5. UTR Timișoara	154
7.2.5.1. Anul 2012.....	154
7.2.5.2. Anul 2013.....	155
7.2.6. Ansamblul Enel Distribuție Banat.....	157
7.2.6.1. Anul 2012.....	157
7.2.6.2. Anul 2013.....	159
7.2.7. Analiza comparativă a rezultatelor	161
7.5. Concluzii	164

8. CONCLUZII GENERALE ȘI CONTRIBUȚII PERSONALE.....	165
BIBLIOGRAFIE	169
SINTEZA PRIVIND LUCRĂRILE PROPRII.....	181
ANEXA	CD

ACRONIME

ABC	Artificial Bee Colony
ACO	Ant Colony Optimization
AD	Arbori de Decizie
AG	Algoritm Genetic
AIE	Agenția Internațională a Energiei
AMI	Advanced Metering Infrastructure
AMM	Advanced Metering Management
AMR	Automated Meter Reading
ANFIS	Adaptive Neuro-Fuzzy Inference System
ANRE	Autoritatea Națională de Reglementare în domeniul Energiei
ARIMA	AutoRegressive Integrated Moving Average
ARIMAX	AutoRegressive Integrated Moving Average With Exogenous Variables
ARMA	Autoregressive Moving Average
CART	Classification And Regression Tree
CE	Calculul Evolutiv
CET	Centrala Electrică de Termoficare
CIGRE	Conseil International des Grands Réseaux Électriques
CNE	Centrala Nuclearo-Electriă
COG	Center-of-Gravity
DS	Descompunerea Spectrală
DSM	Demand Side Management
EIA	Energy Information Administration
ENTSO-E	European Transmission and System Operators for Electricity
EPRI	Electric Power Research Institute
ERNN	Elman Recurrent Neural Network
ETSO	European Transmission and System Operators
EUNITE	EUropean Network on Intelligent TEchnologies
FACTS	Flexible Alternating Current Transmission System
FK	Filtre Kalaman
IA	Inteligență Artificială
IEEE	Institute of Electric and Electronic Engineers
ISPE	Institutul de Studii și Proiectări Energetice
LEA	Linie electrică aeriană

10 Acronime

LF	Logica Fuzzy
LMS	Least Mean Square
MCP	Modelul McCulloch-Pitts
MOM	Mean-of-Maxima
Mtep	Milioane Tone Echivalent Petrol
NE	Netezirea Exponențială
NIST	National Institute of Standards and Technology
OD	Operatorii rețelelor de Distribuție
OECD	Organizația pentru Cooperare Economică și Dezvoltare
OTD	Operatorul de Transport și Distribuție
OTS	Operatorul de Transport și de Sistem
PMS	Perceptron Multistrat
PNAER	Planul Național de Acțiune pentru Energii din Surse Regenerabile
PSO	Particle Swarm Optimization
PSOERNN	Particle Swarm Optimized Elman Recurrent Neural Network
RBFN	Radial Basis Function Network
RET	Rețeaua Electrică de Transport
RLM	Regresia Liniară Multiplă
RMSE	Root Mean Square Error
RNA	Rețele Neuronale Artificiale
RP	Rețele Petri
RPROP	Resilient PROPagation
SDS	Stochastic Diffusion Search
SEE	Sistem Electroenergetic
SEN	Sistemul Energetic Național
SET	Planul European Strategic pentru tehnologiile energetice
SGAM	Smart Grid Architecture Model Framework
SLF	Sistem cu logică fuzzy
SRE	Surse Regenerabile de Energie
SSE	Sum of Squares due to Error
SSR	Sum of Squares due to Regression
SST	Total Sum of Squares
STLF	Short Time Load Forecasting
STS	Seriile de Timp Stohastice
SVM	Support Vector Machines
UE	Uniunea Europeană

LISTA DE FIGURI

Nr. crt.	Numărul figurii	Titlul figurii
1.	Fig. 2.1.1.	Ponderea creșterii globale a consumului de energie 2012-2035
2.	Fig. 2.1.2.	Cererea estimată de energie primară pe plan mondial pentru anul 2035
3.	Fig. 2.1.3.	Creșterea cererii totale de energie primară
4.	Fig. 2.1.4.	Evoluția consumului de energie în UE în 2010-2014
5.	Fig. 2.2.1.	Secțiuni SEN-SE ale țărilor vecine
6.	Fig. 2.2.2.	Vârfurile de consum înregistrate la nivelul sistemului electroenergetic național (MWh/h)
7.	Fig. 2.2.3.	Fluxuri comerciale (TWh)
8.	Fig. 2.2.4.	Consumul net anual de energie electrică
9.	Fig. 2.2.5.	Scenarii de evoluție a consumului net de energie electrică
10.	Fig. 2.3.1.	Creșterea producției de energie electrică provenită din surse regenerabile, în perioada 2010-2014, conform ENTSO-E
11.	Fig. 2.3.2.	Tendența istorică și proiectată a creșterii energiei din surse regenerabile în UE
12.	Fig. 2.3.3.	Emisii de CO ₂ cumulate legate de energie
13.	Fig. 2.3.4.	Distribuția SRE în România
14.	Fig. 2.4.1.	Actorii implicați în implementarea Smart Grids
15.	Fig. 2.4.2.	Modelul conceptual pentru Smart Grids al UE
16.	Fig. 2.4.3.	Evoluția procesului de mapare a sistemelor de smart grid în Modelul de arhitectură a unui Smart Grid (SGAM)
17.	Fig. 3.1.1.	Originile Data Minin
18.	Fig. 4.2.1.	Structura unui algoritm de calcul evolutiv de tip AG
19.	Fig. 4.2.2.	Algoritmi de tip roi
20.	Fig. 4.2.3.	Funcții de apartenență utilizate frecvent
21.	Fig. 4.2.4.	Exemple de defuzzyficare după metoda maximului

Nr. crt.	Numărul figurii	Titlul figurii
22.	Fig. 4.2.5.	Schema bloc a sistemului cu logica fuzzy
23.	Fig. 4.3.1.	Neuronul formal
24.	Fig. 4.3.2.	Modelul perceptronului
25.	Fig. 4.3.3.	Arhitectura tipică a unei RNA
26.	Fig. 4.3.4.	Rețea feedforward
27.	Fig. 4.3.5.	Rețea Hopfield
28.	Fig. 4.3.6.	Rețea Kohonen
29.	Fig. 4.3.7.	Rețea Hamming
30.	Fig. 4.3.8.	Arhitectura unui sistem cu învățare supervizată
31.	Fig. 4.3.9.	PMS cu un singur strat ascuns
32.	Fig. 5.1.1.	Modelul Regresia liniară multiplă
33.	Fig. 5.2.1.	Modelul Arbori
34.	Fig. 5.3.1.	Modelul Curve Fitting
35.	Fig. 5.4.1.	Etape în proiectarea RNA
36.	Fig. 5.4.2.	Structura rețelei neuronale
37.	Fig. 5.4.3.	Mărimile din stratul de intrare
38.	Fig. 6.1.1.	Structura sistemului
39.	Fig. 6.1.2.	Verificarea rezultatelor
40.	Fig. 6.2.1.	Datele încărcate – variația pe durata unui an sau a unei luni
41.	Fig. 6.2.2.	Datele încărcate – variația pe durata unei săptămâni sau a unei zile
42.	Fig. 6.2.3.	Captură din interfața aplicației
43.	Fig. 6.2.4.	Modelul RNA
44.	Fig. 6.2.5.	Variabilele ce monitorizează procesul de instruire a rețelei neuronale
45.	Fig. 6.2.6.	Evoluțiile erorilor mse, pe durata instruirii
46.	Fig. 6.2.7.	Graficul Training State
47.	Fig. 6.2.8.	Graficul de regresie
48.	Fig. 7.1.1.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
49.	Fig. 7.1.2.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
50.	Fig. 7.1.3.	Analiza comparativă a rezultatelor pentru anul 2011

Nr. crt.	Numărul figurii	Titlul figurii
51.	Fig. 7.1.4.	Analiza comparativă a rezultatelor pentru anul 2012
52.	Fig. 7.1.5.	Analiza comparativă a rezultatelor pentru anul 2013
53.	Fig. 7.1.6.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
54.	Fig. 7.1.7.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
55.	Fig. 7.1.8.	Analiza comparativă a rezultatelor pentru anul 2011
56.	Fig. 7.1.9.	Analiza comparativă a rezultatelor pentru anul 2012
57.	Fig. 7.1.10.	Analiza comparativă a rezultatelor pentru anul 2013
58.	Fig. 7.1.11.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
59.	Fig. 7.1.12.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
60.	Fig. 7.1.13.	Analiza comparativă a rezultatelor pentru anul 2011
61.	Fig. 7.1.14.	Analiza comparativă a rezultatelor pentru anul 2012
62.	Fig. 7.1.15.	Analiza comparativă a rezultatelor pentru anul 2013
63.	Fig. 7.1.16.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
64.	Fig. 7.1.17.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
65.	Fig. 7.1.18.	Analiza comparativă a rezultatelor pentru anul 2011
66.	Fig. 7.1.19.	Analiza comparativă a rezultatelor pentru anul 2012
67.	Fig. 7.1.20.	Analiza comparativă a rezultatelor pentru anul 2013
68.	Fig. 7.1.21.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
69.	Fig. 7.1.22.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
70.	Fig. 7.1.23.	Analiza comparativă a rezultatelor pentru anul 2011
71.	Fig. 7.1.24.	Analiza comparativă a rezultatelor pentru anul 2012
72.	Fig. 7.1.25.	Analiza comparativă a rezultatelor pentru anul 2013
73.	Fig. 7.2.1.	Analiza comparativă a rezultatelor pentru anul 2012
74.	Fig. 7.2.2.	Analiza comparativă a rezultatelor pentru anul 2013
75.	Fig. 7.2.3.	Analiza comparativă a rezultatelor pentru anul 2012
76.	Fig. 7.2.4.	Analiza comparativă a rezultatelor pentru anul 2013
77.	Fig. 7.2.5.	Analiza comparativă a rezultatelor pentru anul 2012
78.	Fig. 7.2.6.	Analiza comparativă a rezultatelor pentru anul 2013
79.	Fig. 7.2.7.	Analiza comparativă a rezultatelor pentru anul 2012

Nr. crt.	Numărul figurii	Titlul figurii
80.	Fig. 7.2.8.	Analiza comparativă a rezultatelor pentru anul 2013
81.	Fig. 7.2.9.	Analiza comparativă a rezultatelor pentru anul 2012
82.	Fig. 7.2.10.	Analiza comparativă a rezultatelor pentru anul 2013

LISTA DE TABELE

Nr. crt.	Numărul tabelului	Titlul tabelului
1.	Tabelul 2.1.1	Consumul de energie din România în ultimii 5 ani
2.	Tabelul 2.1.2	Putere instalată
3.	Tabelul 2.1.3.	Consum maxim 2012 - 2014
4.	Tabelul 2.3.1	Potențialul din România al SRE
5.	Tabelul 2.4.1.	Comparație rețele clasice versus Smart Grids
6.	Tabelul 3.1.1	Repartiția metodelor statistice pentru prognoza consumului
7.	Tabelul 4.1.1.	Domenii de aplicare ale IA în electroenergetică
8.	Tabelul 4.2.1.	Comparație între sistemele fuzzy și rețelele neuronale
9.	Tabelul 7.1.1.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
10.	Tabelul 7.1.2.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
11.	Tabelul 7.1.3.	Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)
12.	Tabelul 7.1.4.	Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)
13.	Tabelul 7.1.5.	Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)
14.	Tabelul 7.1.6.	Valoarea comparativă a indicilor de performanță
15.	Tabelul 7.1.7.	Valoarea comparativă a erorilor maxime de prognoză
16.	Tabelul 7.1.8.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
17.	Tabelul 7.1.9.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
18.	Tabelul 7.1.10.	Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)
19.	Tabelul 7.1.11.	Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)
20.	Tabelul 7.1.12.	Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)
21.	Tabelul 7.1.13.	Valoarea comparativă a indicilor de performanță
22.	Tabelul 7.1.14.	Valoarea comparativă a erorilor maxime de prognoză
23.	Tabelul 7.1.15.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
24.	Tabelul 7.1.16.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
25.	Tabelul 7.1.17.	Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)
26.	Tabelul 7.1.18.	Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)

Nr. crt.	Numărul tabelului	Titlul tabelului
27.	Tabelul 7.1.19.	Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)
28.	Tabelul 7.1.20.	Valoarea comparativă a indicilor de performanță
29.	Tabelul 7.1.21.	Valoarea comparativă a erorilor maxime de prognoză
30.	Tabelul 7.1.22.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
31.	Tabelul 7.1.23.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
32.	Tabelul 7.1.24.	Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)
33.	Tabelul 7.1.25.	Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)
34.	Tabelul 7.1.26.	Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)
35.	Tabelul 7.1.27.	Valoarea comparativă a indicilor de performanță
36.	Tabelul 7.1.28.	Valoarea comparativă a erorilor maxime de prognoză
37.	Tabelul 7.1.29.	Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)
38.	Tabelul 7.1.30.	Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)
39.	Tabelul 7.1.31.	Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)
40.	Tabelul 7.1.32.	Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)
41.	Tabelul 7.1.33.	Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)
42.	Tabelul 7.1.34.	Valoarea comparativă a indicilor de performanță
43.	Tabelul 7.1.35.	Valoarea comparativă a erorilor maxime de prognoză
44.	Tabelul 7.1.36.	Indicii specifici de performanță
45.	Tabelul 7.1.37.	Valoarea comparativă a erorilor maxime de prognoză
46.	Tabelul 7.2.1.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2012
47.	Tabelul 7.2.2.	Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)
48.	Tabelul 7.2.3.	Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)
49.	Tabelul 7.2.4.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
50.	Tabelul 7.2.5.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2013
51.	Tabelul 7.2.6.	Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)
52.	Tabelul 7.2.7.	Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)
53.	Tabelul 7.2.8.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
54.	Tabelul 7.2.9.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2012

Nr. crt.	Numărul tabelului	Titlul tabelului
55.	Tabelul 7.2.10.	Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)
56.	Tabelul 7.2.11.	Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)
57.	Tabelul 7.2.12.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
58.	Tabelul 7.2.13.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2013
59.	Tabelul 7.2.14.	Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)
60.	Tabelul 7.2.15.	Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)
61.	Tabelul 7.2.16.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
62.	Tabelul 7.2.17.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2012
63.	Tabelul 7.2.18.	Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)
64.	Tabelul 7.2.19.	Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)
65.	Tabelul 7.2.20.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
66.	Tabelul 7.2.21.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2013
67.	Tabelul 7.2.22.	Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)
68.	Tabelul 7.2.23.	Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)
69.	Tabelul 7.2.24.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
70.	Tabelul 7.2.25.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2012
71.	Tabelul 7.2.26.	Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)
72.	Tabelul 7.2.27.	Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)
73.	Tabelul 7.2.28.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
74.	Tabelul 7.2.29.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2013
75.	Tabelul 7.2.30.	Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)
76.	Tabelul 7.2.31.	Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)
77.	Tabelul 7.2.32.	Valoarea comparativă a indicilor de performanță și a erorilor maxime

Nr. crt.	Numărul tabelului	Titlul tabelului
78.	Tabelul 7.2.33.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2012
79.	Tabelul 7.2.34.	Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)
80.	Tabelul 7.2.35.	Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)
81.	Tabelul 7.2.36.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
82.	Tabelul 7.2.37.	Curbele de sarcină zilnice pentru perioada 01.01 – 31.08.2013
83.	Tabelul 7.2.38.	Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)
84.	Tabelul 7.2.39.	Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)
85.	Tabelul 7.2.40.	Valoarea comparativă a indicilor de performanță și a erorilor maxime
86.	Tabelul 7.2.41.	Indicii specifici de performanță
87.	Tabelul 7.2.42.	Indicii specifici de performanță pentru anul 2012
88.	Tabelul 7.2.43.	Indicii specifici de performanță pentru anul 2013
89.	Tabelul 7.2.44.	Indicii specifici de performanță cumulați (2012, 2013)
90.	Tabelul 7.2.45.	Valoarea comparativă a erorilor maxime de prognoză

1. INTRODUCERE

Ființa umană a primit numele de "homo sapiens" datorită capacităților sale intelectuale (mentale). Conceptul de "inteligentă artificială (IA)" reprezintă o combinație între știința calculatoarelor, matematică, psihologie, filosofie etc., încercând să explice caracteristicile ființelor inteligente și să elaboreze entități artificiale comparabile cu acestea.

Începuturile IA se pot regăsi în antichitate, procesul de formalizare și de mecanizare a gândirii omenești fiind destul de vechi. Câteva nume semnificative în acest sens: René Descartes, Gottfried Wilhelm von Leibniz, Blaise Pascal, Charles Babbage, George Boole, John von Neumann etc. Cel care a utilizat pentru prima dată sintagma de IA a fost John McCarthy (considerat părintele IA).

Prin tehnicile de IA se urmărește crearea unor sisteme de calcul inteligente, fundamentate pe caracteristicile inteligenței umane – raționamentul, capacitatea de învățare, rezolvarea și comunicarea. Aceste sisteme sunt destinate problemelor pentru care rezolvarea pe calea modelării matematice clasice este foarte dificilă (laborioasă) sau chiar imposibilă.

Ingineria energetică, la modul general, respectiv ingineria sistemelor electro-energetice, la modul particular, constituie cu certitudine domenii unde tehnicile bazate pe IA își au cu certitudine locul. Există foarte multe probleme extrem de complexe, care necesită, din punct de vedere al utilității practice, soluții rapide și concrete. Abordarea acestor probleme utilizând modelarea matematică clasică este foarte greoaie (sau chiar exclusă), mai ales în situațiile în care datele de intrare nu sunt cunoscute cu suficientă exactitate, restricțiile nu pot fi reproduse prin relații matematice riguroase. În asemenea situații IA își găsește un teren fertil de aplicare.

Domeniile predilecte de aplicare a metodelor de soluționare bazate pe tehnici de IA vizează planificarea extinderii rețelelor de transport al energiei electrice, planificarea extinderii rețelelor de distribuție, conducerea optimă a sistemelor electro-energetice, restaurarea sistemelor electroenergetice după avarii, diagnoza stării și a defectelor, prognoza consumului de energie electrică (de care se leagă și preocupările din cadrul acestei teze de doctorat) etc.

Creșterea consumului de energie, în general, și de energie electrică în special, constituie o caracteristică esențială atât pentru țările dezvoltate, cât și pentru cele în curs de dezvoltare. În pofida unor posibile perioade de recesiune, trendul general rămâne. Se impune cercetarea unor noi tehnologii de conversie și de utilizare a energiei. Discrepanțele tot mai mari dintre cererea și producția de energie electrică ridică o serie de semnale de alarmă cu referire la disponibilitatea surselor de energie și efectele proceselor energetice asupra mediului.

Economia europeană se vrea, la ora actuală, o economie a consumurilor energetice scăzute, bazată pe surse de energie mai sigure, mai curate, mai competitive și sustenabile. Prioritățile energetice actuale vizează asigurarea unei piețe interne europene funcționale, stabile, securitatea strategică a surselor de energie, structuri ale balanței energetice care să asigure conservarea și protejarea mediului ambiant.

Liberalizarea pieței de energie și dereglementarea au condus la utilizarea și integrarea de modalități noi, mai eficiente, de producere și de management al energiei. Ca urmare, atât consumatorii cât și companiile de producere a energiei electrice caută căi de creștere a eficienței în condițiile instabilității prețului energiei, îmbătrânirii infrastructurii energetice și a modificărilor privind reglementările referitoare la protecția mediului.

În România, piața de energie s-a liberalizat complet relativ recent, lucru care a determinat apariția unei competiții în domeniu. Conectarea la sistemul național a producătorilor de energie din surse regenerabile și dezvoltarea industriei prin achiziția de echipamente noi, precum și dotarea populației cu echipamente electrice pentru confortul rezidențial, ridică probleme care necesită rezolvare urgentă, prin prisma acestor noi provocări. Tendința de a oferi consumatorului final posibilitatea de alegere a furnizorului de energie electrică, tinde să devină o realitate. 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.

Proгноza consumului de energie electrică este o funcție principală a operatorilor de distribuție și furnizare a energiei electrice. Energia electrică nu poate fi stocată în mod eficient, la scară mare (raportat la cantitatea produsă), ceea ce înseamnă că pentru operatorii de distribuție și furnizare, estimarea cererii este un factor indispensabil în procesul de management al tranzacției într-un mod relativ rezonabil.

Consumatorii de energie electrică sunt sisteme complexe a căror cunoaștere din punct de vedere al factorilor care stau la baza modificărilor în structura consumului de energie electrică este esențială pentru operatorul de sistem, furnizorul de energie electrică și pentru consumatorul în cauză. Implementarea măsurilor de reducere a consumurilor de energie electrică aduce economii prin reducerea facturii, precum și încadrarea în legislația europeană și națională de optimizare a consumului total.

Istoricul consumului, progноza valorilor lui și interpretarea corectă a acestora, reprezintă condiții necesare pentru realizarea deciziilor care vor sta la baza planificării extinderii rețelelor de transport al energiei electrice și a celor de distribuție, atât pe termen scurt cât și pe termen lung, care să determine îmbunătățiri la nivelul infrastructurii și funcționării întregului sistem. Cunoașterea trendului consumurilor, analiza factorilor de influență, politicile de constrângeri legislative, sunt instrumente indispensabile factorilor decizionali din sectorul energetic.

În scopul estimării (extrapolării) tendințelor pentru momentul actual, un istoric al consumurilor energetice din ultimii 5 sau chiar 10 ani de activitate este necesar, sau chiar pentru viitorul apropiat. Aceste date provin în general de la societățile de distribuție a energiei electrice sau, la nivel național, de la operatorul de transport și de sistem.

În acest context, tematica tezei de doctorat se încadrează în preocupările actuale din domeniul managementului sistemelor de producere, transport, distribuție și consum al energiei electrice. Teza urmărește două obiective esențiale: activitatea de progноză (a curbelor de sarcină, a consumului de energie electrică și de putere) și utilizarea unor tehnici de inteligență artificială (în principal rețele neuronale artificiale) pentru obținerea progноzelor.

Metodele de analiză utilizate sunt finalizate prin tehnici originale de soluționare, implementate în instrumente soft proprii, care utilizează la maxim posibilitățile oferite de mediile de programare și de sistemele informatice actuale.

Aplicațiile prezentate în cadrul tezei de doctorat au pornit de la cazuri simple și baze de date test, utilizate pentru validarea metodelor propuse și pentru "calibrarea"

instrumentelor soft, ca apoi să se treacă la situații reale, vizând principalii operatori de distribuție din România: Enel, Electrica, CEZ etc.

Pentru partea aplicativă propriu-zisă a tezei s-au selectat o serie de studii de caz referitoare la 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.

Rezultatele obținute sunt extrem de utile operatorului zonal de distribuție (Enel Distribuție Banat), altor operatori de transport și de distribuție a energiei electrice, cât și firmelor care au ca obiect de activitate implementarea generării locale distribuite (din surse regenerabile de energie).

Teza de doctorat, extinsă pe 182 de pagini, este structurată pe 8 capitole, prefață, anexă (pe suport de informație electronic) și o listă bibliografică, conținând un număr de 82 figuri, scheme, histograme și 90 tabele. Lista bibliografică cuprinde 198 titluri, semnalându-se prezența unor lucrări reprezentative, atât cele considerate deja clasice, cât și cele de dată relativ recentă, apărute în țară sau în reviste de prestigiu din străinătate.

Capitolul 1 are un caracter introductiv, prima parte cuprinzând încadrarea și justificarea tematicii care constituie obiectul tezei de doctorat, în contextul stadiului actual al evoluției sistemelor electroenergetice și al preocupărilor existente pe plan mondial și la noi în țară. Partea a doua cuprinde prezentarea succintă a conținutului fiecărui capitol al tezei. În încheierea capitolului se evidențiază atât modul de valorificare a cercetărilor efectuate în cadrul elaborării tezei de doctorat (publicații, contracte, instrumente soft), cât și perspectivele privind direcțiile ulterioare de continuare a investigațiilor. De asemenea, se subliniază utilitatea rezultatelor obținute pentru operatorii de distribuție și de transport, precum și pentru alți agenți economici.

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

Capitolul 2 prezintă o sinteză a problemelor actuale privind sectorul energetic. Prima parte a capitolului cuprinde o scurtă sinteză referitoare la obiectivele politicii energetice la nivelul Uniunii Europene (UE) și a evoluției consumului de energie pe plan mondial, european și național.

A doua parte a capitolului este consacrată pieței europene de energie electrică și a celei din România. În continuare se prezintă situația utilizării surselor regenerabile de energie în cadrul UE și pe plan național. Ultima parte a capitolului prezintă evoluția și strategia de dezvoltare a rețelelor Smart Grid. Sunt prezentați actorii implicați în implementarea Smart Grids, rolul și responsabilitățile lor, prioritățile de implementare iar în final este realizată o comparație între rețelele clasice și Smart Grids. Toate aceste elemente sunt abordate și prin prisma prognozei consumului de energie electrică.

Obiectivul capitolului 3 constă în prezentarea sistematizată a aspectelor generale legate de cercetările privind prognoza consumului de energie electrică, a metodelor utilizate, cu accent pe cele care fac uz de o serie de tehnici de inteligență artificială.

Se trec în revistă manierele de abordare și de soluționare utilizate de diverși specialiști precum și rezultatele obținute, aplicațiile concrete soluționate referitoare la situații reale. Metodele de abordare pentru problema în discuție sunt împărțite în două mari categorii: metode statistice (clasice) și metode bazate pe tehnici ale inteligenței artificiale, incluzând rețelele neuronale artificiale (RNA) de diverse tipuri, algoritmi genetici (AG), tehnici de tip roi de particule (Particle Swarm Optimization –

PSO), logica fuzzy (LF), sisteme expert (SE), tehnici utilizând SVM (Support Vector Machines), metode hibride, tehnici de tip Data Mining (DM).

Tot în contextul tematicii tezei de doctorat, ultima parte a acestui capitol abordează și o serie de aspecte legate de metodele ce aplică tehnici ale inteligenței artificiale, utilizate pentru amplasarea și dimensionare a optimă a surselor de generare distribuită.

Capitolul 4 are ca obiect prezentarea, într-un cadru mai larg, a tehnicilor de inteligență artificială utilizate în cadrul tezei de doctorat. El furnizează elementele teoretice necesare pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.

În prima parte a capitolului se trec în revistă o serie de aspecte legate de istoricul tehnicilor de inteligență artificială și de aplicațiile specifice domeniului ingineriei sistemelor electroenergetice.

În a doua parte se realizează o descriere a metodelor de abordare bazate pe tehnici de inteligență artificială: algoritmi genetici (AG), inteligența de tip roi, rețele neuronale artificiale (RNA), sisteme expert (SE), metode bazate pe logica fuzzy și metode hibride.

Un subcapitol aparte este consacrat RNA. Pornind de la câteva considerații cu caracter istoric, se abordează succesiv elemente legate de terminologie, de structură și de clasificare, de caracteristici, de neuronul formal și de perceptron, de perceptronul multistrat, de diversele procedee de antrenare (învățare), cu accent special pe cele de tip backpropagation.

Capitolul 5 are ca obiectiv prezentarea modelelor matematice ale metodelor utilizate efectiv în lucrare pentru prognoza consumului de energie electrică și putere, a curbelor de sarcină. O bună parte dintre ele au fost elaborate pe baza elementelor teoretice prezentate în capitolele anterioare.

Prima parte a capitolului prezintă modelul Regresiei Linjare Multiple (RLM), iar partea a doua descrie modelul Arborilor de Decizie (AD). În partea a treia se tratează modelul de aproximare Curve Fitting (CF), ultima parte a capitolului referindu-se la metodele utilizând Rețele Neuronale Artificiale (RNA).

Capitolul 6, în întregime original, prezintă un instrument software de prognoză a consumului de energie electrică (curbelor de sarcină) și analiză statistică a indicatorilor de performanță. Instrumentul soft, care implementează toate metodele de prognoză prezentate în capitolul 5 (regresie liniară multiplă – RLM, "curve fitting" – CF, arbori de decizie – AD și rețele neuronale de tip perceptron multistrat cu algoritm de învățare de tip backpropagation – RNA), 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 software matematic produs de firma The MathWorks Inc., dedicat calculului numeric și reprezentărilor grafice în știință și inginerie [Matlab].

Capitolul 7 constituie principala parte aplicativă a lucrării. În acest capitol se prezintă rezultatele obținute privind prognoza curbelor de sarcină utilizând tehnici bazate pe inteligența artificială (IA) – rețele neuronale artificiale (RNA). Elementele teoretice, metodologiile de calcul elaborate și instrumentele soft dezvoltate, care au constituit obiectul capitolelor anterioare, au fost aplicate și utilizate la obținerea prognozelor menționate pentru o gamă largă de studii de caz.

Analizele efectuate au pornit de la cazuri simple și baze de date test, utilizate pentru validarea metodelor propuse și pentru "calibrarea" instrumentelor soft, ca apoi să se treacă la situații reale, vizând operatori de distribuție din România.

Pentru acest capitol, din motive de spațiu, s-au selectat o serie de studii de caz referitoare la Enel Distribuție Banat. Se menționează că o parte a datelor și rezultatelor sunt prezentate în detaliu în cadrul capitolului, restul doar în sinteză (detaliile fiind regăsite în Anexă, sub formă electronică).

Rezultatele obținute au fost utilizate și în cadrul unor contracte derulate în ultimii 2 ani prin Centrul de Cercetare pentru Analiza și Optimizarea regimurilor SEE din cadrul Universității Politehnica din Timișoara (director prof.dr.ing. Ștefan Kilyeni), beneficiarii fiind operatori de distribuție de România (Enel Distribuție Banat) și o serie de agenți economici cu preocupări domeniul implementării resurselor regenerabile de energie [UPT2014a], [UPT 2014b], [UPT 2014c], [UPT 2014d], [UPT 2014e].

Prima parte a capitolului se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: UTR Timișoara, UTR Arad, UTR Deva și UTR Reșița. Se realizează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie. Datele cunoscute acoperă 10 ani (2001 – 2010), iar verificarea rezultatelor vizează 3 ani (2011-2013).

A doua parte a capitolului se referă tot la ansamblul Enel Distribuție Banat și la principalele UTR menționate mai sus. Se realizează prognoza curbei de sarcină pentru ziua de 1 septembrie (o curbă de sarcină), pe baza celor din perioada 1 ianuarie – 31 august (243 de curbe). Sunt prezentate rezultatele pentru 2 ani – 2012 și 2013.

Prognozele s-au efectuat cu metodele prezentate în capitolele anterioare (rețele neuronale artificiale – RNA, regresie liniară multiplă – RLM, arbori de decizie – AD, "curve fitting" – CF), utilizând instrumentul soft propriu descris în capitolul 6.

La finele fiecărui subcapitol în parte și la sfârșitul capitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau mai general, vizând atât rezultatele concrete ale prognozelor cât și metodele utilizate.

Capitolul 8 cuprinde concluziile generale ale tezei și prezentarea sistematizată a contribuțiilor originale ale autorului, precum și reliefaarea direcțiilor și perspectivelor oferite de lucrarea de față pentru continuarea cercetărilor și aplicarea rezultatelor și a experienței obținute. Metodologiile și programele de calcul elaborate sunt de aplicabilitate generală, oferind 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 oferă o serie de elemente și de rezultate de detaliu referitoare la prognozele efectuate în cadrul studiilor de caz prezentate în teza de doctorat.

Rezultatele obținute au fost și vor fi valorificate în cadrul unor contracte de cercetare științifică încheiate între Universitatea Politehnica Timișoara, Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor SEE, și Operatorul Național de Transport și de Sistem, C.N.T.E.E. Transelectrica S.A., operatorii de distribuție (Enel, Electrica, CEZ, Eon) și o serie de agenți economici care se ocupă de implementarea în sistem a resurselor regenerabile de energie. Contractele derulate și finalizate sunt prezentate în lista lucrărilor proprii de la finele tezei ([UPT2014a], [UPT2014b], [UPT 2014c], [UPT2014d], [UPT2014e]).

De asemenea, o parte a rezultatelor obținute în cadrul tezei au fost publicate și sunt în curs de publicare: 13 lucrări publicate până la ora actuală, 1 lucrare în curs de publicare, 2 referate științifice și 5 de contracte de cercetare. Așa cum rezultă din lista lucrărilor proprii de la finele tezei de doctorat, 9 au fost publicate în țară și 4 în străinătate. Se remarcă faptul că 2 lucrări sunt indexate ISI Journal, 5 lucrări sunt indexate în BDI – Scopus, Compendex, Inspec, IEEE Explore etc. și o lucrare acceptată la o conferință indexată ISI (aprilie 2016).

Analizele teoretice și practice realizate în cadrul tezei de doctorat, precum și rezultatele obținute, deschid o serie de perspective și direcții de continuare și aprofundare ulterioară a cercetărilor în domeniul prognozei consumului de energie electrică și a curbelor de sarcină:

- rafinarea metodelor de soluționare bazate pe RNA, în scopul creșterii eficienței și ameliorării performanțelor acestora;
- utilizarea unor alte tehnici de inteligență artificială în cadrul studiilor de prognoză din domeniul ingineriei energetice;
- implementarea unor alte clase de metode de soluționare bazate pe tehnici de inteligență artificială și logică fuzzy;
- elaborarea unor metode care să depisteze unele date evident eronate în istoricul consumului;
- introducerea în modelul matematic a unor factori suplimentari, pe lângă evoluția în timp a consumului: condițiile meteo, elemente legate de dezvoltarea economică, influența producerii distribuite etc.

2. TENDINȚE ȘI DIRECȚII PRIVIND SECTORUL ENERGETIC

Capitolul 2 prezintă o sinteză a problemelor actuale privind sectorul energetic. Prima parte a capitolului cuprinde o scurtă sinteză referitoare la obiectivele politicii energetice la nivelul Uniunii Europene (UE) și a evoluției consumului de energie pe plan mondial, european și național.

A doua parte a capitolului este consacrată pieței europene de energie electrică și a celei din România. În continuare se prezintă situația utilizării surselor regenerabile de energie în cadrul UE și pe plan național. Ultima parte a capitolului prezintă evoluția și strategia de dezvoltare a rețelelor Smart Grid. Sunt prezentați actorii implicați în implementarea Smart Grids, rolul și responsabilitățile lor, prioritățile de implementare iar în final este realizată o comparație între rețelele clasice și Smart Grids. Toate aceste elemente sunt abordate și prin prisma prognozei consumului de energie electrică.

2.1. Evoluția consumului de energie

2.1.1. Obiectivele politicii energetice la nivelul Uniunii Europene

Obiectivele fundamentale ale politicii energetice comune la nivelul UE, sustenabilitatea (dezvoltarea durabilă), securitatea alimentării și competitivitatea, înscrise în Tratatul de la Lisabona, vorbesc de la sine despre prioritățile Europei în domeniul energetic. Ritmul de adaptare al sistemelor energetice europene la aceste obiective este în din păcate prea lent [StEn35].

Primul obiectiv poate fi atins printr-o utilizare eficientă a energiei de către toți consumatorii, ceea ce implică printre altele un rol mai activ al consumatorilor în lanțul de furnizarea energiei (demand-side user participation). Dezvoltarea durabilă implică și o creștere a unităților de producție ce folosesc surse regenerabile de energie sau care utilizează mai eficient energia primară.

Al doilea obiectiv, referitor la securitatea alimentării poate primi un sprijin din partea surselor regenerabile de energie deoarece scade dependența de combustibilii fosili. Caracterul intermitent al surselor pe bază de energii regenerabile poate însă influența continuitatea alimentării, iar generarea distribuită poate influența calitatea tensiunii și siguranța alimentării. Pentru asigurarea securității sunt deci necesare noi măsuri. Interconectarea sistemelor electroenergetice și integrarea piețelor transfrontaliere sunt de asemenea importante pentru securitatea alimentării la nivel european.

Competitivitatea presupune că rețelele electrice sprijină dezvoltarea unei piețe interne a UE cu adevărat competitivă. Astfel la nivelul rețelelor de transport este necesară creșterea interconexiunilor între statele membre, ceea ce ar permite creșterea concurenței și ar putea îmbunătăți capacitatea părților de a echilibra cerințele lor de energie și a minimiza costurile de echilibrare asociate cu variabilitatea surselor pe bază de energii regenerabile. Un rol important îl are transparența în funcționarea rețelelor de energie electrică [Vatră2014].

Obiectivele UE 20/20/20 pentru anul 2020 prevăd o reducere a emisiilor de CO₂ cu 20%, creșterea eficienței energetice cu 20% și regăsirea a 20% din ponderea energiilor regenerabile în consumul brut de energie. Aceste obiective conduc la îndeplinirea primelor două din cele trei obiective fundamentale ale UE. Strategia energetică pentru perioada 2011-2020 stabilește prioritățile industriilor energetice ale UE pentru următorii ani. În cadrul acesteia sunt prezentate măsurile care trebuie luate pentru a face față provocărilor legate de necesitatea reducerii consumului de energie, de realizare a unei piețe a energiei, în care să se garanteze furnizarea sigură a energiei la prețuri competitive.

2.1.2. Evoluția consumului de energie pe plan mondial

Deși recesiunea economică a încetinit rata de creștere a consumului mondial de energie în 2008 și 2009, acesta este estimat să crească, conform previziunilor Agenției Internaționale a Energiei (AIE), la 35.200 TWh în 2035 (o creștere a consumului de energie, cu aproape 50% comparativ cu anul 2007); ponderea cea mai mare, o vor avea țările din afara Organizației pentru Cooperare Economică și Dezvoltare (țări non-OECD) (Fig. 2.1.1) [StEn35].




Fig. 2.1.1. Ponderea creșterii globale a consumului de energie 2012-2035

În prezent China este principalul motor de creștere a cererii de energie (Fig. 2.1.2) și conform [World2013] se estimează că după anul 2020 acest loc va fi ocupat de India.

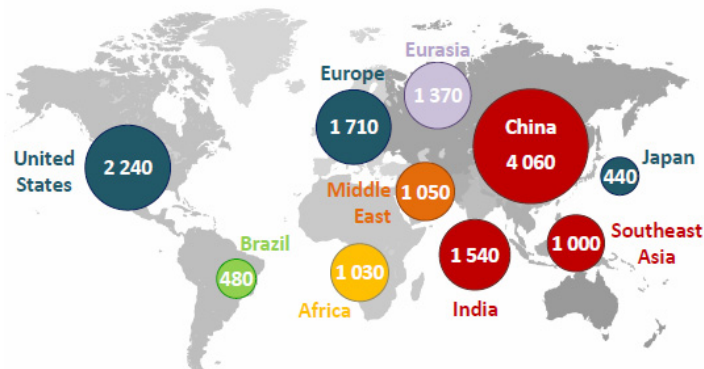


Fig. 2.1.2. Cererea estimată de energie primară pe plan mondial pentru anul 2035

Ponderea surselor primare de energie utilizate în producerea energiei electrice a suferit în ultimele patru decenii mai multe schimbări (Fig. 2.1.3). Cu toate că se înregistrează o creștere importantă în cazul surselor nucleare (între anii 1970-1980) și a gazelor de sondă (între anii 1990-2000), cărbunele este încă combustibilul cel mai utilizat. Petrolul ca sursă primară de energie a suferit un declin continuu de la începutul anilor '70 ai secolului trecut datorită faptului că prețul a crescut brusc.

Prețul ridicat al combustibililor fosili înregistrat în perioada 2003 – 2008, combinat cu preocupările legate de mediu, au condus la dezvoltarea unor alternative la combustibilii fosili, atenția îndreptându-se spre energia nucleară și sursele regenerabile de energie [EIA2012]. Deși va avea loc o reducere a ponderii energiei generată din combustibili fosili, se estimează că până în anul 2020 utilizarea acestora va cunoaște totuși o creștere (aproximativ 1500 Mtoe).




Fig. 2.1.3. Creșterea cererii totale de energie primară

2.1.3. Evoluția consumului de energie în Europa

Creșterea semnificativă a cererii de energie în alte părți ale lumii ar putea avea impact direct asupra Europei, știind că UE participă la cursa mondială pentru sursele de energie.

În prezent, suntem departe de a produce cantitatea de energie necesară pentru a acoperi cererea de la nivelul UE (Fig. 2.1.4). Dependenta Europei de importuri a crescut în ultimele două decenii și se prevede că până în 2035 va crește la peste 80% [CCCE2013].

Din punct de vedere al consumului, în Europa s-a înregistrat o scădere per ansamblu a consumului de curent electric în ultimii 5 ani. Cele mai mari scăderi ale consumului au fost în Germania (-4,8%) și Franța (-5,9%), în timp ce țările est-europene (România, Ungaria sau Polonia) au contorizat o ușoară creștere a consumului de energie. Conform mai multor analize, Europa a ajuns la nivelul de consum energetic din anii '90 (după unele măsurători ne situăm la 87% din emisiile de CO₂ din 1990), deși populația a crescut cu 6%, iar activitatea industrială s-a intensificat cu 45%. Unul dintre principalele motive pentru care emisiile CO₂ au scăzut în 2014 față de 2013 ține de limitarea utilizării cărbunilor, în special în Marea Britanie, Germania și Danemarca. Totuși, specialiștii ENTSO-E sunt convinși că vom asista la o creștere vertiginoasă a consumului, odată cu scăderea prețurilor la energie, dar și datorită înlocuirii surselor convenționale (termocentralele în principal) cu noile sisteme care folosesc energii regenerabile [WebEco].




Fig. 2.1.4. Evoluția consumului de energie în UE în 2010-2014

Statele membre UE și industria au conștientizat impactul evoluției pieței de energie și a necesității extinderii și funcționării optime a sistemului electroenergetic european. Securitatea aprovizionării cu energie, utilizarea eficientă a resurselor, prețurile accesibile și soluțiile inovatoare fiind cruciale pentru o creștere durabilă și pentru îmbunătățirea calității vieții în Uniunea Europeană [Simo2014].

2.1.4. Evoluția consumului de energie în România

România dispune de o gama diversificată, de resurse de energie primară, și anume: resurse epuizabile fosile și minerale (țiței, gaze naturale, cărbune, minereu de uraniu); resurse regenerabile potențiale de energie (solară, eoliană, hidroelectrică, biomasa și biogaz, energie geotermală) [ANRE2013].

Și în România desigur există tendința de creștere a cererii de putere, în pofida tendinței de scădere a consumului energetic din ultimii ani (36,4% între 1999 și 2010), unul din motive fiind urbanizarea excesivă [ANRE2014].

Urmărind datele referitoare la consumul de energie din țara noastră (Tabelul 2.1.1) în ultimii 5 ani, prezentate în [VLER2014], consumul de energie electrică a fluctuat de la creșteri pozitive, la scăderi importante (Fig. 2.1.5), influențele fiind de natură economică, meteorologică și politică.

Tabelul 2.1.1. Consumul de energie din România în ultimii 5 ani

An	Consum de energie electrică [TWh]	Consum de gaze naturale [mld. mc]	Consum de cărbune [mil. t]	Temperatura maximă medie [°C]	Temperatura medie [°C]	Temperatura minimă medie [°C]	Creștere economică [%]
2008	60,3	15,6	-	29	13	-11	7,10%
2009	55,1	13,3	5,9	28	13	-9	-6,60%
2010	57,8	14	5,98	30	12	-14	-1,60%
2011	60	14,3	5,78	28	12	-10	2,50%
2012	59,3	13,7	5,96	31	12	-14	0,60%
2013	55,6	12,8	-	27	12	-9	3,50%

Producția de energie primară în România bazată atât pe valorificarea rezervelor fosile de energie primară, cărbune și hidrocarburi cât și pe cele de minereu de uraniu, în cea mai optimistă situație, nu va crește în următoarele 2-3 decade [EnSTR2020].




Fig. 2.1.5. Consumul intern de energie electrică pentru perioada 2000-2013 [TWh]

Pentru a acoperi creșterea cererii de energie primară se impune creșterea utilizării surselor regenerabile de energie și apelarea în continuare a importurilor de energie primară. În perioada următoare țara noastră va fi în continuare dependentă de importurile de energie primară. Această dependență va fi influențată de măsurile de creștere a eficienței energetice, de descoperirea unor noi resurse interne exploatabile și nu în ultimul rând de gradul de integrare a surselor regenerabile de energie [SE2007], [SEN2014].

În ceea ce privește energia electrică, România este un furnizor regional, dar deocamdată exportul energiei electrice este condiționat de disponibilitatea surselor regenerabile de energie, în special a sectorului eolian.

2.2. Piața energetică

2.2.1. Piața energetică europeană

În prezent sistemul energetic global este angrenat într-o etapă de tranziție rapidă. Cu peste 500 de milioane de consumatori, piața energetică europeană este cea mai mare piață regională din lume și totodată cel mai mare importator. În contextul unei concurențe tot mai acerbe pentru resursele energetice mondiale, UE trebuie să rămână o piață atrăgătoare pentru companii.

Schimbările rapide în inovațiile tehnologice, în politicile energetice și în așteptările utilizatorilor determină o creștere a complexității piețelor de energie. Modelele de piață și condițiile de business nu sunt actualmente capabile să facă față ratelor în creștere ale tehnologiilor surselor regenerabile, sistemelor distribuite și arhitecturii informaționale în dezvoltare. De aceea sunt necesare eforturi semnificative în ceea ce privește inovarea tehnică și investițiile. O prioritate maximă este aducerea pe piața europeană a tehnologiilor de vârf cu emisii reduse de carbon și în acest context vor fi încurajate în continuare de instrumente bazate pe piață, precum comercializarea și impozitarea emisiilor. În ultimii ani, efectele turbulențelor de pe piețele globale de energie au fost în mare măsură atenuate ca urmare a liberalizării, aprovizionării și posibilităților adecvate de import.

Dezvoltarea pieței de energie electrică și creșterea gradului de deschidere a pieței pentru consumatorii care își pot alege furnizorul (consumatori eligibili) determină ca problemele legate de calitatea energiei electrice livrată consumatorilor să devină deosebit de importantă pe piața concurențială [AlbertWeb].

Planul SET (Planul European Strategic pentru tehnologiile energetice) conturează o strategie pe termen mediu, valabilă pentru toate sectoarele. Însă dezvoltarea și proiectele demonstrative aferente tehnologiilor principale (biocarburanți de generația a doua, rețele inteligente, orașe și rețele inteligente, captarea și stocarea carbonului, stocarea electricității și electromobilitatea, tehnologii nucleare din generația următoare, încălzire și răcire regenerabile) trebuie accelerate [EnSTR2020].

Prețurile energiei vor fi afectate de nevoia uriașă de investiții în sectorul energiei, de stabilirea prețului carbonului și de creșterea prețurilor energiei la nivel internațional. Dacă nu se actualizează rețelele electrice, dacă nu se înlocuiesc instalațiile depășite cu alternative competitive și dacă nu se eficientizează utilizarea energiei pe parcursul întregului lanț energetic, competitivitatea, securitatea aprovizionării și obiectivele climatice vor avea de suferit.

În ultimii 20 de ani s-au făcut primii pași în direcția modificării concepției privind funcționalitatea în operare a rețelelor electrice și a surselor de generare ca urmare a dezvoltării unor tehnologii de bază în domeniul surselor regenerabile. Principala provocare a reprezentat-o dezvoltarea și integrarea acestor tehnologii în cadrul sistemului energetic european și validarea lor în condiții reale de funcționare în rețea.

2.2.2. Piața energetică internă

Începând din 1 iulie 2007 piața de energie electrică internă, alcătuită din piața angro și piața cu amănuntul, este o piață liberalizată. Piața cu amănuntul a energiei electrice este alcătuită dintr-o componentă reglementată (piața reglementată) și una concurențială (piața concurențială), în funcție de tipul consumatorilor de energie electrică.

Teoretic, consumatorii de energie electrică pot să își aleagă singuri furnizorul de energie electrică. Practic lucrurile nu stau chiar așa, consumatorii fiind captivi, alimentați de furnizori implicați în funcție de poziționarea geografică.

Pentru promovarea producerii de energie electrică din surse / tehnologii considerate prioritare, Codul Comercial prevede reguli comerciale specifice pentru participarea la piață a unităților de producție calificate ca producții prioritare.

În aplicarea Codului Comercial, Operatorul Pieței de Energie Electrică, Operatorul Pieței de Echilibrare, Operatorul de Transport și de Sistem și Operatorul de Decontare elaborează proceduri proprii pe care le supun spre aprobare Autorității Competente.

Piața internă a energiei este încă fragmentată și nu și-a atins potențialul de transparență, accesibilitate și diversitate a ofertelor; există un număr prea mic de opțiuni la dispoziția consumatorilor, iar implementarea legislației pentru piața internă lasă de dorit.

Liberalizarea pieței de energie electrică în România a impus mai multe modificări ale SEN. Astfel, în anul 2010, RET era compusă din 42 de stații cu tensiune de 220 kV (cu lungime totală de 4.035 km), 36 de stații cu tensiune de 400 kV (cu lungime totală de 4.704 km) și o stație cu tensiune de 750 kV (cu lungime totală de 155 km). Lungimea totală a RET, indiferent de tensiunea rețelei, era de 8.932 km (38 km rețea cu tensiune de 110KV) [Trans2014].

Sistemul Electroenergetic Național (SEN) este interconectat cu Sistemele Electroenergetice (SEE) ale țărilor vecine, rezultând mai multe secțiuni [Deacu2015], prezentate schematic în Fig. 2.2.1.

Aproximativ 80% din grupurile termoelectrice existente în prezent au fost instalate în perioada 1970-1980, aflându-se azi la limita duratei normale de exploatare, cu randamente de circa 30%. Este de așteptat ca până în anul 2020 unele centrale să fie închise (CET Iași, CET Suceava, CET Bacău, CET Brașov, CET Govora, CET Halânga, CET Arad, CET Giurgiu, CET Oradea etc.) [Mușatescu2012].

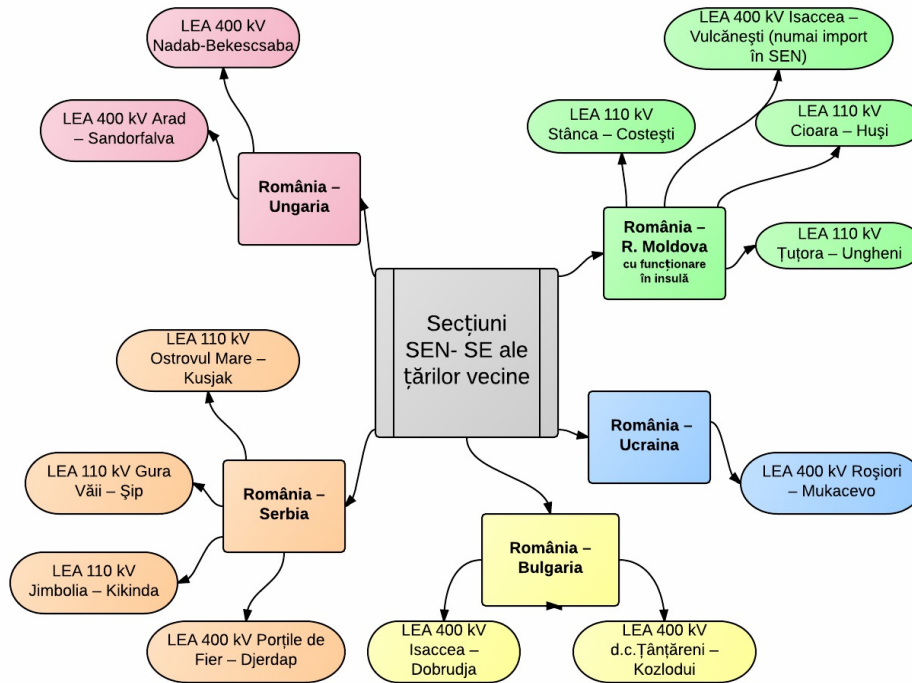


Fig. 2.2.1. Secțiuni SEN-SE ale țărilor vecine

Majoritatea echipamentele electrice din cadrul rețelelor de distribuție a energiei electrice sunt caracterizate prin faptul că se află la sfârșitul duratei de amortizare. Acestea vor fi supuse înlocuirii excesive cu echipamente inteligente. În plus rețelele actuale de distribuție a energiei electrice de 6 kV, din mediul urban, vor fi înlocuite în următorii ani cu rețele de 20 kV.

Performanțele deosebit de bune ale unităților nucleare electrice de la CNE Cernavodă, de la punerea în funcțiune și până în prezent, inclusiv costurile de funcționare și mentenanță relativ scăzute comparativ cu centralele clasice cu combustibili fosili, coroborat cu necesitatea asigurării securității energetice în condițiile respectării cerințelor privind schimbările climatice, au permis analiza oportunităților de finalizare a Unităților 3 și 4 de la CNE Cernavodă, proces inițiat în anul 2004. În contextul actual, finalizarea acestui proiect este estimată în jurul anului 2020.

Producția netă de energie în 2014 a continuat tendința crescătoare manifestată în 2013 față de anul 2012, aceasta accentuându-se și depășind 10% (11,4% comparativ cu anul anterior). Anul 2014 a înregistrat o creștere a puterii instalate brute de 3,4% (797 MW) comparativ cu anul 2013, datorată într-o proporție semnificativă surselor regenerabile (Tabelul 2.1.2.) [Trans2014a].

Tabelul 2.1.2. Putere instalată

P [MW]	2014	2013	2012
Termo	12.102	12.079	12.454
Nuclear	1.413	1.413	1.413
Hidro	6.709	6.648	6.563
Regenerabile	4.276	3.563	2.008
Total	24.500	23.703	22.438

La nivel lunar, consumul mediu net de energie electrică în anul 2014 a înregistrat o tendință de creștere față de anul 2013, situație evidențiată în Tabelul 2.1.3.

Tabelul 2.1.3. Consum maxim 2012 - 2014

An	Lună	Valoare [MWh / h]
2014	Dec	8.464
2013	Ian	8.312
2012	Feb	8.627

Consumul maxim orar net corespunzător anului 2014, a fost înregistrat în luna decembrie, în aceeași tendință a ultimilor ani când valorile maxime au fost înregistrate în lunile de iarnă (Fig. 2.2.2) [Trans2014a].




Fig. 2.2.2. Vârfulurile de consum înregistrate la nivelul sistemului electroenergetic național (MWh/h)

În perioada 2009-2014 în România s-au construit și pus în funcțiune în eolian 2.967 MW, cu o producție anuală de circa 5 TWh, totalizând investiții de 4,8 miliarde Euro, din care 1,8 în economia națională (drumuri, rețele și stații electrice, studii, taxe pentru autorizații, cheltuieli cu forța de muncă, etc.). Energia eoliană a favorizat scăderea prețului mediu al energiei de la o valoare de 188,3 RON/Mwh în 2008 la 147,57 RON/MWh în 2014. Semnificativ este faptul că la consumatorii casnici în România prețul mediu se situează la circa 65% (128 față de 201 Euro/MWh) din media la nivelul UE, iar pentru consumatorii industriali la circa 68% (82 față de 119 Euro/MWh). Efectul negativ al schimbărilor legislative pe fondul crizei economice a fost o scădere abruptă a investițiilor străine în anul 2014 (de la circa 5,99 miliarde în 2013 la circa 2 miliarde Euro în 2014) [Vilt2015].

În domeniul furnizării piața a fost liberalizată, și în prezent există aproape 60 de furnizori de electricitate. În privința distribuției, însă concurența este greu de implementat.

Anul 2014 a fost unul de export net pe fondul unui an cu hidraulicitate ridicată și creștere a producției în centralele electrice fotovoltaice. În plus, o contribuție importantă la creșterea exportului din punct de vedere comercial a avut-o scutirea energiei exportate de la plata contribuției pentru cogenerarea de înaltă eficiență, intrată în vigoare de la 1 iulie 2014 [Trans2014a]. În Fig. 2.2.3 sunt ilustrate grafic schimburile comerciale de energie electrică în perioada 2012-2014.




Fig. 2.2.3. Fluxuri comerciale (TWh)

Producătorii care vând energie în componenta reglementată de stat sunt hidrocentralele și reactoarele nucleare. Prețurile cu care vând aceste companii sunt fixate tot de ANRE la 120, respectiv 158 de lei pentru fiecare megawatt. Pe bursă vând și alți producători: termocentralele, turbinele eoliene, câmpurile fotovoltaice și centralele pe gaz. Prețul mediu pe bursă este de 170 de lei pentru fiecare megawatt. Companiile de distribuție cumpără energie din ambele surse și îi adaugă taxe. Din păcate pierderile energetice din sistem datorate vechimii instalațiilor și lipsei de investiții sunt încă mari. În contractele de privatizare semnate în anii 2005 și 2007 companiile de distribuție trebuie să întrețină transformatoarele, cablurile de joasă tensiune și stațiile de transformare. Aceste investiții sunt recuperate din facturi și astfel s-a ajuns ca taxa de distribuție să fie aproximativ 35% - 38% din prețul final pe energie electrică.

În prezent prețul final al energiei electrice este stabilit astfel: 60% din factură este un preț fix, stabilit de stat și 40% este energie cumpărată de pe bursă de către companii; în viitorul apropiat procentele vor fi egale, de 50%.

Lipsa concurenței face ca prețul energiei care iese de pe poarta centralei să crească de la 120 până la 400 de lei pe megawatt oră, astfel de la producător și până la priză, prețul electricității crește de peste trei ori. Ponderea cea mai mare în factură o are taxa de distribuție care depășește 35% din factura finală în timp ce tariful perceput de furnizor este de doar 6%.

În concluzie liberalizarea distribuției printr-o concurență reală poate duce la o scădere substanțială a prețului pe care îl suportă consumatorul final.

Progresele făcute în perfecționarea funcționării sistemului energetic sunt remarcabile, dar cu toate acestea fiabilitatea serviciului energetic, atât în alimentarea consumatorilor casnici cât și a celor industriali, este departe de a fi perfectă. În serviciul de alimentare cu energie a consumatorilor au loc destul de dese întreruperi, iar frecvența de apariție a perturbațiilor în sistem a crescut, printre acestea numărându-se armonicile, golurile de tensiune și supratensiunile.

□ Scenarii privind evoluția consumului de energie electrică în SEN

Separarea sectoarelor de producție, furnizare, transport și distribuție a introdus pentru OTS un grad mare de incertitudine asupra evoluției viitoare a producției și consumului. Pornind de la informațiile disponibile de la Ministerul de resort, institutele de prognoză, utilizatorii RET, alte părți interesate și OTS europeni, Transelectrica, a elaborat mai multe scenarii privind evoluția SEN în perspectivă – perioada 2014 - 2023 -2030 [Trans2014].

Consumul prognozat pentru toate trei scenarii: de bază, de consum maxim și de consum minim pentru perioada anilor 2012-2020 este prezentat în fig. 2.2.4 [Simo2014a].

Un alt studiu se referă la câteva scenarii privind evoluția consumului de energie electrică cu perspectiva până în 2030 – ca parte integrantă a strategiei energetice naționale, elaborat de ISPE S.A. (Fig.2.2.5). La elaborarea scenariilor privind evoluția consumului de energie electrică, s-au avut în vedere previziunile macroeconomice disponibile, în principal prognozele elaborate de Comisia Națională de Prognoză privind evoluția PIB. În acest studiu se propune un scenariu de referință (bază) privind ratele de creștere a consumului, apropiat de scenariul de bază al Transelectrica și două scenarii alternative pesimiste, cu rate mai mici de creștere. Ținând seama de evoluția înregistrată a consumului în anul 2013, s-a luat în considerare și un scenariu suplimentar cu o prognoză de scădere a consumului pe primii patru ani din perioada respectivă [Trans2014].

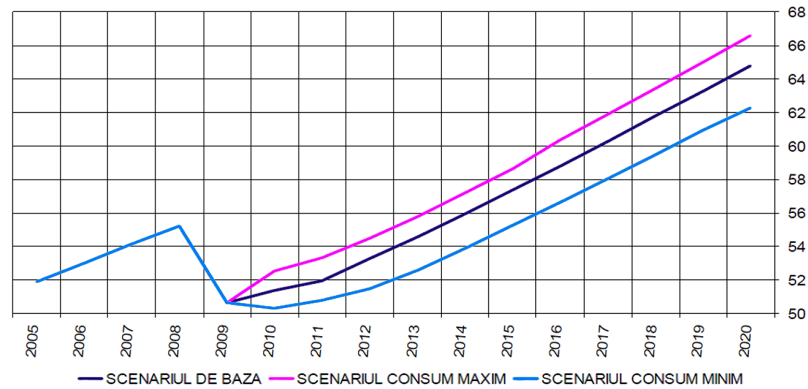


Fig. 2.2.4. Consumul net anual de energie electrică prognozat




Fig. 2.2.5. Scenarii de evoluție a consumului net de energie electrică

2.3. Sursele regenerabile de energie

2.3.1. Situația pe plan european

Emisiile generate de sectorul energetic reprezintă aproape 80% din totalul emisiilor de gaze cu efect de seră din UE. Aproape 45% din capacitatea europeană de generare a energiei electrice se bazează pe surse cu emisii reduse de carbon, în principal pe centralele nucleare și pe hidrocentrale [EnSTR2020].

Adoptat în 2009 de UE „Planul strategic european pentru tehnologiile energetice – Către un viitor cu emisii reduse de carbon” propune o strategie cu accent pe tehnologiile de îmbunătățire a eficienței energetice, utilizare a surselor regenerabile de energie și de reducere a emisiilor de CO₂ (centrale cu ardere pe combustibil solid cărora să li se aplice tehnologia de captare și stocare a CO₂ și a patra generație de centrale nucleare).

Consiliul Mondial al Energiei folosește în studiile sale așa zisele scenarii JAZZ și SYMPHONY, care servesc la compararea diferitelor abordări pentru progresele viitoare în domeniul energetic. Scenariul JAZZ se concentrează pe soluții individuale în cadrul țărilor individuale și o preferință pentru deciziile benefice din punct de vedere economic. Pe de altă parte scenariul SYMPHONY oferă soluții uzuale la probleme din

cadru unor unități mai mari, și pune accent pe achiziția de energie din surse regenerabile și pe mediu [Janiček2015].

Creșterea producției de energie electrică provenită din surse regenerabile a crescut considerabil în ultimii 5 ani cu aproape 6,6%, conform ENTSO-E (Fig. 2.3.1). Acest lucru a condus la scăderea emisiilor de CO₂. Energia solară și eoliană au crescut cumulativ de la doar 9% în 2011 la aproape 22% după numai 4 ani, iar față de 2013 creșterea se cifrează la aproape 5% [ENTSO2015]. Obiectivul UE este de a crește energia electrică obținută din surse regenerabile (Fig. 2.3.2).




Fig. 2.3.1. Creșterea producției de energie electrică provenită din surse regenerabile, în perioada 2010-2014, conform ENTSO-E

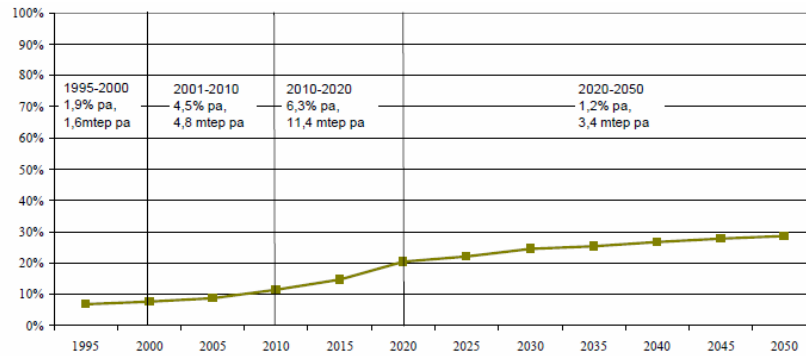


Fig. 2.3.2. Tendința istorică și proiectată a creșterii energiei din surse regenerabile în UE

În ciuda creșterii investițiilor în sursele regenerabile de energie emisiile de CO₂ eliberate în atmosferă vor crește (Fig. 2.3.3), principala cauză fiind dezvoltarea economică rapidă a țărilor din sud estul Asiei.




Fig. 2.3.3. Emisii de CO₂ cumulate legate de energie

Astfel conform scenariilor privind energia la nivel mondial, în anul 2050, planeta noastră se va confrunta cu o creștere aproape dublă a nivelului emisiilor de gaze cu efect de seră la nivel mondial comparativ cu situația pe care ne-am dori-o, în varianta optimistă, sau la o creștere de 4 ori a gazelor cu efect de seră în varianta pesimistă. În UE conform planurilor statelor membre, rata de creștere a energiei din surse regenerabile va atinge o valoare de până la 6,3 % pe an [WebA].

Conform estimărilor din [Mușatescu2012] în Europa, aproximativ 12% din producția obținută din surse regenerabile de energie, în 2020, va fi din instalațiile „offshore”, în mod special din Marea Nordului. Cantități importante vor veni din fermele solare și eoliene din sudul Europei, respectiv din instalații utilizând biomasă din Europa Centrală și de Est.

Folosind rețele inteligente și interconectate (incluzând stocare de mare capacitate), costul electricității produsă din surse regenerabile poate fi scăzut semnificativ, iar eficiența poate fi mărită la nivel paneuropean.

2.3.2. Producția din surse regenerabile în România

Deși România dispune de un potențial energetic teoretic semnificativ al SRE, potențialul care poate fi utilizat al acestor surse este mult mai mic, datorită tehnologiilor, limitărilor naturale, restricțiilor de mediu și a eficienței economice.

Potrivit Strategiei energetice a României pentru perioada 2007–2020, actualizată până în 2020, potențialul național surse regenerabile de energie din România este estimat la 14.718 ktep și se prezintă în Fig. 2.3.4 [CCCE2013].




Fig. 2.3.4. Distribuția SRE în România

Deoarece în prezent costurile de producere a energiei electrice în unități ce utilizează surse regenerabile de energie (cu excepția centralelor hidroelectrice mari) sunt mai ridicate decât cele aferente utilizării combustibilului fosil și nuclear, sunt necesare investiții; acestea, la rândul lor, se sprijină pe stabilitatea politicii în domeniul energiei din surse regenerabile.

Energia electrică produsă din surse regenerabile de energie este dispecerizată cu prioritate. Solicitățile de racordare la rețea pentru unitățile utilizând surse regenerabile de energie au crescut semnificativ după aplicarea prevederilor legii 220/2008. În acest context au apărut noi grupuri de centrale eoliene, fotovoltaice sau utilizând biomasă și apă.

La începutul anului 2014 CN Transelectrica SA înregistra o creștere de 1638 MW datorată conectării la rețea a energiei produse folosind surse regenerabile de energie [ANRE2013].

Directiva 2009/28/CE prevede că în cazul României, ținta din 2020 pentru SRE este de 24% (față de valoarea de referință de 17,8% în anul 2005), iar participarea SRE în necesarul brut de electricitate ar trebui să fie de 35% în 2015, respectiv, de 38% în 2020.

La sfârșitul anului 2013, era în funcțiune în România o capacitate de producere de energie electrică din surse regenerabile de energie de 3815 MW, din care 2470 MW (64,7%) din surse eoliene, 810 MW (21,2%) din energie solară, 480 MW (12,6%) din energie hidro (sub 10 MW), 55 MW (1,5%) din biomasă și biogaz [Leca2015].

România practic și-a îndeplinit ținta de promovare a surselor regenerabile de energie SRE pentru anul 2020. Tabelul 2.3.1 prezintă potențialul surselor regenerabile de energie al României, conform Planului Național de Acțiune pentru Energii din Surse Regenerabile (PNAER), 2010.

Tabelul 2.3.1. Potențialul din România al SRE - Sursa: Planul Național de Acțiune în Domeniul Energiei din Surse Regenerabile (PNAER) 2010

Tipul de SRE (% din potențialul economic total)		SRE pentru	Potențialul energetic anual	Echivalentul energetic economic [ktep]
Solar Termal (9,8%)		Căldură	60 mil. GJ	1433
Solar FV (0,7%)		Energie electrică	1200 GWh	103
Eolian (13,4%)		Energie electrică	23000 GWh	1978
Hidro (23,4%) (și Micro Hidro)		Energie electrică	40000 GWh (6000 GWh)	3440 (516)
Geotermal (1,1%)		Căldură	7 mil. GJ	167
Biomasă (51,6%)	Biomasă solidă	Căldură / Energie electrică	290 mil GJ	6917
	Biogaz	Căldură / Energie electrică	15 mil GJ	353
	Deșeuri urbane	Căldură / Energie electrică	14 mil. GJ	327

Se poate observa că mai mult de jumătate din potențialul total al țării, este aproape în totalitate nefolosit în scopuri energetice.

2.4. Smart Grid

2.4.1. Considerații preliminare

Termenul de „Smart Grid” a fost utilizat pentru prima oară într-un document oficial la sfârșitul anului 2007, în [EnISA2007]. Conform raportului Electric Power Research Institute (EPRI), din iunie 2009, termenul Smart Grid se referă la o modernizare a sistemului de furnizare a energiei electrice în ceea ce privește monitorizarea, protecția și optimizarea automată a funcționării elementelor sale interconectate – de la generarea centralizată și distribuită a energiei electrice, prin intermediul rețelelor electrice de transport și distribuție, la utilizatori industriali și sistemele / rețelele automatizate din clădiri, instalațiile de stocare a energiei și până la utilizatorii finali care au receptoare cu termostate, vehicule electrice, aparate de uz casnic și alte aplicații [Vatră2014].

Definirea termenului și a conceptului general de Smart Grid, în UE, s-a adoptat în 2009 și apoi s-a reconfirmat în 2010 de către European Regulators Group for Electricity and Gas (ERGEG):

“Smart Grid este o rețea de energie electrică capabilă să integreze în mod eficient comportamentul și acțiunile tuturor utilizatorilor conectați la aceasta – producători de energie electrică, consumatori și cei care produc și consumă simultan – în scopul de asigura, eficient din punct de vedere economic, un sistem energetic sustenabil cu pierderi reduse și niveluri ridicate de calitate și securitate în alimentarea cu energie electrică și în condiții de siguranță.”

Această ultimă formă a definiției reprezintă punctul de vedere oficial comun al Comisiei Europene și a principalelor organisme de lucru pentru Smart Grid [Vatră2014].

Beneficiile oferite Smart Grids sunt [EUCTF2010] [ERGEG2009]:

- facilități mai mari pentru o mai bună conectare și funcționare a tuturor generatoarelor din sistem;
- permit consumatorilor să joace un rol în optimizarea funcționării sistemului electroenergetic;
- oferă consumatorilor mai multe informații și opțiuni pentru alegerea alimentării cu energie electrică;
- reduc semnificativ impactul asupra mediului al întregului sistem de alimentare cu energie electrică;
- mențin sau chiar măresc nivelurile actuale ridicate de fiabilitate a sistemului de alimentare cu energie electrică, de calitate și securitate a alimentării cu energie electrică;
- mențin și îmbunătățesc eficiența serviciilor existente;
- grăbesc integrarea în Piața Europeană Integrată de Energie Electrică.

Pentru implementarea conceptului de Smart Grid, Comisia Europeană a stabilit formarea unei Comisii de Coordonare Smart Grid (Task Force), alcătuită din 3 grupuri de lucru (EG1, EG2 și EG3), care va lua în considerare conceptele și dezvoltările tehnologice ale tuturor părților interesate. Aceasta recomandă ca funcțiile de bază ale Smart Grid să fie dezvoltate preponderent de Operatorii de Transport și Distribuție (OTD) în conformitate cu reglementările și tarifele legal stabilite de autoritățile de reglementare.

Smart Grid constituie practic a treia generație de sisteme energetice, cea în care rețeaua electrică este dublată sinergetic de cea a rețelei informatice care realizează conectarea participanților și prin informație. Smart Grid combină elemente de software și hardware menite să îmbunătățească semnificativ modul în care sunt conduse și exploatate actualele rețele electrice și să permită interacțiunea în timp real între entitățile interesate din lanțul producție, transport, distribuție, furnizare, consumator final de energie electrică [Vatră2014].

Implementarea în România a conceptului de Smart Grids a fost decisă de MECMA în 2010. Conform Planului de Acțiuni, aprobat de MECMA toate societățile din cadrul SEN încep să treacă la măsuri concrete de implementare a acestui concept revoluționar. România și-a propus să devină un jucător important și chiar lider pe piața de energie din zonă [Vilt2010].

2.4.2. Actorii implicați în implementarea Smart Grids. Rol și responsabilități

Conform raportului efectuat de Grupul de Experți EG3(20) din aprilie 2011 actorii participanți la Smart Grids se clasifică astfel (Fig. 2.4.1):

- operatorii rețelelor electrice (Grid Operators);
- utilizatorii rețelelor electrice (Grid Users);
- actorii din piața de energie electrică (Energy Market Place);
- furnizorii de tehnologii, produse și servicii (Providers of technologies Products and Services);
- influențatori (Influencers) [Vatră2014].

Operatorii rețelelor electrice includ OTS și Operatorii rețelelor de distribuție (OD). OTS și OD sunt primii care trebuie să acționeze pentru implementarea Smart Grids. Au rolul de a implementa structura de rețea ce permite fluxul de energie și de informații între consumatori, producători, furnizori și ceilalți actori din cadrul Smart Grid. Sunt necesare investiții și inovații importante din partea OD și OTS. OD

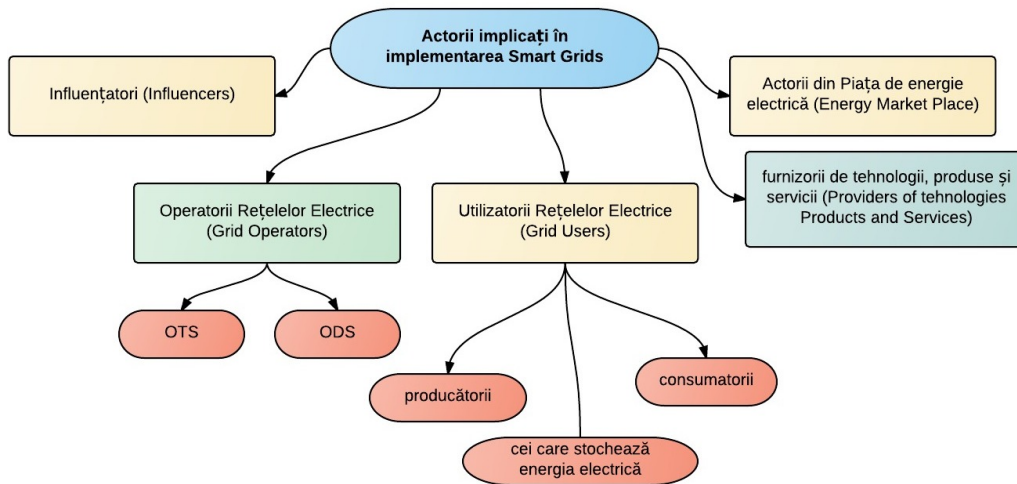


Fig. 2.4.1. Actorii implicați în implementarea Smart Grids

trebuie să continue modernizarea infrastructurii rețelelor, a dispeceratelor, iar OTS să-și restructureze treptat controlul sistemului electroenergetic și managementul informațiilor de piață cu privire la prognoza sarcinii totale în SE (în colaborare cu OD) [Vatră2014].

Utilizatorii rețelelor electrice pot participa în calitate de consumatori dar și în calitate de producători (Prosumers). În funcție de caracteristicile lor consumatorii / clienții sunt clasificați în:

- consumator / client industrial;
- consumator / client transportator;
- clădiri;
- consumator / client casnic;
- instalator / contractor în domeniul energiei electrice;
- furnizor;
- vânzător cu amănuntul.

Consumatorii de energie electrică vor fi în centrul atenției putând participa activ atât la piețele de energie electrică cât și la operarea în siguranță și eficiență a rețelelor electrice. Sub denumirea de Prosumers pot dispune de Resurse de Energie Distribuite controlabile local sau de la distanță. Ei trebuie să fie capabili să utilizeze energia electrică generată, ori de câte ori aceasta este disponibilă [Vatră2014].

Actorii din piața de energie electrică se referă la:

- bursa de energie (Power Exchange);
- partea responsabilă cu echilibrarea (Balance Responsible Party);
- agent de compensare și decontare (Clearing & Settlement Agent);
- comerciant (Trader);
- furnizor (Supplier);
- agregator.

Furnizorii de tehnologii, produse și servicii pentru actorii menționați mai sus se clasifică în următoarele categorii:

- furnizori / vânzători de echipamente pentru rețele electrice;
- furnizori de servicii de sistem;
- operatori de metering;
- furnizori de servicii de IT&C;

- furnizori de sisteme / rețele de comunicații pentru rețelele electrice;
- furnizori de aparate de uz casnic;
- furnizori de sisteme de management a energiei în clădiri;
- furnizori de soluții pentru transporturile electrificate și vehiculele electrice.

Influențatorii, sunt cei care influențează adică:

- consumatorii și Smart Metering;
- autoritatea de reglementare;
- organisme de standardizare;
- autorități legislative ale UE și naționale;
- întreprinderile din sectorul financiar.

2.4.3. Evoluția actualelor sisteme spre Smart Grids

Pentru implementarea Smart Grids au fost definite două etape de calendar, prima etapă se întinde până în anul 2020 și cea de-a doua până în anul 2050.

Prioritățile de implementare pentru Smart Grids până în anul 2020 conform [Vatră2014] sunt:

1. Optimizarea operării și utilizării sistemului electroenergetic – se referă la funcționarea descentralizată și coordonată a sistemului electroenergetic, securitatea operațională a acestuia, optimizarea pierderilor și a piețelor bazat pe fluxurile de energie electrică;
2. Optimizarea infrastructurii sistemului electroenergetic – se referă la îmbunătățirea și optimizarea sistemelor electroenergetice existente și la realizarea unor noi categorii de rețele electrice;
3. Integrarea generării intermitente la scară mare și la scară mică – se referă la integrarea în rețele electrice și în piața de energie a generării pe bază de surse regenerabile de energie atât în centrale electrice de puteri mari cât și în cele de dimensiuni mici;
4. Tehnologia informației și comunicații, implică utilizarea pe scară largă a standardelor și soluțiilor din domeniul informaticii și comunicațiilor;
5. Rețele de distribuție active, adică "activarea" rețelelor de distribuție (se referă la gradul de automatizare și de funcționare, marea majoritate a acestor rețele depind, în prezent, de intervenția unui operator uman);
6. Piețe și utilizatori noi și eficiență energetică, prin punerea clientului în centrul atenției.

European regulators Group for electricity and Gas a evidențiat 5 elemente motrice care impun evoluția actualelor sisteme electroenergetice spre Smart Grids [ERGEG2009], [Vatră2014]:

1. producerea la scară mare din surse regenerabile de energie;
2. generare distribuită;
3. participarea activă a utilizatorilor finali;
4. integrarea piețelor;
5. îmbunătățirea securității naționale (monitorizarea fluxurilor de putere, a stării rețelelor electrice și declanșarea acțiunilor de remediere înainte de a se produce congestiile).

Conform Directivei 2009/72/CE [Dir2009/72], prin generare distribuită se înțelege producerea de energie electrică în centralele electrice conectate la rețelele de distribuție. Generarea distribuită presupune o colaborare între producătorii de energie și entitățile de transport și distribuție, fiind necesară o schimbare de optică. Acest lucru poate fi înlesnit prin considerarea mai multor producători mici, apropiați geografic, ca fiind legați între ei pe partea de joasă tensiune și făcând parte din așa

numite centrale virtuale conduse prin intermediul unui sistem de management al generării distribuite (Demand Side Management – DSM).

Sursele de generare distribuită pot fi amplasate la diferite nivele de tensiune, pentru a servi zonele de consum situate în apropiere, dar și pentru a acorda un sprijin rețelelor electrice de distribuție. Generarea distribuită va afecta mai ales rețelele de distribuție, dar poate influența chiar și rețelele de transport. Nu este luată în considerare la proiectarea rețelelor electrice deoarece în majoritatea cazurilor există o marjă suficientă pentru a se conecta și generatoare de mică putere. Producția de energie din surse de generare distribuită poate fi prognozată numai în anumite limite, ca procent din puterea instalată, puterea reală putând avea abateri semnificative față de cea prognozată.

Sursele de generare distribuită sunt foarte sensibile la parametrii energiei electrice din SE, putând fi declanșate de la sistem de variații care pot apărea destul de des în funcționarea normală a SE: goluri de tensiune, variații de frecvență și alte fenomene tranzitorii. Rezultă că nu se poate garanta o calitate a energiei electrice livrate de aceste generatoare decât între anumite limite.

Dintre principalele probleme cu caracter general apărute în sistemele electrice din țările vecine având un număr important de centrale bazate pe surse de generare distribuită, în particular cele eoliene, racordate la sistem s-au evidențiat:

- circulații mari și neprevăzute de puteri care afectează sistemele vecine și reduc capacitățile disponibile pentru comerț și liniile de interconexiune;
- creșterea frecvenței de apariție a congestiilor de rețea, ceea ce duce la necesitatea de întărire și dezvoltare a rețelelor naționale;
- amplasarea producătorilor de energie regenerabilă în zonele cu potențial ridicat, indiferent de zonele avantajoase din punct de vedere a dezvoltării rețelelor electrice în ansamblu și a polilor de consum;
- punerea în pericol a siguranței sistemelor electroenergetice datorită deconectării rapide a centralelor regenerabile la avarii minore în sistem, experiența arătând că generarea eoliană nu "susține" rețeaua;
- creșterea necesarului de rezervă de putere la dispoziția operatorilor de sistem;
- creșterea pierderilor de energie în rețea și creșterea nivelului de energie reactivă necesar a fi compensată.

În tabelul 2.4.1 se prezintă sintetizat o comparație a rețelelor clasice versus Smart Grids.

Tabelul 2.4.1. Comparație rețele clasice versus Smart Grids

Rețelele clasice	Smart Grids
Generare centralizată și control centralizat	Generare centralizată și distribuită Control inteligent central și distribuit
Circulația liberă a puterilor conform legilor lui Kirchhoff	Controlul circulației de puteri cu ajutorul electronicii de putere
Producția de energie electrică prin simpla urmărire a sarcinii	Echilibrarea dinamică a producției sau consumului variabil
Comutație manuală	Răspuns automat, Acțiuni predictive
Mentenanță periodică	Mentenanță predictivă
Comunicare într-un singur sens	Comunicare în ambele sensuri
Topologie radială	Topologie buclată
Informații limitate privind prețul energiei	Informații complete privind prețul energiei
Alegerea furnizorului de energie de către consumator este redusă	Posibilități multiple ale consumatorului de alegere a furnizorului de energie

2.4.4. Modelul conceptual european de Smart Grid

Modelul conceptual pentru Smart Grids al UE se bazează pe modelul NIST (National Institute of Standards and Technology), introdus de SUA în 2009.

Modelul NIST definește șapte domenii de nivel înalt (Generare în cantități / centrale mari, Transport, Distribuție, Clienți, Operațiuni, Piețe și Furnizori de servicii) și prezintă toate fluxurile de comunicații și de energie electrică. Fiecare din cele șapte domenii conține elemente importante Smart Grid, conectate între ele prin căi bidirecționale de comunicații și/sau de energie electrică și interfețe aferente acestor căi.

Modelul conceptual european de Smart Grid vine în plus cu câteva extensii (Fig. 2.4.2), dar și cu unele particularizări. Apare astfel încă un domeniu, cel intitulat Domeniul Resurselor de Energie Distribuite (Distributed Energy Resources Domain). Aria de aplicare a conceptului de microgrid include Domeniile Clienți, Distribuție și Resurse de Generarea Distribuite.

Unul din obiectivele microgrid este de a se găsi un echilibru între producție și consum, pe cât posibil la nivel local, evitând astfel pierderile din rețeaua de transport și de a crește fiabilitatea rețelei electrice de transport prin serviciile de sistem oferite de generarea distribuită.

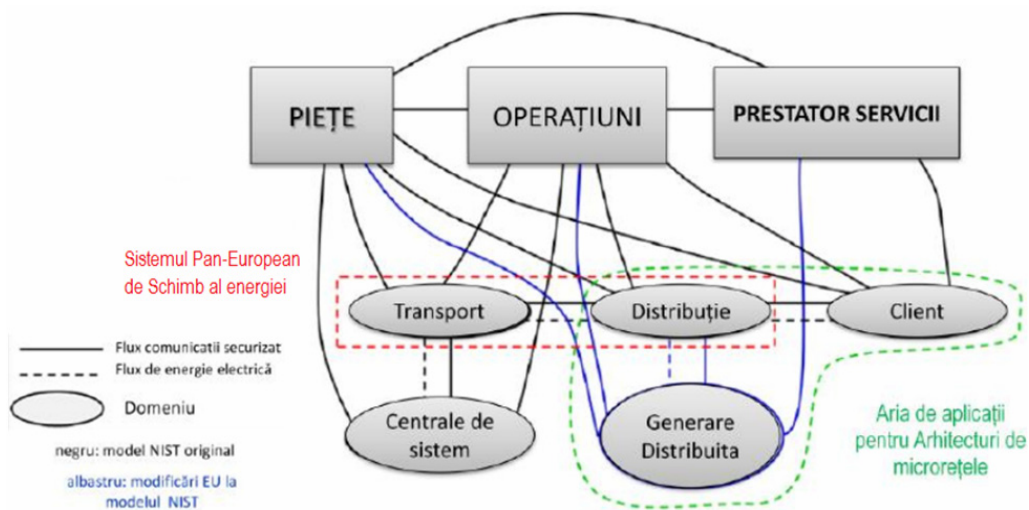


Fig. 2.4.2. Modelul conceptual pentru Smart Grids al UE

Cadrul Modelului Arhitectural Smart Grid SGAM (Smart Grid Architecture Model Framework) constă din cinci straturi reprezentând obiective și procese de afaceri, funcțiuni, schimbul și de modele de informații, protocoale și componente de comunicații. Fiecare strat se referă la Planul Smart Grid, care este format din Domenii electrice și Zone de management a informațiilor.

Obiectivul principal a procesului de mapare în SGAM este realizarea / dezvoltarea unei arhitecturi de tip Smart Grid pentru cazul de utilizare analizat și identificarea standardelor care se aplică pentru implementarea cazului de utilizare.

Fig. 2.4.3 prezintă evoluția procesului de mapare a sistemelor de smart grid în Modelul arhitectural Smart Grid SGAM, pentru anul 2014.

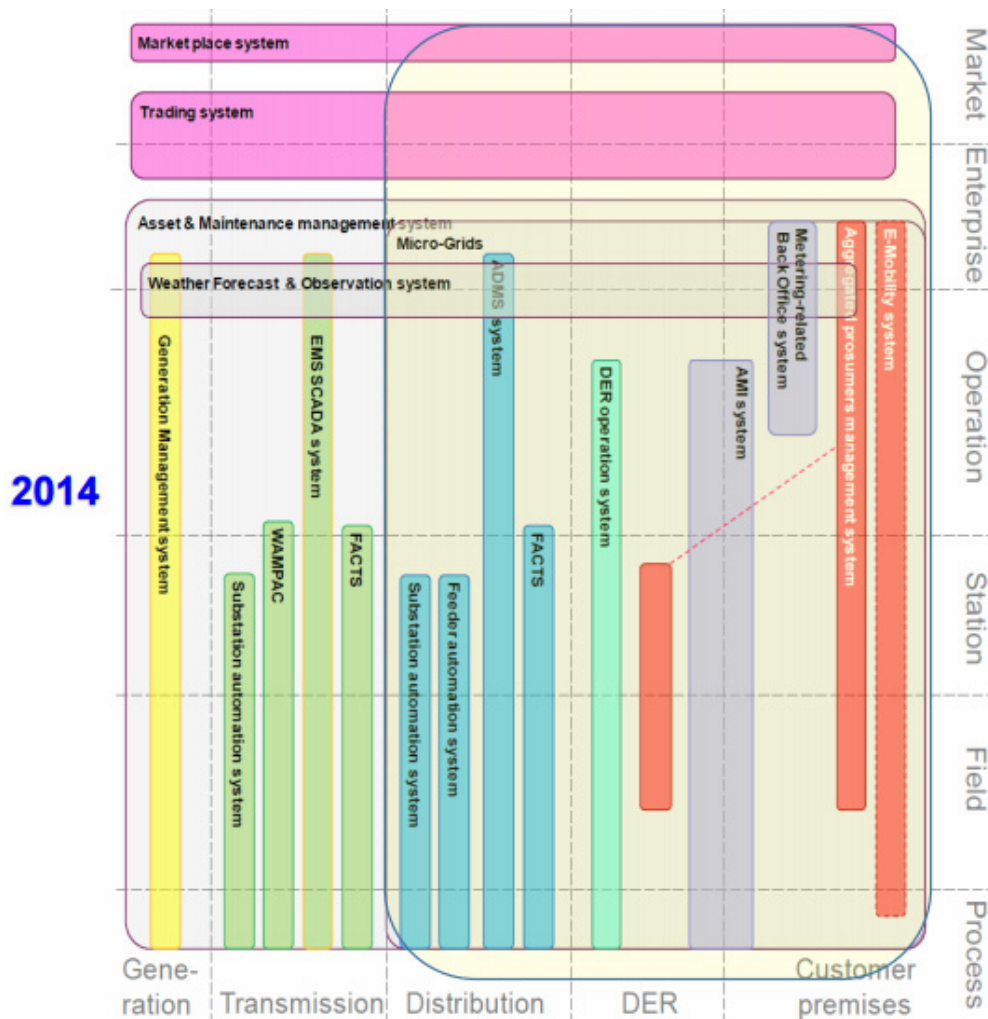


Fig. 2.4.3. Evoluția procesului de mapare a sistemelor de smart grid în Modelul de arhitectură a unui Smart Grid (SGAM). Sursa: CEN_CENELEC_ETSI

2.5. Concluzii

Capitolul 2 prezintă o sinteză a problemelor actuale privind sectorul energetic. Prima parte a capitolului cuprinde o scurtă sinteză referitoare la obiectivele politicii energetice la nivelul UE și a evoluției consumului de energie pe plan mondial, european și național. A doua parte este consacrată pieței europene de energie electrică și celei din România. Se prezintă și situația utilizării surselor regenerabile de energie în cadrul UE și pe plan național precum și o serie de elemente legate de rețelele inteligente, privite în contextul tematicii tezei de doctorat.

Cererea mondială de energie este în creștere, fiind în principal determinată de dezvoltarea economică în țările din afara OECD. Pentru a suporta cererea crescută de energie, mai ales a celei electrice, rețelele electrice trebuie să fie modernizate.

Integrarea surselor regenerabile de energie în piața de electricitate este, conform UE, în continuă creștere și se preconizează că până în anul 2050 acestea vor acoperi o mare parte din consumul de energie electrică, fapt ce ar conduce la reducerea emisiilor de CO₂ și la reducerea dependenței UE de importul de combustibili fosili. Sursele regenerabile de energie din România au un potențial teoretic important.

România este în faza finală a reorganizării sectorului de generare, în contextul cerințelor UE, pentru optimizarea investițiilor și scăderea costurilor de producție. Trebuie subliniat că România are o piață a energiei funcțională cu o deschidere a pieței de 100% atât la energia electrică cât și la gaze, fiind în zona mediei conform clasificării UE.

Generarea distribuită a luat, în ultima perioadă, o amploare deosebită pe plan mondial, prin urmare o atenție deosebită este acordată modului de comportare a întregului sistem electroenergetic. Amplasarea optimă a surselor de generare distribuită poate fi una benefică, dar în același timp poate avea repercusiuni negative prin încălcarea restricțiilor de sistem.

Smart Grids integrează tehnologiile electrice și informatice în orice punct al rețelei de la cele de generare până la cele de consum. Supranumită „internetul energiei”, Smart Grid, transformă practic rețeaua electrică existentă într-un sistem al secolului 21, capabil de autovindecare și auto-optimizare, în perfectă compatibilitate cu utilizarea pe scară largă a surselor regenerabile de energie. Prin promovarea noilor concepte de Smart Grid, și de consumatori activi care dialoghează cu utilitățile, energia trebuie să fie accesibilă în condiții de siguranță.

O primă analiză a datelor prezentate și a altor informații din acest domeniu evidențiază evoluția de multe ori contradictorie a consumului de energie electrică și, evident, a producției. Dacă la cele menționate se adaugă și elementele suplimentare aduse de liberalizarea completă a pieței de energie electrică, de dereglementarea sectorului energetic, rezultă că activitatea de prognoză a consumului reprezintă o sarcină complexă și foarte dificilă la ora actuală, atât la nivel global, cât și la scara unei zone mai reduse de consum.

În continuare se prezintă o trecere în revistă a contribuțiilor originale din cadrul acestui capitol:

- prezentarea, într-o manieră sintetică a obiectivelor politicii energetice la nivelul UE și reliefaarea evoluției cadrului legal actual în domeniu, în concordanță cu legislația comunitară corespunzătoare;
- realizarea unei sinteze documentate, în viziunea proprie a autorului, privind stadiul actual al evoluției consumului de energie pe plan mondial, european și național;
- prezentarea unei sinteze documentate, a situației utilizării surselor regenerabile de energie în cadrul UE și pe plan național, cu evidențierea avantajelor obținute în reducerea emisiilor de CO₂;
- realizarea unei sinteze documentate, în viziunea proprie a autorului, asupra conceptului Smart Grid, cu expunerea actorilor implicați, a rolului și a responsabilităților acestora, și cu evidențierea beneficiilor produse de generarea distribuită, dar și a repercursiunilor negative prin încălcarea unor restricții de sistem;
- prezentarea sintetică a modelului conceptual european și a cadrului modelului arhitectural Smart Grid SGAM, cu evidențierea priorităților de implementare și realizarea unei paralele între rețelele clasice și Smart Grids;
- evidențierea necesității unei atenții sporite acordate activității de prognoză a consumului (și a producerii), în contextul unor evoluții de multe ori contradictorii (înregistrarea unor perioade de scădere, urmate de creștere).

3. DINAMICA CERCETĂRILOR ÎN DOMENIUL PROGNOZEI CONSUMULUI DE ENERGIE ELECTRICĂ

Obiectivul capitolului 3 constă în prezentarea sistematizată a aspectelor generale legate de cercetările privind prognoza consumului de energie electrică, a metodelor utilizate, cu accent pe cele care fac uz de o serie de tehnici de inteligență artificială.

Se trec în revistă manierele de abordare și de soluționare utilizate de diverși specialiști precum și rezultatele obținute, aplicațiile concrete soluționate referitoare la situații reale.

Metodele de abordare pentru problema în discuție sunt împărțite în două mari categorii:

- metode statistice (clasice) [Heinemann1966], [Lijesen1971], [Christiansen1971], [Papalex1990], [Villalba2000], [Amjady2001], [Engle1992], [Chen1995], [Charytoniuk1998], [Haida1994], [Hyde1997], [Zivanovic2001], [Ruzic2003], [Jin2004], [Hor2005], [Fan1994], [Cho1995], [Yang1996], [Yang1998], [Jin2010], [Senjyu2004], [Fu2003], [Chow2004].
- metode bazate pe tehnici ale inteligenței artificiale, incluzând rețelele neuronale artificiale (RNA) de diverse tipuri, algoritmi genetici (AG), tehnici de tip roi de particule (Particle Swarm Optimization – PSO), logica fuzzy (LF), sisteme expert (SE), tehnici utilizând SVM (Support Vector Machines), metode hibride, tehnici de tip Data Mining (DM): [Chen1995], [Chen1996], [Khotanzad1997], [Hayati2007], [Quaiyum2011], [Sheikh2012], [Park1991], [Djukanovic1993], [Peng1993], [Ranaweera1995], [Lame1996], [Chow1997], [Chow1997a], [Senjyu1998], [Nazarco1999], [Dimitrovski2000], [Cârțină2002], [Cârțină2004], [Mori1996], [Frantti2009], [Pandian2006], [Ismail2011], [Cârțină1994], [Rahman1996], [Ho1990], [Chauhan2005], [Wang2005], [Srinivasan1999], [Fu-yuan2006], [Mordjaoui2010], [Islam2011], [Farahat2004], [Șchiopu2015], [Deacu2015a], [Rădășanu2000], [Vapnik1995], [Yang2004], [Li2002], [Ghelardoni2013], [Tan2005], [Mori2001], [Liu2011], [Mori2002], [Mohammed2008], [Karapidakis2007], [Chen2004], [Qingle2010], [Gou2006], [He2006], [Zhang2008], [Xinhui2010], [Amjady2008], [AlRashidi2010], [Hong2012].

Tot în contextul tematicii tezei de doctorat, ultima parte a capitolului abordează și o serie de aspecte legate de metodele ce aplică tehnici ale inteligenței artificiale, utilizate pentru amplasarea și dimensionare a optimă a surselor de generare distribuită [Kim1998], [Greatbanks2003], [Wang2004], [Gandomkar2005], [Quezada2006], [Celli2001], [Carpinelli2001], [Carpinelli2005], [Celli2005], [Keane2006], [Keane2007], [Ochoa2008], [Rahim2008], [Varikuti2009], [Parizad2010], [Ameli2010], [Ghosh2010], [Yun-Feng2010], [Singh2010], [Atwa2010], [Barin2010], [Falaghi2011].

3.1. Metode de prognoză a consumului de energie electrică

3.1.1. Prezentare generală

Prognoza consumului de energie și putere este definită în [Vuc2001] ca fiind activitatea științifică ce are drept scop previziunea consumului de energie și putere pe baza analizei calculelor și interpretărilor unui ansamblu de date diversificate, astfel încât în final să se realizeze o concordanță cât mai exactă între consumurile estimate și cele efectiv realizate. Denumită și prognoza sarcinii, prognoza consumului de energie electrică este necesară pentru planificarea rezervei de putere și pentru efectuarea unor studii privind gradul de încărcare al rețelei și eventualele contingente. Prognoza sarcinii electrice are un rol important în formularea strategiilor economice pentru sistemele de putere. Prognoza cererii de energie înseamnă prognoza caracteristicilor acestei cereri: mărime, curbe de sarcină, structuri de cereri (pe categorii de consum, pe purtători, etc).

Curbele de sarcină reprezintă o importanță deosebită în energetică fiind utile atât în faza de proiectare, cât și în cea de exploatare a sistemului electroenergetic datorită faptului că ele conțin informația maximă despre dinamica consumului [Luștrea2001]. În țara noastră, curbele de sarcină se construiesc sub formă de paliere cu durată de o zi (24 paliere), sarcinile fiind exprimate în unități relative, raportate la sarcina medie a sarcinilor din curbele înregistrate și prelucrate. Forma curbei de sarcină nu diferă mult pentru consumatorii din aceeași categorie de consum. Curbele de sarcină se pot obține prin:

1. măsurători realizate în sistem;
2. calcule care se rezumă de regulă fie la însumări de curbe de sarcină, fie la adăugarea unor pierderi de energie, a consumului propriu tehnologic etc. la curbele de sarcină măsurate;
3. prin prognoză.

Prin intermediul curbelor de sarcină se poate prognoza consumul pentru o perioadă de timp viitoare și, deci, se poate estima cantitatea necesară energie electrică.

Prognoza consumului de energie poate fi clasificată după mai multe criterii [Luștrea2001], cu observația că părerile nu sunt întotdeauna unitare (mai ales în ceea ce privește orizontul de timp): după perioada pe care se referă (foarte scurte – până la un an, scurte – între 1-5 ani, medii – între 5-10 ani, lungi – între 10-25 ani, foarte lungi – peste 25 de ani); după extinderea spațială (consumatori individuali, consumatori regionali, consumatori zonali, consumatori naționali, consum mondial); după scop (în profil teritorial, pe ramuri economice, la nivel național); după natura metodei matematice (deterministe, probabiliste); după tipul metodei (explorative, normative, mixte); după natura variabilei independente (directe – endogene, indirecte – exogene, analitice, de tip Delphi); după numărul de componente ale consumului: globale – sintetice, pe componente – analitice).

Metodele de abordare pentru problema în discuție sunt împărțite în două mari categorii: metode statistice și metode bazate pe tehnici ale inteligenței artificiale. Prin combinarea a două sau mai multe metode există posibilitatea creării și utilizării unor tehnici hibride.

3.1.2. Metode statistice

Cele mai folosite metode statistice pentru prognoza sarcinii conform [CIGRE 1992] au fost regresia liniară multiplă (RLM) și seriile de timp stohastice (STS). Pentru prognoza pe termen mediu și lung au fost folosite și metode ce apelează la descompunerea spectrală (DS).

Alte metode statistice folosite pentru prognoza consumului utilizează Filtre Kalaman (FK), netezirea exponențială (NE) și altele. O repartitie a acestor metode conform [CIGRE1992] este prezentată în Tabelul 3.1.1.

Tabel 3.1.1. Repartiția metodelor statistice pentru prognoza consumului

Tip prognoză \ Metoda	RLM	STS	DS	NE	FK	Alte
Termen lung sau mediu	32%	20%	11%	7%	5%	14%
Termen scurt	34%	11%	2%	0%	2%	23%
Termen foarte scurt	16%	11%	0%	5%	0%	18%

Studiile referitoare la prognoza sarcinii pe termen scurt au debutat în anii '60, astfel în 1966 Heinemann a tratat în [Heinemann1966] dependențele între temperatură și consum. În anul 1971, Lijesen și Rosling au dezvoltat un sistem de prognoză a consumului folosind o abordare statistică [Lijesen1971]. Analistii au încercat în primul rând să aplice tehnici statistice, cum ar fi regresia și ARIMA (AutoRegressive Integrated Moving Average) (modele Box-Jenkins) [Luștea2001].

De-a lungul timpului au fost publicate o multitudine de articole ce tratează problema prognozei pe termen scurt folosind diferite metode din categoria statistică. Au fost folosite netezirea exponențială generală [Christianse1971], regresia liniară multiplă [Papalex1990], analiza în spațiul stărilor [Villalba2000], respectiv seriile de timp stohastice [Amjady2001].

În [Engle1992] sunt prezentate mai multe modele de regresie care efcuează prognoza consumului pentru ziua următoarea (next day). Modelele lor încorporează influențe deterministe, cum ar fi zilele de concediu, influențe stohastice cum ar fi sarcina medie și influențe exogene, cum ar fi vremea. Alte aplicații ale modelelor ce folosesc regresia pentru prognoza consumului de energie electrică și de putere sunt prezentate în [Charytoniuk1998], [Haida1994], [Hyde1997], [Zivanovic2001], [Ruzic2003], [Jin2004], [Hor2005]. Se remarcă și utilizarea diverselor tipuri de funcții de regresie: regresie polinomială [Zivanovic2001], regresie neparametrică [Charytoniuk1998], regresie robustă [Jin2004]. [Engle1992] prezintă câteva modele de regresie pentru prognoza zilelor următoare. Modelele lor încorporează influențe deterministe cum ar fi sărbătorile, influențe stohastice ca sarcina medie și influențe exogene cum ar fi vremea. 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.

Metodele ce folosesc seriile de timp se bazează pe presupunerea că datele au o structură internă, cum ar fi de autocorelația, trend-ul sau variațiile sezoniere. Seriile de timp au fost folosite de zeci de ani în domeniul precum cel al economiei, procesării digitale a semnalului precum și pentru prognoza sarcinii electrice. ARMA (Autoregressive Moving Average) [Chen1995], ARIMA (AutoRegressive Integrated

Moving Average) și ARIMAX (AutoRegressive Integrated Moving Average with Exogenous Variables) sunt metodele cel mai des folosite din această categorie.

Deoarece consumul depinde în general de vreme și oră ARIMAX este cea mai potrivită pentru prognoza sarcinii. [Fan1994] și [Cho1995] au descris implementări ale modelelor ARIMAX pentru prognoza consumului de energie electrică și de putere. În lucrările [Yang1996], [Yang1998] autorii au folosit o abordare bazată pe programarea evolutivă pentru a identifica parametrii modelului ARMAX. [Jin2010] utilizează modelul ARIMA pentru a prognoza consumul de energie electrică pe termen scurt din New South Wales, Australia.

[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. O abordare asemănătoare este utilizată, în cadrul unei analize de regresie adaptivă, în [Ruzic2003], pentru prognoza pe termen scurt a unor curbe de sarcină sensibile la condițiile meteo (mai ales la valoarea temperaturii), aplicația fiind implementată la Compania de Distribuție a Energiei Electrice din Serbia.

Tot aici se pot încadra și o serie de lucrări care vizează prognoza pe termen mediu și cea pe termen lung [Fu2003], [Chow2004].

Abordarea "end-use" estimează direct consumul de energie folosind o gamă largă de informații existente despre consumul final și utilizatorului final. Datele statistice de consum și dinamica schimbărilor stau la baza prognozei [Chow2004]. În mod ideal această abordare ar fi foarte precisă. Totuși, în mod real, ea depinde foarte mult de gradul de încredere al datelor inițiale. Faptul că informațiile nu trebuie să acopere o perioadă anterioară foarte lungă, ci se referă mai mult la calitatea echipamentelor și la obiceiurile de consum, reprezintă un avantaj incontestabil.

În [Fu2003] se prezintă un model econometric bazat pe metoda regresiei, în care s-au inclus și tehnica rețelelor de tip wavelet. Identificarea parametrilor modelului de prognoză se realizează prin soluționarea unei probleme de optimizare neliniară secvențial pătratică [Kilyeni2010]. În final se include în model, într-o manieră probabilistică, și influența temperaturii asupra consumului de energie electrică.

3.1.3. Metode bazate pe tehnici ale inteligenței artificiale

3.1.3.1. Metode utilizând Rețelele Neuronale Artificiale (RNA)

Începând cu anul 1990, accentul a căzut pe folosirea diferitelor tehnici de aplicare a inteligenței artificiale (IA). Astfel, autorii lucrării [Park1991] au fost printre primele grupuri de cercetare care au ales să folosească RNA pentru prognoza pe termen scurt a consumului de energie electrică.

Un nou algoritm bazat pe RNA pentru este prezentat în [Djukanovic1993]. Algoritmul a fost dezvoltat pe baza conceptului de învățare supervizată utilizat în tandem cu învățarea nesupervizată și realizează o clasificare a modelelor de intrare în clase, realizând apoi o antrenare supervizată pentru fiecare clasă formată. Intervalul

de prognoză este de 24 de ore, iar ca date de intrare se folosesc tipul zilei, temperatura și sarcinile zilei anterioare și temperatura prognozată pentru ziua curentă.

Modelul de rețea utilizat de [Peng1993] realizează prognoza pentru o săptămână și folosește un neuron adaptiv liniar (Adaline). Sarcina (consumul) conține trei componente: sarcina de bază, o componentă de joasă și una de înaltă frecvență. Fiecare componentă a sarcinii are un interval de frecvență unic. Descompunerea sarcinii se realizează folosind filtre digitale cu benzi de frecvență diferite. Acesta abordare este folosită și la prognoza încărcării grupurilor generatoare.

Capacitățile predictive ale rețelelor bazate pe funcții radiale și abilitatea lor de a furniza măsurători exacte, care pot fi utilizate pentru a estima intervalele de încredere, sunt prezentate în lucrarea [Ranaweera1995].

Pentru a depăși deficiențele legate de calitatea prognozei pentru cazul unor consumuri anormale care apar în timpul vacanțelor și a week-end-urilor, în [Lame1996] se propune o procedură bazată pe combinarea învățării supravegheate cu învățarea nesupravegheată. Etapa de învățare nesupravegheată realizează o clasificare a datelor cu ajutorul hărții de auto-organizare a lui Kohonen. În etapa supravegheată se realizează activitatea de prognoză propriu-zisă, un algoritm de antrenare de tip retro-propagare (backpropagation). Folosirea neconvențională a informației, provenind din etapa de clasificare, permite procedurii propuse să conducă la o îmbunătățire relevantă a calității prognozei pentru situații anormale.

În [Chen1996] se utilizează o RNA supervizată pentru realizarea prognozei sarcinii pentru trei stații din Taiwan, care alimentează diferite tipuri de consumatori (rezidențiali, comerciali și industriali). Luând în considerație efectul temperaturii asupra consumului de energie electrică se îmbunătățește calitatea prognozei.

În [Bakirtzis1996] se prezintă o metodă de prognoză pe termen scurt utilizând RNA, elaborată pentru serviciul de dispecer al sistemului electroenergetic din Grecia. Modelul adoptat utilizează o RNA cu trei straturi, complet conectată și cu parcurgere în sens direct. Antrenarea este realizată cu un algoritm de tip backpropagation. Variabilele de intrare cuprind datele orare de consum, temperaturile și zilele săptămânii, prognoza curbelor de sarcină fiind realizată pentru o săptămână. [Khotanzad 1997] prezintă un sistem de prognoză utilizând strategii RNA multiple, pentru a surprinde cât mai bine diversele tendințe de consum. Metoda este dezvoltată în continuare în [Khotanyad1998], care include două RNA – prima pentru consumul de bază, iar a doua pentru modificările de consum. Prognoza finală rezultă prin combinarea adaptivă a celor două componente. Metoda a fost utilizată un număr mare de operatori de distribuție din SUA și Canada.

[Chen2001] utilizează de asemenea o RNA complet conectată, cu trei straturi, și algoritmul Backpropagation ca metodă de antrenare. În [Lu2004] se propune o abordare mixtă, utilizând o combinație între RNA și seriile de timp de tip AutoRegressive Integrated Moving Average (ARIMA). Componenta liniară a datelor cunoscute de consum este tratată cu ARIMA, iar cea neliniară cu RNA. Studiile de caz prezentate, referitoare la date test empirice, evidențiază calitățile unei asemenea abordări.

În [He2006] se realizează o prognoză pe termen mediu cu ajutorul unei RNA recurente de tip Elman, la care se adaugă teoria entropiei și o abordare fuzzy, în scopul identificării factorilor de influență relevanți și a antrenării RNA.

[Hayati2007] a folosit trei arhitecturi de RNA: perceptron multistrat, Elman Recurrent Neural Network (ERNN) și Radial Basis Function Network (RBFN) pentru prognoza consumului pe termen scurt. Rezultatele au arătat că rețele de tipul RBFN sunt mult mai rapide și mai fiabile.

[Qingle2010] aplică o metodă de prognoză bazată pe RNA pentru situațiile când gradul de corelare a datelor cunoscute este extrem de scăzut ("rough set").

În [Quaiyum2011] prognoza sarcinii pe termen scurt se realizează folosind diferite tipuri de rețele neuronale artificiale. Analizele au arătat că rețele neuronale recurente de tip PSOERNN (Particle Swarm Optimized Elman Recurrent Neural Network) sunt cele mai eficiente. Pentru același scop, în [Sheikh2012] se utilizează unui model de RNA de tip perceptron multistrat (PMS) implementat în Matlab. Ei au arătat că modelul lor PMS este performant și are o precizie rezonabilă (au obținut pentru eroarea medie absolută procentuală valori în jur de 1%).

În final se remarcă rezultatele obținute în cadrul Centrului de Cercetare pentru Analiza și Optimizarea Regimurilor de Funcționare a Sistemelor Electroenergetice (Universitatea Politehnica Timișoara, director Prof.dr.ing. Ștefan Kilyeni) privind utilizarea tehnicilor de inteligență artificială atât la prognoza consumului de energie electrică și putere cât și la prognoza curbelor de sarcină. Majoritatea abordărilor utilizează RNA multistrat cu algoritmi de învățare de tip backpropagation, completate cu o serie de tehnici de optimizare neliniară, în scopul ameliorării calității rezultatelor și a timpului de calcul. Toate metodele elaborate au fost implementate în instrumente software originale, utilizând mediul Matlab. Aplicațiile concrete vizează studii de caz pentru situații reale, majoritatea vizând aria acoperită de operatorul de distribuție Enel Distribuție Banat (ansamblul rețelei, filialele de distribuție componente – Timișoara, Arad, Reșița, Hunedoara, zone deservite de o serie de stații de transformare de 110 / 20 kV) [Jigoria2009a], [Jigoria2010], [Jigoria2011], [Șchiopu2015], [Deacu2015], [Bărbulescu2015], [Bărbulescu2016]. Rezultatele obținute, verificate prin consumurile din anii următori, sunt de bună calitate.

3.1.3.2. Metode utilizând logica fuzzy

Considerarea informațiilor incerte despre consumatorii de energie electrică se poate face cu ajutorul teoriei mulțimilor fuzzy, ceea ce înseamnă că sarcina prognozată va fi exprimată sub forma unor numere fuzzy [Cârțină2004]. Alegerea funcțiilor de apartenență este una din cele mai importante etape. Pentru o alegere cât mai corectă se estimează / calculează pentru variabila respectivă valorile minimă și maximă, pe baza experienței decidentului [Cârțină2002]. Plecând de la aceste valori decidentul stabilește aliați funcțiilor de apartenență. Evident sarcina fuzzy nu va fi rezultatul unor aprecieri lingvistice ale experților, ci rezultatul unor calcule unde parametrii care intervin sunt numere fuzzy. Se știe că operațiile algebrice cu numere fuzzy duc la amplificarea incertitudinii, dacă aceste numere sunt considerate independente [Nazarco1999]. De cele mai multe ori, aceste numere sunt corelate, adică se presupune simultaneitatea punctelor caracteristice funcțiilor de apartenență [Dimitrovski 2000]. Astfel este rezonabil să se considere că o parte din parametrii considerați numere fuzzy sunt corelați. Stabilirea dinamicii sarcinii se bazează pe datele serviciilor de exploatare din rețelele electrice existente. În [Chow1997] se ține seama de efectul de saturație.

Deoarece dinamica sarcinii depinde de tipul consumatorilor dintr-o anumită zonă, rezultă că principala problemă a prognozei spațiale a consumului de energie electrică este cea a determinării preferințelor pentru anumiți consumatori. Din cauza incertitudinii informațiilor modelele indicate de estimare a utilizării terenului sunt cele fuzzy. Primele modele folosite, în acest scop se bazează pe logica fuzzy de tip clasic [Chow1997a]. Pentru obținerea curbei de sarcină a zilei următoare (next day) [Senjyu1998] prezintă o abordare de tip fuzzy. În prima fază se determină o serie de coeficienți de corecție pentru curbele de sarcină aferente zilelor anterioare similare. 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.

Alte lucrări care prezintă rezultatele obținute în prognoza pe termen scurt a sarcinii electrice prin aplicarea logicii fuzzy sunt [Mori1996], [Frantti2009], [Pandian 2006], [Ismail2011].

3.1.3.3. Metode utilizând sisteme expert

Ceea ce caracterizează, în ansamblul lor, metodologiile de dezvoltare a sistemelor expert este faptul că ele se bazează pe paradigma realizării evolutive a aplicațiilor software, care diferă de modelul liniar, al trecerii o singură dată printr-o serie de etape, faze, activități etc. Metoda se potrivește situațiilor în care cunoștințele pot fi modularizate în segmente mici, relativ independente, în care conținutul cunoștințelor este procedural [Cârțină1994].

Un sistem expert pentru prognoza pe termen scurt a consumului de energie electrică pentru sistemul electroenergetic din Taiwan este prezentat în [Ho1990]. Lucrarea [Rahman1996] prezintă o tehnică general valabilă de prognoză pe termen scurt a consumului. Baza de reguli cuprinde cunoștințele generale despre consum și despre factorii care influențează consumul și este completată de o bază de date parametrizată referitoare la consum.

3.1.3.4. Metode care utilizează SVM (Support Vector Machines)

O altă tehnică predictivă, foarte promițătoare, care a fost de asemenea aplicată pentru prognoza pe termen scurt a consumului de energie electrică și a dat rezultate bune este cea a mașinilor cu suport vectorial (Support Vector Machines – SVM), care folosește algoritmi ce pot fi utilizați atât pentru clasificare, cât și pentru regresie. SVM are la bază teoria de învățare statistică elaborată de [Vapnik1995]. Ideea de bază în SVM este de a mapa datele originale într-un spațiu inițial printr-o funcție neliniară și de a construi un hiperplan optim într-un spațiu nou cu mai multe dimensiuni.

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 exemplurilor ca puncte într-un spațiu, mapate astfel încât exemplele categoriilor separate sunt despărțite de o zonă cât mai largă. Noile exemple sunt mapate în același spațiu și prognozate ca aparținând uneia sau alteia dintre cele două categorii dependent de poziția lor față de zona de graniță.

În cadrul lucrărilor [Yang2004], [Li2002] s-a folosit algoritmul Support Vector Regression (SVR). Folosind o metodă de descompunere empirică pe baza căreia se obțin două seturi de componente în [Ghelardoni2013], acestea sunt apoi utilizate la antrenarea SVM. Primul set de componente descrie trendul și al doilea oscilațiile locale ale valorilor consumului de energie. Rezultatele practice obținute validează metoda propusă.

[Gou2006] are ca obiect un model bazat pe SVM, utilizat la prognoza consumului de energie electrică din provincia Hebei (China). Rezultatele arată că modelul

propus depășește ca performanțe modelul utilizând RNA în ceea ce privește acuratețea prognozei. 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.

3.1.3.5. Metode hibride

Fiecare tehnică inteligentă are unele proprietăți computaționale tipice (de exemplu, capacitatea de a învăța, explicarea deciziilor) care îi conferă aplicabilitatea pentru anumite probleme și prezintă dezavantaje în rezolvarea altora.

Sistemele inteligente hibride combină diferite metode și tehnici provenite din subdomeniul ale inteligenței artificiale, cu scopul de a obține în urma hibridizării performanțe mai bune decât ale fiecărei dintre componente, luate în parte. Sistemele neuro-fuzzy combină trăsături conexioniste (neuronale) și simbolice (fuzzy). Studiul efectuat în [Srinivasan1999] este un exemplu de abordare a metodelor hibride, care combină logica fuzzy și RNA. [Wang2005] consideră că integrând Fuzzy-Rough Sets cu RNA se obține o prognoză mai performantă decât în cazul FNN (Fuzzy Neural Network). [Fu-yuan2006] propun o metodă bazată pe FNN și combinată cu algoritmul de antrenare de tip backpropagation utilizând și o optimizare de tip PSO. Pentru prognoza pe termen scurt [Chauhan2005] folosește două modele: RNA, respectiv un sistem hibrid neuro-fuzzy. Studiul de caz se referă la consumul din zona New England, SUA, și demonstrează superioritatea celui de-al doilea model. Calitatea prognozei se verifică prin suma abaterilor medii pătratice pentru o serie de consumuri cunoscute.

Lucrarea [Mohammed2008] discută și prezintă rezultatele obținute prin utilizarea RNA pentru prognoza consumului de energie electrică și de putere. RNA este antrenată folosind un algoritm de optimizare de tipul PSO. Rezultatele folosind aceasta tehnică sunt comparate cu rezultatele obținute cu ajutorul algoritmului backpropagation.

Sistemele neuro-fuzzy ANFIS (Adaptive-Network-based Fuzzy Inference Systems) au capacitatea de a se adapta pe parcursul unui proces de învățare. ANFIS sunt rețele neuronale adaptive echivalente funcțional cu sisteme fuzzy de tip Takagi-Sugeno. [Mordjaoui2010] a prezentat un model pentru prognoza sarcinii electrice bazat pe ANFIS, aplicat datelor din istoric, pentru o metropolă din Franța. S-au obținut rezultate satisfăcătoare pentru prognoza a curbei de sarcină pe o săptămână, ce au arătat că acuratețea modelului nu este afectată de fluctuațiile rapide ale cererii de energie, care este principalul dezavantaj al modelelor RNA.

[Islam2011] observă că aplicarea tehnicilor de prognoză sarcină a moderne, cum ar fi sistemele expert, RNA și logica fuzzy sunt deosebit de atractive, deoarece acestea au capacitatea de a gestiona relațiile neliniare dintre sarcină și factorii care afectează în mod direct prognoza.

Algoritmii genetici s-au aplicat din ce în ce mai mult la proiectarea rețelelor neuronale, în optimizarea topologiei, algoritmi de antrenare genetici sau în optimizarea parametrilor de control. Pentru problemele de predicție și clasificare, algoritmii genetici pot fi folosiți la optimizarea RNA, la căutarea combinațiilor corecte de date de intrare, a orizontului de predicție cel mai potrivit, a structurilor și ponderilor de

interconectare optimale sau aproape optimale între neuroni, și a parametrilor de control optimi, pe baza datelor de antrenare folosite și a criteriilor predefinite În [Huan 1996] se prezintă o metodă care folosește un AG, combinat cu o rețea neuronală de tip perceptron multistrat. Folosind capacitatea de optimizare a algoritmilor genetici, este de așteptat o îmbunătățire a performanțelor în învățarea unei rețele neuronale. În acest sistem hibrid, AG realizează o inițializare aproape optimală a RNA. Deoarece rețelele neuronale sunt bine inițializate, riscul convergenței premature este scăzut, timpul total de antrenare fiind de asemenea scăzut. O tehnică hibridă este utilizată și în [Farahat2004]. Aplicația combină RNA cu logica fuzzy și se referă la consumul industrial dintr-un oraș egiptean, eroarea de prognoză fiind sub 2%.

[Amjady2008] prezintă o metodă de prognoză pe termen mediu a puterii de vârf zilnice (care se consideră a fi un "semnal" neliniar, volatil și nestaționar). Problema se complică și datorită volumului insuficient de informații. Se utilizează o tehnică hibridă, care se compune dintr-un model eficient al datelor inițiale, un mecanism de prognoză preliminară și o combinație care reunește RNA 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 PSO (Particle Swarm Optimization) este utilizat în [AIRashidi2010] în scopul minimizării erorii asociate parametrilor modelului estimat. Aplicația se referă la consumul de energie electrică aferent unor sisteme de distribuție din Kuweit și Egipt și la puterea de vârf. Rezultatele sunt comparate cu cele obținute cu metoda celor mai mici pătrate (în locul algoritmului PSO), concluzia fiind favorabilă noii metode.

În principiu, arborii de clasificare sunt utilizați în prognoza apartenenței unor obiecte-instanțe la categorii distincte, plecând de la măsurările lor în raport cu una sau mai multe variabile predictoare. În [Karapidakis2007] se folosește pentru prognoza consumului de energie electrică un model bazat pe arborii de decizie. Metoda prezentată în [Mori2001] se bazează pe o tehnică hibridă ce folosește arbori de regresie și o rețea neuronală artificială. Arborii de regresie contribuie la gruparea datelor de intrare în timp ce RNA este folosită pentru prognoza sarcinii pe termen scurt. Lucrarea pune accentul pe clarificarea relației neliniare dintre variabilele de intrare și de ieșire într-un model de predicție.

În [Zhang2008] se pornește de la faptul că modelul ARMA (AutoRegressive Moving Average) pentru metoda seriilor de timp nu oferă rezultate suficient de bune pentru tiparele de consum neliniare. Lucrarea prezintă o metodă hibridă, care adaugă la modelul ARMA o tehnică de tip SVM, rezultatele obținute pentru aplicații concrete fiind promițătoare.

[Hong2012] combină o metodă de tip SVM cu un algoritm de calcul evolutiv. Motivația este legată de mai buna tratare a situațiilor când apar cicluri diferite de consum datorate unor activități economice sezonale sau condițiilor meteo. Dintre tehnicile de calcul evolutiv s-a ales un algoritm genetic haotic. Rezultatele obținute pentru o serie de aplicații practice adevărate calitățile modelului propus.

3.1.3.6. Metode ce utilizează tehnici de tip Data Mining

Data Mining este procesul descoperirii (semi)automate a informațiilor utile în depozite mari de date [Tan2005]. Data mining utilizează orice metodă de analiză a datelor pentru descoperirea de informație ascunsă în acestea. Procesul de Data Mining este influențat de tipul atributelor obiectelor analizate. Originile Data Mining sunt prezentate în Fig. 3.1.1.

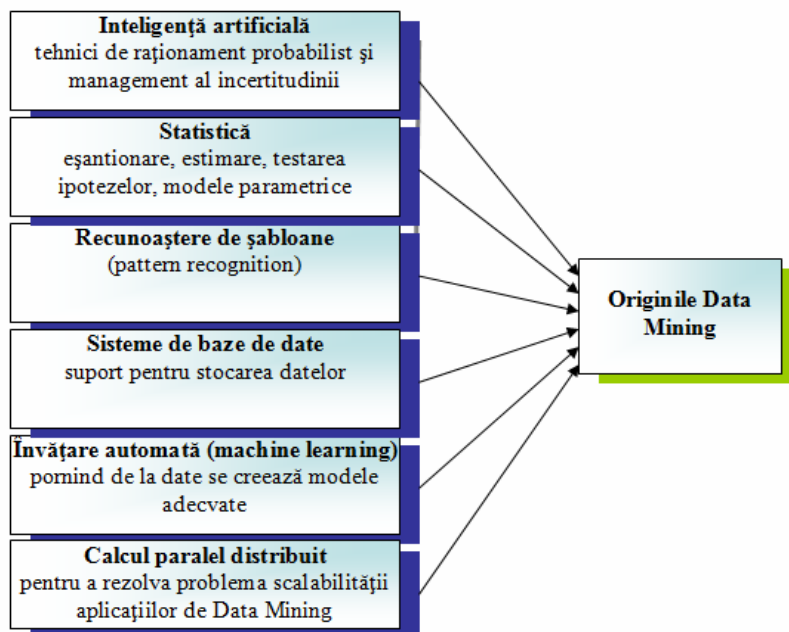


Fig. 3.1.1. Originile Data Mining

Principiul de funcționare în data mining este următorul: se prelucrează datele referitoare la perioadele trecute, examinând o varietate de situații care s-au produs și ale căror rezultate sau consecințe sunt deci, bine cunoscute, pentru a evidenția caracteristicile acestora și a permite elaborarea unui model. Odată construit, modelul poate fi aplicat situațiilor noi de același tip. Informațiile obținute prin data mining sunt de natură predictivă sau descriptivă. Aportul data mining se rezumă la următoarele acțiuni: clasificarea, estimarea, predicția, gruparea, analiza grupărilor. Clasificarea urmărește să plaseze obiectele prelucrate într-un grup limitat de clase predefinite.

Dintre tehnicile de data mining, cele mai adecvate clasificării sunt arborii de decizie și raționamentul bazat pe cazuri. Estimarea urmărește să atribuie o valoare unei variabile, pe baza celorlalte date de intrare.

Rețelele neuronale artificiale sunt printre cele mai bune tehnici de data mining pentru acest gen de prelucrări. Predicția urmărește să claseze înregistrările tratate în funcție de un comportament sau o valoare estimată viitoare. Gruparea urmărește să determine într-o manieră cât mai clară care sunt obiectele care apar cel mai frecvent împreună.

Folosind data mining, Mori și colab. [Mori2001] au propus o metodă de exploatare a datelor care se bazează pe o tehnică hibrid ce folosește arbori de regresie și RNA. Domeniul consumului se împarte în mai multe clase, și, conform regulilor de clasificare, se decide cărei clase aparține sarcina prognozată. Apoi este folosită o RNA de tip perceptron multistrat pentru a antrena eșantioane în fiecare clasă.

În [Liu2011] prin intermediul tehnicilor de data mining, este concepută o platformă de depozit de date, obținute după preprocesarea unor cantități uriașe de date cunoscute de consum, și este dezvoltat un sistem de prognoză a consumului pe termen scurt. Datele utile, excavate din cantități mari de date, pot oferi informații

eficiente și exacte în prognoza consumului. Valabilitatea metodei elaborate pentru prognoza pe termen scurt este demonstrată de rezultatele simulării unui sistem de distribuție real din China.

Lucrarea [Mori2002] prezintă o metodă de data mining utilizată tot pentru prognoza consumului de energie electrică pe termen scurt. Metoda de data mining este folosită pentru a clarifica relația neliniară dintre variabilele de intrare și de ieșire ce intervin în prognoza pe termen scurt a consumului. În lucrare sunt prezentate trei strategii: un model hibrid de regresie liniară multiplă, o structură optimă cu căutare Tabu și fuzzy data mining.

3.2. Metode de amplasare și dimensionare optimă a surselor de generare distribuită

O caracteristică esențială a resurselor regenerabile este aceea că ele sunt distribuite pe o arie geografică extinsă și că depind în mare măsură de schimbările meteorologice și climatice; ca urmare, ele nu pot fi direct controlate, în modul în care acest lucru se realizează la sursele clasice de generare. Creșterea semnificativă a producției de energie electrică obținute din surse regenerabile impune o revizuire a modului în care sistemele electroenergetice sunt proiectate și exploatate, în scopul de a asigura o mai bună acomodare cu aceste surse. În acest context, apar o serie de probleme suplimentare legate de prognoza consumului, respectiv a producției de energie electrică.

În literatura de specialitate, au fost propuse mai multe metode pentru soluționarea problemei amplasării și dimensionării a optime a surselor de generare distribuită. Pierderile din rețelele electrice de distribuție sunt un obiectiv cheie tradițional în acest context. Impactul surselor de generare distribuită asupra pierderilor de energie a făcut obiectul mai multor studii. Cele mai multe dintre aceste studii au fost efectuate pentru cazuri particulare (anumiți distribuitori și anumite conexiuni ale surselor de generare distribuită) sau în scopul dezvoltării de metodologii pentru evaluarea de situații specifice analizei unui scenariu particular privind introducerea surselor de generare distribuită în rețelele electrice.

În lucrările [Kim1998] și [Gandomkar2005] se aplică algoritmul Ranch Hereford pentru a minimiza pierderile totale de putere în sistemul electroenergetic luând în considerare puterea totală instalată a surselor de generare distribuită. Studiile din [Greatbanks2003] folosesc o metodă iterativă pentru amplasarea optimă a surselor de generare distribuită, care are la bază o analiză a ecuațiilor circulațiilor de puteri atât pentru nivelul tensiunii în noduri cât și pentru pierderile de putere activă din sistem.

Lucrarea [Varikuti2009] prezintă o metodologie bazată pe logica fuzzy și algoritmi genetici pentru amplasarea surselor de generare distribuită în rețelele electrice de distribuție. Modelarea fuzzy este folosită pentru a determina amplasarea optimă, iar algoritmi genetici pentru dimensionarea optimă a surselor de generare distribuită. În identificarea nodurilor de amplasare optimă folosind logica fuzzy s-au utilizat două variabile – tensiunile nodale și factorii de sensibilitate în raport cu pierderile. Un set de reguli fuzzy sunt utilizate pentru a determina nodurile optime de amplasare a surselor de generare distribuită în rețeaua de distribuție a energiei electrice.

Selectarea celei mai bune variante de amplasare a surselor de generare distribuită, dar și dimensionarea optimă a acestor surse în rețelele de distribuție a energiei electrice, reprezintă o problemă complexă de optimizare combinatorială. În lucrarea [Ameli2010] este descris un algoritm pentru amplasarea optimă a surselor de generare distribuită, cu scopul de a îmbunătăți nivelul tensiunii în noduri și de a reduce pierderile de putere activă din rețelele de distribuție. Algoritmul are la bază modelarea fuzzy cu căutare completă. Amplasarea optimă a diferitelor tipuri de surse de generare distribuită, stă la baza lucrării [Quezada2006] în care este efectuată analiza privind efectele modificării nivelelor de integrare în funcție de nivelul pierderilor de energie anuale. În cazul acestei analize s-au considerat următoarele tipuri de tehnologii de generare distribuită: surse de cogenerare, surse eoliene și panouri fotovoltaice. Pentru fiecare tip de sursă s-au considerat diferite nivele de generare corespunzătoare diferitelor puteri instalate a surselor de generare distribuită și diverse nivele de concentrare cu mai multe unități de generare distribuită conectate de-a lungul unui distribuitor. O altă abordare prezentă în literatura de specialitate se referă la algoritmi bazați pe fluxuri de sarcină care sunt comparați din punct de vedere al erorilor de calcul și convergenței rapide în scopul de a selecta varianta cu cele mai bune performanțe.

Lucrarea [Parizad2010] prezintă două variante pentru amplasarea surselor de generare distribuită într-un sistem de distribuție a energiei electrice. În aceste două variante, diferitele soluții de amplasare a surselor de generare distribuită sunt comparate în vederea analizei pierderilor de putere, a capacității de încărcare și a indicelui de stabilitate a tensiunii.

O abordare euristică a planificării investițiilor în surse de generare distribuită, din punct de vedere al licitațiilor de pe piața de energie electrică, este propusă în [Barin2010]. Amplasarea optimă a surselor de generare distribuită este obținută printr-o analiză cost-beneficiu corespunzătoare unei companii de distribuție a energiei electrice. Metoda euristică ajută la atenuarea utilizării variabilelor binare din cadrul modelului de optimizare, reducând în mod substanțial volumul de calcul.

În [Wang2004] este propusă o tehnică de analiză pentru amplasarea optimă a unităților de generare distribuită într-un sistem de distribuție a energiei electrice cu scopul minimizării pierderilor de putere. Această tehnică consideră tipuri diferite de profile de încărcare cu sarcini variabile în timp pentru diverse surse de generare distribuită, ținând seama de restricțiile tehnice, cum ar fi limitele capacității de transport a liniei electrice și limitele de variație ale tensiunii în nodurile rețelei.

Lucrarea [Yun-Feng2010] abordează modalități analitice pentru amplasarea optimă a surselor de generare distribuită cu un factor de putere unitar, în sistemele de distribuție a energiei electrice. Este analizată amplasarea optimă într-o rețea radială a surselor de generare distribuită pentru diferite tipuri de încărcări. În [Ghosh2010] se propune minimizarea unei funcții obiectiv, care are la bază costurile privind sursele de generare distribuită și pierderile de putere, în scopul determinării locului de amplasare și a dimensiunii optime acestora. Lucrarea [Celli2005] prezintă o abordare bazată pe optimizare multi-obiectiv în dimensionare a surselor de generare distribuită și amplasarea lor în rețelele electrice de distribuție existente. Soluția determinată reprezintă un compromis între costurile de modernizare ale rețelelor, costul privind pierderile de energie, costul energiei nelivrate precum și costul energiei cerute de consumatori.

Pentru a monitoriza efectele incertitudinilor asociate cu penetrarea și protecția surselor de generare distribuită în [Celli2001] și [Carpinelli2001] se utilizează un

algoritm de optimizare euristic bazat pe teoria deciziilor. În [Carpinelli2005] este analizată o metodologie bazată pe optimizarea multi-obiectiv și teoria deciziilor care ajută la identificarea soluțiilor corespunzătoare dezvoltării planificării luând în considerare și amplasarea surselor de generare distribuită. Metodologia rezolvă problemele privind maximizarea performanțelor rețelelor prin îmbunătățirea unor indicatori de calitate a energiei electrice și minimizarea costurilor în rețea printr-o utilizare optimală a acestor surse. Dimensionarea optimală dar și determinarea locației surselor de generare distribuită este tratată ca o problemă multi-obiectiv cu restricții. Ideea de bază este de a se aplica o procedură cu două etape: în prima etapă printr-o tehnică multi-obiectiv cu restricții, se determină domeniul admisibil al soluțiilor pentru amplasarea și dimensionarea surselor pentru toate variantele considerate și a doua etapă permite determinarea soluției.

Folosind optimizarea multi-obiectiv în dimensionarea optimă a surselor de generare distribuită, [Barin2010] consideră următoarele obiective: pierderile de energie, nivelul tensiunii în noduri și nivelul de încărcare a liniilor electrice. Soluția se determină utilizând modelarea fuzzy.

În [Ochoa2008] se propune un procedeu multi-stratificat pentru maximizarea amplasării surselor de generare distribuită printr-un procedeu bazat pe circulațiile de puteri. Tehnica propusă consideră diferite nivele de încărcare pentru sistemul analizat precum și caracterul aleator al rezultatelor privind turbinele eoliene.

Pentru determinarea tipului de sursă de generare distribuită, în [Keane2006] și [Keane2007] este descris un algoritm de programare liniară pentru a se utiliza optim resursele disponibile de energie pentru o rețea de distribuție. În lucrarea [Atwa2010] se prezintă o tehnică de planificare probabilistică pentru a determina tipul optim de generare distribuită în scopul minimizării pierderilor anuale de energie într-un sistem de distribuție respectând restricțiile impuse.

Problema este formulată cu ajutorul programării neliniare mixte luând în considerare caracterul aleator asociat surselor de generare distribuită și profilele tip de sarcină. Optimizarea în [Falaghi2011] se face prin luarea în considerare a costurilor cu investiția, a costurilor de exploatare și fiabilitate în găsirea locației, a tipului și dimensiunii unei surse de generare distribuită, algoritmul sugerând și perioada optimă pentru realizarea investițiilor aferente. Problema de optimizare este rezolvată cu ajutorul algoritmilor genetici.

[Singh2010] formulează o problemă de maximizare a profitului cu/fără a lua în considerare profilele tip de sarcină ale nodurilor din rețelele de distribuție. O altă metodă de alocare optimă a surselor de generare distribuită aplicată în [Rahim2008] folosește programarea evolutivă ca tehnică de optimizare. În acest studiu amplasarea optimă este identificată pe baza unei analize de sensibilitate. O tehnică de metaeuristică este adoptată pentru dimensionarea optimă a unităților de generare distribuită.

Se poate concluziona faptul că au fost depuse până în prezent eforturi științifice considerabile în domeniul amplasării surselor de generare distribuită în rețelele de distribuție a energiei electrice. Majoritatea abordărilor au la bază ipoteza conform căreia producția de putere sau energie din aceste surse este dispecerizabilă și controlabilă și nu modelează natura aleatoare a acestor surse de generare distribuită. Cu toate acestea, principalele probleme cu privire la calculul computațional se referă la optimizarea combinatorială și la variația în timp a sarcinii, ce fac dificilă dimensionarea unităților de generare distribuită și necesită o atenție deosebită. Cercetările efectuate până în prezent consideră incertitudinea puterilor generate a surselor de generare distribuită, dar și varietatea tipurilor acestor surse.

3.3. Concluzii

În cadrul acestui capitol s-a realizat o prezentare sistematizată a aspectelor generale legate de cercetările privind prognoza consumului de energie electrică, a metodelor utilizate, cu accent pe cele care fac uz de o serie de tehnici de inteligență artificială. S-au trecut în revistă manierele de abordare și de soluționare utilizate de diverși specialiști precum și rezultatele obținute, aplicațiile concrete soluționate referitoare la situații reale.

Tot în contextul tematicii tezei de doctorat, s-au abordat și o serie de aspecte legate de metodele ce aplică tehnici ale inteligenței artificiale, utilizate pentru amplasarea și dimensionare a optimă a surselor de generare distribuită.

Tehnici clasice din statistică, regresia liniară și logistică, sunt încă folosite pe larg în modelele predictive de azi. De obicei, metodele statistice pot prezice foarte bine curba de sarcină în zilele obișnuite, dar din cauza lipsei de flexibilitate, le lipsește capacitatea de a analiza corect sarcina în zilele de sărbătoare sau în alte zile anormale.

Cercetările efectuate și rezultatele publicate în literatura de specialitate arată o deplasare semnificativă a interesului în problema prognozei consumului de energie electrică către modele ce folosesc elemente ale inteligenței artificiale. Aceleași cercetări au demonstrat că modelele statistice tradiționale pot fi privite, de fapt, ca particularizări ale RNA, astfel încât acestea din urmă reprezintă mijloace de abordare a prognozei mai puternice și mai flexibile.

Noile tehnici predictive, cum sunt: RNA, tehnicile hibrid, mașini cu suport vectorial și alți algoritmi matematici se folosesc de puterea de lucru tot mai mare a sistemelor actuale de prelucrare a informației pentru a face calcule complexe, care de multe ori necesită parcurgeri multiple ale setului de date (rulează volume mari de date, cu multe variabile).

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

- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a metodelor utilizate pentru prognoza consumului de energie electrică 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, SVM, data mining etc.);
- focalizarea unei atenții speciale asupra metodelor de soluționare bazate pe tehnici de inteligență artificială;
- realizarea unei sinteze documentate, în viziune proprie, bazată pe un studiu bibliografic consistent, a metodelor utilizate pentru amplasarea și dimensionarea optimă a surselor de generare distribuită, ca element conex al tematicii principale a tezei de doctorat;
- pregătirea elementelor pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.

4. TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ UTILIZATE ÎN ELECTROENERGETICĂ

Capitolul 4 are ca obiect prezentarea, într-un cadru mai larg, a tehnicilor de inteligență artificială utilizate în cadrul tezei de doctorat. El furnizează elementele teoretice necesare pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.

În prima parte a capitolului se trec în revistă o serie de aspecte legate de istoricul tehnicilor de inteligență artificială și de aplicațiile specifice domeniului ingineriei sistemelor electroenergetice.

În a doua parte se realizează o descriere a metodelor de abordare bazate pe tehnici de inteligență artificială: algoritmi genetici (AG), inteligența de tip roi, rețele neuronale artificiale (RNA), sisteme expert (SE), metode bazate pe logica fuzzy și metode hibride.

Un subcapitol aparte este consacrat RNA. Pornind de la câteva considerații cu caracter istoric, se abordează succesiv elemente legate de terminologie, de structură și de clasificare, de caracteristici, de neuronul formal și de perceptron, de perceptronul multistrat, de diversele procedee de antrenare (învățare), cu accent special pe cele de tip backpropagation.

4.1. Considerații generale

4.1.1. Istoricul tehnicilor de inteligență artificială

Există numeroase definiții ale conceptului de inteligență artificială (IA). Definițiile din diverse lucrări poartă amprenta domeniului particular în care aceasta este aplicată [Neagoe2011]:

- „știința care permite realizarea de mașini care au competența de a fi inteligente” [Minsky1975];
- „disciplina care are ca obiect înțelegerea naturii și construirea de programe pe calculator imitând inteligența umană” [Bonnet1984].

Începuturile IA ca domeniu al științei calculatoarelor pot fi situate în jurul anului 1950, odată cu apariția unui articol al lui Turing care pentru prima oară, pune problema posibilității simulării gândirii umane cu ajutorul calculatorului.

Termenul IA a fost introdus în 1956 de J. McCarty în cadrul unei conferințe organizată la propunerea acestuia la Dorthmouth College. În acea perioadă existau puțini cercetători care investigau căile prin care mașinile ar fi putut fi realizate astfel încât să reproducă procese similare creierului uman. În 1959, McCarthy elaborează limbajul LISP, limbaj care a stat la baza elaborării sistemelor expert Dendral și Mycin. Perioada anilor '70 a fost dominată de sistemele expert, iar în anii '80 s-au dezvoltat primele aplicații în domeniul învățării automate. Chiar dacă sfârșitul anilor '80 a însemnat o perioadă de declin, cercetătorii nu au fost descurajați, astfel că în Japonia au fost produse microprocesoare bazate pe logica fuzzy. Primul calculator bazat pe tehnici ale inteligenței artificiale (Deep Blue – 1997), și care l-a învins la șah pe marele campion Kasparov, a constituit un rezultat notabil.

Caracteristica de bază a IA este căutarea euristică. În problemele complexe, numărul soluțiilor posibile poate fi enorm, de aceea rezolvarea problemelor pe baza tehnologiei IA este în mod obișnuit orientată după reguli empirice, referitoare la intuiție, experiență, generalizare, folosindu-se intens cunoștințele acumulate pe bază de experiență în acest domeniu.

Cercetările din domeniul IA s-au conturat în două direcții fundamentale de cercetare: direcția logico-simbolică și calculul inteligent [Dumitrescu2000].

Prima direcție este caracterizată de un nivel înalt de abstractizare și o privire macroscopică. Acoperă arii cum ar fi: sisteme bazate pe cunoștințe, raționamentul logic, învățarea simbolică, tehnicile de căutare și procesarea limbajului natural.

Calculul inteligent include modele conexioniste (rețele neuronale), modele și metode bazate pe LF și calculul evolutiv. Deși la început aceste două direcții ale IA: paradigma conexionistă și cea logico-simbolică, păreau rivale, o serie de noțiuni, metode și rezultate circulă între acestea.

Prin tehnicile de IA se vizează crearea unor sisteme destinate problemelor pentru care nu există un algoritm de calcul clasic și care sunt fundamentate pe caracteristici ale inteligenței umane ca: raționament, capacitate de învățare, rezolvare și comunicare.

Sistemele inteligente hibride combină diferite metode și tehnici provenite din subdomenii ale IA, cu scopul de a obține în urma hibridizării performanțe mai bune decât ale fiecărei dintre componente, luate în parte. Câteva astfel de realizări sunt: sistemele neuro-fuzzy, sistemele fuzzy-expert, cele conexionist-expert, sistemele evolutiv-neuronale, sistemele fuzzy-genetice etc.

4.1.2. Aplicații în electroenergetică

Sistemul electroenergetic (SEE) este caracterizat printr-o mare complexitate a problemelor care trebuie rezolvate în vederea exploatării și dezvoltării optime a acestuia. Această complexitate se datorează unor particularități specifice sistemului electroenergetic printre care: variația permanentă a sarcinii electrice, importanța strategică, eforturile economice substanțiale pentru funcționare și extindere, interacțiuni cu toate ramurile economiei, restructurarea, deschiderea către exterior precum și atragerea capitalului privat.

Posibilitatea unei reprezentări precise a comportării unui sistem complex scade pe măsură ce complexitatea sistemului crește.

Problemele apărute ca urmare a liberalizării pieței energiei, a privatizării sectorului energetic sunt multiple, cele mai importante fiind: îmbunătățirea calității energiei electrice furnizate și creșterea siguranței în alimentarea consumatorilor, reducerea costurilor de investiții și a celor de exploatare, reducerea impactului asupra mediului, planificarea rațională a mentenanței etc.

De regulă găsirea soluțiilor cele mai raționale implică modelarea și simularea acestor sisteme. O modelare matematică a acestor sisteme este de cele mai multe ori dificilă datorită numărului mare de variabile și câteodată greu de cuantificat. În absența unui model funcțional riguros al sistemului a apărut necesitatea dezvoltării unor tehnici noi bazate pe metode ale IA.

Primele aplicații ale tehnicilor de inteligență artificială în energetică au fost sistemele expert (SE), dezvoltate încă din anii '70 (Nuclear Power Plant Consultant, REACTOR) [Eremia2001].

Astăzi, avem o multitudine de aplicații ale IA în energetică care acoperă o arie întinsă de probleme. Unele aplicații ale IA din energetică sunt proiectate pentru funcționarea în timp real, altele constituie instrumente pentru analiza off-line, ambele

reprezentând suport de decizie pentru operatorii umani. Rezolvarea concretă a problemelor complexe din domeniul energetic, precum, conducerea și planificarea dezvoltării rețelelor electrice, prelucrarea și adoptarea deciziilor în situația lichidării avariilor, prognoza consumului de energie electrică și de putere, diagnoza cauzelor defectelor, a implicat elaborarea unor metodologii bazate pe diferite forme ale inteligenței artificiale, cuprinzând soluții din domeniile sistemelor expert, rețelelor neuronale artificiale (RNA), logicii fuzzy (LF) și algoritmilor genetici (AG).

Odată cu dezvoltarea tehnicilor de inteligență artificială au fost elaborați algoritmi hibridi: sisteme expert bazate pe logica fuzzy, logica fuzzy combinată cu rețele neuronale sau cu algoritmi genetici etc.

Tabloul 4.1.1 sintetizează domeniile de aplicabilitate ale tehnicilor de inteligență artificială în electroenergetică.

Tabloul 4.1.1. Domenii de aplicare ale IA în electroenergetică

Tehnici de inteligență artificială	Tipul de problemă în care se aplică
Sisteme expert	<ul style="list-style-type: none"> • diagnosticarea defectelor • conducerea centralelor nucleare • conducerea operativă și automatizarea instalațiilor electrice • mentenanța sistemelor de protecție ale instalațiilor energetice • analiza și reconstrucția postvarie a rețelelor electrice • formarea și instruirea operatorilor • prognoza consumului • reglajul puterii reactive și al tensiunii • planificarea circulației de puteri • planificarea rețelelor de distribuție • probleme de stabilitate tranzitorie • analiza alarmelor • evaluarea securității în funcționare
Rețele neuronale artificiale	<ul style="list-style-type: none"> • prognoza consumului • optimizarea conducerii on-line a proceselor energetice • planificarea rețelelor electrice • reglarea tensiunii și a puterii reactive • controlul proceselor energetice • identificarea sistemelor • conducerea optimă a rețelelor electrice
Algoritmi genetici	<ul style="list-style-type: none"> • optimizarea structurii rețelelor electrice • optimizarea regimurilor normale de funcționare a rețelelor electrice • optimizarea repartiției surselor de putere reactivă • optimizarea ploturilor de funcționare ale transformatoarelor din stații • repartiția puterilor între celule
Logica fuzzy	<ul style="list-style-type: none"> • reglajul puterii reactive • reglajul tensiunii • prognoza consumului de energie electrică • analiza securității sistemului energetic • repartiția sarcinii între generatoarele unei centrale • planificarea dezvoltării rețelelor electrice • conducerea proceselor din echipamente energetice • urmărirea arderii în cazane folosind recunoașterea imaginilor
Rețele Petri	<ul style="list-style-type: none"> • diagnosticarea defectelor din sistemul energetic • optimizarea amplasării surselor de putere reactivă

4.2. Prezentarea metodelor de inteligență artificială

4.2.1. Considerații preliminare

În acest subcapitol se realizează o descriere a metodelor de abordare a unor probleme de optimizare (și nu numai) din domeniul electroenergeticii, bazate pe tehnici de inteligență artificială: algoritmi genetici (AG), inteligența de tip roi, rețele neuronale artificiale (RNA), sisteme expert (SE), metode bazate pe logica fuzzy și metode hibride.

Având în vedere faptul că subcapitolul următor se referă în exclusivitate, în detaliu, la rețelele neuronale artificiale, paragraful actual referitor la RNA constituie doar o prezentare succintă.

4.2.2. Algoritmi genetici

O ramură importantă a inteligenței artificiale o reprezintă Calculul Evolutiv (CE). CE s-a dezvoltat începând cu anul 1975, pe baza lucrărilor publicate de J. Holland și De Jong, iar mai târziu și de Goldberg și Wilson [Gold1985]. Tehnicile de CE marchează un punct de cotitură în abordarea problemelor de optimizare, control și căutare. CE cuprinde o colecție de algoritmi bazați pe tehnici euristice, inspirate din evoluția biologică. Metodele dezvoltate de CE sunt generale, independente de problemă și de funcția criteriu. CE acoperă trei direcții principale de cercetare: algoritmi genetici (AG), strategiile evolutive, programarea evolutivă, programare genetică, algoritmi de tip roi de particule (Particle Swarm Optimization – PSO).

Aceste direcții au multe componente comune, elementele care stau la baza calculului evolutiv fiind inspirate din biologie, în special din genetică [SumIm2009], [Sun2000].

AG urmăresc modelele naturale ale operatorilor genetici și le aplică cromozomilor strategiile evolutive și programarea evolutivă, urmărind transformările care mențin legăturile de comportament între părinți și urmași. AG sunt tehnici adaptive de căutare euristică, bazate pe principiile geneticii și ale selecției naturale, enunțate de Darwin (supraviețuiește cel mai bine adaptat). Sunt folosiți în special în rezolvarea problemelor de optimizare combinatorială.

Un algoritm genetic este un model informatic care emulează modelul biologic evoluționist pentru a rezolva probleme de optimizare ori căutare. Acesta cuprinde un set de elemente individuale reprezentate sub forma unor șiruri binare (populația) și un set de operatori de natură biologică definiți asupra populației. Cu ajutorul operatorilor, algoritmi genetici manipulează cele mai promițătoare șiruri, evaluate conform unei funcții obiectiv, căutând soluții mai bune.

Elementul de bază este cromozomul. AG operează cu o populație de cromozomi, fiecare dintre lanțurile de cromozomi fiind o soluție potențială a problemei care trebuie rezolvată. După generarea aleatorie a populației inițiale, algoritmul o prelucrează cu ajutorul a trei operatori genetici: selecția, încrucișarea și mutația (Fig. 4.2.1).

Factorii critici în aplicarea AG sunt legați de dimensiunea populației inițiale, criteriul de selecție și operatorii genetici folosiți [Dumitrescu2006].

Datorită proprietăților lor algoritmi au fost aplicați în energetică în special pentru problemele de optimizare. Câteva din avantajele remarcabile ale AG care recomandă utilizarea acestora în problemele de optimizare sunt:

- nu necesită modelarea foarte riguroasă a problemei analizate și nici calcul dificil;
- numărul restricțiilor dintr-un model poate fi de orice natură și este nelimitat;
- realizează o căutare paralelă în spațiul soluțiilor.

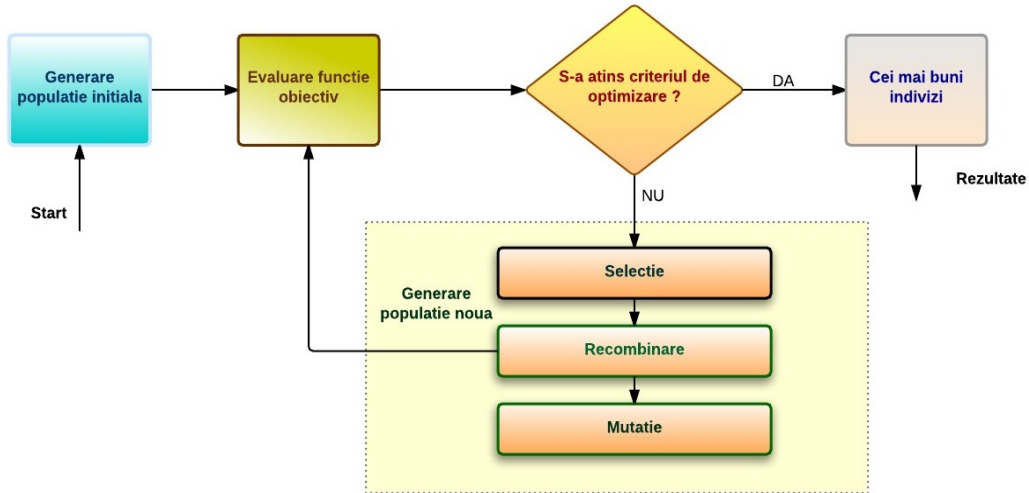


Fig. 4.2.1. Structura unui algoritm de calcul evolutiv de tip AG

4.2.3. Inteligența de tip roi

Inteligența de tip roi este folosită pentru a desemna o formă de inteligență specifică unui sistem colectiv, format din agenți relativ simpli, particule (fiecare agent în parte reprezentând un subsistem care interacționează cu mediul înconjurător fără a urma un plan prestabilit), capabil să se auto-organizeze, în urma interacțiunilor cu caracter local de tip agent-agent precum și de tip agent-mediul înconjurător. Organizarea sistemelor de tip roi se produce descentralizat, adică în lipsa oricărei influențe externe [Beni1989], [Berian2010].

Termenul "swarm intelligence" apare prima dată în 1989, fiind introdus de Gerardo Beni și Jing Wang în contextul sistemelor de roboți [Beni1989].

Inteligența de tip roi este inteligența colectivă emergentă a grupurilor de simpli agenți. Mecanismul de organizare naturală a roiului inteligent este auto-organizarea: structura globală a roiului apare (emerge) din interacțiunile particulelor (indivizilor, agenților) care compun roiul [Simo2014a].

Auto organizarea se bazează pe:

- amplificarea activității cu ajutorul reacției pozitive;
- echilibrarea (stabilizarea) structurii folosind reacția negativă;
- existența interacțiunilor multiple;
- prezența unei componente aleatoare în desfășurarea activității.

Principalii algoritmi de tip roi, prezentați în fig. 4.2.2, sunt:

- Particle Swarm Optimization (PSO);
- Ant Colony Optimization (ACO);
- Artificial Bee Colony (ABC);
- Stochastic Diffusion Search (SDS).

Tehnicile din "swarm intelligence" se bazează pe mulțimi de agenți caracterizați prin:

- reguli simple de "funcționare";
- interacțiuni locale;
- absența unor structuri de control centralizat.

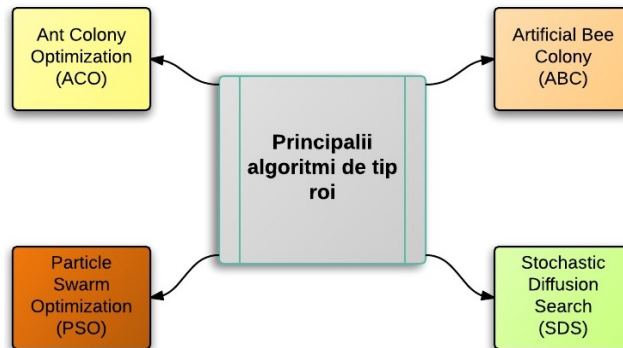


Fig. 4.2.2. Algoritmi de tip roi

4.2.4. Rețele neuronale artificiale (RNA)

RNA au ca referință sistemul nervos uman, atât ca model de organizare cât și de funcționare. Funcționarea modularizată (paralelă) a creierului uman, cunoscută ca procesare distribuită, are avantajul de a-l face tolerant la erori, ceea ce constituie o trăsătură vitală a funcționării sale, deoarece în fiecare zi un număr de neuroni moare ca urmare a unui proces natural. Deși pierderile cumulative sunt din ce în ce mai mari, creierul uman continuă să funcționeze ca și cum nimic nu s-ar fi întâmplat.

Neuronul (celulă specializată a creierului care poate propaga un semnal electrochimic) primește informație de la ceilalți neuroni prin intermediul dendritelor și o procesează. Semnale sunt transmise apoi, printr-un canal de comunicație numit axon. Axonul are o structură arborescentă, fiecare ramură terminându-se printr-o sinapsă, prin intermediul căruia axonul se leagă la dendritele altor neuroni. Sinapsele, prin modificarea unor praguri de inhibiție / excitație, controlează acțiunea asupra neuronului conectat. Prin reglările fine de la nivelul sinapselor, pe baza învățării din experiența acumulată, se obțin output-uri (semnale de ieșire) optime ca răspunsuri la input-urile (semnale de intrare) primite. Un neuron este astfel fie inhibat, fie excitat, în funcție de semnalul primit de la alt neuron și, în raport de aceasta, va răspunde sau nu, influențând acțiunea neuronilor conectați în rețea.

La fel ca și în cazul unui sistem nervos natural, și RNA este compusă dintr-un număr mare de elemente de procesare - neuronii artificiali - puternic interconectați și lucrând în paralel pentru rezolvarea unei anumite probleme. În consecință, vom privi neuronul artificial ca pe componentă de bază a unei rețele neuronale și nu ca pe un mecanism singular, lucrând independent. Neuronii, aranjați și lucrând în paralel, formează un strat al rețelei neuronale. O RNA poate avea unul sau mai multe straturi de neuroni [Luștea2004].

Sintetic vorbind, RNA reprezintă sisteme neprogramate (ne-algoritmice) de procesare adaptivă a informației. RNA învață din exemple și se comportă ca niște "cutii negre", modul de procesare a informației fiind neexplicit.

Datorită caracteristicilor lor fundamentale, adică abilitatea de a învăța din datele de antrenament "cu sau fără profesor" rețelele neuronale sunt aplicate în modelare, recunoașterea formelor, analiza seriilor temporale, teoria controlului procesarea semnalelor, etc. Interesul crescând pentru acest domeniu a dus la organizarea în 1987 a primei conferințe internaționale de rețele neuronale.

Proprietățile de bază ale rețelelor neuronale, anume faptul că sunt aproximatori universali și ca au o capacitate de predicție deosebită, își găsesc utilizarea imediată în cadrul multor domenii, inclusiv în energetică.

În anii 1990, Institutul de Cercetare Electric Power (EPRI) a sponsorizat un proiect care a dezvoltat mai multe rețele neuronale artificiale, pentru prognoza pe termen scurt a sarcinii electrice [Khotanzad1997]. Unele cercetări rezultate din acest proiect EPRI au fost mai târziu comercializate.

Pentru studiul aplicațiilor RNA în domeniul energiei, în 1993 s-a înființat pe lângă CIGRE grupul de lucru TF 38-06-06, constatându-se totodată o creștere semnificativă a numărului lucrărilor dedicate acestui subiect.

4.2.5. Sisteme expert (SE)

Spre deosebire de programele de calcul convenționale care se bazează pe o abordare algoritmică, SE sunt concepute să folosească, în principal, raționamente simbolice, desfășurate prin inferență.

SE constituie o clasă particulară de sisteme informatice bazate pe inteligența artificială, având ca scop reproducerea cu ajutorul calculatorului a cunoștințelor și raționamentelor experților umani.

O caracteristică specifică a SE este organizarea pe reguli în loc de instrucțiuni. SE constau dintr-o colecție de reguli ce nu sunt executate secvențial decât atunci când condiția de aplicabilitate este îndeplinită.

SE lucrează de regulă cu informații simbolice și se referă de obicei la probleme în care cunoștințele pot fi mai puțin deterministe, permițând o anumită incertitudine în raționament.

Structura unui sistem expert poate fi grupată în jurul a cinci componente [Cârțină1994]:

- baza de cunoștințe, conține o colecție de adevăruri relevante despre un domeniu oarecare; este formată din:
 - baza de reguli – conține cunoștințe generale din domeniul de expertiză;
 - baza de fapte – cuprinde cunoștințele specifice problemei ce se rezolvă.
- motorul de inferență, este folosit pentru a decide care reguli sunt satisfăcute, pentru ierarhizarea și executarea acestora, începând cu regula care are prioritatea cea mai mare;
- interfața de dialog cu utilizatorii, dă posibilitatea accesului utilizatorilor la faptele și cunoștințele din bază deoarece permite achiziția cunoașterii de la experți precum și dialogul cu ceilalți utilizatori;
- modulul de achiziție și actualizare a cunoștințelor;
- un modul explicativ prin care SE explică utilizatorului pașii raționamentului său. Aceasta se justifică, în faza de dezvoltare a SE, prin necesitatea confirmării corectitudinii însușirii și folosirii cunoștințelor, iar în faza de utilizare, prin importanța consecințelor deciziilor care urmează a fi luate. Se pot depista, în felul acesta, eventuale erori datorate introducerii greșite a cunoștințelor de către operator sau neînțelegerilor dintre inginerul de cunoștințe și expertul uman.

Performanțele SE depind de corectitudinea și volumul cunoștințelor pe care acesta le posedă, dar și de calitatea mecanismelor care îi permit să opereze cu aceste cunoștințe pentru a deduce concluziile valide.

Reprezentarea cunoștințelor are o mare importanță pentru un SE. Cunoștințele în domeniu pot fi reprezentate sub formă de reguli (sau reguli de producție), rețele semantice, structuri împachetate (frame), programare orientată pe obiecte.

Regulile de producție au la bază o structură de tip Condiție (faptă) ⇒ Acțiune. Metoda se potrivește situațiilor în care cunoștințele pot fi modularizate în segmente mici relativ independente, în care conținutul cunoștințelor este procedural. Este cea mai utilizată metodă, principalele avantaje fiind [Cârțină2004]:

- simplitatea metodei;
- abilitatea de a trata și cunoștințe incerte;
- satisfac cererea de modularitate;
- permit separarea efectivă a domeniului cunoștințelor de motorul de inferență.

Metoda are desigur și unele dezavantaje [Cârțină2004]:

- la seturi mari de reguli căutarea prin setul de reguli devine inefficientă;
- verificarea și validarea seturilor mari de reguli poate fi dificilă;
- mentenabilitatea seturilor de date este dificilă;
- este dificil de evaluat eficiența abordării pe seturi de reguli complexe.

Rețelele semantice se bazează pe utilizarea grafurilor orientate, fiind folosite pentru reprezentarea cunoștințelor care au caracter declarativ și nu se pretează modularizării.

Reprezentarea prin cadre se bazează pe conceptul frame. Un frame este o unitate complexă, ce descrie un prototip al unui obiect sau situații, atât prin modele declarative cât și prin metode procedurale [Bălăceanu1983].

Reprezentarea orientată pe obiecte unifică, într-o aceeași unitate structurală numită "obiect", datele și funcțiile sau metodele care acționează asupra lor. Din punct de vedere al tehnicii de programare tipurile structurilor amintite se definesc cu ajutorul conceptului de clasă, iar obiecte cu care operează programul sunt instanțieri ale claselor. În cazul unui sistem electroenergetic, fiecare componentă a acestuia (generatoare, sistem de bare colectoare, linie de transport sau de distribuție, consumatori etc.) poate fi reprezentată ca un obiect echipament.

Baza de fapte conține informațiile relative la domeniul de aplicație studiat. Faptele reprezintă partea dinamică a bazei de cunoștințe și au rolul de a reprezenta starea obiectelor la un moment dat. În aplicații din domeniul energetic faptele sunt de exemplu o valoare sau o mărime electrică în afara limitelor admisibile, date normale de tipul închis-deschis (pentru un echipament de comutație), o alarmă de ieșire din funcțiune a unui echipament, etc.

Conform unui raport CIGRE, obiectivele SE în domeniul sistemelor electroenergetice pot fi clasificate în [CIGRE1993] :

- planificare;
- monitorizare;
- control;
- analiza sistemelor;
- simulare / antrenare;
- altele.

Motivația de a implementa tehnici de tip SE în energetică rezultă în principal pentru probleme caracterizate de următoarele proprietăți [Eremia2001]:

- complexitatea structurii sistemului energetic – SE poate modela cunoștințele expertului uman pentru a ajuta la o identificare rapidă a regiunilor slabe din sistem;
- date inconsistente – de exemplu SE poate extrage informația utilă dintr-o multitudine de date incomplete în cazul diagnozei și prelucrării alarmelor;
- multitudinea datelor achiziționate;
- natura combinatorie a soluțiilor – un exemplu este restaurarea stării de funcționare după o avarie în sistem, care necesită o strategie de căutare într-o problemă multidimensională. În acest sens se construiesc scenariile ale stărilor posibile și se caută soluția în spațiul acestor stări.

Principalul dezavantaj al sistemelor expert reprezintă incapacitatea de generalizare și dificultatea de validare și menținere a unor baze de reguli mari.

4.2.6. Logica fuzzy. Sisteme fuzzy

Stochastic Logica tradițională consideră că un obiect poate aparține sau nu unei mulțimi. Logica fuzzy permite o interpretare mai flexibilă a noțiunii de apartenență. Astfel, mai multe obiecte pot aparține unei mulțimi în grade diferite.

Introdusă în 1965, de Lotfi A. Zadeh, teoria mulțimilor fuzzy apare de fapt ca o încercare de generalizare a teoriei mulțimilor clasice. Mulțimile fuzzy și în general conceptele fuzzy au apărut din necesitatea de a exprima cantitativ vagul, imprecisul. Deși există numeroase ramuri ale matematicii mai vechi decât teoria mulțimilor fuzzy, care se ocupă cu studiul proceselor de natură aleatorie (teoria probabilităților, statistică matematică, teoria informației, etc.), nu se pot face substituții între acestea și teoria mulțimilor fuzzy.

În prezent, teoria fuzzy este aplicată în diverse domenii științifice și tehnologice, devenind un instrument util în modelarea raționamentelor umane, respectiv a incertitudinilor care caracterizează procesul de gândire umană.

Mulțimile fuzzy sunt legate conceptual de proprietățile intrinseci de incertitudine ale modelului. Ele modelează noțiunea de posibilitate, și anume posibilitățile individuale ale unor obiecte de a fi încadrate într-un concept semantic. O mulțime fuzzy are în vedere implicit [Cârțină2004]:

- un domeniu ce reprezintă populația mulțimii fuzzy
- reprezentarea semantică asociată populației fuzzy
- o funcție care definește gradul de apartenență al unui element din domeniu la mulțime.

Dacă X este o mulțime de obiecte și A este un domeniu de proprietăți, mulțimea fuzzy A este complet determinată de mulțimea perechilor ordonate [Cârțină2005]:

$$A = \{x, \mu_A(x) \mid x \in X\} \quad (4.2.1)$$

unde $\mu_A(x)$ este numită funcție de apartenență. Valoarea acesteia indică gradul de apartenență a elementului x la A , sau gradul de încredere că elementul x are proprietatea asociată semantic mulțimii respective.

Pentru o mulțime fuzzy sunt definite următoarele noțiuni:

- setul de elemente care compune o mulțime fuzzy care este alcătuit din acele elemente ce aparțin domeniului de definiție și au gradul de apartenență la mulțime mai mare decât zero;

$$S(A) = \{x \in X \mid \mu_A(x) > 0\} \quad (4.2.2)$$

- setul de nivelul α al unei mulțimi fuzzy A care reprezintă mulțimea elementelor ce aparțin cel puțin în măsura α a mulțimii fuzzy A ;

$$A_\alpha = \{x \in X \mid \mu_A(x) \geq \alpha\} \quad (4.2.3)$$

- nucleul unei funcții de apartenență pentru o mulțime fuzzy A se caracterizează prin mulțimea elementelor x care aparțin complet mulțimii A , astfel încât $\mu_A(x) = 1$;
- zonele de imprecizie ale funcției de apartenență care conțin elementele x pentru care $0 < \mu_A(x) < 1$. Acesta este elementul care evidențiază practic caracterul nuanțat pe care îl introduc mulțimile fuzzy;
- element tipic al mulțimii A este acel element x_0 cu proprietatea $\mu_A(x_0) = 1$;
- universul discuției X reprezintă o mulțime clasică, tranșantă, pe care se definesc mulțimile fuzzy;
- suportul unei mulțimi fuzzy A este submulțimea strictă a lui X ale cărei elemente au grade de apartenență nenule în A :

$$\text{supp } A = \{x \in X \mid \mu_A(x) > 0\} \quad (4.2.4)$$

Funcțiile de apartenență se definesc astfel încât sistemul fuzzy să modeleze cât mai corect posibil procesul studiat. Alegerea formei funcției de apartenență este una din etapele cele mai importante ale lucrului cu mulțimile fuzzy. În operația de stabilire a funcției de apartenență trebuie să fie înglobată experiența specialiștilor din domeniu. Cele mai folosite funcții de apartenență sunt de tipul celor prezentate în Figura 4.2.3.

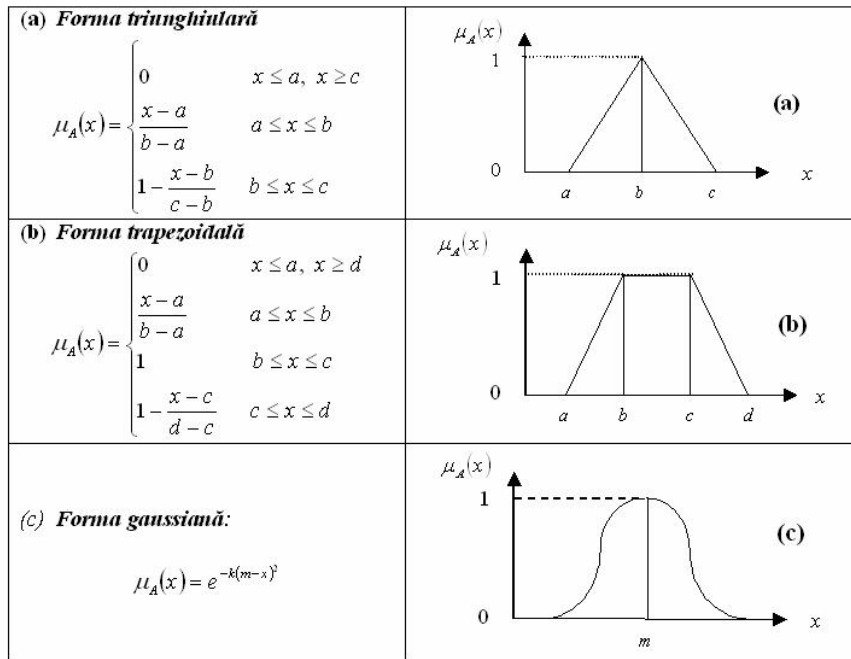


Fig. 4.2.3. Funcții de apartenență utilizate frecvent

Asocierea unei semnificații lingvistice pentru un set de valori numerice, obținând astfel un set de mărimi fuzzy, se numește fuzzificare. Operația inversă, care asociază unei mărimi fuzzy o valoare numerică precisă, poartă denumirea de defuzzificare.

Fuzzificarea realizează trecerea din domeniul cuantificărilor numerice, specifice sistemelor tehnice și matematice, în domeniul aprecierilor logic calitative, specific gândirii umane. Fuzzificarea este în general un proces subiectiv, în care operatorul uman atribuie grade lingvistice unui domeniu fizic și stabilește funcții de apartenență în conformitate cu experiența și cunoștințele proprii.

Etapa de defuzzificare produce valori ferme pornind de la valori fuzzy. Aceasta operație, opusă fuzzificării, este necesară doar când avem nevoie de valori ferme la ieșire.

Necesitatea defuzzificării apare pentru că mai multe reguli pot fi active în același timp, fiind necesară fie alegerea uneia singure dintre ele, fie sintetizarea unei ieșiri care să țină cont într-o anumită măsură de fiecare dintre ele.

Pentru defuzzificare sunt definite diverse metode care permit obținerea unei valori numerice printr-o expresie ce combină mai multe funcții de apartenență, dintre care, MOM (mean-of-maxima) și COG (center-of-gravity).

Metoda centrului de greutate (COG) al suprafeței delimitate de maximele locale asociază funcției de apartenență abscisa centrului de greutate al suprafeței rezultate prin suprapunerea graficelor funcțiilor de apartenență. Este metoda de defuzzificare cea mai sensibilă, care ține seama, într-o manieră ponderată, de

influența fiecărui termen lingvistic al ieșirii, considerând toate valorile posibile pentru gradele de apartenență. Prin COG domeniul valorilor discrete de ieșire devine continuu.

În Fig. 4.2.4 este prezentat un exemplu de defuzzyficare după metoda MOM. Alegerea metodei de defuzzyficare se face în funcție de mai multe criterii, dintre care cele mai importante sunt:

- caracteristicile mulțimi fuzzy de ieșire $Y = \{y_1, y_2, \dots, y_n\}$ și ale elementului de execuție;
- viteza cerută de aplicație și capacitatea de calcul disponibilă.

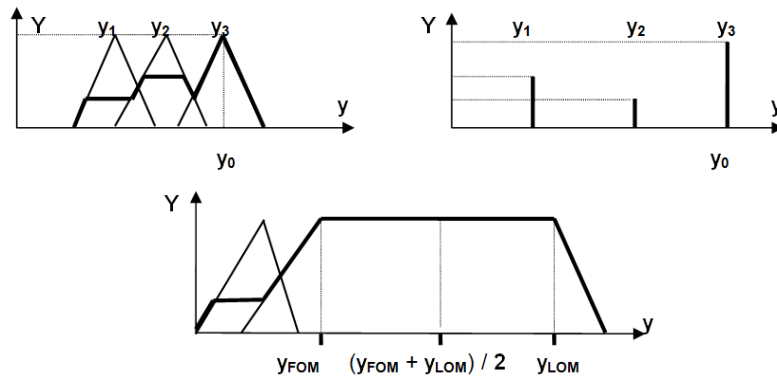


Fig. 4.2.4. Exemple de defuzzyficare după metoda maximului

Partea centrală a unui sistem fuzzy constă din mecanismul său de inferență, care este realizat de către baza de reguli [Yang1998]. Blocul de inferență permite scrierea rapidă și ușoară a regulilor printr-un tabel McVicar-Whelan.

Cu cât există mai multe reguli în baza de reguli, cu atât sunt disponibile mai multe puncte de fixare a suprafeței de comandă; pe de altă parte implementarea este mai greoaie.

Ideea de bază a teoriei mulțimiilor fuzzy este să modeleze și să fie capabilă să lucreze cu incertitudini. Modelele matematice și algoritmi din teoria sistemelor electroenergetice tind, pe cât posibil, să fie cât mai aproape de realitate [Momoh1995].

Structura sistemului cu logică fuzzy (SLF) cuprinde Figura 4.2.5:

a) baza de cunoștințe a SLF alcătuită din:

- mulțimile fuzzy peste universul discuției variabilei de intrare, X ;
- mulțimile fuzzy peste universul discuției variabilei de ieșire, Y ;
- baza de reguli fuzzy, care leagă între ele valorile fuzzy ale variabilei x (mulțimile fuzzy definite peste X) de valorile fuzzy ale variabilei y (mulțimile fuzzy definite peste Y).

b) operațiile (operatorii) SLF, adică fuzzificarea, inferența și defuzzificarea.

Baza de cunoștințe este specifică fiecărei aplicații; de calitatea ei depinde în general calitatea SLF pentru o aplicație dată. Forma, numărul și, în special, valorile numerice care definesc suportul și valoarea mediană a mulțimilor fuzzy afectează calitatea aplicației, și obținerea lor este:

- fie rezultatul unui proces de încercări succesive;
- fie rezultatul învățării printr-o rețea neuronală (ANFIS);
- fie rezultatul unui proces de clasificare în mulțimi (clase) fuzzy a unor date cunoscute (clasificare substractivă, Fuzzy C-Means).

Regulile fuzzy sunt mai ușor de definit, deoarece ele trebuie doar să asocieze datele descrise prin mulțimi fuzzy după legile de corespondență dorite (care sunt în general ușor de exprimat lingvistic).

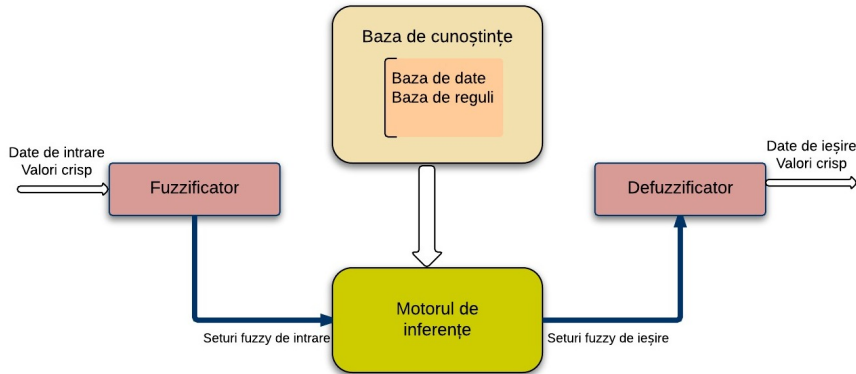


Fig. 4.2.5. Schema bloc a sistemului cu logica fuzzy

Incertitudinea sarcinii va fi reprezentată în acest caz prin numere fuzzy, cu funcții de apartenență în domeniul real R . Un număr fuzzy poate avea diferite forme dar, în general, sarcinile sunt reprezentate ca numere fuzzy trapezoidale sau triunghiulare în cazuri speciale [Cârțină2002].

4.2.7. Sisteme hibrid

Tabelul 4.2.1 prezintă sintetic avantajele și dezavantajele pentru două din tehnicile IA utilizate frecvent în electroenergetică și anume RNA, respectiv SF.

Combinarea sistemelor fuzzy cu rețelele neuronale conduce la reducerea și chiar eliminarea dezavantajelor individuale ale celor două tehnici. În același tip, prin diverse modalități de hibridizare, se pot pune în valoare avantajele incontestabile ale acestora: capacitatea de învățare a rețelelor neuronale și reprezentarea explicită, simbolică a cunoștințelor prin intermediul sistemelor fuzzy.

Tabelul 4.2.1. Comparație între sistemele fuzzy și rețelele neuronale

Rețele neuronale	Sisteme fuzzy
Avantaje	
Pot învăța fără nici o informație inițială	Încorporează cunoștințe predefinite bazate pe reguli
Există mai multe paradigme de învățare, potrivite diverselor situații	Implementare simplă
Există o multitudine de algoritmi de învățare disponibili în literatura de specialitate	Sunt interpretabile (reguli dacă-atunci)
	Cunoștințele sunt disponibile în orice moment
Dezavantaje	
Sunt cutii negre sub-simbolice	Nu pot învăța
Nu pot utiliza cunoștințe a-priori	Nu există metode formale pentru ajustarea regulilor
Necesită algoritmi de învățare complecși	Trebuie să dispună de reguli stabilite apriori
Nu există garanția că învățarea converge spre soluție	
Prezintă dificultăți în extragerea cunoștințelor structurale	

Rețelele neuronale fuzzy mențin proprietățile de bază ale rețelelor neuronale, la care se adaugă fuzzyficarea unora din elementele lor caracteristice pentru a putea prelucra informații fuzzy.

Sistemele fuzzy neuronale încearcă ajustarea regulilor din sistemul fuzzy prin metode tipice rețelelor neuronale, fără a-și pierde caracteristicile esențiale (fuzzyficarea, defuzzyficarea, motorul de inferență și fundamentul logicii fuzzy).

O rețea neuronală fuzzy (Fuzzy Neural Network, FNN) reprezintă o rețea neuronală care dispune de capacitatea de a prelucra informații fuzzy. Într-o astfel de rețea, semnalele de intrare și/sau ponderile conexiunilor și/sau ieșirile sunt submulțimi fuzzy sau mulțimi de valori de apartenență la mulțimi fuzzy. De obicei, se utilizează ca modele termeni lingvistici precum mic, mediu, mare, numere sau intervale fuzzy.

În electroenergetică există deja aplicații în care tehnicile hibride pot furniza o modelare oportună. Ca exemple se pot cita modelarea / corecția tensiunilor anormale, optimizarea planului de tensiune, coordonarea mijloacelor de reglaj tensiune – putere reactivă în stațiile de distribuție etc.

4.3. Rețele neuronale artificiale (RNA)

4.3.1. Scurt istoric al RNA

Există trei perioade distincte în evoluția RNA: prima perioadă are loc în anii '40 (McCulloch și Pitts), a doua în anii '60 (teorema lui Rosenblatt de convergență a perceptronului, demonstrarea limitărilor pe care le are perceptronul simplu de către Minsk și Papert) și ultima care începe cu anii '80.

Modelarea comportării neuronului natural printr-un neuron artificial a fost propusă în anul 1943 de către Warren McCulloch și Walter Pitts. Cu toate că cei doi au dezvoltat ipoteze și teoreme privind modele de calcul natural, la acea vreme puține dintre ele au fost implementate, datorită unei tehnologii computaționale precare.

Pornind de la modelul McCulloch-Pitts (MCP), din dorința de a modela funcția de percepție vizuală a retinei, psihologul Rosenblatt a introdus în anul 1958 noțiunea de **perceptron** sau neuronul clasificator. Cercetările în domeniul RNA cunosc un avânt deosebit după apariția perceptronului.

În anul 1969 M. Minsky și S. Papert publică însă un studiu în care evidențiază limitele teoretice ale perceptronului și mai ales imposibilitatea modelării cu ajutorul acestuia a funcțiilor logice XOR (SAU Exclusiv). Ca urmare RNA au trecut pentru mai mult de un deceniu în penumbră. Revigorarea acestui domeniu începe după publicarea de către J. Hopfield (1982) a unei lucrări și mai apoi prin introducerea noțiunii de perceptron multistrat (Rumelhart și McClelland).

4.3.2. Neuronul formal. Modelul McCulloch-Pitts

Rețelele neuronale artificiale, sunt realizate prin interconectarea unui număr de unități elementare de prelucrare a informației care se numesc neuroni artificiali. Neuronul formal este o unitate elementară de procesare a informației care modelează, de o manieră simplificată, neuronul uman; el realizează o operație simplă pe un set de mărimi de intrare, pentru a produce o mărime de ieșire. Cea mai simplă versiune de neuron formal (Fig. 4.3.1) este un automat binar cu două stări – activ (+1) și inactiv (-1) – unde x_1, x_2, \dots, x_n reprezintă setul mărimilor de intrare, y_i este mărimea de ieșire și v_j este potențialul neuronal (reprezintă suma ponderată a intrărilor x_j).

Starea neuronului se actualizează periodic astfel: v_j este comparat cu un prag θ_j . Dacă $v_j \geq \theta_j$ neuronul se activează ($y = +1$); dacă $v_j < \theta_j$ neuronul devine pasiv ($y = -1$).




Fig. 4.3.1. Neuronul formal

Prin urmare suma ponderată a intrărilor este trecută printr-o funcție de activare, cu o formă de tip treaptă.

Acest model are meritul istoric că a pus în evidență o structură simplă, la care relația funcțională intrare-ieșire este codificată sub forma unor valori numerice corespunzând ponderilor. La acea dată rămânea însă deschisă problema stabilirii unui *algorithm de antrenare* pentru determinarea valorilor acestor ponderi.

4.3.3. Perceptronul

Ecuțiile de funcționare ale perceptronului (neuronul clasificator) sunt asemănătoare cu ecuațiile modelului MCP, deosebirea provine din faptul că de această dată intrările sunt valori reale și nu valori binare de tipul 1 sau 0, funcția de activare fiind tot de tipul treaptă.




Fig. 4.3.2. Modelul perceptronului

Evoluția perceptronului este descrisă de:

$$v = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (4.3.1)$$

$$y = f(v) = \begin{cases} 1, & v \geq 0 \\ 0, & v < 0 \end{cases} \quad (4.3.2)$$

Regiunile de decizie vor fi separate de un hiperplan definit de relația:

$$\sum_{i=1}^n w_i \cdot x_i - \theta = 0 \quad (4.3.3)$$

care împarte spațiul vectorilor de intrare în două regiuni de decizie.

Perceptronii sunt folosiți mai ales pentru rezolvarea problemelor simple de clasificare a punctelor dintr-un spațiu bidimensional.

4.3.4. Structura rețelei neuronale artificiale

RNA sunt formate din neuroni, organizați pe straturi și legați prin conexiuni sinaptice, caracterizate de anumite ponderi. Fig. 4.3.3 ilustrează structura tipică a unei RNA.

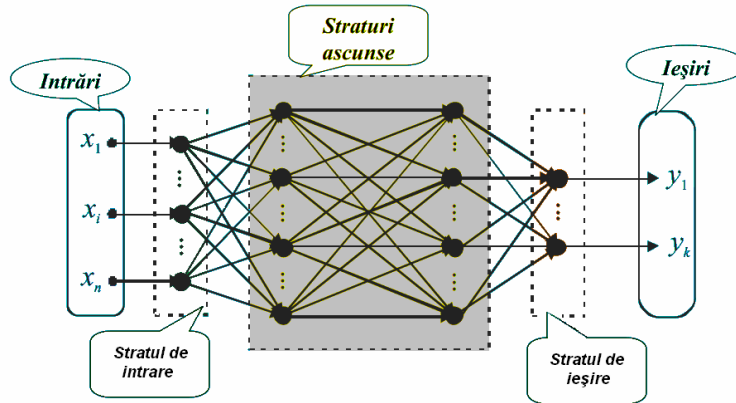


Fig. 4.3.3. Arhitectura tipică a unei RNA

Rețeaua din exemplul prezentat conține trei straturi de neuroni, dintre care primul este stratul de intrare, iar ultimul stratul de ieșire, stratul intermediar numindu-se și strat ascuns. Fiecare neuron dintr-un strat este legat cu toți neuronii din stratul următor și nu există legături între straturile neconsecutive. O asemenea structură este cunoscută sub numele de RNA complet conectată.

Stratul ascuns și cel de ieșire sunt cele care realizează procesarea propriu-zisă a informației. Neuronii din primul strat au numai rolul de a prelua mărimile de intrare în rețea; de aceea, acești neuroni, fie nu au funcții de activare, fie folosesc funcții activare identitate ($y_i = v_i$).

Structura RNA este descrisă complet de matricele ponderilor conexiunilor dintre două straturi consecutive \mathbf{W} , ale cărei elemente w_{ij} indică influența pe care ieșirea neuronului j din stratul inferior o are asupra activării neuronului i din stratul superior. Astfel, ponderile pozitive caracter excitatoriu, ponderile negative – caracter inhibitoriu, iar ponderile nule indică absența conexiunii între cei doi neuroni. Cu cât valoarea absolută a ponderii w_{ij} este mai mare, cu atât influența excitatorie/inhibitorie a neuronului j asupra neuronului i este mai pregnantă.

RNA din Fig. 4.3.3 are anumite proprietăți care se aplică unei categorii largi de rețele neuronale [Eremia2006].

- fiecare neuron acționează independent de ceilalți neuroni din același strat; ieșirea unui neuron depinde numai de semnalele ce se aplică pe conexiunile sinaptice de intrare;
- activarea fiecărui neuron depinde numai de informații cu caracter local; informația ce este prelucrată de neuron provine numai de pe conexiunile adiacente, nefiind necesară cunoașterea stării altor neuroni cu care neuronul considerat nu are legături directe;
- numărul mare de conexiuni existente asigură un grad ridicat de rezervare și ușurează reprezentarea distribuită a informației.

Primele două proprietăți permit funcționarea eficientă a RNA în "paralel", iar ultima proprietate le conferă o sensibilitate redusă față de posibilele perturbații și calități de generalizare greu de obținut cu sistemele clasice de calcul.

4.3.5. Caracteristicile principale și clasificarea RNA

În ultimii ani au fost dezvoltate o mare varietate de modele de RNA pentru diverse scopuri; ele diferă în structură, implementare și principii de funcționare, dar au o serie de proprietăți comune:

- procesarea informației și memoria sunt distribuite în întreaga structură a rețelei neuronale;
- neuronii artificiali sunt interconectați astfel încât starea unui neuron influențează potențialul unui număr mare de neuroni cu care este el conectat, în concordanță cu ponderile conexiunilor;
- ponderile conexiunilor sunt de obicei adaptive. Deoarece modificarea lor poate avea loc oriunde în structura rețelei, se vorbește de memorie distribuită a rețelei;
- neuronii au asociată o funcție de activare, de regulă, neliniară.

Clasificarea rețelelor neuronale poate fi făcută pe baza mai multor criterii care țin cont de arhitectura RNA, numărul de straturi, modul de învățare, tipul parametrilor de intrare etc.

Există diferite moduri de conectare a neuronilor dintr-o rețea, obținându-se astfel diverse arhitecturi de RNA. Acestea pot fi capabile să realizeze lucruri complexe pe care neuronii singuri nu le-ar putea realiza.

După **arhitectură** RNA pot fi grupate în următoarele categorii:

- **Rețele feedforward (nebuclate)** – informația **circulă într-un singur sens**, de la intrare către ieșire. Un set de valori aplicat la intrarea în rețea se transmite, de-a lungul rețelei spre ieșire, prin intermediul funcțiilor de activare, prin așa-numitul proces de propagare înainte (forward propagation). RNA nebuclate sunt structuri statice. Din această categorie fac parte rețelele de tipul perceptron multistrat (PMS) (Fig. 4.3.4).
- **Rețele feedback (buclate)** sunt acele rețele ale căror grafuri de conexiuni conțin cicluri; **circulația informației are loc de această dată în ambele sensuri, prin urmare starea** neuronilor la un moment dat este determinată de starea curentă și de starea la momentul anterior. RNA buclate au proprietățile unor sisteme dinamice; ele sunt utilizate ca memorii asociative și pentru identificarea sau controlul sistemelor dinamice. Din această categorie fac parte rețeaua Hopfield (Fig. 4.3.5). Rețeaua Hopfield este o rețea recurentă formată dintr-un singur strat de neuroni cu interconexiune completă; matricea de ponderi este simetrică cu elementele diagonale egale cu zero.
- **Rețele de tip celular (plasă)** constau din neuroni artificiali numiți celule, organizați într-o "plasă" bidimensională, neuroni care comunică direct doar cu alți neuroni aflați în imediata vecinătate a lor. Neuronii neconectați se pot influența unul pe celălalt indirect din cauza propagării semnalelor în timpul regimului dinamic. Un exemplu de astfel de rețea este rețeaua Kohonen (Fig. 4.3.6).
- **Rețele hibrid**, folosesc atât legături feedforward, cât și legături feedback, un exemplu fiind rețeaua Hamming (Fig. 4.3.7).




Fig. 4.3.4. Rețea feedforward




Fig. 4.3.5. Rețea Hopfield




Fig. 4.3.6. Rețea Kohonen




Fig. 4.3.7. Rețea Hamming

Un alt criteriu de clasificare a RNA are în vedere **numărul straturilor de neuroni** din rețea. Din acest punct de vedere se disting:

- **RNA cu un singur strat**, care joacă rol dublu intrare-iesire. Totodată, absența altor straturi impune ca aceste RNA să aibă o topologie buclată. În această categorie se înscriu rețelele Hopfield (Fig. 4.3.5), precum și variante ale acestora, care se deosebesc în funcție de modul de conectare a neuronilor. Sunt folosite pentru rezolvarea unor probleme de optimizare, filtrarea unor semnale.
- **RNA cu două straturi**, primul strat joacă rolul stratului de intrare, iar al doilea cel de ieșire, neexistând un strat ascuns. Sunt folosite cu precădere ca *rețele clasificatoare*.
- **RNA multistrat**, care pot avea, în principiu, un număr nelimitat de straturi. Toate straturile, cu excepția primului și ultimului strat, se numesc straturi ascunse (deoarece nu se cunosc informații legate de intrările și ieșirile neuronilor din aceste straturi). În această categorie intră PMS. Majoritatea RNA multistrat utilizate în diverse aplicații practice fac parte din categoria rețelelor feedforward (nebuclate), iar răspândirea cea mai mare o are PMS.

În funcție de tipul **parametrilor de intrare** rețelele neuronale sunt:

- rețele cu *intrări binare*;
- rețele cu *intrări reale*; în acest caz, valorile parametrilor de intrare trebuie mapate (scalate) în domeniul $[-1, 1]$.

Un alt criteriu de clasificare al RNA se referă la **tipul de învățare** folosit la proiectarea acestora: rețele cu învățare *supravegheată* și *nesupravegheată*.

1. **Învățarea supervizată** numită uneori și învățare neadaptivă se desfășoară pe baza unor exemplare care comportă perechi univoce intrare / ieșire, cu ajutorul cărora algoritmi specializați stabilesc măsura influențelor între neuroni. În acest caz rețeaua neuronală este antrenată să execute o sarcină în mod repetat de către un "profesor", pe baza unor exemple reprezentative de intrare / ieșire. În timpul fiecărei iterații de antrenament se calculează eroarea de clasificare (diferența dintre răspunsul așteptat și cel real) care va fi apoi utilizată pentru ajustarea ponderilor, în funcție de anumiți algoritmi de învățare. Rezultă o diminuare a erorii. Încheierea etapei de antrenare se face la hotărârea "supraveghetorului", care decide unilateral dacă, în acel moment, performanțele rețelei sunt sau nu satisfăcătoare până la atingerea unui prag de acuratețe acceptabil. Schematic învățarea supravegheată este reprezentată în Fig. 4.3.8.




Fig. 4.3.8. Arhitectura unui sistem cu învățare supervizată

2. În cazul **învățării nesupravegheate** (cu auto-organizare) se utilizează doar input-uri, și reglarea rețelei nu mai beneficiază de tutela unui "profesor". Are loc de fapt un proces de auto-organizare a rețelei, nemaifiind necesară precizarea unor corelații intrare / ieșire de tipul menționat mai înainte. Fără a i se specifica răspunsul corect pentru fiecare exemplu prezentat la intrare, rețeaua neuronală artificială cu auto-organizare învață singură. Cu alte cuvinte, ea descoperă trăsături caracteristice ale datelor de intrare pe care le organizează și le memorează într-o manieră specifică, asigurând simultan adaptarea ponderilor. Setul de date de învățare poate conține un număr nelimitat de exemplare, care se adaugă la setul inițial pe măsura rafinării performanțelor rețelei. Etapa de antrenare se încheie în momentul în care se definește organizarea datelor din setul de învățare inițial; ea poate fi reluată însă oricând, dacă apar noi caracteristici ale datelor din acest set. Spre deosebire de antrenarea supravegheată unde informația prelucrată are caracter global, în acest caz informația prelucrată are caracter local.

4.3.6. Perceptronul multistrat

Aranjarea în paralel a neuronilor de tip perceptron în mai multe straturi conectate în serie formează *rețeaua neuronală de tip perceptron multi-strat* (PMS).

Majoritatea rețelelor neuronale utilizate practic sunt de tipul PMS și utilizează pentru învățare algoritmul backpropagation. Celulele elementare ale PMS se numesc neuroni și se deosebesc de perceptronul definit de Rosenblatt prin utilizarea unor funcții de activare de tip sigmoid, în locul funcției treaptă.

Rețeaua PMS are un strat de intrare, unul de ieșire și unul sau mai multe straturi intermediare – ascunse. Numărul straturilor ascunse nu este limitat, dar s-a constatat că pentru majoritatea problemelor practice este suficientă folosirea a unu sau două straturi ascunse [White1989]. În general, toți neuronii de pe un strat sunt conectați cu toți neuronii straturilor adiacente, prin conexiuni unidirecționale (ponderi sinaptice) și nu există legături între neuronii ca nu aparțin unor straturi consecutive. Numărul neuronilor din fiecare strat depinde de problema analizată.

Procesarea informației este realizată doar de către neuronii din straturile ascunse și eventual a celor din stratul de ieșire. Rolul neuronilor din stratul de intrare este de distribui intrările preluate din exteriorul rețelei către primul stat ascuns.

Tipic, o rețea neuronală de tip PMS este formată din [Haykin1994]:

- un *strat de intrare*: neuronii ce formează acest strat au ca intrări mărimile aplicate la intrarea rețelei neuronale;
- unul sau mai multe *straturi interne*: neuronii ce formează aceste straturi au ca intrări mărimile de ieșire ale neuronilor din stratul precedent;
- un *strat de ieșire*: mărimile de ieșire corespunzătoare neuronilor acestui strat reprezintă ieșirile rețelei neuronale.

În Fig. 4.3.9 este reprezentat schematic PMS cu un singur strat ascuns. Intrările PMS sunt x_1, x_2, \dots, x_n , iar ieșirile sunt y_1, y_2, \dots, y_m . Stratul ascuns este format din nodurile a_1, a_2, \dots, a_h .




Fig. 4.3.9. PMS cu un singur strat ascuns

Toate valorile RNA sunt valori reale, normalizate într-un interval care poate fi unipolar sau biplolar. Funcția de activare (aceiași pentru toți neuronii de pe un strat) are ca rezultat o valoare reală aparținând aceluiași interval ca și intrările. Tipul intervalului utilizat depinde de funcția de activare folosită. Cele mai utilizate funcții de activare sunt sigmoidul logistic și arctangenta (sunt continuu derivabile).

Numărul neuronilor din statul de intrare depinde de specificul problemei. Cel al neuronilor din statul de ieșire depinde de forma și de structura în care se doresc a fi prezentate estimările pentru mărimile de ieșire. Pentru neuronii din statul ascuns se recomandă ca numărul acestora să fie cât mai mic (fiecare neuron ascuns multiplică de fapt numărul conexiunilor și încarcă calculatorul).

Rata de învățare η este un alt parametru care poate influența performanța rețelei. Inițial este recomandat să alegem valori mici pentru η (0,05÷0,25). Aceste valori mici implică un număr mare de iterații dar, dacă dorim o rețea performanță este indicat să acceptăm acest compromis. Pentru a crește viteza de convergență a rețelei se poate mări, în cursul antrenării, valoarea pentru η , însă nu se recomandă valori prea mari (există riscul unor oscilații în jurul valorii de minim).

4.3.7. Algoritm BackPropagation

Cel mai cunoscut și utilizat algoritm pentru antrenarea PMS este algoritmul backpropagation (propagarea înapoi a erorii), numit și algoritmul delta generalizat sau error backpropagation (retropropagării erorii).

Algoritmul backpropagation a fost descris pentru prima dată în 1971 de Paul Werbos, care l-a publicat în teza sa de doctorat [Werbos1974], dar nu a fost aplicat până în 1986 când Rumelhart, prin lucrarea [Rumelhart1986], a redescoperit această tehnică, care a câștigat recunoașterea și a dus la o renaștere în domeniul cercetării RNA.

□ Algoritm standard BackPropagation pentru antrenarea PMS

Antrenarea unei RNA necesită construirea în prealabil a unui set de antrenare (perechi intrări-ieșiri dorite). Fiecare model din setul de antrenare este format din n intrări \mathbf{x}_i și m ieșiri dorite corespunzătoare d_j . Antrenarea PMS pentru o anumită problemă este echivalentă cu găsirea valorilor tuturor ponderilor sinaptice astfel încât ieșirea dorită să fie generată pentru intrările corespunzătoare. Mai exact, antrenarea PMS constă în modificarea tuturor ponderilor astfel încât măsura erorii dintre ieșirea dorită d_{jp} și ieșirea actuală y_{jp} pentru toate modelele din setul de învățare P să fie minimă. Algoritmul standard este o metodă de tip LMS (Least Mean Square – metoda celor mai mici pătrate) care urmărește determinarea acelor ponderi, [Dumitrescu1996] ce minimizează funcția eroare, funcție care pentru modelul \mathbf{p} de antrenare este dată de relația:

$$E_p = \frac{1}{2} \sum_{j=1}^m (d_{jp} - y_{jp})^2 = \frac{1}{2} \sum_{j=1}^m e_{jp}^2 \quad (4.3.4)$$

Funcția eroare globală, numită și funcție de performanță, pentru toate modelele din setul de antrenare este dată de relația:

$$E_p = \sum_p E_p = \frac{1}{2} \sum_p \sum_j (d_{jp} - y_{jp})^2 \quad (4.3.5)$$

unde d_{jp} reprezintă ieșirea dorită a neuronului de ieșire j pentru modelul p , y_{jp} reprezintă ieșirea actuală a neuronului de ieșire j pentru modelul p .

Există două abordări principale pentru găsirea minimumului acestei funcții globale de eroare E . Prima este așa numita învățare *on-line* sau *exemplu cu exemplu* în care modelele de antrenare sunt prezentate secvențial, de obicei în ordine aleatorie. După fiecare model de antrenare prezentat, ponderile sinaptice w_{ji}^s , $s = 1, 2, \dots, L$ sunt modi-

ficat cu o valoare Δw_{ji}^s proporțională cu valoarea negativă a gradientului funcției de eroare locală corespunzătoare E_p , care poate fi scris sub forma:

$$\Delta w_{ji}^s = -\eta \cdot \frac{\partial E_p}{\partial w_{ji}^s} \quad (4.3.6)$$

unde $\eta > 0$.

S-a demonstrat că dacă parametrul de învățare η este suficient de mic, această procedură minimizează funcția globală de eroare $E = \sum_p E_p$.

Regula gradientului prezentată anterior poate fi înlocuită cu ecuații diferențiale continue:

$$\frac{dw_{ji}^s}{dt} = -\mu \cdot \frac{\partial E_p}{\partial w_{ji}^s} \quad \text{cu } \mu > 0 \quad (4.3.7)$$

Astfel de ecuații pot fi modelate practic folosind circuite analogice sau pot fi rezolvate aplicând algoritmi iterativi mai complicați.

În cea de-a doua tehnică, numită *învățare globală (batch learning)*, funcția de eroare globală E este minimizată după ce toate modelele au fost procesate, modificările ponderilor fiind acumulate pentru tot setul de antrenare.

În continuare se prezintă tehnica învățării *exemplu cu exemplu* în care calculul gradientului în spațiul ponderilor se realizează pe baza funcției de eroare locală E_p . Mai întâi se determină formula de actualizare a ponderilor dintre ultimul strat ascuns și stratul de ieșire w_{ji}^s ($s = m$). Astfel, relația (4.3.6) poate fi scrisă sub forma:

$$\Delta w_{ji}^m = -\mu \cdot \frac{\partial E_p}{\partial w_{ji}^m} = -\frac{\partial E_p}{\partial u_j^m} \cdot \frac{\partial u_j^m}{\partial w_{ji}^m} \quad (4.3.8)$$

Luând în considerație că:

$$u_j^m = \sum_{i=1}^m w_{ji}^m \cdot x_i^m = \sum_{i=1}^m w_{ji}^m \cdot o_i^{m-1} \quad (4.3.9)$$

și definind termenul eroare prin relația:

$$\delta_j^m = -\frac{\partial E_p}{\partial u_j^m} = -\frac{\partial E_p}{\partial e_{jp}} \cdot \frac{\partial e_{jp}}{\partial u_j^m} = e_{jp} \cdot \frac{\partial \psi_j^m}{\partial u_j^m} \quad (4.3.10)$$

se obține relația generală pentru actualizarea ponderilor dintre ultimul strat ascuns și cel de ieșire:

$$\Delta w_{ji}^s = \eta \cdot \delta_j^m \cdot x_i^m = \eta \cdot \delta_j^m \cdot o_i^{m-1} \quad (4.3.11)$$

unde

$$\delta_j^m = e_{jp}(\psi_j^m) = (d_{jp} - y_{jp}) \cdot \frac{\partial \psi_j^m}{\partial u_j^m} \quad (4.3.12)$$

Actualizarea ponderilor sinaptice dintre straturile ascunse și dintre primul strat ascuns și cel de intrare este ceva mai complicată. Pentru ultimul strat ascuns se poate scrie:

$$\Delta w_{ji}^{m-1} = -\eta \cdot \frac{\partial E_p}{\partial u_j^{m-1}} \cdot \frac{\partial u_j^{m-1}}{\partial w_{ji}^{m-1}} = \mu \cdot \delta_j^{m-1} \cdot x_i^{m-1} = \eta \cdot \delta_j^{m-1} \cdot o_i^{m-2} \quad (4.3.13)$$

unde termenul eroare pentru ultimul strat ascuns este dat de:

$$\delta_j^{m-1} = -\frac{\partial E_p}{\partial u_j^{m-1}} \quad (4.3.14)$$

Totuși, termenul eroare nu poate fi direct evaluat, așa cum s-a făcut pentru cei aparținând stratului de ieșire.

$$\delta_j^{m-1} = -\frac{\partial E_p}{\partial u_j^{m-1}} = -\frac{\partial E}{\partial o_j^{m-1}} \cdot \frac{\partial o_j^{m-1}}{\partial u_j^{m-1}} \quad (4.3.15)$$

Luând în considerație că:

$$o_j^{m-1} = \psi_j^{m-1}(u_j^{m-1}) \quad (4.3.16)$$

avem

$$\delta_j^{m-1} = -\frac{\partial E}{\partial o_j^{m-1}} \cdot \frac{\partial \psi_j^{m-1}}{\partial u_j^{m-1}} \quad (4.3.17)$$

Factorul $-\frac{\partial E_p}{\partial o_j^{m-1}}$ poate fi evaluat ca:

$$\begin{aligned} -\frac{\partial E_p}{\partial o_j^{m-1}} &= -\sum_{i=1}^m \frac{\partial E_p}{\partial u_i^m} \cdot \frac{\partial u_i^m}{\partial o_j^{m-1}} = \sum_{i=1}^m \left(-\frac{\partial E_p}{\partial u_i^m} \right) \cdot \frac{\partial}{\partial o_j^{m-1}} \left(\sum_{k=1}^m w_{ik}^m x_k^m \right) = \\ &= \sum_{i=1}^m \delta_i^m \frac{\partial}{\partial o_j^{m-1}} \left(\sum_{k=1}^m w_{ik}^m \cdot o_k^{m-1} \right) = \sum_{i=1}^m \delta_i^m \cdot w_{ij}^m \end{aligned} \quad (4.3.18)$$

Astfel, termenul eroare pentru ultimul strat ascuns poate fi evaluat cu formula:

$$\delta_j^{m-1} = \frac{\partial \psi_j^{m-1}}{\partial u_j^{m-1}} \cdot \sum_{i=1}^m \delta_i^m \cdot w_{ij}^m \quad (4.3.19)$$

În general, termenul eroare pentru celelalte straturi ascunse este determinat pe baza termenilor eroare aparținând stratului imediat superior. Diferența majoră în corecția ponderilor stratului de ieșire față de straturile ascunse constă în evaluarea termenilor eroare δ_j^s ($s = 1 \dots L$).

Algoritmul de învățare Backpropagation este prezentat mai jos.

Pasul 1 Inițializează ponderile w_{ji}^s , aleator, cu valori mici

Pasul 2. Prezentarea unui model

Din setul datelor de învățare se alege un model intrare - ieșire dorită.

Pasul 3 Propagarea înainte

3.1. Pentru vectorul de intrare se determină ieșirile

3.2. Se compară ieșirile curente cu cele dorite, pentru a determina o măsură a erorii. Dacă sunt satisfăcute condițiile de oprire procesul de învățare se sistează

Pasul 4 Propagarea erorilor înapoi și ajustarea ponderilor

Se pornește de la stratul de ieșire către stratul de intrare, realizând adaptarea ponderilor

$$w_{ij}^{[s]}(t+1) = w_{ij}^{[s]}(t) + \Delta w_{ij}^{[s]}$$

$$\Delta w_{ij}^{[s]} = \eta \delta_j^{[s]} x_i^{[s]}$$

unde $\delta_j^{[s]}$ este termenul de eroare

Pasul 5 Test de convergență

Se prezintă un nou model și se repetă pașii 2-4, cu perechile de vectori din mulțimea de antrenare până când sunt satisfăcute condițiile de oprire - eroarea globală într-un ciclu scade sub valoarea impusă.

După antrenare, PMS are proprietatea de generalizare, adică poate furniza un răspuns corespunzător unor modele de intrare care nu au fost prezentate rețelei în timpul procesului de antrenare. Această capacitate de generalizare a PMS poate fi interpretată astfel: rețeaua neuronală realizează o mapare neliniară între spațiul intrărilor și cel al ieșirilor. Antrenarea PMS poate fi privită ca o aproximare a unei funcții multidimensionale, care realizează o simplă operație de adaptare sau de reconstrucție a unei hipersuprafețe într-un spațiu multidimensional, pe un set finit de puncte (modelele de antrenare). Din acest punct de vedere, generalizarea nu este altceva decât interpolarea setului test pe hipersuprafața reconstruită [Eremia2006].

Ponderile și pragurile rețelei sunt inițializate aleator cu valori nenule [Haykin1994], [Eremia2006] și distribuite uniform într-un interval mic $[-0,1; 0,1]$ sau $[-2,4 / \text{nr. intrări}, 2,4 / \text{nr. intrări}]$.

□ Algoritmul BackPropagation cu moment

Algoritmul de învățare descris anterior are anumite dezavantaje. Mai întâi, parametrul de învățare ar trebui să fie ales de valoare mică pentru a realiza minimizarea funcției globale eroare **E**. Totuși, pentru valori mici ale lui η procesul de antrenare devine foarte lent. Pe de altă parte, valori prea mari pentru η corespund unei învățări rapide, dar conduc la oscilații parazite, care împiedică algoritmul de la convergență către soluția dorită. Mai mult, dacă funcția eroare conține minime locale, rețeaua neuronală ar putea fi „prinsă” într-un astfel de minim local sau „aruncată” pe o suprafață „netedă”.

O cale simplă de îmbunătățire a algoritmului standard este să „netezim” modificările ponderilor prin suprarelașare, de exemplu, adăugând un termen moment:

$$\Delta w_{ji}^s(k) = \eta \cdot \delta_j^s \cdot o_i^{s-1} + \alpha \cdot \Delta w_{ji}^s(k-1) \quad (4.3.20)$$

unde $\eta > 0$, iar $0 \leq \alpha < 1$ (de obicei $\alpha = 0.9$)

Al doilea termen al ecuației (4.3.20) este așa numitul termen moment care poate îmbunătăți rata de convergență și deci performanța algoritmului. Intuitiv, dacă modificarea ponderii din pasul anterior este mare, atunci adăugând o fracțiune din această valoare la valoarea curentă a ponderii vom accelera convergența procesului. Mai exact, dacă ne situăm pe o suprafață „netedă” a funcției eroare, atunci componenta gradientului $\partial E / \partial w_{ji}$ va fi aceeași la fiecare pas, iar relația (4.3.20) poate fi scrisă astfel:

$$\Delta w_{ji}^s(k) = -\eta \cdot \frac{\partial E_p}{\partial w_{ji}^s(k)} + \alpha \cdot \Delta w_{ji}^s(k-1) \cong -\frac{\eta}{1-\alpha} \cdot \frac{\partial E_p}{\partial w_{ji}^s(k)} \quad (4.3.21)$$

Aceasta demonstrează că rata de învățare crește cu valoarea efectivă $\eta_{ef} = \eta / (1-\alpha)$ fără a mări oscilațiile parazite. Termenul moment este folositor nu numai în cazul învățării *exemplu cu exemplu*, ci și la învățarea batch backpropagation în care actualizarea ponderilor se face după prezentarea tuturor modelelor, prin sumarea tuturor modificărilor.

4.3.8. Algoritmul Resilient Propagation

O soluție foarte eficientă pentru creșterea vitezei de convergență a algoritmului de antrenare este algoritmul Resilient PROPagation (RPROP), propus în anul 1993 de doi cercetători germani Martin Riedmiller și Heinrich Braun de la Universitatea Karlsruhe. În locul introducerii termenului moment, ei au propus alte tehnici pentru accelerarea convergenței câteva dintre ele fiind bazate pe variația adaptivă a ratei de învățare în timpul procesului de antrenare, în concordanță cu evoluția funcției eroare. După cum au observat cei doi cercetători, toate tehnicile au ca punct de pornire observația că variația ponderilor depinde nu numai de rata de învățare, ci și de derivatele parțiale ale funcției eroare. Chiar dacă se utilizează o rată de învățare variabilă algoritmul poate fi total perturbat de anumite comportări neașteptate ale derivatelor parțiale. De asemenea, dacă rețeaua se găsește într-o zonă „netedă” a suprafeței de eroare, convergența este foarte lentă, în puternică concordanță cu faptul ca derivata funcției eroare este foarte mică.

Aspectul inovativ al algoritmului RPROP constă în faptul că nu se iau în considerație valorile derivatelor funcției eroare, ci doar informațiile referitoare la semnul acestora și se folosesc rate de învățare diferite pentru fiecare conexiune.

Fiecare parametru liber al sistemului (ponderi și biași) are atașat un factor de corecție, indicat prin Δ_{ji}^s , care determină adaptarea parametrului respectiv:

$$\Delta_{ji}^s(k) = \begin{cases} \eta^+ \Delta_{ji}^s(k-1) & \text{dacă } \frac{\partial E(k-1)}{\partial w_{ji}^s} \cdot \frac{\partial E(k)}{\partial w_{ji}^s} > 0 \\ \eta^- \Delta_{ji}^s(k-1) & \text{dacă } \frac{\partial E(k-1)}{\partial w_{ji}^s} \cdot \frac{\partial E(k)}{\partial w_{ji}^s} < 0 \\ \Delta_{ji}^s(k-1) & \text{dacă } \frac{\partial E(k-1)}{\partial w_{ji}^s} \cdot \frac{\partial E(k)}{\partial w_{ji}^s} = 0 \end{cases} \quad (4.3.22)$$

unde $0 < \eta^{-1} < 1 < \eta^+$

În acest fel, în orice moment, derivatele parțiale ale funcției eroare în raport cu ponderile își schimbă semnul. De exemplu, dacă ultima adaptare a ponderii a fost prea mare și algoritmul a condus la un minim local, Δ_{ji}^s este scăzut prin înmulțirea cu η^- . Dacă derivatele în două iterații succesive își păstrează semnul, Δ_{ji}^s este multiplicat cu η^+ , accelerând în acest fel convergența procesului spre zone mai „netede”. Actualizând în acest fel valoarea de corecție a parametrilor liberi, regula de modificare a ponderilor devine foarte simplă:

$$w_{ji}^s(k+1) = w_{ji}^s(k) + \Delta w_{ji}^s(k) \quad (4.3.23)$$

unde:

$$\Delta w_{ji}^s(k) = \begin{cases} -\Delta_{ji}^s(k) & \text{dacă } \frac{\partial E(k)}{\partial w_{ji}^s} > 0 \\ \Delta_{ji}^s(k) & \text{dacă } \frac{\partial E(k)}{\partial w_{ji}^s} < 0 \\ 0 & \text{dacă } \frac{\partial E(k)}{\partial w_{ji}^s} = 0 \end{cases} \quad (4.3.24)$$

Valorile ponderilor sunt modificate după prezentarea întregului set de modele de antrenare. Corecția inițială $\Delta_{ji}(0) = 0.1$, iar rezultatele cele mai bune se obțin pentru $\eta^+ = 1.2$ și $\eta^- = 0.5$.

4.4. Concluzii

În acest capitol s-au prezentat, într-un cadru mai larg, tehnicile de inteligență artificială utilizate în cadrul tezei de doctorat. El furnizează elementele teoretice necesare pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.

În prima parte a capitolului s-au trecut în revistă o serie de aspecte legate de istoricul tehnicilor de inteligență artificială și de aplicațiile specifice domeniului ingineriei sistemelor electroenergetice. În a doua parte s-a realizat o descriere a metodelor de abordare bazate pe tehnici de inteligență artificială: algoritmi genetici, inteligența de tip roi, rețele neuronale artificiale, sisteme expert, metode bazate pe logica fuzzy și metode hibride.

Un subcapitol aparte a fost consacrat RNA. Pornind de la câteva considerații cu caracter istoric, se abordează succesiv elemente legate de terminologie, de structură și de clasificare, de caracteristici, de neuronul formal și de perceptron, de perceptronul multistrat, de diversele procedee de antrenare (învățare), cu accent special pe cele de tip backpropagation.

În continuare se prezintă o sinteză a contribuțiilor personale:

- realizarea unei sinteze originale asupra utilizării tehnicilor de inteligență artificială în domeniul electroenergeticii;
- realizarea unei sinteze originale asupra unei game largi de aspecte legate de rețelele neuronale artificiale;
- pregătirea elementelor teoretice necesare pentru modelul de prognoză utilizat în cadrul tezei: RNA cu structură perceptron multistrat, algoritm de învățare de tip backpropagation.

5. MODELE MATEMATICE UTILIZATE

Obiectivul capitolului 5 constă în prezentarea modelelor matematice ale metodelor utilizate efectiv în lucrare pentru prognoza consumului de energie electrică și putere, a curbelor de sarcină. O bună parte dintre ele au fost elaborate pe baza elementelor teoretice prezentate în capitolele anterioare.

Prima parte a capitolului prezintă modelul Regresiei Liniare Multiple (RLM), iar partea a doua descrie modelul Arborilor de Decizie (AD). În partea a treia se tratează modelul de aproximare Curve Fitting (CF), ultima parte a capitolului referindu-se la metodele utilizând Rețele Neuronale Artificiale (RNA).

5.1. Modelul Regresiei Liniare Multiple (RLM)

5.1.1. Considerații teoretice

Regresia este o metodă de predicție a valorilor unei variabile pe baza valorilor altei variabile. Regresia simplă se bazează pe corelația simplă dintre criteriu și predictor și are o singură variabilă predictor. Regresia multiplă se bazează pe corelația multiplă dintre criteriu și predictor și are mai multe variabile predictor.

Scopul folosirii modelului de regresie este de a obține parametrii ce corespund setului de variabile formulat, prin analiza dependenței dintre variabile, precum și pentru evidențierea dependenței dintre variabile într-un anumit orizont de timp. Modelul liniar de regresie presupune identificarea variabilelor pentru definirea modelului și precizarea variabilei reziduale; contextul în care este utilizat modelul de regresie. Majoritatea dependențelor reale sunt de tip liniar sau pot fi reduse la modelul liniar motiv pentru care studierea unui astfel de model ocupă un loc important în modelarea matematică.

Modelul regresiei multiple are la bază aceleași principii ca și regresia simplă, dar calculele sunt mai laborioase. Modelul are următoarea formă generală [Negrea2006]:

$$Y(t) = f(X_1, X_2, \dots, X_m) + \varepsilon \quad (5.1.1)$$

unde Y este variabila endogenă, X_1, X_2, \dots, X_m variabile exogene explicite, ε - perturbare aleatoare.

Modelele multivariaționale frecvent utilizate sunt modelul liniar:

$$Y = a_0 + b_1 \cdot X_1 + \dots + b_m \cdot X_m + \varepsilon \quad (5.1.2)$$

$$Y = P_k(X_1, X_2, \dots, X_m) + \varepsilon \quad (5.1.3)$$

$$Y = a_1 \cdot X_1^{b_1} + a_2 \cdot X_2^{b_2} + \dots + a_m \cdot X_m^{b_m} + \varepsilon \quad (5.1.4)$$

Variabilele din membrul drept se numesc variabile independente deși ele pot fi într-o slabă dependență pentru că ele modelează la rândul lor alți factori de influență. Forma de dependență este sugerată de tipul de corelație existent între Y și variabilele X_i , și chiar între variabilele X_i respective.

Termenul perturbator asimilat de eroarea de modelare se consideră a fi o variabilă aleatoare normală cu valoarea medie $M(\varepsilon) = 0$ independentă de valorile variabilelor $X_i, i = \overline{1, m}$, cu varianța (dispersia) $D^2(\varepsilon) = \sigma^2 = \text{constantă}$ și independentă de X_i , ceea ce implică și interdependența varianței lui Y , $D^2(y) = \sigma^2$ și se obține, în medie relația:

$$M(Y / X_1 = x_1, \dots, X_m = x_m) = f(x_1, \dots, x_m) \quad (5.1.5)$$

care se mai numește și ecuația de regresie multiplă (adică valoarea medie a tuturor valorilor lui Y , pentru x_i fixate este $f(x_1, x_2, \dots, x_m)$ și eroarea ε reflectă abaterea dintre valoarea actuală a lui Y și respectiv valoarea medie a lui Y pentru x_1, \dots, x_m fixate, adică $f(x_1, \dots, x_m)$. Rezultă că și funcția de repartiție a lui Y din modelul (5.1.2) este de tip Gauss-Laplace (deci normală) pentru că $a_i, b_j, x_i, i = \overline{1, m}$ sunt constante și deci:

$$M(Y) = a + b_1 \cdot x_1 + \dots + b_m \cdot x_m \quad (5.1.6)$$

Revenind la modelul dat de (5.1.2) și la ecuația de regresie multiplă asociată, care presupune că fiecare variabilă dependentă Y_i este egală în medie, cu o funcție liniară cu parametrii $a_0, b_j, j = \overline{1, m}$, adică variabilele aleatoare Y_1, \dots, Y_n satisfac sistemul de ecuații liniare:

$$Y_i = a_0 + b_1 \cdot X_{1i} + b_2 \cdot X_{2i} + \dots + b_m \cdot X_{mi} + \varepsilon_i, \quad i = \overline{1, n} \quad (5.1.7)$$

unde $a_0, b_j, j = \overline{1, m}$ sunt parametri; $\varepsilon_i, i = \overline{1, n}$, sunt variabile aleatoare cu o repartiție normală, cu $M(\varepsilon_i) = 0, i = \overline{1, n}$ sunt independente între ele și interdependente de X_j , $D^2(\varepsilon_i) = \text{constant}$; X_{ji} sunt variabile aleatoare sau valori fixate ale acestora.

Una din metodele de estimare a parametrilor $a_0, b_j, j = \overline{1, m}$, este *metoda celor mai mici pătrate* [Kilyeni2011], care constă în înlocuirea acestora cu soluțiile problemei:

$$\begin{aligned} \min_{a_0, b_j} SSE &= \min_{a_0, b_j} SSE \sum_{i=1}^n e_i^2 = \min_{a_0, b_j} SSE \sum_{i=1}^n (y_i - M(Y_i / x_{i1}, \dots, x_{im}))^2 \stackrel{not}{=} \\ &= \min_{a_0, b_j}^{not} SSE \sum_{i=1}^n (y_i - M(Y_i))^2 \stackrel{not}{=} \\ &= \min_{a_0, b_j}^{not} SSE \sum_{i=1}^n (y_i - a_0 - b_1 x_{i1} - \dots - b_m x_{im})^2 \stackrel{not}{=} \min_{a_0, b_j} SS_{er} \end{aligned} \quad (5.1.8)$$

Estimațiile parametrilor $a_0, b_j, j = \overline{1, m}$, sunt soluții ale sistemului de ecuații normale asociat obținut prin anularea derivatelor parțiale

$$\partial SS_{er} / \partial a_0, \partial SS_{er} / \partial b_j, j = \overline{1, m} \quad (5.1.9)$$

adică date prin

$$\begin{aligned}
 a_0 \cdot \sum_{i=1}^n x_{i0}^2 + b_1 \cdot \sum_{i=1}^n x_{i0} \cdot x_{i1} + \dots + b_m \cdot \sum_{i=1}^n x_{i0} \cdot x_{im} &= \sum_{i=1}^n x_{i0} \cdot y_i \\
 a_0 \cdot \sum_{i=1}^n x_{i0} \cdot x_{i1} + b_1 \cdot \sum_{i=1}^n x_{i1}^2 + \dots + b_m \cdot \sum_{i=1}^n x_{i1} \cdot x_{im} &= \sum_{i=1}^n x_{i1} \cdot y_i \\
 \dots &\dots \\
 a_0 \cdot \sum_{i=1}^n x_{i0} \cdot x_{im} + b_1 \cdot \sum_{i=1}^n x_{i1} \cdot x_{im} + \dots + b_m \cdot \sum_{i=1}^n x_{im}^2 &= \sum_{i=1}^n x_{im} \cdot y_i
 \end{aligned} \tag{5.1.10}$$

în care s-a notat $x_{i0} = 1, i = \overline{1, n}$.

În continuare avem

$$\begin{aligned}
 \sum_{i=1}^n x_{i0}^2 &= n \\
 \sum_{i=1}^n x_{i0} \cdot x_{ik} &= \sum_{i=1}^n x_{ik}, \quad k = \overline{1, m} \\
 \sum_{i=1}^n x_{i0} \cdot y_i &= \sum_{i=1}^n y_i
 \end{aligned} \tag{5.1.11}$$

și sistemul de ecuații normale devine

$$\begin{aligned}
 a_0 \cdot n + b_1 \cdot \sum_{i=1}^n x_{i1} + \dots + b_m \cdot \sum_{i=1}^n x_{im} &= \sum_{i=1}^n y_i \\
 a_0 \cdot \sum_{i=1}^n x_{i1} + b_1 \cdot \sum_{i=1}^n x_{i1}^2 + \dots + b_m \cdot \sum_{i=1}^n x_{i1} \cdot x_{im} &= \sum_{i=1}^n x_{i1} \cdot y_i \\
 \dots &\dots \\
 a_0 \cdot \sum_{i=1}^n x_{im} + b_1 \cdot \sum_{i=1}^n x_{i1} \cdot x_{im} + \dots + b_m \cdot \sum_{i=1}^n x_{im}^2 &= \sum_{i=1}^n x_{im} \cdot y_i
 \end{aligned} \tag{5.1.12}$$

Se consideră matricele asociate

$$X' = \begin{bmatrix} x_{10} & x_{11} & \dots & x_{1m} \\ x_{20} & x_{21} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{n0} & x_{n1} & \dots & x_{nm} \end{bmatrix} \tag{5.1.13}$$

$$XX' = \begin{bmatrix} n & \sum_{i=1}^n x_{i1} & \dots & \sum_{i=1}^n x_{im} \\ \sum_{i=1}^n x_{i1} & \sum_{i=1}^n x_{i1}^2 & \dots & \sum_{i=1}^n x_{i1} \cdot x_{im} \\ \dots & \dots & \dots & \dots \\ \sum_{i=1}^n x_{im} & \sum_{i=1}^n x_{i1} \cdot x_{im} & \dots & \sum_{i=1}^n x_{im}^2 \end{bmatrix} \tag{5.1.14}$$

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}, \quad \Theta = \begin{bmatrix} a_0 \\ b_1 \\ \vdots \\ b_m \end{bmatrix}, \quad XY = \begin{bmatrix} \sum_{i=1}^n y_1 \\ \sum_{i=1}^n x_{i1} \cdot y_i \\ \vdots \\ \sum_{i=1}^n x_{im} \cdot y_i \end{bmatrix} \quad (5.1.15)$$

unde X' este transpusa matricei X cu elementele cunoscute, date de valorile experimentale de selecție pentru factorii ce influențează (adică acele valori ce explică valorile variabilelor dependente și se mai numesc variabile aleatoare independente), vectorul dependent Y care se mai numește vectorul observațiilor, Θ este vectorul parametrilor necunoscuți, adică de tipul $m \times 1$, iar ε este vectorul aleator al erorilor, adică de tipul $n \times 1$.

În acest caz modelul de regresie liniară multiplă ce depinde de $m+1$ variabile x_0, \dots, x_m devine:

$$Y = X' \cdot \Theta + \varepsilon$$

$$\eta = \overset{not}{M}(Y) = X' \cdot \Theta, M(\varepsilon) = 0 \quad (5.1.16)$$

$$D^2(\varepsilon) = M[(\varepsilon - M(\varepsilon))(\varepsilon - M(\varepsilon))'] = M(\varepsilon\varepsilon') = (\sigma^2) \times (I_n)$$

Expresia sumei pătratelor erorilor (reziduurilor) devine:

$$SSE(y, \theta) = (Y - X' \cdot \theta)' \cdot (Y - X' \cdot \theta) = \|Y - X' \cdot \theta\|^2 =$$

$$= \sum_{i=1}^n (\varepsilon_i)^2 = \sum_{i=1}^n \left(y_i - \sum_{j=0}^m x_{ij} \theta_j \right)^2 \quad (5.1.17)$$

Mulțimea funcțiilor $\hat{\theta} = \hat{\theta}(y) = \overset{not}{\hat{a}}_0, \hat{b}_j, j = \overline{1, m}$, care minimizează forma pătratică (5.1.17) se numește mulțimea estimățiilor în sensul celor mai mici pătrate pentru parametrul θ , adică soluțiile $\hat{\theta}$ ale ecuației

$$SSE(y, \hat{\theta}) = \min_{\theta} SSE(y, \theta) = \overset{not}{\min_{\theta}} SS_{er} \quad (5.1.18)$$

O condiție necesară pentru ca ecuația (5.1.17) să aibă soluție este dată de sistemul

$$\frac{\partial(SSE(y, \theta))}{\partial \theta} = 0 \quad (5.1.19)$$

care este echivalent cu sistemul

$$2 \cdot X \cdot (Y - X' \cdot \theta) = 0 \quad \text{sau} \quad X \cdot Y = X' \cdot X \cdot \theta \quad (5.1.20)$$

numit sistemul ecuațiilor normale.

În ipoteza că rangul lui $X' = m + 1 = \text{rang}(X) = \text{nr. parametrilor } a_0, b_1, \dots, b_m$, atunci matricea XX' este de tipul $(m+1, m+1)$, are rangul $m+1$, există $(XX')^{-1}$ și deci sistemul de ecuații normale (5.1.20) are soluție unică dată de:

$$\hat{\Theta} = (XX')^{-1} \cdot XY \quad (5.1.21)$$

unde XX' și XY sunt date de relațiile (5.1.15)

Această soluție a sistemului (5.1.20) este și o soluție a ecuației (5.1.18) pentru că are loc egalitatea

$$\frac{\partial^2(SSE(y, \theta))}{\partial \theta^2} = 2 \cdot XX' \quad (5.1.22)$$

iar forma pătratică $u' \cdot (XX') \cdot u$ este pozitiv definită și deci $\hat{\theta}$ este un punct de minim iar ecuația de regresie estimată devine

$$\hat{Y} = \hat{a}_0 + \hat{b}_1 \cdot X_1 + \dots + \hat{b}_m \cdot X_m \quad (5.1.23)$$

În cazul rangului complet există și alte metode de estimare a parametrului Θ , cum este estimarea în sensul celor mai mici pătrate generalizate sau metoda verosimilității maxime, metode ale căror rezultate coincid sau sunt foarte strâns legate între ele.

5.1.2. Prezentarea modelului utilizat

Pentru modelul ce aplică regresia liniară multiplă s-a elaborat o variantă modificată a funcției *regress* care face parte din Statistics Toolbox [Matlab].

Funcția permite determinarea parametrilor unui model multiplu de regresie liniară, împreună cu intervalele de încredere. De asemenea, se mai poate returna ca rezultat, șirul reziduurilor împreună cu intervalele de încredere și cu câteva statistici care dau calitatea regresiei. Sintaxa cea mai complexă este:

```
>> [b,bint,r,rint,stats] = regress(y,X,alpha).
```

Parametrii de intrare:

- y – stochează datele înregistrate pentru variabila răspuns;
- X – stochează datele înregistrate pentru variabilele factori, coloanele sale reprezentând câte un factor;
- α se stochează pragul de semnificație pentru intervalele de încredere determinate în cadrul regresiei.

Parametrii de ieșire:

- b – stochează vectorul parametrilor modelului, ordinea fiind corespunzătoare ordinii din X ;
- $bint$ – stochează capetele intervalelor de încredere corespunzătoare parametrilor de regresie;
- r – stochează vectorul reziduurilor (de dimensiune egală cu numărul de date);
- $rint$ – stochează intervalele de încredere pentru reziduuri;
- $stats$ – returnează în această ordine, valoarea lui R^2 , valoarea statisticii F asociate ipotezei că toți coeficienții de regresie sunt 0, respectiv valoarea de semnificație p , asociată acestui test.

Se prezintă în continuare, sintetic, algoritmul metodei elaborate, cu observația că o serie de detalii "tehnice" se regăsesc în textul sursă al programului de calcul.

1. Se generează predictorii:

- $ziua_prec_ora$ – consumul din ziua precedentă la aceeași oră;
- $pre24HourAverLoad$ – consumul mediu orar din ziua precedentă;
- $ziua$ – cu valori $1, 2, \dots, 31$;
- $ziuasapt$ – se referă la ziua din cadrul săptămâni și ia valori de la 1 (pentru luni) până la 7.

2. Se formează datele de intrare folosite la validare: au denumire asemănătoare cu predictorii doar că fiecare variabilă are numele precedat de caracterul v;
3. Sunt creați coeficienții de regresie b, bint și r cu funcția *regress*.
4. În urma procesului de validare, folosind coeficienții de regresie, rezultă variabila REGRESSsarc;
5. Se calculează MAPE pentru datele de intrare modelate (REGRESSsarc);
6. Se reprezintă grafic datele de intrare modelate (REGRESSsarc);
7. Se utilizează coeficienții de regresie pentru prognoza sarcinii electrice pe următoarele 24 de ore, rezultând variabila REGRESSprogn;
8. Se calculează MAPE pentru prognoza pe ziua următoare;
9. Se reprezintă grafic REGRESSprogn pentru $t=(1, 24)$.

Prognoza pe baza modelului de regresie este cu atât mai veridică, cu cât modelul este mai bine ales să se potrivească datelor și cu cât orizontul de previziune este mai mic.

Modelul regresiei liniare multiple prezentat în Fig. 5.1.1 este bun pentru a estima tendințele generale ale datelor, cu toate acestea, nu poate estima nelinearitățile.

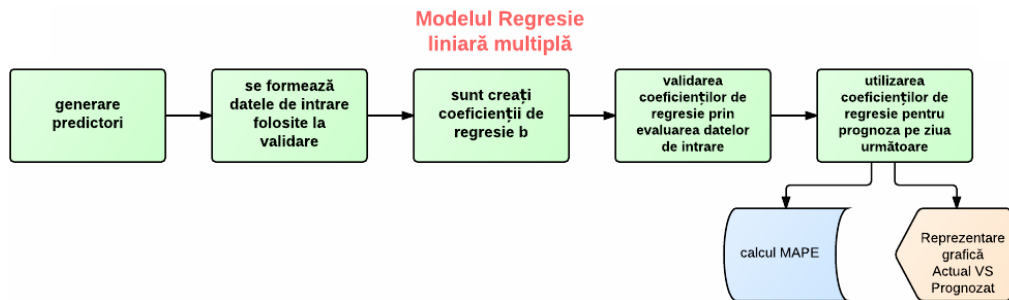


Fig. 5.1.1. Modelul Regresia liniară multiplă

5.2. Modelul Arborilor de Decizie (AD)

5.2.1. Considerații teoretice

Teoria arborilor de decizie ocupă un loc important în teoria sistemelor de învățare automată. Un arbore de decizie este de fapt un clasificator capabil să extragă și să sintetizeze informația conținută în bazele de date. Pe baza acestei informații el este capabil ulterior să ofere un răspuns exact atunci când este pus să rezolve probleme asemănătoare, al căror rezultat nu este cunoscut [Ereimia2001].

Avantajele arborilor de clasificare și decizie [Gorunescu2006]:

- sunt ușor de înțeles și interpretat;
- relativ rezistenți în fața datelor cu zgomot;
- acuratețe comparabilă cu a altor tipuri de clasificatori;
- necesită un volum mic de pregătire a datelor în raport cu alte tehnici;
- permit utilizarea atât a datelor nominale cât și a celor categoriale, fără nicio restricție;
- sunt modele de tip white-box, în care logica deciziei poate fi urmărită ușor, regulile de clasificare fiind "la vedere";
- fac posibilă utilizarea unor tehnici statistice clasice pentru validarea modelului;
- algoritmi de construire sunt de regulă rapizi, clasificarea pe baza lor este și mai rapidă;
- sunt robuști.

Desigur există și unele dezavantaje:

- sunt greu de manevrat;
- pot surveni instabilități, ceea ce implică o modificare a datelor de antrenament;
- sunt necesare costuri mari pentru inducerea arborilor de decizie;
- inducerea arborilor de decizie necesită multă informație.

Arborii de clasificare sunt utilizați în prognoza apartenenței unor obiecte – instanțe la categorii distincte, plecând de la măsurările lor în raport cu una sau mai multe variabile predictoare. Procedura de construire a unui arbore de clasificare (și decizie) este un proces inductiv și de aceea termenul consacrat este de inducție a arborelui.

Prin convenție primul nod – nodul rădăcină – se află în vârf legat prin ramuri (links) de nodurile interne – noduri de decizie. Fiecare nod (intern) al arborelui exprimă testarea după un anumit atribut, fiecare ramură reprezintă rezultatul testului, iar „frunzele” sunt noduri terminale cărora nu le mai corespunde nici o întrebare. Unui nod frunză îi corespunde o anumită categorie (clasă). În cazul unor decizii binare, prin convenție, arcul din stânga corespunde unui răspuns afirmativ la test.

Odată construit un arbore de clasificare, această structură este aproape întotdeauna utilizată pentru luarea unei decizii, din această cauză, de multe ori se utilizează doar termenul de arbore de decizie. În literatura de specialitate se întâlnesc mai multe denumiri pentru arborii de clasificare și decizie: arbori de clasificare (termen folosit atunci când rezultatul predicției este clasa de apartenență a datelor), arbori de regresie (când rezultatul prognozat poate fi considerat un număr real) sau CART (Classification And Regression Tree), atunci când suntem în ambele situații de mai sus.

Un arbore de clasificare și decizie este un discriminator de clasă (categorie) care partiționează (divide) în mod recursiv mulțimea de antrenament până la obținerea „frunzelor”, adică a acelor noduri finale care sunt constituite fie din aceeași categorie de obiecte, fie dintr-o categorie dominantă. În acest sens, orice nod al arborelui care nu este „frunză” reprezintă un punct de partiționare pe baza unui atribut test care determină modul de divizare a nodului respectiv. Strategia care stă la baza partiționării optime a unui nod este o metodă de tip greedy algorithm, adică o construcție recursivă „de sus în jos” de tip *divide and conquer* [Gorunescu2006].

Metodologia inducției arborelui de clasificare și decizie constă în două etape. Prima etapă constă în construirea arborelui inițial, utilizând mulțimea de antrenament disponibilă, până când fiecare *frunză* devine *pură* sau *aproape pură*. A doua etapă, numită **fasonarea arborelui**, este responsabilă cu îmbunătățirea acurateței obținută pe mulțimea de testare. Odată construit arborele de clasificare și decizie, pe baza setului de obiecte de antrenament, este natural ca acesta să reflecteze, mai mult sau mai puțin, caracteristicile acestei mulțimi. Multe din ramurile sale vor fi influențate puternic de anomaliile care se pot afla în mulțimea de antrenament, anomalii datorate *zgomotului* sau anumitor valori extreme scăpate de procesul de filtrare a datelor inițiale, dacă acesta a fost în prealabil efectuat. Dacă arborele indus pe baza datelor de antrenament se potrivește prea accentuat cu datele de antrenament, apare eroarea de overfitting, arborele nefiind capabil să generalizeze pentru date noi. Dacă arborele indus pe baza datelor de antrenament este prea simplu apare o situație inversă, adică underfitting, rezultând o eroare de clasificare mare atât în etapa de antrenare, cât și în cea de testare.

Algoritmul Hunt (Hunt’s Concept Learning System) este unul dintre primii algoritmi de construire a unui arbore de clasificare. Conceptual, algoritmul Hunt rezidă în următorii pași [Gorunescu2006]:

- se notează cu D_t mulțimea de antrenament care se găsește la nodul t ;
- dacă D_t este mulțimea vidă, atunci t este o „frunză” etichetată prestabilit C_ϕ ;

- dacă D_t conține instanțe ce aparțin aceleiași clase C_t , atunci t este o frunză etichetată prestabilit C_t ;
- dacă D_t conține instanțe ce aparțin la mai mult de o clasă, atunci se utilizează un atribut test pentru a divide nodul în submulțimi (noduri) mai mici. Procedeu se aplică recursiv fiecărui nou nod.

În literatura de specialitate sunt prezentate variante îmbunătățite ale algoritmului Hunt printre care: ID3, C4.5, C5.0, CART, CHAID, SLIQ, SPRINT, QUEST, FACT, THAID. În prezent există programe specializate de creare a arborilor de clasificare.

□ Algoritm ID3

Inițial acest algoritm propus de Ross Quinlan a fost utilizat pentru învățarea unor strategii în jocul de șah, fiind apoi modificat și îmbunătățit pentru a fi aplicat la o varietate largă de probleme. Algoritm determină clasificarea obiectelor testându-le valorile proprietăților lor. Construirea arborelui se face de sus în jos, pornind de la un set de obiecte și specificații ale proprietăților lor. La fiecare nod al arborelui, se testează o proprietate și rezultatul este utilizat pentru partiționarea setului de obiecte. Procesul este realizat recursiv până când setul dintr-un subarbore dat este omogen în raport cu criteriul de clasificare și acest subarbore devine nod-frunză. Algoritm alege predictorii și valorile lor de ramificare bazat pe câștigul în informație pe care ramificarea sau ramificările îl aduc. La fiecare nod proprietatea de test este aleasă pe baza unui criteriu teoretic de informație care caută să maximizeze câștigul în informație și să minimizeze entropia. Câștigul reprezintă diferența dintre cantitatea de informație care este necesară pentru realizarea unei predicții corecte înainte ca o ramificare să fie făcută și după ce ramificarea a fost făcută. Dacă cantitatea de informație cerută este mai mică după ce ramificarea a fost făcută atunci această ramificare a scăzut dezordinea din unicul segment original [Bădulescu2005].

Esența algoritmului ID3 este prezentată mai jos.

funcție ind-arbore (set-învățare, attribute, default)

1. **dacă** set-învățare = vid
atunci întoarce frunza etichetată cu default sau "Failure"
2. **dacă** toate exemplele din set-învățare sunt în aceeași clasă
atunci întoarce o frunză etichetată cu acea clasă
3. **dacă** attribute este vidă
atunci întoarce o frunză etichetată cu disjuncția tuturor claselor din set-învățare
4. selectează un atribut A, crează nod pentru A și etichetează nodul cu A
5. șterge A din attribute → attribute'
6. m = cea mai frecventă clasă (set-învățare)
7. **pentru** fiecare valoare V a lui A **repetă**
 fie partiție V mulțimea exemplilor din set-învățare,
 cu valoarea V pentru A
 crează nodV = ind-arbore (partitieV, attribute', m)
 crează legatură nod A - nod V etichetată cu V

Sfârșit

O îmbunătățire a lui ID3 a fost adusă în cadrul algoritmului C4.5. În C4.5 sunt utilizați în continuare predictorii cu valori lipsă, pot fi utilizați predictorii cu valori continue și este introdusă simplificarea arborelui.

Pentru a măsura eficiența divizării nodurilor în literatura de specialitate se utilizează mai mulți indici (criterii) de partiționare.

Entropia de clasificare reprezintă gradul de impuritate al claselor din mulțimea de antrenare și este definită de formula [Eremia2001]:

$$H_C = - \sum_{i=1}^m \frac{n_i}{n} \cdot \log_2 \frac{n_i}{n} \quad (5.2.1)$$

unde n_i este numărul de exemple de antrenare aparținând clasei c_i , n este numărul de exemple ce trebuie clasificate în acest pas, $i = 1 \div m$ numărul de clase.

Se definește entropia testului [Eremia2001]:

$$H_{C/T} = - \sum_{j=1}^p \frac{n^j}{n} \cdot \left(\sum_{i=1}^m \frac{n_i^{j1}}{n^j} \log_2 \frac{n_i^{j1}}{n^j} \right) \quad (5.2.2)$$

unde n_i^j este numărul exemplilor ce aparțin clasei c_i și rezultatului j al testului, n^j este numărul total de exemple ce aparțin rezultatului j al testului.

Indexul Gini utilizat mai ales în cazul algoritmului CART (Classification and Regression Trees) se bazează pe selectarea acelu atribute de partiționare care minimizează impuritatea divizării [Eremia2001]:

$$G = 1 - \frac{1}{n} \cdot \sum_{j=1}^p \left(\sum_{i=1}^m \frac{(n_i^j)^2}{n^j} \right) \quad (5.2.3)$$

În cadrul algoritmului CART3.1 testul selectat este acela care are măsura Gini a impurității cea mai mică, în timp ce metoda ID3 selectează atributul ce are cantitatea informațională maximă.

Utilizat cu predilecție în ID3, C4.5 și C5.0, **câștigul de informație** (information gain) se calculează ca diferență între gradul de impuritate al nodului părinte și gradul de impuritate ale nodurilor fii. Atributul de clasificare ales este cu atât mai bun cu cât această diferență este mai mare [Gorunescu2006].

$$Gain(S) = Entropia(S) - \sum_{j=1}^k \frac{N(v_j)}{N} \cdot Entropia(v_j) \quad (5.2.4)$$

unde $Entropia(S)$ este entropia nodului părinte S , $Entropia(v_j)$ este entropia nodului fiu v_j , N este numărul de obiecte din nodul părinte, k este numărul stări ale atributului ales pentru clasificare, $N(v_j)$ este numărul de obiecte ce aparțin nodului-fi v_j .

Pe lângă criteriile prezentate anterior și care au la bază noțiunea de entropie, în literatura de specialitate pot fi întâlnite și alte criterii de selecție a celui mai bun test.

Regula împărțirii binare poate fi aplicată numai pentru teste ce au două răspunsuri, ceea ce înseamnă că arborii de decizie rezultați sunt arbori binari [Eremia2001]:

$$RIB = \frac{n_d}{n} \frac{n_b}{n} \left(\sum_{i=1}^k \left| \frac{n_{di}}{n_d} - \frac{n_{bi}}{n_b} \right| \right)^2 \quad (5.2.5)$$

unde n_d este numărul de exemple ce răspund "DA" la întrebarea testului, n_b – numărul de exemple ce răspund "NU" la întrebarea testului, n_{di} – numărul de exemple ce răspund "DA" la întrebarea testului și aparțin clasei c_i , n_{bi} – numărul de exemple ce răspund "NU" la întrebarea testului și aparțin clasei c_i , k – numărul de clase.

Testul care are valoarea dată de relația (5.2.5) maximă va fi ales ca test pe baza căruia se va realiza partiționarea mulțimii de exemple curentă. S-a demonstrat că regula împărțirii binare este o măsură mult mai bună ca entropia.

În cazul criteriului **maximul minorităților** pentru fiecare răspuns al testului se determină clasa careia aparțin cele mai multe exemple din mulțimea de antrenare curentă. Se definește minoritatea maximă a rezultatului j al testului ca fiind [Eremia2001]:

$$\text{Minoritate}(j) = \sum_{i=1, i \neq \max n_1^j}^p n_1^j \quad (5.2.6)$$

iar maximul minorității se definește

$$\text{Max Minoritate}(j) = \max_{j=1}^p \text{Minoritate}(j) \quad (5.2.7)$$

Testul pe baza căruia se partiționează mulțimea de antrenare curentă este cel care are minoritatea cea mai mare.

Criteriul **suma minorităților** este asemănător cu maximul minorității, doar că în acest caz se calculează suma [Eremia2001].

$$\text{Suma Minoritate} = \sum_{j=1}^p \text{Minoritate}(j) \quad (5.2.8)$$

Ultimele două criterii au dezavantajul că nu selectează întotdeauna testul cel mai bun, dar oferă rezultate foarte bune atunci când sunt utilizate pentru construcția arborilor de decizie oblici.

5.2.2. Prezentarea modelului utilizat

Se prezintă în continuare, sintetic, algoritmul metodei elaborate pentru prognoza sarcinii, cu observația că o serie de detalii "tehnice" se regăsesc în textul sursă al programului de calcul.

1. Se generează predictorii:

- an;
- luna – cu valori 1,2,...,12;
- ziua – cu valori 1,2,...,31;
- ora – cu valori 1,2,...,24;
- ziua_sapt – cu valori 1,2,...,7;
- sapt_prec_ora – consumul din săptămâna precedentă la aceeași oră;
- ziua_prec_ora – consumul din ziua precedentă la aceeași oră;
- pre24HourAverLoad – consumul mediu orar din ziua precedentă.

2. Se formează datele folosite la validare în același format cu de intrare de la pasul precedent (vor fi precedate de caracterul v);

3. Se crează arborele de decizie;

Crearea arborelui implică construirea arborelui, utilizarea lui ca model de rezolvare a problemelor și tăierea (fasonarea) arborelui.

a) *Construirea arborelui*

În cadrul modelului AD s-a utilizat din Matlab clasa *classregtree*, care construiește un arbore de clasificare și decizie. Sintaxa este:

```
t = classregtree(X,y,'Name',value)
```

unde X este o matrice $n \times m$ de valori predictor ($X = \text{in_tree}'$); y este răspunsul, ($y = \text{sarcina}'$) – dacă y este un vector de n valori de răspuns, classregtree efectuează regresie; t este un arbore clasificare și decizie, în care fiecare nod

de ramificare este divizat pe baza valorilor coloanei aferente din X ; $Name$ și $value$ pot lua mai multe valori printre care și $method$; $Method$ poate lua valoarea $classification$ sau $regression$ (valoarea implicită dacă y are valori numerice).

Pe baza matricei X de dimensiuni $n \times m$, în care liniile reprezintă obiectele, iar coloanele reprezintă atributele predictoare și a vectorului coloană y , care conține etichete de clasă pentru fiecare obiect, arborele de clasificare și decizie t creat face o clasificare.

În cazul modelului creat de autor s-a folosit:

```
T = classregtree(in_tree',sarcina', 'method', 'regression');
```

b) Fasonarea arborelui

Pentru evitarea unor dificultăți legate de underfitting (sub-potrivire) sau overfitting (supra-potrivire, autorul a folosit *prune*, pentru fasonarea arborelui (îndepărtarea ramurilor nesemnificative, redundante), rezultând astfel un arbore mai puțin stufos.

În cazul modelului creat de autor s-a folosit:

```
simpleTree = prune(T, 100);
```

4. În urma validării rezultă variabila R_{TREE_sarc} ;
5. Se calculează MAPE pentru datele de intrare modelate (R_{TREE_sarc});
6. Se reprezintă grafic datele de intrare modelate (R_{TREE_sarc});
7. Se utilizează arborii de decizie (folosind *treeeval*) pentru prognoza sarcinii electrice pe următoarele 24 de ore, și rezultă variabila R_{TREE_progn} ;
8. Se calculează MAPE pentru prognoza pe ziua următoare;
9. Se reprezintă grafic R_{TREE_progn} , pentru $t=(1, 24)$.

Modelul arborilor de decizie este prezentat în Fig. 5.2.1.

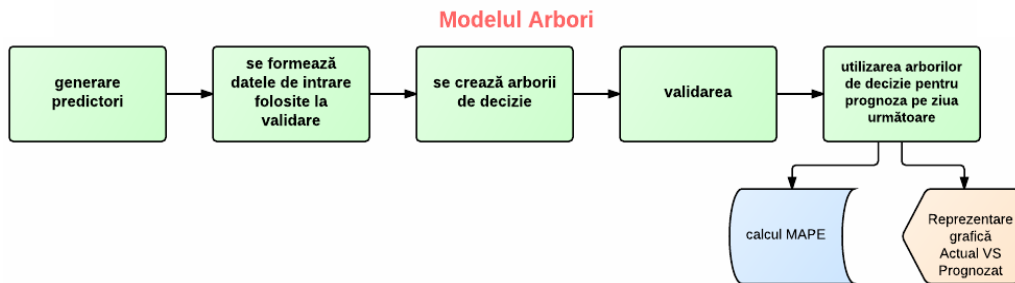


Fig. 5.2.1. Modelul Arbori

5.3. Modelul Curve Fitting (CF)

5.3.1. Considerații teoretice

Problema aproximării valorilor unor funcții se poate pune în situații diverse în domeniul ingineriei. În general în cadrul aplicațiilor din domeniul energetic nu se cunoaște expresia analitică a funcției care trebuie aproximată, ci doar valorile ei într-un anumit număr de puncte, urmărindu-se determinarea aproximativă a valorilor corespunzătoare unor alte puncte, diferite de cele date. Un astfel de exemplu este și cel al prognozei consumului de energie electrică. În situațiile practice nu este neapărat necesară determinarea explicită a expresiei funcției de aproximare, fiind suficientă doar găsirea valorii acestei funcții pentru orice valoare din intervalul pe care se face

aproximarea. Alegerea funcției de aproximare se bazează și pe cunoașterea formei funcției care trebuie aproximată [Kilyeni2011].

În continuare se trec în revistă metodele numerice folosite pentru interpolarea unei funcții dată sub formă discretă.

Dacă funcția de aproximare $g(x)$ are aceleași valori cu cele ale funcției de aproximat $f(x)$ în nodurile rețelei x_i [Hadar2004]:

$$g(x_i) = f(x_i), \quad i = 0, 1, 2, 3, \dots, n \quad (5.3.1)$$

este utilizată *interpolarea polinomială*. O condiție suplimentară pentru unele metode de interpolare polinomială este legată de valorile derivatelor de ordinul I și/sau II ale celor două funcții în nodurile rețelei (de interpolare $g(x)$ și de interpolat $f(x)$). Această condiție se scrie:

$$g'(x_i) = f'(x_i) \text{ și/sau } g''(x_i) = f''(x_i) \quad (5.3.2)$$

Când funcția de interpolat $f(x)$ îndeplinește condițiile lui Dirichlet: este periodică, are un număr finit de puncte de discontinuitate și valori extreme finite se aplică *aproximarea prin dezvoltarea în serii Fourier*, cunoscută și sub numele de *descompunerea în armonice a funcției*. Determinarea coeficienților funcțiilor de aproximare (armonice) se numește analiză armonică.

În cazul în care funcția de interpolat $f(x)$ și funcția de interpolare $g(x)$ nu au aceleași valori în nodurile rețelei se utilizează *aproximarea prin minimizarea abaterii maxime*. Această aproximare prin minimizare se poate face prin:

1. minimizarea abaterii maxime dintre valorile celor două funcții calculată pentru orice punct al intervalului considerat, adică [Hadar2004]:

$$\max |f(x) - g(x)| = \min, \quad \forall x \in [a, b] \quad (5.3.3)$$

2. minimizarea abaterii maxime dintre valorile celor două funcții calculate într-un număr finit de puncte al intervalului considerat, adică:

$$\max |f(x) - g(x)| = \min, \quad i = \overline{0, n} \quad (5.3.4)$$

Când funcția de interpolat $f(x)$ și funcția de interpolare $g(x)$ nu au aceleași valori în nodurile rețelei se utilizează *minimizarea sumei pătratelor abaterilor sau abaterii pătratice medii* dintre valorile celor două funcții, calculate într-un număr finit de puncte din intervalul considerat. Abaterea se calculează conform relației [Hadar 2004]:

$$S = \sum_{i=1}^n [y_i - g(x_i)]^2 = \min, \quad i = \overline{0, n} \quad (5.3.5)$$

În cadrul mediului de programare Matlab este înglobat utilitarul *Curve Fitting Tool*. Acesta permite realizarea de analize de date exploratorii, pre-procesarea și post-procesarea datelor, compararea modelelor candidate și înlăturarea excepțiilor.

Folosind bibliotecile de modele liniare și neliniare de care dispune pot fi implementate regresii sau pot fi specificate propriile ecuații. Biblioteca oferă parametri de rezolvare optimizați și condiții inițiale pentru îmbunătățirea calității *aproximărilor*. Pachetul suportă și tehnici de modelare neparametrice, cum sunt spline, interpolarea și netezirea. Există o serie de funcții de identificare incluse, care sunt grupate după tip: "Sumă de sinusoid", "Polinomiale" etc. Din fiecare grup trebuie aleasă funcția specifică ce se dorește a fi folosită pentru identificare.

Pentru prognoza sarcinii folosind Curve Fitting, se prezintă în continuare, sintetic, algoritmul metodei elaborate, cu observația că o serie de detalii "tehnice" se regăsesc în textul sursă al programului de calcul.

Pentru crearea modelului de aproximare (de potrivire) s-a folosit funcția *fitype* care construiește tipuri de aproximare, specificând numele modelului de bibliotecă. În cadrul apps-ului Curve Fitting Toolbox există 10 tipuri de modele de aproximare, parametrice sau neparametrice. Pentru fiecare tip de model parametric există mai multe forme [Soare2006]:

1. modele de tip exponențial

$$\begin{aligned} &ae^{bx} \\ &ae^{bx} + ce^{dx} \end{aligned} \quad (5.3.6)$$

2. dezvoltări în serie Fourier

$$\begin{aligned} &a_0 + a_1 \cdot \cos wx + b_1 \cdot \sin wx \\ &a_0 + a_1 \cdot \cos wx + b_1 \cdot \sin wx + a_2 \cdot \cos 2wx + b_2 \cdot \sin 2wx \\ &\vdots \\ &a_0 + a_1 \cdot \cos wx + b_1 \cdot \sin wx + \dots + a_8 \cdot \cos 8wx + b_8 \cdot \sin 8wx \end{aligned} \quad (5.3.7)$$

3. sumă de sinusuri

$$\begin{aligned} &a_1 \cdot \sin(b_1 \cdot x + c_1) \\ &a_1 \cdot \sin(b_1 \cdot x + c_1) + a_2 \cdot \sin(b_2 \cdot x + c_2) \\ &\vdots \\ &a_1 \cdot \sin(b_1 \cdot x + c_1) + a_2 \cdot \sin(b_2 \cdot x + c_2) + \dots + a_8 \cdot \sin(b_8 \cdot x + c_8) \end{aligned} \quad (5.3.8)$$

4. Modele gaussiene

$$\begin{aligned} &a_1 \cdot e^{-(x-b_1)^2 / c_1^2} \\ &a_1 \cdot e^{-(x-b_1)^2 / c_1^2} + a_2 \cdot e^{-(x-b_2)^2 / c_2^2} \\ &\vdots \\ &a_1 \cdot e^{-(x-b_1)^2 / c_1^2} + a_2 \cdot e^{-(x-b_2)^2 / c_2^2} + \dots + a_8 \cdot e^{-(x-b_8)^2 / c_8^2} \end{aligned} \quad (5.3.9)$$

5. Modele Weibull

$$a \cdot b \cdot x^{b-1} \cdot e^{-a \cdot x^b} \quad (5.3.10)$$

6. Serii de puteri

$$\begin{aligned} &a \cdot x^b \\ &a \cdot x^b + c \end{aligned} \quad (5.3.11)$$

7. Modele polinomiale

$$\begin{aligned} &p_1 \\ &p_1 \cdot x + p_2 \\ &\vdots \\ &p_1 \cdot x^9 + p_2 \cdot x^8 + \dots + p_{10} \end{aligned} \quad (5.3.12)$$

8. Modele de tip fracție rațională

$$\frac{\sum_{k=1}^{n+1} p_k \cdot x^{n+1-k}}{x^m + \sum_{k=1}^m q_k \cdot x^{n-k}} \quad (5.3.13)$$

Pentru aprecierea adecvanței modelului sunt utilizate diverse criterii [Soare2006]:

- Criteriul suma pătratelor erorilor SSE (Sum of Squares due to Error)

$$SSE = \sum_{k=1}^n w_k \cdot (y_k - \hat{y}_k)^2 \quad (5.3.14)$$

în care: w_k – ponderile (dacă nu sunt impuse se consideră $w_k = 1$, pentru $k = \overline{1, n}$;

y_k – valoarea corespunzătoare pentru x_k ; \hat{y}_k – valoarea aproximată în x_k .

Aproximarea e mai bună pe măsură ce SSE este mai mică.

- Criteriul R-pătrat (R-Square) se definește prin:

$$R - \text{patrat} = \frac{SSE}{SST} \quad (5.3.15)$$

în care:

$$SSR = \sum_{k=1}^n w_k \cdot (\hat{y}_k - \bar{y})^2 \quad (5.3.16)$$

$$SST = \sum_{k=1}^n w_k \cdot (y_k - \bar{y})^2$$

Valoarea criteriului R-pătrat este cuprinsă între 0 și 1. Aproximarea este mai bună cu cât valoarea este mai apropiată de unitate.

Dacă crește numărul parametrilor ce intră în cadrul modelului este posibil să crească și valoarea lui R-pătrat, fără ca aproximarea să se îmbunătățească. În acest caz se folosește criteriul R-pătrat ajustat [Soare2006].

$$\text{Adjusted } R - \text{square} = 1 - \frac{SSE \cdot (n - 1)}{SST \cdot (n - m)} \quad (5.3.17)$$

Valoarea criteriului este subunitară, aproximarea este e mai bună cu cât valoarea este mai apropiată de 1.

- Criteriul RMSE (Root Mean Square Error) este evaluat cu relația [Soare2006]:

$$RMSE = \sqrt{\frac{SSE}{n - m}} \quad (5.3.18)$$

unde $SSE = SST - SSR$.

Aproximarea e mai bună cu cât valoarea este mai apropiată de zero

5.3.2. Prezentarea modelului utilizat

Din cadrul modelelor de bibliotecă Fourier disponibile s-a folosit, *fourier8*. Secvența de cod prin care s-a creat modelul este următoarea:

```
ft_1 = fittype('fourier8');
fit_model_1 = fit(ziua_prec_ora(:,25:end)', sarcina(:,25:end)', ft_1);
1. Pentru a obține o estimare medie autorul a folosit apoi regresia
liniară multiplă, mai precis funcția regress, care aproximează un
set de date cu o funcție de mai multe variabile:
[b,bint,r]=regress(sarcina',[an' luna' ziua' ziuasapt' ora'
ziua_prec_ora' pre24HourAverLoad]);
unde, b stochează vectorul parametrilor modelului, bint stochează
capetele intervalelor de încredere corespunzătoare parametrilor de
regresie și r stochează vectorul reziduurilor.
```


2. Pasul următor, adică validarea modelului se regăsește în următoarea secvență de cod:


```
sarc_medie=( [an' luna' ziua' ziuasapt' ora' ziua_prec_ora'
pre24HourAverLoad']*b)';
FIT_sarc_1=fit_model_1(ziua_prec_ora)';
FIT_sarc=(FIT_sarc_1+ sarc_medie)/2;
```
3. Se calculează MAPE pentru datele de intrare modelate (FIT_sarc);
4. Se reprezintă grafic datele de intrare modelate (FIT_sarc);
5. Se prognozează consumul pentru următoarele 24 de ore, și rezultă variabila FIT_prognoz;
6. Se calculează MAPE pentru prognoza pe ziua următoare;
7. Se reprezintă grafic sarcina prognozată (variabila FIT_prognoz) pentru ziua următoare.

Modelul Curve Fitting este prezentat în Fig. 5.3.1.

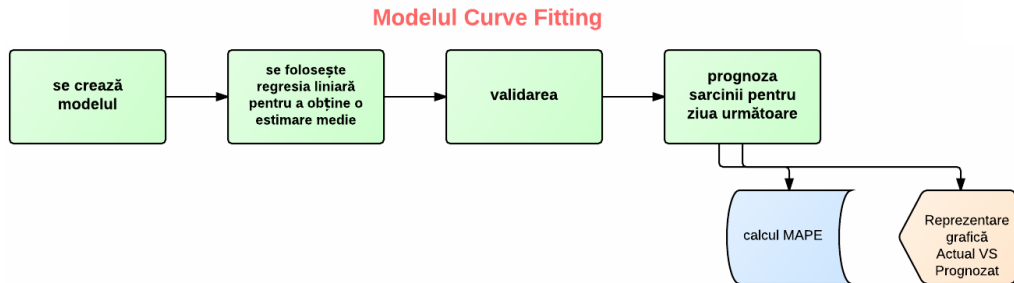


Fig. 5.3.1. Modelul Curve Fitting

5.4. Modelul RNA

5.4.1. Considerații teoretice

Numărul lucrărilor ce tratează metodele de prognoză bazate pe RNA a crescut într-un ritm alert [Gross1987], [Ho1992], [Peng1992], [Riedmiller1993], [Drezga1999], [Hippert2004], [Saksornchai2005], [Espinoza2007]. Aceste studii diferă între ele prin structura rețelelor folosite, numărul de straturi și de neuroni, strategiile de învățare, prin entitatea prognozată (putere orară, putere cerută la vârf de sarcină, energia consumată, curba de sarcină). Numărul de intrări, numărul de straturi ascunse, funcțiile de transfer, sistemele de scalare, și metodele de antrenare afectează performanța prognozei și, prin urmare, trebuie să fie alese cu grijă [Bakirtzis1996].

Antrenarea RNA constă, în esență în determinarea parametrilor de rețea, cum ar fi ponderile, care permit atingerea obiectivului dorit, bazat pe seturile de instruire disponibile. De obicei, rețelele multistrat feed-forward neuronale sunt instruite într-un mod supravegheat. Cel mai cunoscut și utilizat algoritm pentru antrenarea RNA este algoritmul retropropagării erorii (backpropagation), prezentat în paragraful 4.3.7. În principiu, acesta urmărește determinarea pentru fiecare neuron din rețea a valorilor optime ale ponderilor și pragurilor care aproximează cel mai bine soluția exactă pentru o problemă dată. Pentru ameliorarea convergenței și, implicit, reducerea timpului de calcul, se folosesc frecvent procedee de accelerare a convergenței. În toate procedeele de accelerare a convergenței algoritmului de retropropagare se urmărește corectarea ponderilor cu valori mai mari, dacă se constată menținerea tendinței de deplasare pe o pantă descendentă, respectiv micșorarea corecțiilor dacă se constată

depășirea minimului local. Principalul efect al procedurilor de accelerare a convergenței este reducerea timpilor de antrenare.

S-a constatat că reducerea progresivă a ratei de învățare, permite algoritmului de retropropagare determinarea unei soluții mai bune. Cea mai răspândită formă de adaptare a ratei de învățare, cunoscută și sub numele de regula Delta-Bar-Delta, a fost propusă în [Jacobs1988]. Această variantă propune includerea în algoritmul de retropropagare a unei proceduri de adaptare a ratei de învățare în ambele sensuri. Procedura de adaptare are la bază următoarele idei:

- dacă în două iterații succesive derivata $\partial E / \partial w$ își păstrează semnul (eroarea E continuă să scadă), înseamnă că cele două aproximații succesive se află de aceeași parte a punctului de minim local, prin urmare rata de învățare este mărită pentru accelerarea apropierii de minim;
- dacă, între două iterații succesive derivata $\partial E / \partial w$ își schimbă semnul (eroarea E începe să crească), înseamnă că cele două aproximații succesive încadrează minimul local, prin urmare rata de învățare este micșorată pentru revenirea pe partea de pantă descrescătoare. Formal, adaptarea ratei de învățare se face cu relațiile [Gavrilaș2005a]:

$$\begin{aligned}\eta^{t+1} &= \alpha^+ \cdot \eta^t, & \text{dacă} & \left(\frac{\partial E}{\partial w}\right)^{t-1} \cdot \left(\frac{\partial E}{\partial w}\right)^t > 0 \\ \eta^{t+1} &= \alpha^- \cdot \eta^t, & \text{dacă} & \left(\frac{\partial E}{\partial w}\right)^{t-1} \cdot \left(\frac{\partial E}{\partial w}\right)^t < 0 \\ \eta^{t+1} &= \eta^t, & \text{dacă} & \left(\frac{\partial E}{\partial w}\right)^{t-1} \cdot \left(\frac{\partial E}{\partial w}\right)^t = 0\end{aligned}\quad (5.4.1)$$

unde α^+ și α^- sunt coeficienți de adaptare a ratei de învățare. Cei doi coeficienți trebuie să aibă valori supraunitare (α^+) și subunitare.

O altă variantă a acestei metode încearcă să țină seama de forma multidimensională a spațiului în care are loc căutarea soluției și folosește valori distincte pentru ratele de învățare pentru fiecare pondere. Prin intermediul unui coeficient β se recalculează termenul de corecție la pasul t , în funcție de derivata în același pas $(\partial E / \partial w)^t$ și corecția din pasul anterior Δ^{t-1} [Gavrilaș2005a]:

$$\Delta_{ij}^t = \beta \cdot \Delta_{ij}^{(t-1)} + (1 - \beta) \cdot \left(\frac{\partial E}{\partial w_{ij}}\right)^{(t)}, \quad 0 < \beta < 1 \quad (5.4.2)$$

iar adaptarea ratei de învățare η_{ij} asociată ponderii w_{ij} se face conform relațiilor:

$$\begin{aligned}\eta_{ij}^{(t+1)} &= \eta_{ij}^{(t)} + \delta, & \text{dacă} & \Delta_{ij}^{(t-1)} \cdot \left(\frac{\partial E}{\partial w_{ij}}\right)^{(t)} > 0 \\ \eta_{ij}^{(t+1)} &= \eta_{ij}^{(t)} \cdot \theta, & \text{dacă} & \Delta_{ij}^{(t-1)} \cdot \left(\frac{\partial E}{\partial w_{ij}}\right)^{(t)} < 0 \\ \eta_{ij}^{(t+1)} &= \eta_{ij}^{(t)}, & \text{dacă} & \Delta_{ij}^{(t-1)} \cdot \left(\frac{\partial E}{\partial w_{ij}}\right)^{(t)} = 0\end{aligned}\quad (5.4.3)$$

unde δ reprezintă coeficientul de creștere a ratei de învățare ($\delta > 0$); θ este coeficientul de reducere a ratei de învățare ($\theta < 1$); β reprezintă factorul de scară ($\beta < 1$).

În faza inițială a procesului iterativ se recomandă valorile $\delta=0.44$, $\theta = 0.7$ și $\beta = 0.3$, respectiv $\beta = 0.7$ după parcurgerea unui număr dat de cicluri de antrenare. Deși această variantă este mai riguroasă, în sensul că tratează distinct fiecare pondere din rețea, ea are neajunsul unui volum mare de calcule.

Varianta propusă de [Parlos1994] pornește de la următoarele observații: dacă se folosește o rată de învățare constantă η_0 , pe măsura apropierea din minimul local, derivata $\partial E / \partial w$ se apropie de zero, astfel încât în vecinătatea minimului adaptarea ponderilor se face cu pași foarte mici, ceea ce încetinește foarte mult convergența. Pentru a contrabalansa efectul scăderii spre zero a derivatei $\partial E / \partial w$ se propune creșterea ratei de învățare conform unor relații de forma:

$$\begin{aligned}\eta^{(t+1)} &= \frac{\eta_0}{\|\nabla E\|} \\ \eta^{(t+1)} &= \eta_0 \cdot \frac{E^{(t)}}{\|\nabla E\|^2} \\ \eta^{(t+1)} &= \eta_0 \cdot \frac{\tanh(E^{(t)} / E_0)}{\|\nabla E\|^2}\end{aligned}\quad (5.4.4)$$

unde E_0 reprezintă o valoare standardizată a erorii, corespunzătoare de obicei primului ciclu de antrenare. Dezavantajul acestei variante este că în unele situații, în vecinătatea minimului local, comportarea este relativ instabilă, cu variații în limite largi ale erorii.

Din categoria metodelor de proiecție face parte și metoda proiecției erorii propusă de [Kung1991]. La fiecare pas al algoritmului de retropropagare se determină o valoare suboptimală a ratei de învățare, care va fi folosită pentru ajustarea ponderilor după direcția gradientului în iterația următoare. Se consideră dependența funcției eroare:

$$E = \sum_{m=1}^M E^{(m)} = \sum_{m=1}^M \|d^{(m)} - o^{(m)}\|^2 = \sum_{m=1}^M \sum_{k=1}^K (d_k^{(m)} - o_k^{(m)})^2 \quad (5.4.5)$$

de ponderile combinate la iterația t , $z^{(t)} = (w^{(t)}, v^{(t)})$, adică $E = E(z^{(t)})$. Corecția ponderilor în iterația curentă este:

$$\Delta z^{(t)} = z^{(t+1)} - z^{(t)} = \eta \cdot \nabla E(z^{(t)}) \quad (5.4.6)$$

Admițând că, urmare a aplicării acestei corecții, funcția eroare atinge minimul global, anulându-se:

$$E(z^{(t+1)}) = 0 \quad (5.4.7)$$

se folosește dezvoltarea în serii Taylor în jurul punctului $z^{(t)}$ și se rețin numai termenii liniari:

$$E(z^{(t+1)}) \approx E(z^{(t)}) + [\nabla E(z^{(t)})]^T \cdot \Delta z^{(t)} = 0 \quad (5.4.8)$$

unde indicele T indică transpunerea vectorului gradient. Dacă în această relație se înlocuiește expresia corecției (5.4.6) rezultă:

$$E(z^{(t)} - \eta \cdot [\nabla E(z^{(t)})]^T \cdot \nabla E(z^{(t)}) = E(z^{(t)}) - \eta \cdot \|\nabla E(z^{(t)})\|^2 = 0 \quad (5.4.9)$$

de unde se deduce expresia valorii suboptimale a ratei de învățare pentru noua iterație:

$$\eta^{(t-1)} = \eta = E(z^{(t)}) / \|\nabla E(z^{(t)})\|^2 \quad (5.4.10)$$

Pentru a evita salturile exagerate, generate de valori prea mari ale ratei de învățare, [Kung1991] recomandă reducerea valorii suboptimale calculate cu relația (5.4.10), în funcție de numărul de neuroni de ieșire K, conform relației:

$$\eta^{(t-1)} = \eta = \frac{1}{\sqrt{K}} E(z^{(t)}) / \|\nabla E(z^{(t)})\|^2 \quad (5.4.11)$$

Metoda proiecției după cele mai mici pătrate (Least-Squares Projection), consideră dependența față de ponderile cumulate $z^{(t)}$ a ieșirilor fiecărui neuron de pe stratul de ieșire $o_k^{(m)}(z^{(t+1)})$. Funcția eroare la iterația t+1 are expresia:

$$E = \sum_{m=1}^M \sum_{k=1}^K [d_k^{(m)} - o_k^{(m)}(z^{(t+1)})]^2 \quad (5.4.12)$$

Se folosește dezvoltarea în serii Taylor pentru ieșirile rețelei:

$$o_k^{(m)}(z^{(t+1)}) \approx o_k^{(m)}(z^{(t)}) + [\nabla o_k^{(m)}(z^{(t)})]^T \cdot \Delta z^{(t)} \quad (5.4.13)$$

Se folosește regula standard de calcul $\Delta z^{(t)} = -\eta \cdot \nabla E(z^{(t)})$ pentru corecția $\Delta z^{(t)}$ și se face notația:

$$C_k^{(m)} \stackrel{not}{=} [\nabla o_k^{(m)}(z^{(t)})]^T \cdot \nabla E(z^{(t)}) \quad (5.4.14)$$

iar relația (5.4.13) devine:

$$o_k^{(m)}(z^{(t+1)}) \approx o_k^{(m)}(z^{(t)}) - \eta \cdot C_k^{(m)} \quad (5.4.15)$$

Ultima relație înlocuită în (5.4.12), conduce la o nouă expresie a erorii:

$$E = \sum_{m=1}^M \sum_{k=1}^K [d_k^{(m)} - o_k^{(m)}(z^{(t)}) + \eta \cdot C_k^{(m)}]^2 \quad (5.4.16)$$

În urma unor prelucrări simple, se ajunge la valoarea suboptimală a ratei de învățare pentru iterația următoare:

$$\eta^{(t+1)} = \eta = - \frac{\sum_{m=1}^M \sum_{k=1}^K [d_k^{(m)} - o_k^{(m)}(z^{(t)})] \cdot C_k^{(m)}}{\sum_{m=1}^M \sum_{k=1}^K (C_k^{(m)})^2} \quad (5.4.17)$$

În modelarea și identificarea sistemului, este important ca pe baza datelor disponibile să identificăm structura și parametrii sistemului. Identificarea structurii

constă din identificarea variabilelor de intrare ale modelului și a relației intrare-ieșire. Majoritatea abordărilor de modelare consideră variabilele de intrare cunoscute apriori și, prin urmare trebuie să fie găsită doar relația dintre mărimile de intrare și de ieșire. Se pot utiliza 2 tipuri de bază pentru intrări în rețele neuronale:

- intrări booleene (de tipul TRUE/FALSE);
- intrări analogice sunt cele care iau valori continue între o valoare minimă și una maximă. De exemplu, între 0 și 1. Pentru datele de pe intrări de tip analogic, se recomandă ca gama lor de variație să nu fie prea mare (diferența între valoarea maximă așteptată și valoarea minimă așteptată). În acest scop, dacă o intrare analogică are o plajă mare de valori, poate fi eventual înlocuită cu o altă intrare ce folosește diferența între valoarea analogică curentă și cea anterioară. În acest fel, aplicând diferența, gama scade. Atunci când sunt probleme de convergență sau de generalizare, se poate încerca folosirea mai multor rețele neuronale interconectate, în loc de una singură.

5.4.2. Prezentarea modelului utilizat

Etapele principale parcurse în procesul general de proiectare a RNA sunt descrise în Fig. 5.4.1.

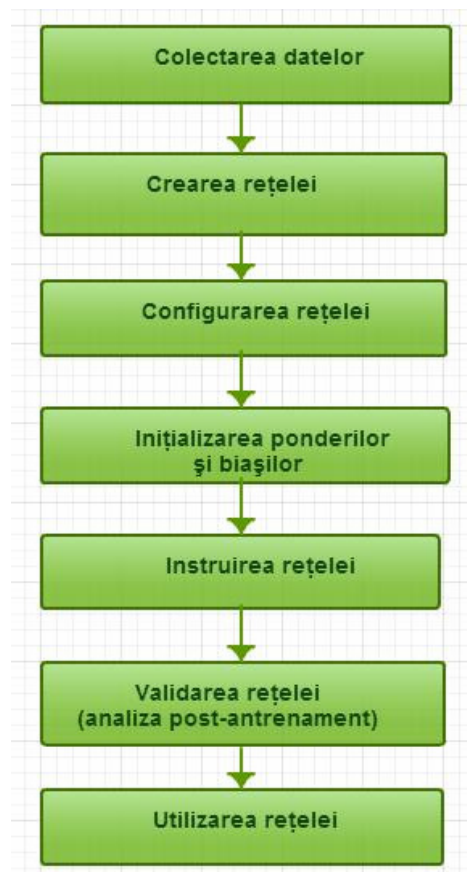


Fig. 5.4.1. Etape în proiectarea RNA

1. Colectarea datelor

Sunt alese variabile de intrare, cum ar fi sarcina, tipul de zi, ora, luna, anul ziua. Datele înregistrate în mod necorespunzător și erorile de observare sunt inevitabile. Prin urmare, datele necorespunzătoare sunt identificate și eliminate sau ajustate cu ajutorul unei metode statistice pentru a evita contaminarea a modelului. Deoarece variabilele au domenii de variație foarte diferite, utilizarea directă a datelor de rețea poate cauza probleme de convergență. Prin urmare se pot utiliza scheme de scalare.

2. Crearea rețelei

Rețeaua este de tipul feed-forward și utilizează algoritmul de învățare prin retropropagare (backpropagation).

3. Configurarea rețelei

Rețeaua este de tip perceptron multistrat cu un singur strat ascuns. Numărul neuronilor din statul de intrare este șase. Mărimile din stratul intrare sunt:

- luna (valori de la 1 la 12);
- ziua (valori de la 1 la 31);
- ora (valori de la 1 la 24);
- ziua din săptămână (valori de la 1 la 7);
- sarcina din săptămâna precedentă la aceeași oră momentului t : $P(t-168)$;
- sarcina din ziua precedentă la aceeași oră t : $P(t-24)$;
- sarcina medie orară din ziua precedentă

Stratul de ieșire conține un singur neuron, a cărui ieșire reprezintă valoarea sarcinii prognozate. În ceea ce privește numărul neuronilor de pe stratul ascuns acesta variază conform unui algoritm prezentat în Anexa 1. Arhitectura rețelei este cea din Fig. 5.4.2. În Fig 5.4.3 sunt prezentate variabilele de intrare.

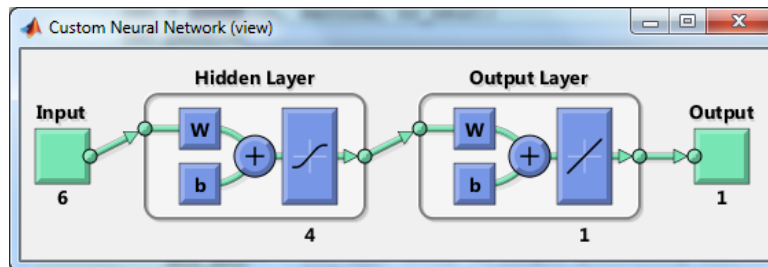


Fig. 5.4.2. Structura rețelei neuronale

Name	Value	Min	Max
luna	1x8760 double	1	12
ora	1x8760 double	1	24
pre24HourAverLoad	1x8760 double	582.54...	2.1986..
sapt_prec_ora	1x8760 double	NaN	NaN
sarcina	1x8760 double	9171	26885
ziua	1x8760 double	1	31
ziua_prec_ora	1x8760 double	NaN	NaN
ziuasapt	1x8760 double	1	7

Fig. 5.4.3. Mărimile din stratul de intrare

4. Inițializarea ponderilor și a biasilor

Ponderile și biasii fiecărui strat sunt inițializate atunci când rețeaua neuronală este configurată.

5. Instruirea rețelei

Pentru a obține rezultate prognozate, cât mai aproape de cele măsurate, în timpul procesului de instruire, ponderile sunt ajustate. Folosind setul de date de antrenare și un algoritmul ales, se stabilesc ponderile conexiunilor dintre neuronii diferitelor straturi.

6. Antrenarea rețelei

Antrenarea unei RNA de tip Perceptron Multistrat, urmărește minimizarea unei funcții de forma:

$$E = \frac{1}{m} \cdot \sum_{p=1}^m \sum_{j=1}^n (t_{pj} - o_{pj})^2 \quad (5.4.18)$$

unde: n – numărul neuronilor din stratul de ieșire; m – numărul modelelor din setul de antrenare; t_{pj} – ieșire dorită la neuronul j al PMS, pentru modelul p de antrenare
 o_{pj} – ieșire curentă la neuronul j al PMS, pentru modelul p de antrenare.

7. Simularea

Folosind rețeaua neuronală antrenată și datele de intrare modelate, este simulată ieșirea prognozată.

Evaluarea performanțelor RNA după antrenare: se folosește un set de date diferit de cel de antrenare și se evaluează precizia rezultatelor furnizate cu o relație de forma:

$$\text{abaterea} \% = \frac{m_{RNA} - m_{calculat}}{m_{calculat}} \cdot 100 \quad (5.4.19)$$

Procesul descris are un caracter iterativ. Este posibil ca o structură stabilită în cadrul etapei de configurare a rețelei să nu permită antrenarea RNA până la o eroare suficient de mică. În această situație, arhitectura trebuie schimbată și rețeaua reantrenată.

8. Utilizarea rețelei

Odată ce procesul este terminat, toate ponderile vor fi reținute și RNA antrenată este pregătită pentru utilizare. Prin introducerea în RNA a unor modele noi, ce nu au fost utilizate în etapa de antrenare, se obțin predicțiile corespunzătoare.

5.5. Concluzii

În cadrul acestui capitol s-au prezentat modelele matematice ale metodelor utilizate efectiv în lucrare pentru prognoza consumului de energie electrică și putere, a curbelor de sarcină. O bună parte dintre ele au fost elaborate pe baza elementelor teoretice prezentate în capitolele anterioare.

Prima parte a capitolului prezintă modelul Regresiei Liniare Multiple (RLM), iar partea a doua descrie modelul Arborilor de Decizie (AD). În partea a treia se tratează modelul de aproximare Curve Fitting (CF), ultima parte a capitolului referindu-se la metodele utilizând Rețele Neuronale Artificiale (RNA).

În continuare se prezintă o sinteză a contribuțiilor personale:

- realizarea unei succinte sinteze teoretice asupra regresiei liniare multiple;
- elaborarea unui model propriu ce aplică regresia liniară multiplă;
- realizarea unei succinte sinteze teoretice referitoare la arborii de decizie;
- elaborarea unui model propriu bazat pe arborii de decizie;
- realizarea unei succinte sinteze teoretice ce prezintă Curve Fitting;
- elaborarea unui model propriu ce folosește aproximarea Curve Fitting
- realizarea unei succinte sinteze teoretice referitoare la RNA;
- elaborarea unui model propriu ce utilizează rețelele neuronale.

6. INSTRUMENTUL SOFT

Capitolul 6, în întregime original, prezintă un instrument software de prognoză a consumului de energie electrică (curbelor de sarcină) și analiză statistică a indicatorilor de performanță. Instrumentul soft, care implementează toate metodele de prognoză prezentate în capitolul 5 (regresie liniară multiplă – RLM, "curve fitting" – CF, arbori de decizie – AD și rețele neuronale de tip perceptron multistrat cu algoritm de învățare de tip backpropagation – RNA), 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 software matematic produs de firma The MathWorks Inc., dedicat calculului numeric și reprezentărilor grafice în știință și inginerie [Matlab].

6.1. Structura instrumentului soft

În capitolul 5, la descrierea modelului matematic, au fost prezentate în detaliu, la finele fiecărui subcapitol, instrumentele utilizate din cadrul bibliotecilor specifice Matlab.

În cadrul acestui capitol se discută structura de ansamblu a instrumentului soft și o serie de elemente de detaliu legate de interfața cu utilizatorul.

Structura generală a instrumentului soft elaborat în cadrul tezei de doctorat este prezentată în Fig. 6.1.1.

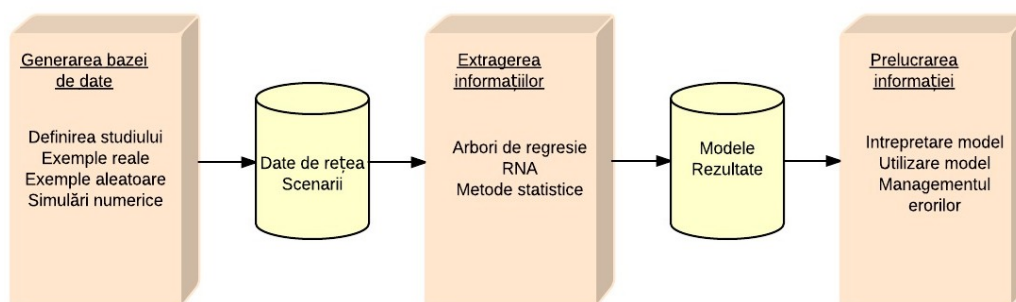


Fig. 6.1.1. Structura sistemului

Instrumentul soft implementează toate metodele de prognoză prezentate în capitolul 5 (regresie liniară multiplă – RLM, "curve fitting" – CF, arbori de decizie – AD și rețele neuronale de tip perceptron multistrat cu algoritm de învățare de tip backpropagation – RNA).

Crearea bazei de date este comună, regulile de introducere a datelor privind istoria consumului fiind simple și clare.

Pentru toate modelele implementate s-a respectat același mod de verificare al rezultatelor (Fig. 6.1.2).

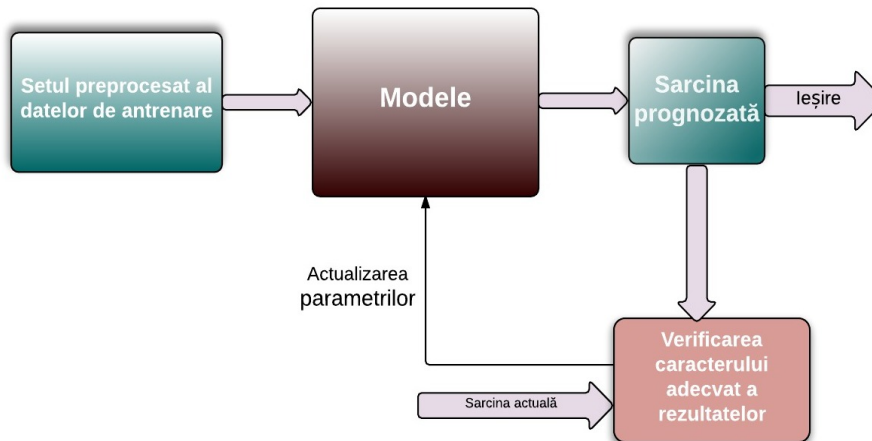


Fig. 6.1.2. Verificarea rezultatelor

6.2. Interfața aplicației

După cum s-a menționat anterior aplicația a fost realizată folosind mediul de programare Matlab – un mediu de dezvoltare propice pentru calcule numerice și analize statistice, având capacități de manipulare a matricelor, de vizualizare a funcțiilor, de implementare a algoritmilor, de creare de interfețe etc. În mod concret s-a folosit GUIDE, un mediu de dezvoltare pentru interfața utilizator grafică MATLAB, care furnizează un set de instrumente pentru crearea interfețelor de tip GUI [Matlab].

La proiectarea interfeței utilizator trebuie asigurat un echilibru între două criterii contradictorii – maximizarea funcționalității aplicației și minimizarea complexității sale.

Pornind de la ideea că activitatea de proiectare a interfeței trebuie să aibă în centrul ei utilizatorul, s-a urmărit respectarea cerințelor recomandate în realizarea unor asemenea interfețe: interfață prietenoasă, intuitivă, ușor de învățat (nefiind nevoie de documentație), extensibilă, dar și consistentă (pentru o anumite operație să se folosească același obiect vizual).

Pentru fiecare obiect al interfeței GUIDE generează de regulă două funcții:

- o funcție pentru inițializarea obiectului, apelată o singură dată de sistemul de operare la crearea obiectului;
- o funcție de tip "callback", apelată de sistemul de operare la fiecare selectare a obiectului, pentru tratarea evenimentelor corespunzătoare obiectului. Fiecare componentă are proprietăți care se specifică în rutinele specifice.

Datele aplicației sunt memorate într-o structură numită handles, care conține variabilele handle ale tuturor obiectelor interfeței și date utilizator. Structura handles este transmisă ca parametru de intrare tuturor funcțiilor callback ale aplicației. Astfel, toate funcțiile callback pot utiliza valorile proprietăților obiectelor grafice și datele aplicației.

În cadrul aplicației (Fig. 6.2.1) preluarea datelor se face din fișiere externe de tip Excel, cu extensia **.xls** (sau **.xlsx**) prin intermediul celor două butoane radio **Incărcare** respectiv **Update**.

Proiectarea modelului de prognoză a consumului se poate face mai bine prin vizualizarea datelor istorice și înțelegerea tendințelor pe care le au acestea și a parametrilor ce pot afecta valorile de la anumite ore. Prin apăsarea butonului **Vizualizare date** se va afișa: variația consumului în decursul unui an, variația sarcinii în decursul unei luni calendaristice (Fig. 6.2.1), variația în decursul unei săptămâni, variația consumului pe 24 de ore (Fig. 6.2.2).

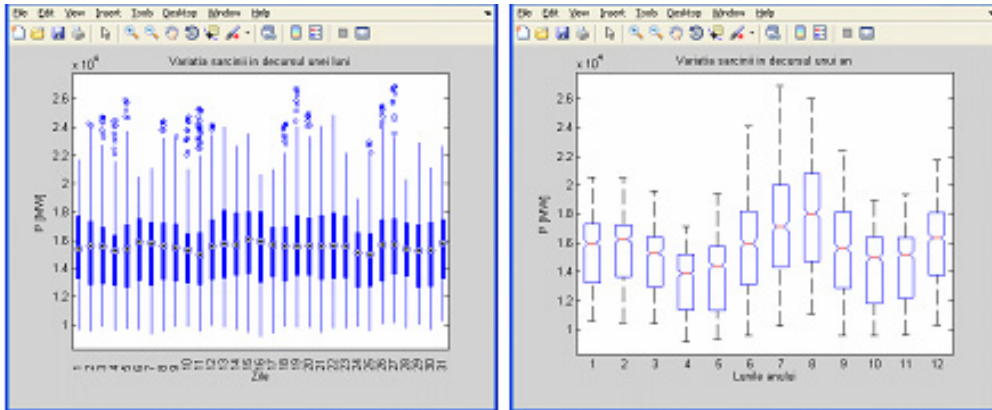


Fig. 6.2.1. Datele încărcate – variația pe durata unui an sau a unei luni

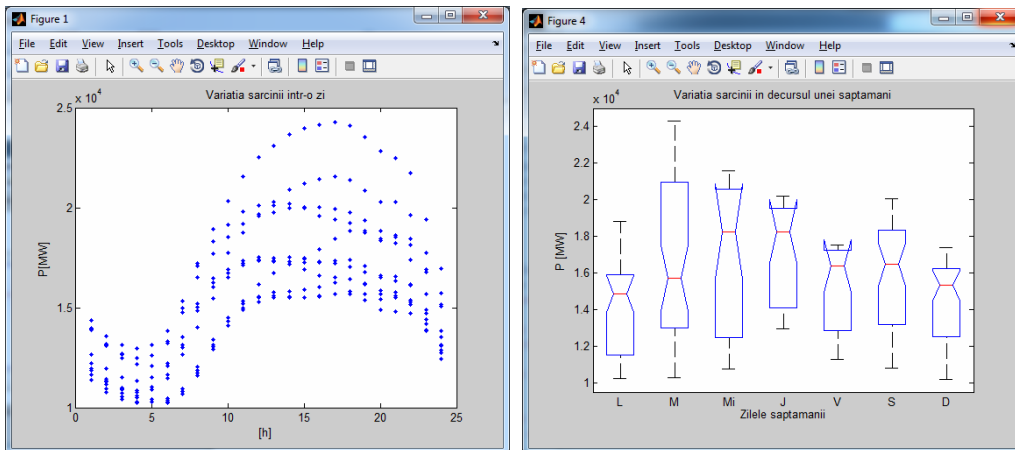


Fig. 6.2.2. Datele încărcate – variația pe durata unei săptămâni sau a unei zile

Pentru alegerea modelului folosit în prognoza sarcinii au fost folosite butoane radio.

Prin alegerea modelului se afișează atât graficele (Consum real versus Consum prognozat) cât și eroarea MAPE (pentru datele de intrare modelate și pentru prognoza pe ziua următoare) (Figura 6.2.3).

În Figura 6.2.4 sunt prezentate rezultatele afișate pentru modelul care utilizează rețele neuronale.

Neural Network Toolbox conține un ansamblu de funcții MATLAB care implementează algoritmi de funcționare și învățare a majorității tipurilor de rețele neuronale. Funcțiile sunt flexibile permițând utilizatorului să specifice arhitectura folosită (inclusiv tipul funcției de activare), să indice modul de conectare între unități și să aleagă între mai multe variante de algoritmi de învățare.

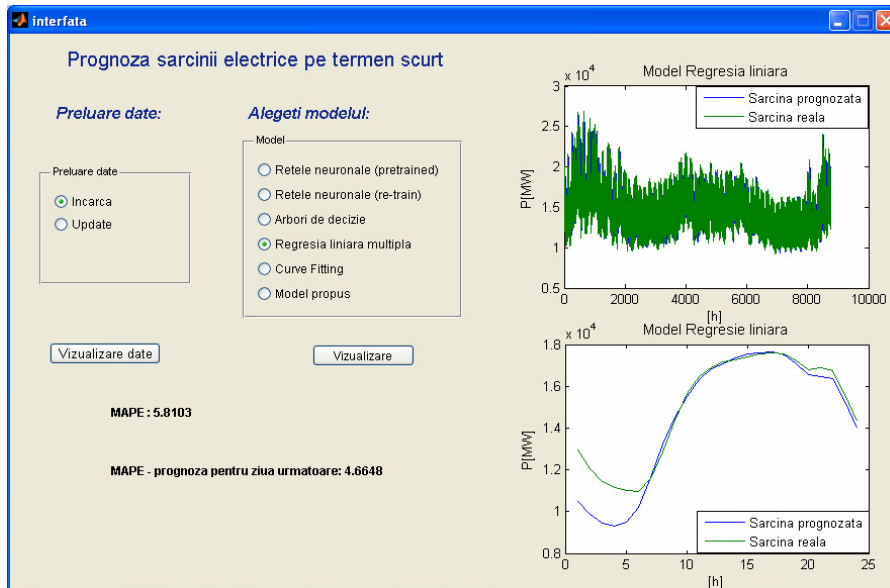


Fig. 6.2.3. Captură din interfața aplicației

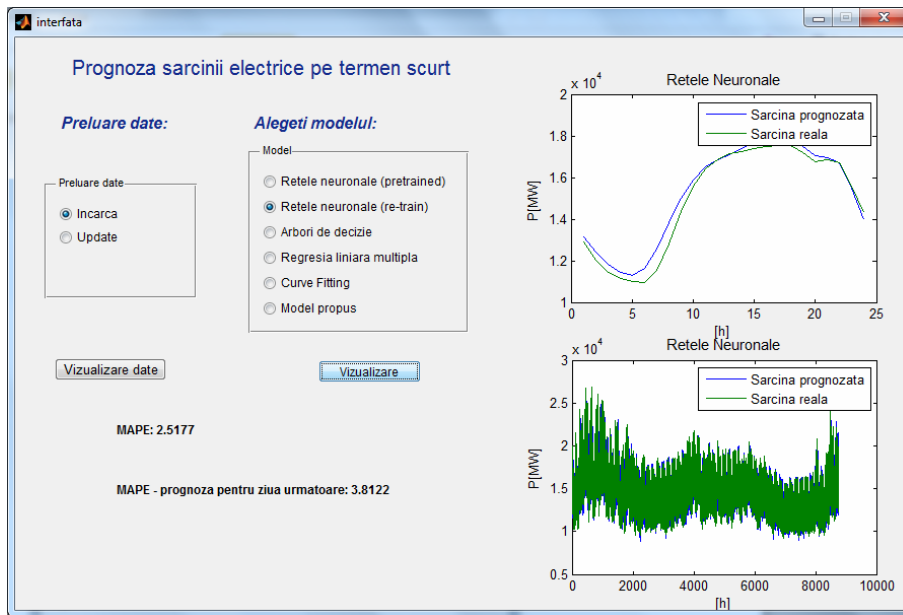


Fig. 6.2.4. Modelul RNA

Pentru modelul RNA parametrii de prognoză ai rețelei utilizați la fiecare antrenare sunt:

- funcția folosită pentru antrenarea rețelei;
- valoarea minimă a gradientului;
- numărul maxim de cicluri de învățare;
- rata de învățare;
- momentum.

La crearea rețelei, toate ponderile conexiunilor și toate polarizările sunt generate aleator în intervalul $[0; 1]$. Astfel, de fiecare dată când se generează rețeaua, rezultă rețele diferite din punctul de vedere al valorilor parametrilor. Prin urmare evoluția pe durata instruirii precum și rețeaua instruită vor fi diferite de la o rulare la alta.

Deoarece RNA are un comportament diferit și poate genera diferite rezultate de fiecare dată când este inițializată rețeaua trebuie să fie reconstruită pentru a genera valoarea minimă pentru MAPE. Acest lucru se face prin încercări până când este atins un rezultat bun pentru eroare; atunci când se instruieste din nou rețeaua prin Reinițializare, codul va asigura să ajungă la rezultatele obținute înainte. Din acest motiv pe interfața aplicației apar două butoane radio, cel de-al doilea fiind pentru Reinițializare.

Figura 6.2.5 prezintă starea procesului de instruire în momentul terminării instruirii într-unul din multiplele cazuri rulate. În cazul prezentat se observă că instruirea s-a oprit la epoca 42, datorită îndeplinirii ultimei condiții de identificarea a apariției fenomenului de suprainstruire – un număr de 6 epoci de instruire succesive fără îmbunătățirea erorii din submulțimea de verificare.

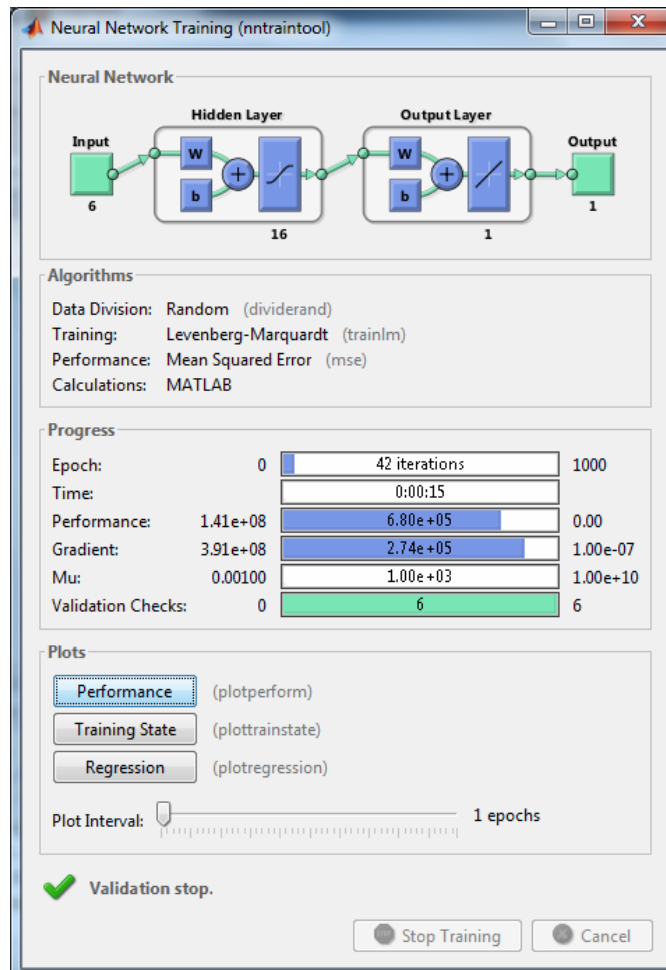


Fig. 6.2.5. Variabilele ce monitorizează procesul de instruire a rețelei neuronale

Rezultatele diferite obținute se datorează în primul rând modului de împărțire a datelor în cele trei submulțimi (instruire, validare, test) care este stabilit prin unul din parametrii algoritmului de instruire, *dividerand* (împărțire aleatoare). Mărimea gradientului (*Gradient*) și numărul controalelor de validare (*Validation Checks*) sunt utilizate pentru a termina instruirea. Pe măsură ce instruirea ajunge la un minim de performanță gradientul va deveni foarte mic. Dacă mărimea gradientului este mai mică de 10^{-7} , instruirea se va opri. Această limită poate fi ajustată prin setarea parametrului gradientul minim de performanță (`net.trainParam.min_grad`).

Numărul *Validation checks* (controale de validare) are valoarea implicită 6 și reprezintă numărul de iterații succesive la care performanța de validare nu reușește să scadă.

Pentru a testa performanța modelului dezvoltat interfața *Neural Network Training Tool* permite afișarea graficului de performanță. Acest grafic reprezintă valoarea indicelui de performanță în funcție de numărul de iterații.

Evoluțiile erorii MSE (care indică performanța de recunoaștere a rețelei) pentru cele trei submulțimi de date este ilustrată în Fig. 6.2.6 Pentru cazul din imagine se constată o scădere accentuată a erorii pe durata primelor 5 epoci de antrenare, urmată de o scădere mai redusă a erorii, iar de la epoca 28 urmează o regiune de platou. RNA instruită finală este considerată rețeaua de la epoca 36, la care valoarea erorii de verificare este cea mai mică și practic se suprapune cu eroarea de test (`best_epoch` indică iterația la care performanța pentru validare a atins un minim).




Fig. 6.2.6. Evoluțiile erorilor mse, pe durata instruirii

Graficul Training State (Fig. 6.2.7) arată evoluția altor variabile de instruire, cum ar fi mărimea gradientului, numărul de verificări de validare etc.

Următorul pas în validarea rețelei este de a crea un grafic de regresie, care arată relația dintre ieșirile rețelei și obiective. Graficul de regresie (Fig. 6.2.8) arată relația între ieșirile rețelei și obiectivele RNA. Dacă $R = 1$, aceasta indică faptul că există o relație liniară exactă între ieșiri și obiective. Primele trei grafice reprezintă datele de instruire, de validare și cele de testare. Pentru acest exemplu, datele de

instruire arată o alegere bună. Validarea și de testarea rezultatelor arată, de asemenea, valori mai mari de 0,9 pentru R, ceea ce indică faptul că există o relație liniară aproape exactă între ieșiri și obiective.




Fig. 6.2.7. Graficul Training State

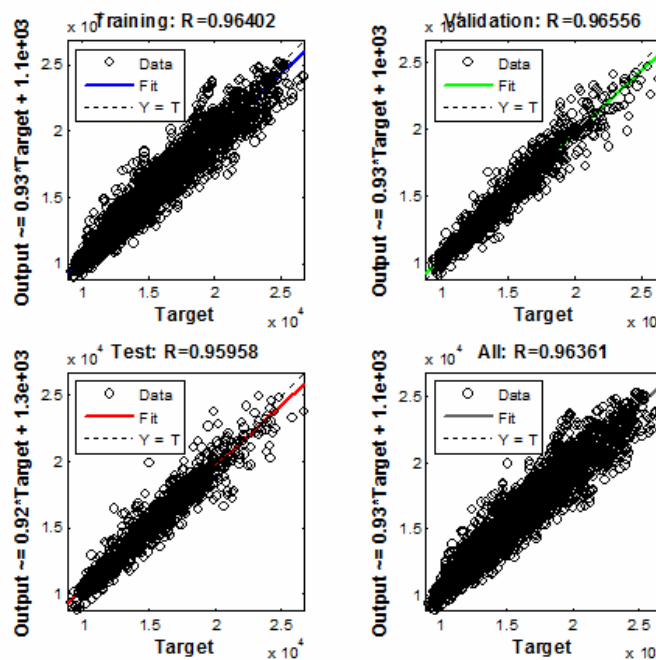


Fig. 6.2.8. Graficul de regresie

6.3. Concluzii

Pentru prognoza consumului de energie electrică și putere, a curbelor de sarcină, există desigur pachete software comerciale. Principalul dezavantaj al acestora este că ele sunt o *cutie neagră*, nu oferă o transparență a modului de modelare, sunt mai greu de modificat.

Modelele dezvoltate în cadrul capitolului precedent au fost integrate într-o aplicație de sine stătătoare, cu interfață grafică pentru utilizator. Această aplicație a fost dezvoltată folosind GUI Toolbox Matlab.

Capitolul 6, în întregime original, prezintă un instrument software de prognoză a consumului de energie electrică (curbelor de sarcină) și analiză statistică a indicatorilor de performanță. Instrumentul soft, care implementează toate metodele de prognoză prezentate în capitolul 5 (regresie liniară multiplă – RLM, "curve fitting" – CF, arbori de decizie – AD și rețele neuronale de tip perceptron multistrat cu algoritmi de învățare de tip backpropagation – RNA), a fost conceput în mediul Matlab. Se utilizează din plin toate facilitățile (de interfață și portabilitate) specifice sistemelor de operare și mediilor informatice actuale, în speță Matlab.

În continuare se prezintă o sinteză a contribuțiilor personale, în contextul în care capitolul este în întregime original, reprezentând suportul soft, partea aplicativă a tezei (capitolul 7):

- implementarea unui algoritm de prognoză ce aplică regresia liniară multiplă, adaptând o funcție care face parte din Statistics Toolbox;
- implementarea unui algoritm ce folosește arborii de decizie pentru prognoza curbelor de sarcină;
- implementarea unui algoritm ce aplică o formă adaptată a funcțiilor disponibile în Curve Fitting;
- implementarea unui algoritm ce folosește RNA, utilizând o variantă adaptată scopului propus a instrumentelor disponibile în Neural Network Toolbox;
- realizarea unui instrument soft pentru prognoza consumului și a curbelor de sarcină, utilizând mediul de programare Matlab, care integrează practic algoritmii enumerați mai sus.

7. STUDII DE CAZ ȘI REZULTATE

Capitolul 7 constituie principala parte aplicativă a lucrării. În acest capitol se prezintă rezultatele obținute privind prognoza curbelor de sarcină utilizând tehnici bazate pe inteligența artificială (IA) – rețele neuronale artificiale (RNA).

Elementele teoretice, metodologiile de calcul elaborate și instrumentele soft dezvoltate, care au constituit obiectul capitolelor anterioare, au fost aplicate și utilizate la obținerea prognozelor menționate pentru o gamă largă de studii de caz.

Analizele efectuate au pornit de la cazuri simple și baze de date test, utilizate pentru validarea metodelor propuse și pentru "calibrarea" instrumentelor soft, ca apoi să se treacă la situații reale, vizând operatori de distribuție din România.

Pentru acest capitol, din motive de spațiu, s-au selectat o serie de studii de caz referitoare la Enel Distribuție Banat. Se menționează că o parte a datelor și rezultatelor sunt prezentate în detaliu în cadrul capitolului, restul doar în sinteză (detaliile fiind regăsite în Anexă, sub formă electronică).

Rezultatele obținute au fost utilizate și în cadrul unor contracte derulate în ultimii 2 ani prin Centrul de Cercetare pentru Analiza și Optimizarea regimurilor SEE din cadrul Universității Politehnica din Timișoara (director prof.dr.ing. Ștefan Kilyeni), beneficiarii fiind operatori de distribuție de România (Enel Distribuție Banat) și o serie de agenți economici cu preocupări domeniul implementării resurselor regenerabile de energie [UPT2014a], [UPT 2014b], [UPT 2014c], [UPT 2014d], [UPT 2014e], [UPT 2014f].

Prima parte a capitolului se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: UTR Timișoara, UTR Arad, UTR Deva și UTR Reșița. Se realizează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie. Datele cunoscute acoperă 10 ani (2001 – 2010), iar verificarea rezultatelor vizează 3 ani (2011-2013).

A doua parte a capitolului se referă tot la ansamblul Enel Distribuție Banat și la principalele UTR menționate mai sus. Se realizează prognoza curbei de sarcină pentru ziua de 1 septembrie (o curbă de sarcină), pe baza celor din perioada 1 ianuarie – 31 august (243 de curbe). Sunt prezentate rezultatele pentru 2 ani – 2012 și 2013.

Prognozele s-au efectuat cu metodele prezentate în capitolele anterioare (rețele neuronale artificiale – RNA, regresie liniară multiplă – RLM, arbori de decizie – AD, "curve fitting" – CF), utilizând instrumentul soft propriu descris în capitolul 6.

La finele fiecărui subcapitol în parte și la sfârșitul capitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau mai general, vizând atât rezultatele concrete ale prognozelor cât și metodele utilizate.

7.1. Prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară

7.1.1. Considerații preliminare

Acest subcapitol se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: UTR Timișoara, UTR Arad, UTR Deva și UTR Reșița.

Se realizează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie. Datele cunoscute acoperă 10 ani (2001 –2010), iar verificarea rezultatelor vizează 3 ani (2011-2013).

Se menționează că s-au considerat de fapt zilele de joi cele mai apropiate de ziua de 21 iunie, cu alte cuvinte în exclusivitate zilele lucrătoare: 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.

Primii 10 ani (dintre cei 13 pentru care se cunosc datele de consum), 2001-2010, s-au utilizat pentru realizare efectivă a prognozei, iar ultimii 3 ani, 2011-2013, pentru verificare prognozelor obținute. Toate datele referitoare la curbele de sarcină au fost obținute de la Enel Distribuție Banat.

Pentru prognoza curbelor de sarcină s-au utilizat atât metoda utilizând RNA cât și o serie de alte metode: regresie liniară multiplă (RLM), "curve fitting" (CF). Metoda bazată pe arbori de decizie (AD) nu a fost luată în considerare din cauza volumului relativ mai redus de date anterioare (10 curbe de sarcină). Ea va fi utilizată în subcapitolul următor, unde datele cunoscute se referă la 243 de zile.

Pe parcursul și la finele subcapitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau mai general, atât legat de rezultatele concrete ale prognozelor cât și de metodele utilizate. O atenție specială se acordă comparării rezultatelor obținute cu diverse metode, aprecierii gradului de corelare a curbelor de sarcină cunoscute și a influenței sale asupra calității prognozelor realizate.

7.1.2. UTR Arad

În tabelul 7.1.1, respectiv Fig. 7.1.1, sunt prezentate curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru efectuarea prognozelor, în scopul obținerii celor pentru anii 2011, 2012, 2013.

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	67.70	72.40	68.70	69.90	65.00	55.30	61.20	63.30	64.80	61.30
2	64.30	68.90	65.50	67.40	61.20	52.30	58.00	59.30	59.90	56.40
3	62.10	66.10	62.80	66.20	58.00	50.10	55.80	56.90	57.60	54.10
4	61.80	64.90	61.90	65.10	57.30	49.00	54.10	55.70	55.80	54.30
5	63.90	68.40	64.50	66.30	59.00	50.90	56.00	58.00	58.10	58.50
6	68.70	74.90	68.90	69.30	63.60	54.60	59.80	61.70	60.30	58.60
7	75.60	81.40	73.60	72.30	65.80	56.40	64.20	63.40	63.60	61.80
8	89.90	97.10	86.40	84.90	80.70	70.60	82.90	79.90	81.30	78.30
9	92.60	101.6	92.60	89.90	86.00	77.60	86.50	85.00	84.80	83.00
10	90.30	99.30	89.30	88.10	88.10	78.60	84.50	85.00	85.40	81.60
11	85.40	95.20	81.60	84.10	84.00	75.30	81.30	80.80	81.10	78.50
12	85.50	95.10	81.40	83.60	85.00	75.90	80.50	80.60	82.30	80.30
13	85.10	94.00	82.80	84.60	84.60	77.80	81.60	83.20	84.90	81.50
14	85.00	93.10	83.40	84.40	84.60	78.20	81.90	84.80	88.00	81.70
15	82.70	91.50	82.40	83.10	79.70	77.20	82.20	82.20	87.30	80.00
16	75.60	84.20	75.70	78.20	73.80	70.80	76.00	77.60	81.90	74.50
17	72.70	81.50	73.30	75.30	72.00	68.60	73.40	74.20	78.10	71.50
18	72.40	80.60	73.20	73.90	70.50	66.50	71.50	70.60	76.60	69.70
19	70.30	80.40	72.20	72.30	67.80	64.80	69.60	69.50	72.10	66.80
20	71.80	81.90	72.20	71.60	67.20	65.00	67.70	68.30	68.50	66.00
21	88.40	95.20	81.90	80.20	73.60	69.10	70.00	69.80	72.80	68.10
22	95.50	101.9	94.20	90.50	89.00	83.60	80.10	79.50	74.60	76.40
23	86.20	91.20	86.70	81.50	84.80	81.40	81.10	81.30	75.40	82.40
24	75.50	79.20	76.40	71.70	73.60	69.50	70.80	70.80	69.00	72.30




Fig. 7.1.1. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.2, respectiv Fig. 7.1.2, sunt prezentate curbele de sarcină pentru o perioadă de 3 ani (2011-2013), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru verificarea rezultatelor prognozelor pentru anii 2011, 2012, 2013.

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	62.60	65.00	71.00	13	84.50	82.30	87.20
2	57.60	59.90	65.20	14	86.80	83.80	87.00
3	56.30	58.50	63.00	15	84.00	84.10	86.60
4	55.40	57.40	61.20	16	78.60	79.90	80.00
5	55.20	58.40	62.20	17	75.90	79.00	79.00
6	58.30	58.20	64.10	18	75.00	74.50	77.40
7	60.60	60.70	67.50	19	71.80	71.70	76.30
8	78.80	78.70	82.20	20	71.40	71.20	74.30
9	84.60	83.00	87.60	21	74.00	72.40	74.40
10	85.50	84.30	87.50	22	87.00	88.10	89.30
11	81.90	80.80	85.00	23	81.00	83.30	84.20
12	83.70	80.90	86.30	24	69.50	75.40	76.10




Fig. 7.1.2. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor prezentate în tablele 7.1.1 și 7.1.2, respectiv figurile 7.1.1 și 7.1.2, evidențiază următoarele concluzii:

- pentru perioada 2001-2010 nu există o tendință clară de creștere sau de scădere a puterii pe ansamblu;
- curbele de sarcină "se intersectează" între ele, cu alte cuvinte forma lor diferă, dar mai puțin decât cele pentru UTR Reșița (paragraful 7.1.4), ceea ce înseamnă o corelare relativ mai bună "pe orizontală";

- pentru perioada 2011-2013 există practic un trend crescător al puterii pe ansamblu (cu mici abateri), ceea ce, corelat cu prima observație, poate conduce la probleme în obținerea prognozelor;
- gradul de corelare a curbilor de sarcină este relativ redus (evoluția în timp și forma pe durata unei zile), dar superior celui de la UTR Reșița (paragraful 7.1.4).

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelele 7.1.3 (anul 2011), 7.1.4 (anul 2012) și 7.1.5 (anul 2013). În partea de jos a tabelelor este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2011, 2012, 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în figurile 7.1.3 (anul 2011), 7.1.4 (anul 2012) și 7.1.5 (anul 2013).

Tabelul 7.1.3. Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	62.6	61.51	-1.75	3.05	54.57	-12.83	164.5	64.49	3.03	9.16
2	57.6	58.49	1.54	2.37	50.79	-11.82	139.7	60.16	4.44	19.72
3	56.3	57.72	2.51	6.32	51.18	-9.10	82.83	58.16	3.31	10.96
4	55.4	57.73	4.21	17.73	51.49	-7.06	49.82	58.43	5.46	29.87
5	55.2	59.36	7.54	56.78	52.78	-4.39	19.25	62.31	12.88	165.8
6	58.3	59.99	2.90	8.39	53.19	-8.76	76.75	62.49	7.18	51.59
7	60.6	63.40	4.62	21.32	57.05	-5.87	34.41	65.47	8.04	64.59
8	78.8	82.76	5.03	25.28	73.04	-7.31	53.46	80.48	2.14	4.56
9	84.6	84.05	-0.66	0.43	77.52	-8.37	70.09	84.85	0.30	0.09
10	85.5	83.76	-2.03	4.13	76.62	-10.38	107.8	83.71	-2.09	4.37
11	81.9	82.53	0.77	0.60	74.48	-9.06	82.07	81.03	-1.06	1.12
12	83.7	83.13	-0.68	0.46	76.32	-8.82	77.78	82.78	-1.10	1.20
13	84.5	83.52	-1.16	1.36	77.82	-7.91	62.57	83.99	-0.60	0.37
14	86.8	83.60	-3.69	13.59	78.44	-9.64	92.83	84.29	-2.89	8.33
15	84.0	83.18	-0.98	0.96	77.37	-7.90	62.35	82.88	-1.33	1.77
16	78.6	79.76	1.48	2.19	73.81	-6.09	37.10	78.03	-0.72	0.52
17	75.9	76.47	0.75	0.56	71.22	-6.17	38.03	75.43	-0.62	0.38
18	75.0	74.39	-0.81	0.66	69.41	-7.45	55.54	73.91	-1.45	2.10
19	71.8	70.36	-2.01	4.03	66.54	-7.32	53.61	71.40	-0.56	0.31
20	71.4	69.39	-2.81	7.92	66.17	-7.32	53.64	70.78	-0.87	0.76
21	74.0	75.17	1.59	2.52	68.62	-7.27	52.82	72.78	-1.65	2.73
22	87.0	83.09	-4.50	20.21	77.46	-10.96	120.2	80.38	-7.60	57.82
23	81.0	83.95	3.65	13.29	82.64	2.03	4.12	85.93	6.08	36.99
24	69.5	75.60	8.78	77.11	74.84	7.69	59.13	76.92	10.68	113.9
		IP_{2011}		291.3	IP_{2011}		1650	IP_{2011}		589.1

Tabelul 7.1.4. Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	65.0	62.36	-4.05	16.44	55.14	-15.17	230.1	63.23	-2.72	7.42
2	59.9	58.70	-2.01	4.03	54.67	-8.73	76.23	58.83	-1.79	3.20
3	58.5	57.94	-0.95	0.90	53.22	-9.03	81.46	57.75	-1.28	1.63
4	57.4	57.47	0.13	0.02	52.40	-8.71	75.88	57.03	-0.64	0.40

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
5	58.4	57.42	-1.67	2.79	52.80	-9.59	91.95	56.95	-2.49	6.20
6	58.2	59.50	2.23	4.97	52.70	-9.45	89.31	59.83	2.80	7.84
7	60.7	61.31	1.00	1.00	54.70	-9.88	97.71	62.00	2.14	4.57
8	78.7	78.94	0.30	0.09	69.18	-12.10	146.5	78.49	-0.26	0.07
9	83.0	83.78	0.94	0.88	74.59	-10.13	102.6	83.85	1.02	1.05
10	84.3	84.49	0.23	0.05	76.14	-9.68	93.74	84.80	0.59	0.35
11	80.8	81.92	1.39	1.93	73.56	-8.96	80.22	81.70	1.11	1.23
12	80.9	83.40	3.09	9.56	75.76	-6.36	40.40	83.45	3.16	9.97
13	82.3	84.06	2.14	4.57	77.16	-6.25	39.02	84.31	2.45	5.98
14	83.8	85.64	2.20	4.84	80.13	-4.38	19.19	86.52	3.25	10.57
15	84.1	83.88	-0.26	0.07	78.05	-7.19	51.75	84.15	0.05	0.00
16	79.9	79.64	-0.33	0.11	74.34	-6.96	48.51	79.42	-0.60	0.36
17	79.0	77.24	-2.22	4.94	72.87	-7.76	60.21	77.12	-2.38	5.68
18	74.5	76.49	2.67	7.13	72.72	-2.40	5.74	76.43	2.59	6.72
19	71.7	73.39	2.36	5.58	70.15	-2.16	4.65	73.67	2.75	7.56
20	71.2	73.11	2.68	7.18	70.29	-1.28	1.63	73.43	3.13	9.81
21	72.4	75.83	4.74	22.50	73.56	1.60	2.56	75.89	4.82	23.24
22	88.1	86.31	-2.03	4.12	85.27	-3.21	10.32	87.72	-0.43	0.18
23	83.3	82.35	-1.14	1.30	80.44	-3.43	11.77	82.46	-1.01	1.01
24	75.4	71.64	-4.98	24.83	70.66	-6.28	39.46	72.24	-4.20	17.61
		IP ₂₀₁₂		129.8	IP ₂₀₁₂		1500	IP ₂₀₁₂		132.7

Tabelul 7.1.5. Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	71.0	68.29	-3.82	14.57	58.06	-18.23	332.2	64.50	-9.15	83.75
2	65.2	63.51	-2.60	6.74	54.80	-15.95	254.4	60.05	-7.91	62.49
3	63.0	62.00	-1.58	2.51	53.22	-15.52	240.9	58.90	-6.51	42.37
4	61.2	61.12	-0.12	0.02	52.20	-14.71	216.3	58.02	-5.20	27.01
5	62.2	62.17	-0.05	0.00	53.40	-14.15	200.2	59.02	-5.11	26.11
6	64.1	62.85	-1.95	3.79	55.82	-12.92	166.9	58.95	-8.04	64.58
7	67.5	65.21	-3.39	11.52	58.25	-13.70	187.8	61.30	-9.19	84.40
8	82.2	82.93	0.88	0.78	67.25	-18.19	330.9	77.56	-5.64	31.86
9	87.6	87.15	-0.52	0.27	71.34	-18.56	344.4	81.56	-6.89	47.51
10	87.5	88.45	1.08	1.18	73.25	-16.29	265.3	82.88	-5.28	27.87
11	85.0	85.30	0.36	0.13	71.12	-16.33	266.8	79.89	-6.01	36.08
12	86.3	85.62	-0.79	0.63	71.94	-16.64	276.9	80.13	-7.15	51.08
13	87.2	86.65	-0.63	0.40	73.79	-15.38	236.5	81.54	-6.50	42.19
14	87.0	87.79	0.90	0.81	75.82	-12.86	165.3	83.03	-4.56	20.79
15	86.6	87.29	0.80	0.64	76.85	-11.25	126.7	83.46	-3.63	13.19
16	80.0	83.18	3.98	15.80	74.21	-7.24	52.36	79.84	-0.20	0.04
17	79.0	82.21	4.06	16.52	74.26	-6.00	36.01	79.18	0.23	0.05
18	77.4	78.34	1.22	1.48	71.28	-7.90	62.45	75.29	-2.73	7.45
19	76.3	75.57	-0.96	0.91	69.18	-9.33	87.04	72.91	-4.44	19.73
20	74.3	75.12	1.11	1.22	69.31	-6.71	45.06	72.59	-2.30	5.28
21	74.4	77.49	4.16	17.30	71.25	-4.24	17.97	73.80	-0.81	0.65
22	89.3	91.78	2.78	7.71	85.83	-3.89	15.13	88.02	-1.43	2.06
23	84.2	88.10	4.64	21.50	81.88	-2.75	7.57	83.87	-0.39	0.15
24	76.1	80.20	5.39	29.02	76.35	0.33	0.11	76.94	1.10	1.21
		IP ₂₀₁₃		155.5	IP ₂₀₁₃		3935	IP ₂₀₁₃		697.9




Fig. 7.1.3. Analiza comparativă a rezultatelor pentru anul 2011




Fig. 7.1.4. Analiza comparativă a rezultatelor pentru anul 2012




Fig. 7.1.5. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.6 s-au reunit indicii de performanță pentru cele 3 metode de prognoză utilizate.

Tabelul 7.1.6. Valoarea comparativă a indicilor de performanță

	RNA	CF	RLM
IP₂₀₁₁	291.3	1650	589.1
IP₂₀₁₂	129.8	1500	132.7
IP₂₀₁₃	155.5	3935	697.9
IP_{total}	576.6	7085	1420

Analiza comparativă a rezultatelor obținute cu cele 3 metode de prognoză utilizate evidențiază următoarele concluzii:

- rezultatele confirmă practic observațiile făcute la analiza curbelor de sarcină pentru perioada 2001-2010, respectiv 2011-2013;
- metodele clasice de prognoză (CF și RLM) sunt inadecvate, așa cum rezultă pe baza valorii indicelui global de performanță (tabelul 7.1.6), cu un plus, totuși, pentru RLM;
- analiza comparativă a valorii indicilor anuali de performanță pentru RNA arată că situația cea mai bună este pentru anul 2012 (129.8) și cea mai proastă pentru 2011 (291.3), cu observația că sunt de același ordin de mărime;
- în tabelul 7.1.7 sunt prezentate comparativ erorile maxime de prognoză, rezultând valori acceptabile pentru RNA (sub 9 %), cele pentru RLM și CF ajungând până la 13 %, respectiv 18 % (confirmându-se practic concluziile anterioare, atât calitativ cât și cantitativ).

Tabelul 7.1.7. Valoarea comparativă a erorilor maxime de prognoză

	RNA	CF	RLM
2011	8.78	12.83	12.88
2012	4.74	15.17	4.82
2013	5.39	18.23	8.19
Maxim	8.78	18.23	12.88

7.1.3. UTR Deva

În tabelul 7.1.8, respectiv Fig. 7.1.6, sunt prezentate curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru efectuarea prognozelor, în scopul obținerii celor pentru anii 2011, 2012, 2013.

Tabelul 7.1.8. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

Anul / ora	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
1	185.6	182.6	179.5	174.2	168.8	167.3	165.7	160.4	159.5	158.6
2	182.6	180.4	178.2	172.7	167.1	168.7	170.3	151.1	153.9	156.8
3	180.5	179.7	178.9	172.4	165.9	171.0	176.1	163.5	171.3	179.0
4	182.9	180.7	178.5	168.6	158.7	160.5	162.4	167.1	170.1	173.2
5	186.6	183.3	180.0	171.8	163.5	171.4	179.3	174.2	168.5	162.7
6	191.2	188.6	185.9	176.3	166.6	171.0	175.5	170.5	157.8	145.1
7	186.8	185.2	183.7	175.8	167.9	166.6	165.2	163.9	156.1	148.3
8	203.2	205.8	208.5	196.3	184.2	179.7	175.3	169.1	162.2	155.3
9	212.1	228.3	244.4	222.2	200.0	188.7	177.3	200.9	195.5	190.1
10	211.8	227.2	242.7	223.2	203.7	197.8	191.8	221.7	203.9	186.1
11	204.6	218.6	232.5	218.3	204.1	194.2	184.3	211.7	207.4	203.0
12	201.5	203.1	204.7	201.3	197.9	183.1	168.2	186.1	185.5	184.9
13	192.7	200.7	208.7	199.1	189.4	176.0	162.6	180.2	175.2	170.1
14	188.6	203.1	217.6	202.7	187.8	182.6	177.4	198.5	180.8	163.1
15	183.9	196.8	209.6	198.8	188.1	175.9	163.6	182.0	178.0	174.0
16	172.4	182.2	192.1	182.9	173.8	175.2	176.7	189.8	174.0	158.2
17	177.1	186.3	195.5	183.1	170.8	171.0	171.2	189.3	177.5	165.8
18	175.0	187.0	199.0	184.4	169.7	174.6	179.5	192.0	176.8	161.6
19	171.3	185.6	199.9	180.7	161.5	164.5	167.6	204.3	184.6	164.8
20	170.4	168.1	165.9	160.1	154.3	153.5	152.8	184.3	173.4	162.6
21	192.4	188.4	184.4	174.6	164.8	151.5	138.3	159.5	166.2	172.9
22	199.9	193.8	187.7	186.8	185.8	166.5	147.3	156.8	169.0	181.1
23	226.3	225.2	224.1	218.3	212.5	201.9	191.3	193.1	192.1	191.1
24	229.6	220.0	210.5	206.4	202.2	194.1	186.0	188.9	184.0	179.1




Fig. 7.1.6. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.9, respectiv Fig. 7.1.7, sunt prezentate curbele de sarcină pentru o perioadă de 3 ani (2011-2013), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru verificarea rezultatelor prognozelor pentru anii 2011, 2012, 2013.

Tabelul 7.1.9. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Anul / Ora	2011	2012	2013	Anul / Ora	2011	2012	2013
1	152.0	144.5	142.8	13	162.0	155.7	158.8
2	150.5	145.6	136.4	14	166.3	158.4	158.5
3	160.4	161.7	150.0	15	164.3	164.7	156.8
4	154.1	149.0	143.9	16	163.5	160.0	156.5
5	154.1	146.1	148.3	17	166.0	169.0	160.1
6	148.5	142.9	140.2	18	166.4	159.6	160.8
7	147.2	148.6	136.7	19	168.1	159.0	161.0
8	154.1	145.0	140.2	20	162.9	159.4	159.0
9	174.7	168.9	163.0	21	150.1	150.0	141.0
10	183.7	179.5	175.2	22	152.7	143.7	143.3
11	194.7	196.3	184.3	23	176.9	177.0	168.2
12	168.7	167.1	160.6	24	170.5	164.6	164.8




Fig. 7.1.7. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor prezentate în tabelele 7.1.8 și 7.1.9, respectiv figurile 7.1.6 și 7.1.7, evidențiază următoarele concluzii:

- pentru perioada 2001-2010 există o tendință destul de clară de scădere a puterii pe ansamblu;
- curbele de sarcină "se intersectează" între ele, cu alte cuvinte forma lor diferă, dar mai puțin decât cele pentru UTR Reșița (paragraful 7.1.4) și cam în aceeași măsură ca la UTR Arad (paragraful 7.1.2), ceea ce înseamnă o corelare relativ mai acceptabilă "pe orizontală";

- pentru perioada 2011-2013 continuă practic trendul descrescător al puterii pe ansamblu, ceea ce, corelat cu prima observație, prefigurează posibilitatea obținerii unor prognoze mai bune decât în cazurile menționate mai sus;
- gradul de corelare a curbelor de sarcină este relativ redus din punctul de vedere al formei pe durata unei zile, dar superior celui de la UTR Reșița (paragraful 7.1.4) și de același ordin de mărime cu UTR Arad (paragraful 7.1.2).

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelele 7.1.10 (anul 2011), 7.1.11 (anul 2012) și 7.1.12 (anul 2013). În partea de jos a tabelelor este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2011, 2012, 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în figurile 7.1.8 (anul 2011), 7.1.9 (anul 2012) și 7.1.10 (anul 2013).

Tabelul 7.1.10. Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	152.0	153.3	0.87	0.75	134.7	-11.42	130.45	138.1	-9.16	83.84
2	150.5	152.4	1.24	1.54	134.6	-10.55	111.21	142.7	-5.18	26.80
3	160.4	163.6	1.99	3.95	152.9	-4.68	21.90	153.0	-4.64	21.56
4	154.1	159.4	3.45	11.89	150.0	-2.63	6.89	149.7	-2.88	8.29
5	154.1	154.1	-0.01	0.00	143.1	-7.16	51.25	142.5	-7.52	56.61
6	148.5	151.1	1.75	3.07	159.4	7.35	53.98	134.3	-9.56	91.32
7	147.2	152.0	3.25	10.55	133.2	-9.51	90.45	135.6	-7.88	62.10
8	154.1	154.0	-0.10	0.01	140.3	-8.97	80.47	146.2	-5.14	26.41
9	174.7	171.2	-1.98	3.92	169.7	-2.83	8.03	169.2	-3.10	9.62
10	183.7	176.7	-3.83	14.64	167.5	-8.81	77.61	167.5	-8.86	78.42
11	194.7	179.5	-7.79	60.73	182.2	-6.40	41.00	182.5	-6.25	39.04
12	168.7	164.3	-2.58	6.68	180.7	7.14	50.96	169.4	0.47	0.22
13	162.0	161.4	-0.38	0.14	158.8	-1.98	3.92	158.9	-1.92	3.70
14	166.3	161.2	-3.05	9.31	153.9	-7.45	55.52	154.6	-7.04	49.56
15	164.3	164.7	0.22	0.05	152.0	-7.49	56.13	164.6	0.17	0.03
16	163.5	161.7	-1.08	1.17	151.5	-7.35	54.00	153.2	-6.33	40.05
17	166.0	164.7	-0.78	0.61	160.1	-3.57	12.76	160.5	-3.32	11.04
18	166.4	165.7	-0.42	0.18	156.7	-5.84	34.12	158.4	-4.82	23.20
19	168.1	168.0	-0.07	0.00	161.3	-4.09	16.70	162.2	-3.55	12.59
20	162.9	163.7	0.47	0.22	168.1	3.17	10.03	161.7	-0.79	0.63
21	150.1	162.3	8.11	65.71	169.1	12.67	160.5	167.2	11.37	129.3
22	152.7	161.3	5.67	32.11	176.5	15.63	244.2	171.4	12.28	150.9
23	176.9	182.8	3.33	11.12	186.8	5.63	31.66	184.6	4.38	19.15
24	170.5	176.2	3.36	11.30	177.1	3.89	15.13	176.2	3.36	11.30
		IP_{2011}		249.7	IP_{2011}		1419	IP_{2011}		955.6

Tabelul 7.1.11. Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	144.5	151.7	5.01	25.12	130.2	-9.93	98.52	130.2	-9.90	97.93
2	145.6	151.3	3.89	15.11	130.1	-10.64	113.3	132.2	-9.23	85.16
3	161.7	154.2	-4.63	21.46	139.0	-14.03	196.9	144.7	-10.51	110.4

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
4	149.0	151.0	1.34	1.80	134.2	-9.96	99.15	139.6	-6.31	39.80
5	146.1	151.8	3.87	14.99	135.2	-7.45	55.48	135.8	-7.05	49.70
6	142.9	149.5	4.60	21.13	132.1	-7.59	57.56	133.6	-6.53	42.61
7	148.6	152.1	2.37	5.60	131.5	-11.55	133.4	136.8	-7.95	63.25
8	145.0	153.2	5.66	32.06	138.3	-4.61	21.22	137.5	-5.20	27.02
9	168.9	171.9	1.81	3.26	154.9	-8.24	67.82	160.7	-4.83	23.30
10	179.5	184.1	2.57	6.60	164.1	-8.56	73.33	166.2	-7.40	54.82
11	196.3	196.4	0.06	0.00	174.6	-11.08	122.8	176.7	-10.00	99.97
12	167.1	164.5	-1.55	2.41	155.7	-6.86	47.04	154.7	-7.42	55.09
13	155.7	161.6	3.75	14.05	151.1	-3.01	9.05	150.8	-3.16	9.98
14	158.4	164.9	4.08	16.65	156.4	-1.28	1.64	155.5	-1.85	3.43
15	164.7	163.0	-0.98	0.96	155.8	-5.37	28.83	155.3	-5.69	32.34
16	160.0	158.0	-1.24	1.55	156.1	-2.44	5.96	156.0	-2.51	6.32
17	169.0	162.0	-4.11	16.92	159.6	-5.55	30.84	159.3	-5.72	32.71
18	159.6	159.9	0.17	0.03	167.2	4.75	22.55	160.9	0.82	0.67
19	159.0	159.9	0.57	0.32	163.3	2.69	7.23	163.7	2.94	8.65
20	159.4	157.9	-0.94	0.89	168.3	5.60	31.40	160.9	0.95	0.91
21	150.0	153.2	2.11	4.44	167.7	11.77	138.5	152.0	1.31	1.72
22	143.7	151.1	5.19	26.90	153.7	7.00	48.97	155.2	8.06	64.95
23	177.0	181.8	2.73	7.45	169.2	-4.39	19.28	175.7	-0.70	0.50
24	164.6	173.4	5.33	28.38	173.1	5.14	26.47	172.1	4.52	20.41
		IP ₂₀₁₂		268.1	IP ₂₀₁₂		1457	IP ₂₀₁₂		931.7

Tabelul 7.1.12. Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	142.8	146.8	2.83	8.01	126.7	-11.25	126.5	129.4	-9.36	87.58
2	136.4	142.3	4.31	18.58	124.8	-8.52	72.55	130.7	-4.19	17.58
3	150.0	152.2	1.45	2.11	133.2	-11.21	125.7	138.5	-7.67	58.79
4	143.9	153.8	6.86	47.06	131.7	-8.48	71.99	135.4	-5.91	34.97
5	148.3	150.5	1.43	2.06	131.8	-11.14	124.3	134.2	-9.53	90.75
6	140.2	148.1	5.63	31.74	132.1	-5.80	33.61	126.8	-9.57	91.60
7	136.7	145.6	6.53	42.69	128.7	-5.83	34.01	132.5	-3.07	9.40
8	140.2	147.1	4.96	24.57	131.8	-5.99	35.90	130.7	-6.80	46.22
9	163.0	169.9	4.21	17.74	157.5	-3.39	11.47	151.0	-7.36	54.20
10	175.2	180.8	3.16	9.98	165.7	-5.46	29.80	160.9	-8.19	67.05
11	184.3	185.4	0.62	0.39	164.2	-10.88	118.4	175.8	-4.56	20.83
12	160.6	165.1	2.79	7.78	149.0	-7.23	52.25	153.7	-4.27	18.25
13	158.8	156.8	-1.25	1.57	148.4	-6.54	42.83	145.8	-8.18	66.90
14	158.5	157.2	-0.83	0.69	152.0	-4.10	16.78	149.1	-5.91	34.96
15	156.8	157.8	0.66	0.44	164.2	4.75	22.59	155.4	-0.88	0.78
16	156.5	151.1	-3.47	12.02	162.4	3.78	14.26	152.8	-2.33	5.41
17	160.1	157.7	-1.47	2.16	164.1	2.51	6.29	161.3	0.76	0.57
18	160.8	155.2	-3.51	12.30	156.6	-2.67	7.11	155.0	-3.62	13.10
19	161.0	154.1	-4.26	18.16	156.6	-2.71	7.35	155.7	-3.26	10.63
20	159.0	153.7	-3.33	11.07	163.4	2.77	7.69	157.2	-1.12	1.24
21	141.0	145.7	3.35	11.24	150.0	6.43	41.40	150.9	7.05	49.67
22	143.3	144.5	0.84	0.70	151.9	6.05	36.62	146.9	2.50	6.26
23	168.2	174.4	3.65	13.29	173.8	3.33	11.12	174.8	3.93	15.45
24	164.8	160.3	-2.70	7.30	176.4	7.05	49.73	166.2	0.87	0.75
		IP ₂₀₁₃		303.7	IP ₂₀₁₃		1100	IP ₂₀₁₃		802.9




Fig. 7.1.8. Analiza comparativă a rezultatelor pentru anul 2011




Fig. 7.1.9. Analiza comparativă a rezultatelor pentru anul 2012

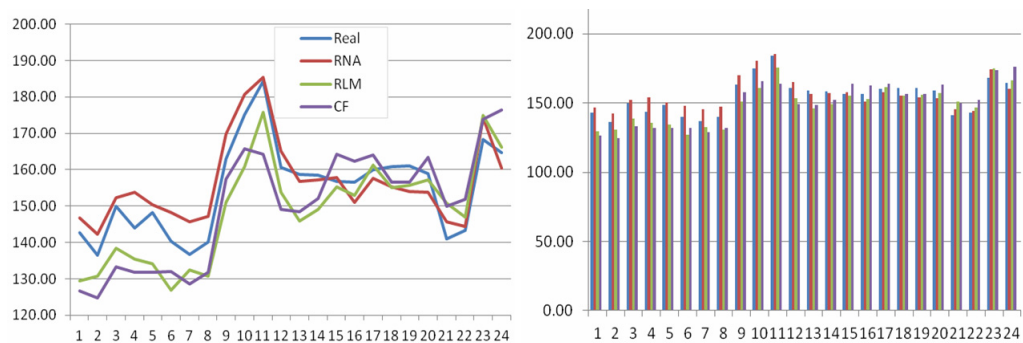


Fig. 7.1.10. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.13 s-au reunit indicii de performanță pentru cele 3 metode de prognoză utilizate.

Tabelul 7.1.13. Valoarea comparativă a indicilor de performanță

	RNA	CF	RLM
IP₂₀₁₁	249.7	1419	955.6
IP₂₀₁₂	268.1	1457	931.7
IP₂₀₁₃	303.7	1100	802.9
IP_{total}	821.5	3976	2690

Analiza comparativă a rezultatelor obținute cu cele 3 metode de prognoză utilizate evidențiază următoarele concluzii:

- rezultatele confirmă practic observațiile făcute la analiza curbelor de sarcină pentru perioada 2001-2010, respectiv 2011-2013;
- metodele clasice de prognoză (CF și RLM) sunt inadecvate, așa cum rezultă pe baza valorii indicelui global de performanță (tabelul 7.1.13), cu un plus, totuși, pentru CF, comparativ cu UTR Arad (paragraful 7.1.2);
- analiza comparativă a valorii indicilor anuali de performanță pentru RNA arată că situația cea mai bună este pentru anul 2011 (249.7) și cea mai proastă pentru 2013 (303.7), cu observația că sunt de același ordin de mărime;
- în tabelul 7.1.14 sunt prezentate comparativ erorile maxime de prognoză, rezultând valori acceptabile pentru RNA (sub 8.2 %), cele pentru RLM și CF ajungând până la 15.6 %, respectiv 12.3 % (confirmându-se concluziile anterioare).

Tabelul 7.1.14. Valoarea comparativă a erorilor maxime de prognoză

	RNA	CF	RLM
2011	8.11	15.63	12.28
2012	5.66	14.03	10.51
2013	6.86	11.25	9.57
Maxim	8.11	15.63	12.28

7.1.4. UTR Reșița

În tabelul 7.1.15, respectiv Fig. 7.1.11, sunt prezentate curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru efectuarea prognozelor, în scopul obținerii celor pentru anii 2011, 2012, 2013.

Tabelul 7.1.15. 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




Fig. 7.1.11. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.16, respectiv Fig. 7.1.12, sunt prezentate curbele de sarcină pentru o perioadă de 3 ani (2011-2013), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru verificarea rezultatelor prognozelor pentru anii 2011, 2012, 2013.

Tabelul 7.1.16. 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




Fig. 7.1.12. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor prezentate în tablele 7.1.15 și 7.1.16, respectiv figurile 7.1.11 și 7.1.12, evidențiază următoarele concluzii:

- pentru perioada 2001-2010 nu există o tendință clară de creștere sau de scădere a puterii pe ansamblu;
- curbele de sarcină "se intersectează" între ele, cu alte cuvinte forma lor diferă;
- observațiile anterioare sunt valabile și pentru anii 2011-2013;
- curba de sarcină pentru anul 2003 are o formă cu totul aparte între orele 7 și 12, când, probabil, un mare consumator nu a fost 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, element care prefigurează mari dificultăți pentru elaborarea prognozelor.

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelele 7.1.17 (anul 2011), 7.1.18 (anul 2012) și 7.1.19 (anul 2013). În partea de jos a tabelelor este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2011, 2012, 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în figurile 7.1.13 (anul 2011), 7.1.14 (anul 2012) și 7.1.15 (anul 2013).

Tabelul 7.1.17. Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	59.40	58.65	-1.26	1.59	61.59	3.69	13.63	60.80	2.36	5.55
2	57.70	57.65	-0.09	0.01	64.26	11.37	129.4	60.60	5.03	25.26
3	57.90	57.65	-0.43	0.19	64.84	11.99	143.8	61.40	6.04	36.54
4	57.60	57.65	0.09	0.01	65.41	13.56	183.9	62.20	7.99	63.78
5	60.40	59.02	-2.28	5.22	65.79	8.93	79.69	63.40	4.97	24.67
6	53.60	56.92	6.19	38.37	65.51	22.22	493.8	62.55	16.70	278.8
7	53.30	56.14	5.33	28.39	64.89	21.75	473.0	61.92	16.17	261.6
8	60.10	57.65	-4.08	16.65	66.15	10.07	101.3	62.40	3.83	14.65
9	59.20	57.65	-2.62	6.87	66.28	11.95	142.8	62.90	6.25	39.06
10	62.50	59.43	-4.91	24.13	67.77	8.43	71.07	64.20	2.72	7.40
11	62.50	60.22	-3.65	13.31	67.87	8.60	73.87	65.70	5.12	26.21
12	62.20	57.65	-7.32	53.52	68.78	10.58	111.9	65.32	5.02	25.16
13	59.50	57.82	-2.82	7.97	69.91	17.49	305.8	64.41	8.25	68.10
14	58.60	58.32	-0.48	0.23	70.77	20.77	431.3	64.20	9.56	91.32
15	60.50	57.65	-4.71	22.19	68.40	13.06	170.6	64.87	7.22	52.17
16	53.80	56.30	4.65	21.59	68.41	27.16	737.7	63.90	18.77	352.4
17	59.40	57.92	-2.49	6.21	68.11	14.67	215.3	63.22	6.43	41.36
18	59.80	57.65	-3.59	12.92	70.19	17.37	301.8	64.57	7.98	63.63
19	55.30	55.22	-0.14	0.02	70.48	27.45	753.7	64.20	16.09	259.0
20	49.30	53.27	8.05	64.85	70.25	42.50	1806	64.15	30.12	907.3
21	50.20	56.14	11.83	140.0	72.92	45.26	2048	64.80	29.08	845.9
22	58.10	57.65	-0.78	0.60	73.78	26.99	728.2	65.22	12.25	150.2
23	64.60	58.35	-9.67	93.60	72.24	11.83	140.0	66.40	2.79	7.76
24	64.10	57.65	-10.06	101.2	74.60	16.38	268.3	66.70	4.06	16.45
			IP_{2011}		IP_{2011}		9925	IP_{2011}		3664

Tabelul 7.1.18. Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	56.80	55.89	-1.60	2.55	58.85	3.61	13.02	58.20	2.46	6.08
2	55.60	56.02	0.75	0.56	59.82	7.58	57.49	58.74	5.65	31.89
3	56.80	55.84	-1.69	2.86	60.26	6.10	37.16	59.10	4.05	16.40
4	55.30	56.06	1.37	1.87	60.99	10.29	105.9	59.84	8.21	67.40
5	58.60	56.16	-4.16	17.33	61.48	4.92	24.16	60.28	2.87	8.22
6	52.00	55.73	7.18	51.56	64.16	23.38	546.5	59.80	15.00	225.0

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
7	49.90	55.09	10.40	108.1	64.58	29.42	865.6	58.90	18.04	325.3
8	55.10	57.05	3.53	12.46	62.94	14.24	202.6	60.10	9.07	82.34
9	57.90	57.03	-1.49	2.23	63.27	9.28	86.07	60.42	4.35	18.94
10	60.70	57.08	-5.96	35.49	65.90	8.56	73.32	62.50	2.97	8.79
11	61.10	57.27	-6.27	39.35	66.50	8.83	77.99	62.90	2.95	8.68
12	60.90	57.42	-5.71	32.58	66.85	9.77	95.41	63.10	3.61	13.05
13	60.10	57.46	-4.39	19.29	65.68	9.28	86.08	63.70	5.99	35.88
14	62.40	56.25	-9.85	97.08	66.25	6.17	38.12	63.90	2.40	5.78
15	58.30	57.34	-1.64	2.70	67.24	15.34	235.3	62.80	7.72	59.58
16	54.70	56.46	3.21	10.32	69.90	27.78	771.7	62.70	14.63	213.9
17	60.60	57.02	-5.91	34.95	67.90	12.05	145.1	63.90	5.45	29.65
18	58.40	56.99	-2.41	5.79	68.58	17.42	303.6	63.80	9.25	85.50
19	54.40	54.65	0.45	0.20	71.18	30.85	951.8	63.20	16.18	261.7
20	48.30	49.73	2.96	8.76	68.37	41.56	1727	63.10	30.64	938.9
21	51.40	49.00	-4.68	21.89	69.58	35.38	1251	63.02	22.61	511.1
22	56.90	55.10	-3.17	10.03	70.75	24.35	592.7	63.90	12.30	151.4
23	65.80	57.41	-12.75	162.5	74.24	12.83	164.5	68.60	4.26	18.11
24	62.80	55.77	-11.19	125.2	74.73	19.00	360.8	68.10	8.44	71.22
		IP ₂₀₁₂		805.6	IP ₂₀₁₂		8814	IP ₂₀₁₂		3194

Tabelul 7.1.19. Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	54.20	56.10	3.50	12.25	59.61	9.98	99.56	58.62	8.15	66.50
2	54.90	57.09	4.00	15.97	60.75	10.66	113.7	59.10	7.65	58.53
3	56.10	57.35	2.24	5.00	60.68	8.17	66.71	59.50	6.06	36.73
4	56.10	56.85	1.33	1.77	61.93	10.40	108.2	59.77	6.54	42.80
5	57.80	57.06	-1.27	1.62	61.03	5.59	31.20	60.25	4.24	17.97
6	53.20	56.68	6.53	42.67	61.93	16.41	269.1	60.01	12.80	163.9
7	53.20	56.35	5.92	35.03	60.69	14.08	198.3	58.00	9.02	81.41
8	53.40	56.75	6.27	39.33	64.06	19.97	398.7	58.27	9.12	83.17
9	56.20	57.86	2.95	8.68	63.29	12.61	159.1	59.64	6.12	37.47
10	57.20	57.82	1.09	1.18	64.16	12.17	148.1	60.89	6.45	41.62
11	61.80	57.92	-6.28	39.49	65.00	5.17	26.75	64.20	3.88	15.08
12	61.80	57.61	-6.77	45.87	65.44	5.89	34.69	64.12	3.75	14.09
13	58.10	57.51	-1.01	1.02	65.58	12.88	165.8	64.02	10.19	103.8
14	57.80	57.44	-0.63	0.40	67.70	17.13	293.4	62.94	8.89	79.08
15	55.20	57.54	4.24	17.98	66.60	20.65	426.5	62.12	12.54	157.2
16	57.30	57.17	-0.23	0.05	68.65	19.81	392.4	62.98	9.91	98.26
17	62.60	57.07	-8.84	78.16	68.07	8.74	76.33	64.50	3.04	9.21
18	57.60	55.99	-2.80	7.85	68.23	18.45	340.5	64.60	12.15	147.7
19	51.90	55.12	6.21	38.55	70.32	35.48	1259	63.40	22.16	490.9
20	47.10	53.64	13.89	192.8	67.61	43.55	1896	62.80	33.33	1111
21	54.10	55.46	2.51	6.32	69.54	28.53	814.2	62.94	16.34	267.0
22	53.60	56.73	5.85	34.19	70.91	32.29	1042	64.50	20.34	413.6
23	66.10	57.59	-12.88	165.8	73.79	11.64	135.4	67.60	2.27	5.15
24	60.40	57.67	-4.52	20.47	73.44	21.59	466.0	67.30	11.42	130.5
		IP ₂₀₁₃		812.5	IP ₂₀₁₃		8963	IP ₂₀₁₃		3672




Fig. 7.1.13. Analiza comparativă a rezultatelor pentru anul 2011




Fig. 7.1.14. Analiza comparativă a rezultatelor pentru anul 2012




Fig. 7.1.15. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.20 s-au reunit indicii de performanță pentru cele 3 metode de prognoză utilizate.

Tabelul 7.1.20. Valoarea comparativă a indicilor de performanță

	RNA	CF	RLM
IP₂₀₁₁	659.6	9925	3664
IP₂₀₁₂	805.6	8814	3194
IP₂₀₁₃	812.5	8963	3672
IP_{total}	2278	27702	10530

Analiza comparativă a rezultatelor obținute cu cele 3 metode de prognoză utilizate evidențiază următoarele concluzii:

- rezultatele confirmă practic observațiile făcute la analiza curbelor de sarcină pentru perioada 2001-2010, respectiv 2011-2013, calitatea prognozelor fiind mult mai proastă decât la celelalte UTR (concluzie valabilă, relativ, pentru toate metodele);
- metodele clasice de prognoză (CF și RLM) sunt inadecvate, așa cum rezultă pe baza valorii indicelui global de performanță (tabelul 7.1.20), cu un plus, totuși, pentru RLM;
- analiza comparativă a valorii indicilor anuali de performanță pentru RNA arată că situația cea mai bună este pentru anul 2011 (659.6) și cea mai proastă pentru 2013 (812.5), cu observația că sunt de același ordin de mărime (dar cele mai proaste valori comparativ cu celelalte UTR);
- în tabelul 7.1.21 sunt prezentate comparativ erorile maxime de prognoză, rezultând valori slabe și pentru RNA (sub 14 %), cele pentru RLM și CF ajungând până la 33 %, respectiv 45 % (confirmându-se concluziile anterioare – situația cea mai proastă comparativ cu UTR, datorită unei evoluții "bizare" a consumului).

Tabelul 7.1.21. Valoarea comparativă a erorilor maxime de prognoză

	RNA	CF	RLM
2011	11.83	45.26	30.12
2012	12.75	41.56	30.64
2013	13.89	43.55	33.33
Maxim	14.91	45.26	33.33

7.1.5. UTR Timișoara

În tabelul 7.1.22, respectiv Fig. 7.1.16, sunt prezentate curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru efectuarea prognozelor, în scopul obținerii celor pentru anii 2011, 2012, 2013.

Tabelul 7.1.22. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

Anul / ora	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
1	122.0	134.0	127.2	114.9	116.0	113.1	110.9	108.9	117.0	112.6
2	113.6	126.9	119.5	107.7	108.7	106.2	102.6	100.6	107.5	104.8
3	111.4	123.5	116.2	104.8	105.2	102.7	100.9	99.20	102.4	100.6
4	111.9	121.8	115.4	104.3	103.3	101.0	98.0	99.70	100.2	102.6
5	113.6	123.0	115.6	106.5	104.8	102.1	99.4	99.00	101.5	102.2
6	120.8	131.4	122.5	113.5	109.5	106.0	103.9	103.6	104.6	102.6
7	139.3	151.4	138.7	127.2	119.9	117.4	115.3	114.6	115.0	116.0
8	160.2	172.7	156.5	143.3	137.0	135.8	134.4	135.2	134.7	135.7
9	162.8	177.0	161.7	150.1	147.0	146.0	144.9	143.1	144.0	144.5
10	161.6	166.0	160.5	148.5	148.6	147.5	146.5	142.6	145.1	145.3
11	154.6	161.1	153.4	143.4	147.5	144.2	143.9	141.1	143.7	143.3
12	152.5	160.4	152.4	145.9	147.3	146.0	145.1	143.5	146.2	146.4
13	148.3	156.3	149.2	143.5	145.1	144.2	143.8	142.6	146.2	145.4
14	148.0	155.6	148.1	144.3	143.4	143.0	143.0	143.6	145.1	146.9
15	146.8	151.2	145.6	141.1	138.9	140.0	141.9	141.3	144.1	143.1
16	135.5	148.6	136.4	131.1	129.2	132.2	135.3	134.2	137.0	135.4
17	128.9	147.8	133.1	126.5	123.5	126.9	131.3	127.4	132.3	129.7
18	127.7	147.4	128.9	123.6	122.4	124.6	127.8	125.7	129.3	126.7
19	126.4	148.7	127.2	122.3	120.1	122.4	125.3	121.4	126.7	124.7
20	133.3	156.2	131.3	125.4	119.8	121.1	123.3	120.6	125.0	122.7
21	158.4	174.4	148.2	140.8	131.0	129.2	128.3	125.5	133.0	127.3
22	170.8	185.7	168.7	160.2	152.8	150.0	148.2	141.0	142.3	139.7
23	157.7	169.1	156.9	150.0	147.9	147.7	147.8	143.6	139.9	149.3
24	142.5	151.4	141.9	134.8	130.6	130.4	130.2	127.2	126.0	131.0




Fig. 7.1.16. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.23, respectiv Fig. 7.1.17, sunt prezentate curbele de sarcină pentru o perioadă de 3 ani (2011-2013), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru verificarea rezultatelor prognozelor pentru anii 2011, 2012, 2013.

Tabelul 7.1.23. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Anul / Ora	2011	2012	2013	Anul / Ora	2011	2012	2013
1	115.4	118.5	116.2	13	143.0	144.2	146.6
2	108.9	109.2	108.1	14	148.1	150.3	147.2
3	102.8	103.9	104.8	15	144.2	143.5	142.8
4	103.7	103.2	102.1	16	137.4	136.5	136.2
5	100.9	104.3	104.2	17	136.2	131.6	132.1
6	107.8	105.0	106.8	18	126.0	125.5	127.2
7	120.9	122.1	122.7	19	124.7	124.5	126.7
8	137.4	142.6	146.9	20	124.7	123.3	125.2
9	145.6	141.2	143.1	21	136.6	137.8	136.5
10	151.1	148.4	151.3	22	152.2	151.1	150.2
11	151.2	148.0	150.8	23	150.1	148.5	149.0
12	146.0	145.0	144.0	24	134.5	133.6	133.3




Fig. 7.1.17. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor prezentate în tabelele 7.1.22 și 7.1.23, respectiv figurile 7.1.16 și 7.1.17, evidențiază următoarele concluzii:

- pentru perioada 2001-2010 există o tendință destul de neclară de evoluție a consumului pe ansamblu (alternarea unor perioade de creștere, respectiv de scădere, într-o plajă relativ îngustă de valori);
- curbele de sarcină nu "se intersectează" prea mult între ele, cu alte cuvinte forma lor este destul de asemănătoare, ceea ce înseamnă o corelare relativ mai bună "pe orizontală";
- pentru perioada 2011-2013 continuă practic trendul destul de neclar, la fel ca și pentru perioada 2001-2010, dar din nou cu o formă destul de asemănătoare

(între ele, respectiv cu cea din perioada 2001-2010), comparativ cu celelalte UTR situația fiind cea mai bună din acest punct de vedere;

- în concluzie, gradul de corelare a curbelor de sarcină este relativ bun din punctul de vedere al formei pe durata unei zile, superior celui de la UTR Reșița, UTR Arad și UTR Deva, ceea ce prefigurează posibilitatea obținerii unor prognoze mai bune, mai ales cu metodele utilizând RNA.

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelele 7.1.24 (anul 2011), 7.1.25 (anul 2012) și 7.1.26 (anul 2013). În partea de jos a tabelelor este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2011, 2012, 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în figurile 7.1.18 (anul 2011), 7.1.19 (anul 2012) și 7.1.20 (anul 2013).

Tabelul 7.1.24. Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	115.4	112.8	-2.28	5.19	108.5	-6.02	36.27	118.5	2.68	7.20
2	108.9	107.2	-1.56	2.44	101.2	-7.07	49.99	111.3	2.18	4.77
3	102.8	104.7	1.90	3.59	100.4	-2.32	5.36	107.4	4.48	20.11
4	103.7	106.1	2.31	5.35	100.0	-3.56	12.66	109.3	5.41	29.28
5	100.9	106.1	5.11	26.10	98.6	-2.31	5.33	109.0	8.01	64.11
6	107.8	106.7	-1.02	1.05	99.2	-7.96	63.35	109.4	1.48	2.18
7	120.9	117.6	-2.74	7.50	102.7	-15.05	226.6	121.9	0.83	0.69
8	137.4	137.8	0.31	0.09	119.2	-13.28	176.4	140.3	2.10	4.42
9	145.6	147.0	0.94	0.88	128.8	-11.51	132.6	148.5	2.01	4.05
10	151.1	148.0	-2.08	4.34	132.7	-12.18	148.3	149.3	-1.17	1.37
11	151.2	146.1	-3.39	11.50	133.8	-11.51	132.4	147.5	-2.43	5.90
12	146.0	149.2	2.19	4.78	135.2	-7.40	54.72	150.5	3.06	9.37
13	143.0	148.4	3.80	14.46	133.7	-6.48	42.03	149.6	4.61	21.27
14	148.1	150.0	1.31	1.70	137.2	-7.36	54.17	151.0	1.99	3.96
15	144.2	146.7	1.76	3.10	134.7	-6.56	42.98	147.6	2.34	5.46
16	137.4	139.1	1.26	1.59	127.7	-7.07	49.95	140.5	2.22	4.95
17	136.2	133.5	-1.95	3.79	123.7	-9.16	83.85	135.2	-0.73	0.54
18	126.0	130.6	3.69	13.59	122.4	-2.86	8.20	132.5	5.13	26.30
19	124.7	128.9	3.35	11.24	121.3	-2.71	7.32	130.6	4.77	22.76
20	124.7	127.4	2.17	4.69	119.8	-3.92	15.39	128.8	3.32	11.00
21	136.6	133.1	-2.55	6.51	125.8	-7.88	62.13	133.2	-2.51	6.32
22	152.2	146.6	-3.65	13.33	138.8	-8.84	78.09	144.8	-4.89	23.91
23	150.1	154.9	3.16	10.02	145.9	-2.77	7.66	153.7	2.43	5.91
24	134.5	137.5	2.25	5.05	131.8	-2.00	4.00	136.8	1.69	2.85
		IP_{2011}		161.9	IP_{2011}		1499	IP_{2011}		288.7

Tabelul 7.1.25. Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	118.5	115.2	-2.82	7.97	112.5	-5.06	25.64	117.5	-0.85	0.73
2	109.2	109.8	0.54	0.29	107.2	-1.81	3.29	111.5	2.15	4.63
3	103.9	104.6	0.68	0.46	99.3	-4.43	19.60	106.0	2.00	3.99

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
4	103.2	105.6	2.36	5.59	93.5	-9.40	88.35	106.8	3.56	12.69
5	104.3	103.1	-1.10	1.22	99.4	-4.70	22.07	107.4	2.97	8.83
6	105.0	109.1	3.91	15.33	99.8	-4.93	24.34	112.2	6.89	47.41
7	122.1	120.7	-1.18	1.39	101.3	-17.04	290.2	126.3	3.46	11.95
8	142.6	135.7	-4.87	23.74	111.9	-21.50	462.1	138.3	-2.99	8.93
9	141.2	143.3	1.48	2.18	129.2	-8.48	71.87	146.0	3.41	11.63
10	148.4	148.9	0.32	0.10	125.1	-15.68	245.9	151.2	1.89	3.56
11	148.0	149.5	1.04	1.08	126.9	-14.26	203.4	151.4	2.29	5.24
12	145.0	144.6	-0.29	0.08	125.7	-13.34	178.0	146.7	1.15	1.33
13	144.2	142.1	-1.48	2.18	125.7	-12.80	163.7	141.2	-2.05	4.21
14	150.3	147.1	-2.12	4.51	129.7	-13.69	187.4	148.8	-1.00	0.99
15	143.5	143.8	0.21	0.04	129.7	-9.63	92.66	145.4	1.25	1.56
16	136.5	138.2	1.23	1.51	124.9	-8.51	72.50	139.1	1.90	3.60
17	131.6	137.6	4.53	20.52	125.0	-5.05	25.45	138.1	4.92	24.17
18	125.5	128.1	2.03	4.13	117.3	-6.52	42.56	128.7	2.57	6.58
19	124.5	127.1	2.08	4.32	117.3	-5.78	33.46	127.6	2.49	6.19
20	123.3	127.1	3.04	9.26	118.7	-3.74	13.97	127.7	3.55	12.61
21	137.8	137.7	-0.10	0.01	131.1	-4.83	23.33	147.3	6.88	47.33
22	151.1	151.4	0.19	0.03	144.7	-4.21	17.70	159.7	5.72	32.70
23	148.5	150.3	1.24	1.54	144.6	-2.65	7.05	155.3	4.59	21.09
24	133.6	136.7	2.30	5.30	133.6	0.01	0.00	139.2	4.19	17.57
		IP ₂₀₁₂		112.8	IP ₂₀₁₂		2314	IP ₂₀₁₂		299.5

Tablul 7.1.26. Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	116.2	119.4	2.77	7.67	111.2	-4.30	18.52	119.8	3.07	9.42
2	108.1	111.0	2.68	7.18	107.3	-0.72	0.52	111.2	2.89	8.35
3	104.8	106.5	1.59	2.53	101.4	-3.24	10.53	106.4	1.51	2.28
4	102.1	106.0	3.82	14.57	94.8	-7.15	51.12	106.3	4.15	17.25
5	104.2	106.9	2.59	6.73	96.4	-7.49	56.03	106.9	2.57	6.61
6	106.8	107.3	0.45	0.21	97.2	-8.97	80.46	107.6	0.74	0.55
7	122.7	123.0	0.21	0.04	99.3	-19.07	363.7	123.5	0.65	0.42
8	146.9	142.3	-3.16	9.98	116.4	-20.76	431.0	142.6	-2.96	8.74
9	143.1	140.3	-1.93	3.73	123.4	-13.77	189.5	141.3	-1.22	1.50
10	151.3	147.0	-2.83	8.00	122.8	-18.86	355.8	148.1	-2.11	4.46
11	150.8	146.8	-2.68	7.20	128.3	-14.92	222.6	147.8	-1.97	3.89
12	144.0	144.0	0.02	0.00	127.9	-11.18	125.0	145.1	0.79	0.62
13	146.6	143.4	-2.15	4.62	125.7	-14.25	203.1	144.5	-1.44	2.08
14	147.2	149.1	1.32	1.74	130.7	-11.23	126.0	150.2	2.05	4.22
15	142.8	143.2	0.30	0.09	128.6	-9.92	98.42	148.0	3.66	13.36
16	136.2	137.1	0.67	0.45	123.2	-9.54	90.96	143.6	5.45	29.68
17	132.1	132.6	0.41	0.17	119.8	-9.30	86.40	139.2	5.34	28.56
18	127.2	126.6	-0.47	0.22	116.1	-8.73	76.27	134.6	5.81	33.75
19	126.7	125.8	-0.72	0.52	116.4	-8.12	65.97	132.7	4.77	22.73
20	125.2	124.6	-0.45	0.21	116.4	-7.04	49.62	131.7	5.20	27.04
21	136.5	138.4	1.43	2.04	132.1	-3.23	10.44	145.2	6.39	40.81
22	150.2	149.6	-0.42	0.18	143.6	-4.39	19.29	158.6	5.61	31.43
23	149.0	147.6	-0.96	0.92	143.4	-3.73	13.89	156.3	4.90	24.00
24	133.3	134.4	0.85	0.72	132.4	-0.70	0.49	142.6	6.97	48.57
		IP ₂₀₁₃		79.70	IP ₂₀₁₃		2745	IP ₂₀₁₃		370.3




Fig. 7.1.18. Analiza comparativă a rezultatelor pentru anul 2011




Fig. 7.1.19. Analiza comparativă a rezultatelor pentru anul 2012




Fig. 7.1.20. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.27 s-au reunit indicii de performanță pentru cele 3 metode de prognoză utilizate.

Tabelul 7.1.27. Valoarea comparativă a indicilor de performanță

	RNA	CF	RLM
IP₂₀₁₁	161.9	1499	288.7
IP₂₀₁₂	112.8	2314	299.5
IP₂₀₁₃	79.40	2745	370.3
IP_{total}	354.1	6558	958.5

Analiza comparativă a rezultatelor obținute cu cele 3 metode de prognoză utilizate evidențiază următoarele concluzii:

- rezultatele confirmă practic observațiile făcute la analiza curbelor de sarcină pentru perioada 2001-2010, respectiv 2011-2013;
- metodele clasice de prognoză (CF și RLM) sunt inadecvate, așa cum rezultă pe baza valorii indicelui global de performanță (tabelul 7.1.27), cu un plus, totuși, pentru RLM;
- analiza comparativă a valorii indicilor anuali de performanță pentru RNA arată că situația cea mai bună este pentru anul 2013 (79.40) și cea mai proastă pentru 2011 (161.90), cu observația că sunt de același ordin de mărime;
- în tabelul 7.1.28 sunt prezentate comparativ erorile maxime de prognoză, rezultând valori acceptabile pentru RNA (sub 5.2 %), cele pentru RLM și CF ajungând până la 8 %, respectiv 21.5 % (confirmându-se concluziile anterioare);
- comparativ cu cele trei paragrafe precedente (UTR Arad – paragraful 7.1.2, UTR Deva – paragraful 7.1.3, UTR Reșița – paragraful 7.1.4), rezultatele pentru UTR Timișoara sunt cele mai bune.

Tabelul 7.1.28. Valoarea comparativă a erorilor maxime de prognoză

	RNA	CF	RLM
2011	5.11	15.05	8.01
2012	4.53	21.50	6.89
2013	3.82	20.76	6.97
Maxim	5.11	21.50	8.01

7.1.6. Ansamblul Enel Distribuție Banat

În tabelul 7.1.29, respectiv Fig. 7.1.21, sunt prezentate curbele de sarcină pentru o perioadă de 10 ani (2001-2010), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru efectuarea prognozelor, în scopul obținerii celor pentru anii 2011, 2012, 2013.

Tabelul 7.1.29. Curbele de sarcină pentru perioada 2010-2010 (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
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




Fig. 7.1.21. Curbele de sarcină pentru perioada 2001-2010 (puterile în MW)

În tabelul 7.1.30, respectiv Fig. 7.1.22, sunt prezentate curbele de sarcină pentru o perioadă de 3 ani (2011-2013), pentru ziua cea mai semnificativă de vară (în condițiile menționate în paragraful 7.1.1). Ele vor fi utilizate pentru verificarea rezultatelor prognozelor pentru anii 2011, 2012, 2013.

Tabelul 7.1.30. 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




Fig. 7.1.22. Curbele de sarcină pentru perioada 2011-2013 (puterile în MW)

Analiza datelor prezentate în tabelele 7.1.29 și 7.1.30, respectiv figurile 7.1.21 și 7.1.22, evidențiază de la bun început următoarele concluzii:

- pentru perioada 2001-2010 există o tendință destul de neclară de evoluție a consumului pe ansamblu (alternarea unor perioade de creștere, respectiv de scădere, într-o plajă totuși relativ îngustă de valori);
- curbele de sarcină nu "se intersectează" prea mult între ele, cu alte cuvinte forma lor este destul de asemănătoare, ceea ce înseamnă o corelare relativ mai bună "pe orizontală";

- pentru perioada 2011-2013 continuă practic trendul destul de neclar, la fel ca și pentru perioada 2001-2010, dar din nou cu o formă destul de asemănătoare a curbelor (între ele, respectiv cu cea din perioada 2001-2010);
- 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 (comparativ cu primele trei UTR), mai ales cu metodele utilizând RNA.

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelele 7.1.31 (anul 2011), 7.1.32 (anul 2012) și 7.1.33 (anul 2013). În partea de jos a tabelelor este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2011, 2012, 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în figurile 7.1.23 (anul 2011), 7.1.24 (anul 2012) și 7.1.25 (anul 2013).

Tabelul 7.1.31. Curbele de sarcină prognozate pentru anul 2011 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	389.4	387.7	-0.45	0.21	358.8	-7.87	61.87	365.2	-6.22	38.67
2	374.7	382.5	2.08	4.34	355.6	-5.08	25.85	353.1	-5.75	33.08
3	377.4	386.1	2.30	5.30	354.2	-6.15	37.79	368.3	-2.42	5.85
4	370.8	385.7	4.01	16.10	353.5	-4.66	21.69	367.1	-1.01	1.02
5	370.6	384.1	3.66	13.37	351.7	-5.10	25.98	362.5	-2.19	4.80
6	368.2	380.6	3.37	11.37	348.4	-5.37	28.83	349.1	-5.19	26.97
7	382.0	386.2	1.10	1.22	348.7	-8.72	75.99	367.1	-3.89	15.14
8	430.4	421.7	-2.02	4.09	375.9	-12.67	160.5	415.6	-3.45	11.89
9	464.1	477.3	2.85	8.14	438.8	-5.45	29.75	463.5	-0.12	0.01
10	482.8	472.0	-2.25	5.06	437.3	-9.44	89.04	460.3	-4.67	21.78
11	490.3	476.4	-2.82	7.98	441.2	-10.01	100.2	469.8	-4.17	17.37
12	460.6	468.5	1.73	3.00	438.5	-4.78	22.88	461.2	0.13	0.02
13	449.0	456.9	1.75	3.07	437.4	-2.59	6.71	451.7	0.59	0.34
14	459.8	454.4	-1.17	1.37	432.2	-5.99	35.93	450.4	-2.05	4.18
15	453.0	454.4	0.31	0.09	413.3	-8.77	76.89	454.2	0.25	0.06
16	433.3	419.7	-3.14	9.85	390.9	-9.79	95.91	431.2	-0.49	0.24
17	437.5	419.2	-4.17	17.43	393.0	-10.18	103.7	431.5	-1.37	1.88
18	427.2	409.9	-4.05	16.43	384.0	-10.12	102.4	423.5	-0.87	0.75
19	419.9	409.2	-2.57	6.59	386.9	-7.86	61.83	424.3	1.05	1.09
20	408.3	402.5	-1.44	2.06	387.6	-5.07	25.72	422.7	3.52	12.38
21	410.9	420.3	2.28	5.20	407.8	-0.77	0.60	437.9	6.56	42.98
22	450.0	454.9	1.10	1.22	440.6	-2.07	4.31	464.5	3.22	10.39
23	472.6	485.9	2.81	7.92	461.3	-2.39	5.72	489.7	3.63	13.20
24	438.6	439.7	0.26	0.07	436.9	-0.38	0.15	456.6	4.12	16.94
		IP_{2011}		151.5	IP_{2011}		1200	IP_{2011}		281.0

Tabelul 7.1.32. Curbele de sarcină prognozate pentru anul 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	384.8	365.8	-4.94	24.38	349.6	-9.16	83.92	357.7	-7.05	49.64
2	370.3	361.0	-2.52	6.37	342.8	-7.45	55.50	347.2	-6.26	39.17
3	380.9	367.3	-3.58	12.80	343.7	-9.77	95.43	351.4	-7.75	60.00

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
4	364.9	367.5	0.70	0.49	342.2	-6.23	38.87	347.7	-4.72	22.29
5	367.4	369.8	0.64	0.41	344.2	-6.31	39.86	349.4	-4.90	24.03
6	358.1	368.5	2.90	8.41	341.2	-4.74	22.43	349.2	-2.48	6.17
7	381.3	378.1	-0.84	0.71	343.2	-10.00	99.95	362.8	-4.85	23.52
8	421.4	411.1	-2.43	5.91	353.6	-16.09	258.8	405.9	-3.68	13.54
9	450.9	446.8	-0.92	0.84	390.8	-13.33	177.7	436.6	-3.17	10.08
10	472.9	474.7	0.39	0.15	423.5	-10.44	108.9	454.9	-3.80	14.43
11	486.2	486.6	0.07	0.00	426.5	-12.28	150.9	463.7	-4.64	21.49
12	453.9	457.1	0.69	0.48	398.5	-12.21	149.1	441.0	-2.86	8.18
13	442.3	446.4	0.92	0.84	394.8	-10.75	115.6	433.5	-2.00	3.98
14	454.9	458.5	0.79	0.62	407.2	-10.49	109.9	444.9	-2.20	4.86
15	450.5	451.7	0.25	0.06	407.2	-9.62	92.45	441.5	-2.01	4.02
16	431.1	429.8	-0.30	0.09	393.8	-8.66	75.04	427.1	-0.93	0.87
17	440.2	431.8	-1.90	3.63	402.3	-8.60	73.94	432.9	-1.66	2.75
18	418.0	422.0	0.95	0.89	396.1	-5.25	27.60	426.3	1.98	3.93
19	409.6	415.3	1.40	1.95	392.5	-4.18	17.49	422.3	3.11	9.68
20	402.2	406.8	1.15	1.33	386.1	-3.99	15.94	414.6	3.09	9.57
21	411.6	410.0	-0.39	0.15	392.3	-4.70	22.10	418.9	1.76	3.10
22	439.8	443.8	0.92	0.84	435.0	-1.08	1.17	454.1	3.26	10.66
23	474.6	464.1	-2.20	4.84	452.8	-4.58	21.00	475.6	0.22	0.05
24	439.4	432.2	-1.64	2.70	433.9	-1.25	1.56	449.1	2.21	4.88
		IP ₂₀₁₂		78.89	IP ₂₀₁₂		1855	IP ₂₀₁₂		350.9

Tabulul 7.1.33. Curbele de sarcină prognozate pentru anul 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	384.2	379.9	-1.10	1.21	343.5	-10.59	112.2	353.8	-7.90	62.47
2	364.6	366.1	0.42	0.17	341.0	-6.48	41.93	343.3	-5.86	34.28
3	373.9	377.0	0.83	0.68	343.2	-8.22	67.50	354.1	-5.31	28.20
4	363.3	362.0	-0.35	0.12	339.7	-6.49	42.16	342.2	-5.81	33.72
5	372.5	364.7	-2.10	4.40	341.2	-8.41	70.73	346.1	-7.10	50.35
6	364.3	356.2	-2.22	4.92	338.6	-7.06	49.88	339.9	-6.70	44.86
7	380.1	379.0	-0.29	0.08	339.8	-10.60	112.3	361.5	-4.89	23.93
8	422.7	418.0	-1.12	1.26	349.6	-17.30	299.3	397.6	-5.95	35.35
9	449.9	442.5	-1.65	2.74	383.3	-14.82	219.5	424.9	-5.57	31.04
10	471.2	457.4	-2.94	8.63	399.4	-15.25	232.6	445.8	-5.40	29.18
11	481.9	464.9	-3.52	12.39	418.6	-13.12	172.1	459.5	-4.65	21.58
12	452.7	445.8	-1.53	2.35	398.4	-12.00	144.1	434.2	-4.09	16.76
13	450.7	437.5	-2.93	8.56	392.4	-12.93	167.1	426.4	-5.38	28.99
14	450.5	447.3	-0.72	0.51	407.3	-9.60	92.16	439.3	-2.49	6.19
15	441.4	444.6	0.73	0.53	408.5	-7.45	55.50	437.7	-0.82	0.67
16	430.0	430.0	0.00	0.00	392.5	-8.73	76.16	423.3	-1.56	2.45
17	433.8	437.9	0.96	0.92	406.5	-6.29	39.51	433.1	-0.16	0.03
18	423.0	419.6	-0.82	0.67	388.3	-8.20	67.30	416.2	-1.61	2.58
19	415.9	412.4	-0.83	0.69	384.8	-7.48	55.90	411.0	-1.16	1.35
20	405.6	405.8	0.06	0.00	381.6	-5.90	34.85	406.7	0.26	0.07
21	406.0	414.8	2.19	4.78	394.2	-2.89	8.36	416.7	2.64	6.98
22	436.4	438.6	0.51	0.26	425.4	-2.51	6.29	442.7	1.45	2.10
23	467.7	461.6	-1.32	1.73	453.6	-3.01	9.07	474.6	1.46	2.14
24	434.6	439.1	1.04	1.08	433.5	-0.25	0.06	446.8	2.81	7.89
		IP ₂₀₁₃		58.72	IP ₂₀₁₃		2176	IP ₂₀₁₃		473.1




Fig. 7.1.23. Analiza comparativă a rezultatelor pentru anul 2011




Fig. 7.1.24. Analiza comparativă a rezultatelor pentru anul 2012




Fig. 7.1.25. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.1.34 s-au reunit indicii de performanță pentru cele 3 metode de prognoză utilizate.

Tabelul 7.1.34. Valoarea comparativă a indicilor de performanță

	RNA	CF	RLM
IP₂₀₁₁	151.5	1200	281.0
IP₂₀₁₂	78.89	1855	350.9
IP₂₀₁₃	58.72	2176	473.1
IP_{total}	289.1	5231	1105

Analiza comparativă a rezultatelor obținute cu cele 3 metode de prognoză utilizate evidențiază următoarele concluzii:

- rezultatele confirmă practic observațiile făcute la analiza curbilor de sarcină pentru perioada 2001-2010, respectiv 2011-2013;
- metodele clasice de prognoză (CF și RLM) sunt inadecvate, așa cum rezultă pe baza valorii indicelui global de performanță (tabelul 7.1.34), cu un plus, totuși, pentru RLM;
- analiza comparativă a valorii indicilor anuali de performanță pentru RNA arată că situația cea mai bună este pentru anul 2013 (58.72) și cea mai proastă pentru 2011 (151.50), cu observația că sunt de același ordin de mărime;
- în tabelul 7.1.35 sunt prezentate comparativ erorile maxime de prognoză, rezultând valori acceptabile pentru RNA (sub 5 %), cele pentru RLM și CF ajungând până la 8 %, respectiv 17 % (confirmându-se concluziile anterioare);
- comparativ cu cele patru paragrafe precedente (UTR Arad – paragraful 7.1.2, UTR Deva – paragraful 7.1.3, UTR Reșița – paragraful 7.1.4, UTR Timișoara – paragraful 7.1.5), rezultatele pentru ansamblul Enel Distribuție Banat sunt cele mai bune, asemănătoare (cu o nuanță mai bune) decât cele pentru UTR Timișoara.

Tabelul 7.1.35. Valoarea comparativă a erorilor maxime de prognoză

	RNA	CF	RLM
2011	4.17	12.67	6.56
2012	4.94	16.09	7.75
2013	3.52	17.30	7.90
Maxim	4.94	17.30	7.90

7.1.7. Analiza comparativă a rezultatelor

În cadrul acestui paragraf se efectuează o analiză comparativă a rezultatelor obținute, pe baza valorii indicelui global (total) de performanță. Se iau în considerare pentru fiecare caz rezultatele obținute cu RNA, respectiv cele cu RLM (în marea majoritate a cazurilor cele mai bune obținute cu metode clasice).

În tabelul 7.1.36 se prezintă sinteza analizei, centralizând rezultatele pentru cele 4 UTR și ansamblul Enel Banat. Clasamentul s-a întocmit pe baza valorii indicelui echivalent de performanță, obținut prin împărțirea valorii indicelui global de performanță la 24 (3 ani x 24 ore = 72). Utilizarea unui indice specific oferă și posibilitatea comparării calității rezultatelor din acest subcapitol cu cele prezentate în subcapitolul 7.2).

Tabelul 7.1.36. Indicii specifici de performanță

Nr. crt.	UTR	RNA		RLM		Raport indici specifici
		Total	Specific	Total	Specific	
1	Enel Banat	289.1	4.02	1105	15.35	3.82
2	UTR Timișoara	354.1	4.92	958.5	13.31	2.71
3	UTR Arad	576.6	8.01	1420	19.72	2.46
4	UTR Deva	821.5	11.41	2690	37.36	3.27
5	UTR Reșița	2278	31.64	10530	146.2	4.63

Analiza rezultatelor prezentate mai sus evidențiază o serie de concluzii, unele cu caracter particular, altele cu caracter general:

- clasamentul din tabelul 7.1.36, pe baza rezultatelor obținute cu RNA, are pe primul loc ansamblul Enel Distribuție Banat, urmat îndeaproape de UTR Timișoara și, la o distanță relativ mai mare, de UTR Arad și UTR Deva, UTR Reșița fiind, la mare distanță, pe ultimul loc;

- din punctul de vedere al ansamblului Enel Distribuție Banat rezultatul menționat este logic – prin însumare erorile se pot atenua, datorită semnelor contrare;
- clasamentul pe baza rezultatelor obținute cu RLM, are pe primul loc UTR Timișoara, urmat îndeaproape de ansamblul Enel Distribuție Banat și, la o distanță relativ mai mare, de UTR Arad și UTR Deva, UTR Reșița fiind, la mare distanță, pe ultimul loc (față de clasamentul pe baza RNA s-au schimbat între ele primele două poziții UTR Timișoara și ansamblul Enel Distribuție Banat);
- indicii specifici de performanță pentru RNA acoperă o plajă relativ largă de valori, de la 4.02 (Enel Banat) până la 31.64 (UTR Reșița);
- valoarea indicelui specific de performanță este determinată de datele inițiale (2001-2010), de gradul de corelare a curbilor de sarcină, de evoluția reală a consumului în anii 2011-2013 (pentru care s-a efectuat confruntarea cu prognoza) și de păstrarea formei curbilor de sarcină comparativ cu perioada cunoscută 2001-2010;
- valorile mari ale indicelui specific de performanță semnaleză prezența unor date probabil eronate de consum (total "discrepante"), prin eliminarea ("corectarea") cărora s-ar ajunge la o situație mai plauzibilă;
- în acest context, se remarcă valorile foarte proaste obținute pentru UTR Reșița (previzibile);
- referitor la cele două clasamente menționate mai sus, o analiză mai atentă a raportului dintre cei doi indici specifici de performanță (RLM/ RNA) este efectuată în ultima coloană a tabelului 7.1.36;
- explicația pentru cele două concluzii anterioare – gradul de corelare a curbilor de sarcină din punctul de vedere al formei, respectiv al valorilor, constituie două elemente distincte, cu influențe diferite asupra rezultatelor prognozei;
- în tabelul 7.1.37 se prezintă o situație comparativă sintetică a erorilor maxime de prognoză;

Tabelul 7.1.37. Valoarea comparativă a erorilor maxime de prognoză

Nr. crt.	UTR	RNA	CF	RLM
1	Enel Banat	4.94	17.30	7.90
2	UTR Timișoara	5.11	21.50	8.01
3	UTR Arad	8.78	18.23	12.88
4	UTR Deva	8.11	15.63	12.28
5	UTR Reșița	14.91	45.26	33.33

- concluzia globală este similară cu cea din paragrafele anterioare: metoda utilizând RNA produce rezultate bune sau acceptabile, metodele clasice – în cel mai bun caz acceptabile (RLM);
- erorile maxime de prognoză de ordinul de mărime până la 5 % se consideră a fi bune, cele în plaja 5-10 % – acceptabile, iar cele peste 10 % nesatisfăcătoare;
- pentru UTR Reșița sunt din nou evidente problemele legate de gradul de încredere a bazei de date sau de elemente cu totul speciale legate de evoluția consumului și/sau a formei curbilor de sarcină.

7.2. Prognoza curbelor de sarcină pentru ziua de 1 septembrie

7.2.1. Considerații preliminare

Acest subcapitol se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: UTR Timișoara, UTR Arad, UTR Deva și UTR Reșița.

Se realizează prognoza curbei de sarcină pentru ziua de 1 septembrie (o curbă de sarcină), pe baza celor din perioada 1 ianuarie – 31 august (243 de curbe de sarcină). Sunt prezentate rezultatele pe 2 ani – 2012 și 2013.

Primele 243 de curbe zilnice de sarcină (perioada 1 ianuarie – 31 august) s-au utilizat pentru realizare efectivă a prognozei, iar ziua de 1 septembrie pentru verificare prognozelor obținute.

Toate datele referitoare la curbele de sarcină au fost obținute de la Enel Distribuție Banat.

Pentru prognoza curbelor de sarcină s-au utilizat atât metoda utilizând RNA cât și o serie de alte metode: regresie liniară multiplă (RLM), "curve fitting" (CF), arbori de decizie (AD).

Pe parcursul și la finele subcapitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau mai general, atât legat de rezultatele concrete ale prognozelor cât și de metodele utilizate. O atenție specială se acordă comparării rezultatelor obținute cu diverse metode, aprecierii gradului de corelare a curbelor de sarcină cunoscute și a influenței sale asupra calității prognozelor realizate.

7.2.2. UTR Arad

7.2.2.1. Anul 2012

În tabelul 7.2.1 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2012 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2012.

În tabelul 7.2.2 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2012. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.

Tabelul 7.2.2. Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	62.60	7	51.70	13	58.40	19	57.20
2	58.30	8	58.00	14	57.90	20	58.20
3	54.30	9	58.30	15	56.00	21	66.00
4	52.70	10	58.60	16	56.20	22	76.40
5	52.70	11	59.20	17	56.40	23	71.00
6	53.20	12	58.50	18	56.60	24	68.00

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.3. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2012$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.1.


Tabelul 7.2.3. Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	62.60	65.42	4.50	20.28	54.92	-12.27	150.5	57.42	-8.27	68.47	64.08	2.36	5.58
2	58.30	60.26	3.36	11.32	53.20	-8.75	76.52	52.20	-10.46	109.5	56.21	-3.58	12.85
3	54.30	56.79	4.58	21.02	50.42	-7.15	51.06	51.22	-5.67	32.17	54.01	-0.54	0.29
4	52.70	54.81	4.00	15.98	49.83	-5.45	29.66	50.44	-4.29	18.39	54.01	2.48	6.14
5	52.70	54.02	2.50	6.27	47.77	-9.35	87.47	49.32	-6.41	41.14	54.01	2.48	6.14
6	53.20	55.33	4.00	16.03	48.96	-7.98	63.64	49.08	-7.75	60.11	51.04	-4.06	16.48
7	51.70	54.39	5.21	27.12	49.38	-4.48	20.11	48.84	-5.53	30.56	49.20	-4.84	23.38
8	58.00	57.07	-1.61	2.60	50.96	-12.14	147.3	51.18	-11.76	138.3	50.21	-13.42	180.2
9	58.30	61.98	6.32	39.94	55.63	-4.58	20.93	56.06	-3.84	14.74	58.76	0.79	0.63
10	58.60	63.10	7.68	58.95	57.83	-1.32	1.73	57.89	-1.20	1.45	59.30	1.19	1.43
11	59.20	63.58	7.39	54.68	58.80	-0.67	0.45	58.75	-0.76	0.58	61.93	4.61	21.27
12	58.50	61.74	5.54	30.72	58.97	0.80	0.65	58.33	-0.29	0.08	54.30	-7.18	51.55
13	58.40	61.22	4.83	23.29	60.15	3.00	9.02	58.98	1.00	1.00	54.30	-7.02	49.29
14	57.90	60.36	4.25	18.09	60.03	3.67	13.50	58.70	1.39	1.93	52.74	-8.91	79.42
15	56.00	58.14	3.81	14.55	59.17	5.66	32.01	57.48	2.64	6.97	51.20	-8.57	73.47
16	56.20	57.61	2.51	6.29	59.16	5.26	27.71	57.33	2.00	4.02	52.32	-6.90	47.66
17	56.40	58.24	3.26	10.66	60.36	7.02	49.26	58.39	3.52	12.42	52.80	-6.38	40.74
18	56.60	58.68	3.67	13.44	61.98	9.50	90.33	59.66	5.40	29.14	53.22	-5.97	35.66
19	57.20	60.21	5.27	27.74	63.11	10.33	106.8	60.96	6.58	43.25	62.92	10.00	100.0
20	58.20	61.41	5.51	30.34	63.91	9.80	96.13	61.94	6.42	41.20	62.92	8.11	65.81
21	66.00	70.73	7.17	51.36	71.77	8.75	76.55	70.13	6.26	39.14	63.30	-4.09	16.74
22	76.40	80.94	5.94	35.28	78.93	3.32	10.99	78.35	2.55	6.48	75.88	-0.69	0.47
23	71.00	76.32	7.50	56.22	75.36	6.15	37.79	74.52	4.96	24.59	70.27	-1.03	1.07
24	68.00	68.38	0.56	0.32	71.23	4.75	22.59	69.28	1.88	3.53	70.88	4.24	17.98
		<i>IP₂₀₁₂</i>	592.5		<i>IP₂₀₁₂</i>	1222		<i>IP₂₀₁₂</i>	729.2		<i>IP₂₀₁₂</i>	854.3	

În tabelul 7.2.4 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.4. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
<i>IP₂₀₁₂</i>	592.5	1222	729.2	854.3
Eroare maximă [%]	7.68	12.3	11.8	13.4






Fig. 7.2.1. Analiza comparativă a rezultatelor pentru anul 2012

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA;
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, dar încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.4 (clasamentul relativ fiind RLM, AD, CF, cu valori de același ordine de mărime ale indicelui de performanță;
- analiza erorilor maxime de prognoză indică rezultate relativ bune pentru RNA (sub 8 %), cele pentru RLM, CF și AD ajungând până la 11.8 %, 12.3 %, 13.4 %;
- comparativ cu celelalte UTR (UTR Deva – paragraful 7.2.3, UTR Reșița - 7.2.4, UTR Timișoara – 7.2.5) și ansamblul Enel Distribuție Banat (paragraful 7.2.6) se poate afirma că rezultatele sunt acceptabile (medii), de același ordin de mărime cu cele pentru UTR Deva (cu o idee mai slabe).

7.2.2.2. Anul 2013

În tabelul 7.2.5 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2013 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2013.

În tabelul 7.2.6 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2013. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.

Tabelul 7.2.6. Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)


Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	63.60	7	54.10	13	62.80	19	64.70
2	59.40	8	58.50	14	62.70	20	65.20
3	57.40	9	61.20	15	63.20	21	67.30
4	56.20	10	61.40	16	63.90	22	72.20
5	53.80	11	62.00	17	63.70	23	70.40
6	54.00	12	62.60	18	64.10	24	63.80

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.7. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.2.

În tabelul 7.2.8 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.7. Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	63.60	65.54	3.04	9.26	55.82	-12.23	149.6	57.00	-10.38	107.7	57.65	-9.36	87.52
2	59.40	61.79	4.03	16.23	54.73	-7.86	61.81	55.16	-7.14	50.95	57.15	-3.79	14.35
3	57.40	58.90	2.61	6.81	51.24	-10.73	115.2	52.82	-7.98	63.67	51.09	-11.00	120.9
4	56.20	58.12	3.41	11.61	50.32	-10.46	109.5	51.58	-8.22	67.58	51.09	-9.10	82.75
5	53.80	58.03	7.86	61.72	51.25	-4.74	22.47	51.21	-4.81	23.18	51.09	-5.04	25.42
6	54.00	57.83	7.10	50.42	51.04	-5.48	30.05	51.87	-3.94	15.56	52.04	-3.63	13.17
7	54.10	57.06	5.47	29.88	50.87	-5.97	35.65	51.84	-4.18	17.45	52.04	-3.81	14.50
8	58.50	56.65	-3.16	9.97	53.26	-8.96	80.23	52.34	-10.53	110.9	54.04	-7.62	58.12
9	61.20	57.52	-6.01	36.08	54.42	-11.08	122.7	55.12	-9.93	98.70	54.04	-11.70	136.9
10	61.40	58.19	-5.23	27.31	55.33	-9.89	97.73	55.64	-9.38	88.01	54.31	-11.55	133.3
11	62.00	58.82	-5.13	26.36	56.22	-9.32	86.91	55.42	-10.61	112.6	54.31	-12.40	153.8
12	62.60	58.87	-5.96	35.48	56.74	-9.36	87.63	55.87	-10.75	115.6	54.31	-13.24	175.4
13	62.80	60.03	-4.42	19.52	56.63	-9.82	96.53	56.43	-10.14	102.9	55.82	-11.11	123.5
14	62.70	60.01	-4.28	18.36	55.81	-10.99	120.7	57.22	-8.74	76.39	55.82	-10.97	120.4
15	63.20	60.19	-4.77	22.74	56.69	-10.30	106.1	58.33	-7.71	59.38	55.82	-11.68	136.4
16	63.90	60.31	-5.61	31.52	57.60	-9.86	97.22	58.80	-7.98	63.70	55.82	-12.64	159.9
17	63.70	59.68	-6.31	39.83	58.48	-8.19	67.10	57.92	-9.07	82.33	55.34	-13.12	172.2
18	64.10	59.40	-7.32	53.66	59.35	-7.41	54.94	56.88	-11.26	126.8	55.34	-13.67	186.8
19	64.70	59.69	-7.74	59.87	60.19	-6.97	48.52	57.60	-10.97	120.5	55.34	-14.47	209.3
20	65.20	60.60	-7.05	49.74	60.74	-6.84	46.80	58.87	-9.70	94.17	57.34	-12.06	145.3
21	67.30	65.42	-2.79	7.78	68.98	2.49	6.20	65.97	-1.97	3.89	64.08	-4.79	22.96
22	72.20	75.91	5.15	26.47	73.17	1.35	1.81	72.26	0.09	0.01	69.51	-3.72	13.84
23	70.40	69.89	-0.72	0.52	67.40	-4.26	18.16	66.88	-5.00	24.97	69.51	-1.26	1.58
24	63.80	64.91	1.75	3.05	64.56	1.19	1.42	63.30	-0.79	0.62	60.24	-5.57	31.06
		IP ₂₀₁₂		654.2	IP ₂₀₁₂		1665	IP ₂₀₁₂		1627	IP ₂₀₁₂		2339






Fig. 7.2.2. Analiza comparativă a rezultatelor pentru anul 2013

Tabelul 7.2.8. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₃	654.2	1665	1627	2339
Eroare maximă [%]	7.86	12.2	11.3	14.5

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA (similar cu 2011);
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, dar încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.8 (clasamentul relativ fiind RLM, CF, AD, cu valori de același ordin de mărime ale indicelui de performanță;
- analiza erorilor maxime de prognoză indică rezultate relativ bune pentru RNA (sub 8 %), cele pentru RLM, CF și AD ajungând până la 11.3 %, 12.2 %, 14.5 % (foarte asemănătoare cu cele pentru anul 2012, chiar dacă indicii de performanță au valori mai proaste (în medie duble) la ultimele trei metode;
- comparativ cu celelalte UTR (UTR Deva – paragraful 7.2.3, UTR Reșița - 7.2.4, UTR Timișoara – 7.2.5) și ansamblul Enel Distribuție Banat (paragraful 7.2.6) se poate afirma că rezultatele sunt acceptabile (medii), de același ordin de mărime cu cele pentru UTR Deva (cu o idee mai slabe).

7.2.3. UTR Deva

7.2.3.1. Anul 2012

În tabelul 7.2.9 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2012 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2012.

În tabelul 7.2.10 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2012. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.


Tabelul 7.2.10. Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	140.9	7	146.2	13	151.1	19	149.5
2	140.1	8	148.0	14	151.0	20	147.2
3	150.5	9	150.4	15	149.7	21	156.4
4	152.2	10	150.8	16	138.0	22	158.8
5	142.2	11	151.6	17	148.2	23	154.2
6	150.7	12	152.1	18	141.1	24	147.4

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.11. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2012$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.3.

Tabelul 7.2.11. Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	140.9	146.0	3.62	13.13	138.9	-1.42	2.01	139.9	-0.70	0.49	135.4	-3.95	15.62
2	140.1	146.5	4.55	20.68	136.4	-2.63	6.94	131.8	-5.94	35.26	135.4	-3.39	11.49
3	150.5	148.6	-1.24	1.54	138.2	-8.15	66.40	135.1	-10.19	103.8	137.2	-8.80	77.43
4	152.2	152.7	0.35	0.12	139.4	-8.41	70.73	140.7	-7.58	57.39	136.2	-10.51	110.5
5	142.2	150.7	5.95	35.43	137.2	-3.54	12.56	140.2	-1.42	2.02	129.3	-9.10	82.76
6	150.7	149.3	-0.95	0.90	138.3	-8.20	67.29	142.2	-5.63	31.67	134.7	-10.58	111.9
7	146.2	147.5	0.86	0.75	137.4	-6.02	36.23	141.7	-3.05	9.31	133.2	-8.89	79.07
8	148.0	143.8	-2.84	8.05	138.2	-6.61	43.67	141.9	-4.11	16.88	135.4	-8.51	72.48
9	150.4	152.9	1.63	2.65	139.4	-7.33	53.67	142.3	-5.38	28.93	147.0	-2.26	5.13
10	150.8	151.8	0.70	0.48	140.3	-6.98	48.76	142.3	-5.62	31.62	138.4	-8.24	67.85
11	151.6	154.6	2.01	4.04	141.2	-6.89	47.52	143.0	-5.69	32.33	139.4	-8.04	64.70
12	152.1	153.3	0.76	0.58	141.0	-7.31	53.45	143.1	-5.90	34.86	147.0	-3.34	11.18
13	151.1	152.1	0.65	0.43	140.9	-6.73	45.30	142.7	-5.56	30.91	147.0	-2.70	7.32
14	151.0	150.0	-0.69	0.47	138.7	-8.16	66.55	139.3	-7.78	60.54	138.4	-8.37	70.07
15	149.7	149.9	0.15	0.02	136.2	-9.00	81.08	139.0	-7.13	50.90	132.2	-11.69	136.6
16	138.0	145.4	5.40	29.14	125.9	-8.75	76.64	124.6	-9.72	94.52	132.2	-4.20	17.62
17	148.2	157.1	6.00	35.96	141.0	-4.87	23.73	139.8	-5.64	31.85	132.2	-10.79	116.5
18	141.1	148.7	5.37	28.89	135.9	-3.71	13.75	134.6	-4.65	21.59	132.2	-6.32	39.89
19	149.5	153.2	2.49	6.21	141.0	-5.66	32.01	141.3	-5.49	30.11	132.2	-11.57	133.8
20	147.2	151.3	2.78	7.71	141.7	-3.73	13.90	142.0	-3.51	12.31	132.2	-10.19	103.7
21	156.4	163.0	4.20	17.61	155.3	-0.69	0.47	155.3	-0.67	0.45	144.0	-7.93	62.86
22	158.8	167.0	5.19	26.91	165.6	4.29	18.42	162.8	2.52	6.35	144.0	-9.29	86.38
23	154.2	160.0	3.79	14.33	161.9	4.97	24.70	160.3	3.98	15.82	173.2	12.32	151.9
24	147.4	155.9	5.78	33.40	163.0	10.59	112.1	160.4	8.83	77.93	158.1	7.28	52.98
		IP_{2012}		289.4	IP_{2012}		1017	IP_{2012}		817.8	IP_{2012}		1689






Fig. 7.2.3. Analiza comparativă a rezultatelor pentru anul 2012

În tabelul 7.2.12 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.12. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₂	289.4	1017	817.8	1689
Eroare maximă [%]	6.00	10.6	10.2	12.3

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA;
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, dar încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.12 (clasamentul relativ fiind RLM, CF, AD, cu valori de același ordine de mărime ale indicelui de performanță;
- analiza erorilor maxime de prognoză indică rezultate relativ bune pentru RNA (sub 6 %), cele pentru RLM, CF și AD ajungând până la 10.6 %, 10.2 %, 12.3 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Reșița – 7.2.4, UTR Timișoara – 7.2.5) și ansamblul Enel Distribuție Banat (paragraful 7.2.6) se poate afirma că rezultatele sunt acceptabile (medii), de același ordin de mărime cu cele pentru UTR Arad, dar ceva mai bune.

7.2.3.2. Anul 2013

În tabelul 7.2.13 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2013 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2013.

În tabelul 7.2.14 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2013. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.

Tabelul 7.2.14. Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	125.0	7	123.9	13	131.8	19	125.9
2	123.3	8	126.7	14	132.6	20	136.8
3	118.4	9	132.4	15	133.5	21	141.4
4	119.2	10	141.7	16	127.5	22	142.7
5	120.2	11	142.0	17	128.1	23	131.4
6	120.6	12	136.6	18	124.0	24	127.8


Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea

pătratică relativă – sunt prezentate în tabelul 7.2.15. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2013$, definit ca suma abaterilor pătratică relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.4.

În tabelul 7.2.16 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.15. Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	125.0	129.1	3.33	11.09	114.7	-8.21	67.40	112.0	-10.36	107.4	118.3	-5.37	28.83
2	123.3	127.5	3.38	11.43	109.3	-11.34	128.6	111.4	-9.63	92.68	118.3	-4.09	16.71
3	118.4	125.8	6.23	38.78	107.4	-9.27	85.84	110.2	-6.91	47.73	118.3	-0.12	0.01
4	119.2	125.9	5.65	31.92	106.2	-10.89	118.6	112.7	-5.42	29.37	118.3	-0.79	0.62
5	120.2	127.9	6.39	40.87	105.8	-11.95	142.7	111.4	-7.32	53.60	118.3	-1.61	2.60
6	120.6	128.7	6.70	44.95	107.2	-11.12	123.6	112.4	-6.81	46.43	113.5	-5.96	35.52
7	123.9	130.7	5.50	30.26	108.8	-12.13	147.2	113.3	-8.57	73.50	113.5	-8.41	70.76
8	126.7	128.2	1.17	1.37	110.3	-12.95	167.7	114.3	-9.81	96.20	114.5	-9.65	93.13
9	132.4	131.3	-0.82	0.67	112.4	-15.12	228.6	115.7	-12.60	158.7	114.5	-13.53	183.1
10	141.7	138.3	-2.41	5.79	118.5	-16.33	266.6	117.2	-17.27	298.1	116.2	-17.96	322.5
11	142.0	138.1	-2.73	7.43	121.7	-14.27	203.7	120.3	-15.27	233.3	118.3	-16.70	278.8
12	136.6	131.1	-3.99	15.90	120.4	-11.81	139.5	121.4	-11.09	123.1	118.3	-13.39	179.4
13	131.8	131.2	-0.44	0.19	117.4	-10.89	118.6	113.2	-14.06	197.6	118.3	-10.24	104.8
14	132.6	130.7	-1.43	2.06	116.5	-12.09	146.2	114.0	-13.99	195.6	118.3	-10.79	116.4
15	133.5	130.9	-1.93	3.72	107.1	-19.81	392.4	114.9	-13.97	195.1	119.3	-10.65	113.4
16	127.5	131.2	2.90	8.44	108.7	-14.75	217.6	112.3	-11.93	142.2	119.3	-6.46	41.74
17	128.1	131.1	2.30	5.27	103.3	-19.40	376.6	114.2	-10.85	117.7	120.4	-6.01	36.12
18	124.0	131.1	5.67	32.13	106.8	-13.88	192.7	114.7	-7.51	56.47	121.1	-2.36	5.58
19	125.9	131.1	4.14	17.16	109.3	-13.16	173.3	108.0	-14.19	201.4	121.1	-3.82	14.60
20	136.8	131.7	-3.73	13.91	105.2	-23.06	531.9	108.6	-20.62	425.2	121.1	-11.46	131.3
21	141.4	133.0	-5.92	35.10	113.5	-19.72	388.8	114.0	-19.36	374.7	128.4	-9.16	83.84
22	142.7	134.2	-5.93	35.22	118.1	-17.24	297.2	117.8	-17.47	305.2	128.4	-10.00	99.93
23	131.4	134.3	2.20	4.82	117.8	-10.34	107.0	118.8	-9.62	92.62	115.3	-12.26	150.2
24	127.8	133.8	4.70	22.10	119.3	-6.64	44.10	120.3	-5.87	34.43	115.3	-9.78	95.72
		IP_{2012}	420.6		IP_{2012}	4806		IP_{2012}	3698		IP_{2012}	2205	






Fig. 7.2.4. Analiza comparativă a rezultatelor pentru anul 2013

Tabelul 7.2.16. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₃	420.6	4806	3698	2205
Eroare maximă [%]	6.70	23.1	20.6	18.0

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA (similar cu 2011);
- metodele clasice de prognoză oferă rezultate mult mai slabe, inacceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.16 (clasamentul relativ fiind AD, RLM, CF, cu valori de același ordin de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate relativ bune pentru RNA (sub 6.7 %), cele pentru RLM, CF și AD ajungând până la 20.6 %, 23.1 %, 18 % (mai proaste decât cele pentru anul 2012, indicii de performanță având valori duble la ultimele trei metode);
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Reșița – 7.2.4, UTR Timișoara – 7.2.5) și ansamblul Enel Distribuție Banat (paragraful 7.2.6) se poate afirma că rezultatele sunt acceptabile (medii), de același ordin de mărime cu cele pentru UTR Arad, dar ceva mai bune.

7.2.4. UTR Reșița

7.2.4.1. Anul 2012

În tabelul 7.2.17 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2012 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2012.

În tabelul 7.2.18 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2012. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.


Tabelul 7.2.18. Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	46.60	7	45.10	13	44.90	19	44.75
2	45.40	8	45.30	14	44.40	20	46.10
3	45.20	9	45.20	15	44.80	21	47.40
4	45.80	10	45.60	16	44.90	22	50.20
5	45.20	11	45.50	17	45.30	23	49.40
6	46.60	12	44.20	18	44.85	24	48.10

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.19. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2012$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.5.

Tabelul 7.2.19. Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	46.60	51.63	10.80	116.6	40.03	-14.10	198.8	38.78	-16.78	281.6	41.70	-10.52	110.6
2	45.40	48.29	6.36	40.42	39.80	-12.33	152.1	38.39	-15.44	238.4	40.05	-11.78	138.9
3	45.20	46.89	3.75	14.05	41.32	-8.58	73.69	38.78	-14.20	201.7	40.05	-11.39	129.8
4	45.80	47.01	2.64	6.96	42.05	-8.19	67.04	39.68	-13.36	178.6	40.05	-12.55	157.6
5	45.20	47.27	4.59	21.06	41.33	-8.56	73.31	39.75	-12.06	145.4	40.05	-11.39	129.8
6	45.10	48.16	6.78	45.99	41.40	-8.20	67.31	40.75	-9.65	93.03	40.00	-11.31	127.9
7	45.10	46.67	3.49	12.17	41.72	-7.49	56.17	40.98	-9.14	83.45	41.02	-9.04	81.76
8	45.30	46.58	2.83	8.04	39.42	-12.98	168.5	41.15	-9.16	83.93	41.07	-9.34	87.19
9	45.20	47.67	5.47	29.88	40.34	-10.75	115.6	41.82	-7.48	55.92	41.07	-9.14	83.49
10	45.60	47.31	3.74	13.99	41.01	-10.07	101.3	42.70	-6.36	40.45	41.07	-9.93	98.69
11	45.50	46.78	2.81	7.88	41.12	-9.63	92.67	42.40	-6.81	46.42	41.07	-9.74	94.79
12	44.20	46.97	6.28	39.38	38.58	-12.72	161.9	40.98	-7.29	53.07	40.10	-9.28	86.04
13	44.90	46.65	3.91	15.27	39.12	-12.88	166.0	41.30	-8.02	64.29	41.22	-8.20	67.17
14	44.40	46.71	5.21	27.15	40.19	-9.48	89.91	41.20	-7.21	51.94	41.00	-7.66	58.64
15	44.80	46.61	4.04	16.35	40.98	-8.54	72.85	41.30	-7.81	61.04	41.27	-7.88	62.09
16	44.90	46.02	2.50	6.24	41.88	-6.73	45.34	41.42	-7.75	60.07	42.30	-5.79	33.53
17	45.30	47.46	4.77	22.72	43.44	-4.10	16.82	42.03	-7.22	52.10	42.10	-7.06	49.90
18	44.85	47.38	5.64	31.79	44.19	-1.47	2.17	42.84	-4.47	19.99	42.17	-5.98	35.71
19	44.75	48.03	7.34	53.87	49.70	11.06	122.4	43.79	-2.14	4.56	42.20	-5.70	32.47
20	46.10	49.53	7.43	55.20	50.38	9.28	86.20	45.53	-1.23	1.51	42.98	-6.77	45.80
21	47.40	51.55	8.76	76.74	53.20	12.24	149.7	48.03	1.33	1.76	44.32	-6.50	42.22
22	50.20	55.32	10.20	104.0	56.69	12.93	167.1	50.98	1.56	2.43	55.74	11.04	121.8
23	49.40	54.43	10.18	103.6	56.20	13.77	189.5	52.18	5.62	31.63	55.74	12.83	164.7
24	48.10	52.86	9.90	97.93	54.57	13.45	180.9	51.55	7.18	51.52	55.18	14.71	216.5
		IP_{2012}	967.3		IP_{2012}	1904		IP_{2012}	2617		IP_{2012}	2257	






Fig. 7.2.5. Analiza comparativă a rezultatelor pentru anul 2012

În tabelul 7.2.20 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.20. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₂	967.3	1904	2617	2257
Eroare maximă [%]	10.8	14.1	16.8	14.7

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA;
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, așa cum rezultă pe baza datelor din tabelul 7.2.20 (clasamentul relativ fiind CF, AD, RLM, cu valori de același ordin de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate relativ slabe și pentru RNA (sub 11 %), cele pentru RLM, CF și AD ajungând până la 14.1 %, 16.8 %, 14.7 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Deva – 7.2.3, UTR Timișoara – 7.2.5) și ansamblul Enel Distribuție Banat (paragraful 7.2.6), rezultatele pentru Reșița sunt cele mai slabe, la fel ca în subcapitolul 7.1 (cauza fiind legată și de această dată de gradul foarte redus de corelare a datelor cunoscute și, posibil, gradul de încredere îndoielnic).

7.2.4.2. Anul 2013

În tabelul 7.2.21 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2013 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2013.

În tabelul 7.2.22 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2013. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.

Tabelul 7.2.22. Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)


Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	72.40	7	79.40	13	60.60	19	64.30
2	75.60	8	71.30	14	59.60	20	66.20
3	70.20	9	78.60	15	60.40	21	66.50
4	75.40	10	80.40	16	56.90	22	63.40
5	80.20	11	67.10	17	65.60	23	71.20
6	81.80	12	60.80	18	70.20	24	70.80

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.23. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.6.

În tabelul 7.2.24 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.23. Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	72.40	82.66	14.17	200.7	62.60	-13.54	183.2	56.45	-22.03	485.3	56.90	-21.41	458.3
2	75.60	75.82	0.29	0.08	62.70	-17.06	291.2	61.27	-18.96	359.3	56.90	-24.74	611.8
3	70.20	66.49	-5.29	27.95	61.18	-12.85	165.1	61.32	-12.65	160.0	56.90	-18.95	358.9
4	75.40	75.85	0.60	0.36	62.94	-16.53	273.1	62.74	-16.79	281.9	58.70	-22.15	490.6
5	80.20	73.46	-8.41	70.65	63.42	-20.92	437.8	64.20	-19.95	398.0	58.70	-26.81	718.7
6	81.80	78.93	-3.51	12.29	63.46	-22.42	502.7	64.70	-20.90	437.0	62.30	-23.84	568.3
7	79.40	72.30	-8.94	79.89	56.20	-29.22	853.8	63.30	-20.28	411.2	62.30	-21.54	463.8
8	71.30	62.79	-11.93	142.3	50.32	-29.42	865.6	59.40	-16.69	278.6	53.20	-25.39	644.4
9	78.60	67.07	-14.67	215.3	55.79	-29.02	842.2	59.75	-23.98	575.1	53.70	-31.68	1003
10	80.40	70.63	-12.15	147.7	56.95	-29.17	650.7	62.30	-22.51	506.8	55.20	-31.34	982.4
11	67.10	63.02	-6.08	36.94	51.77	-22.85	522.0	57.42	-14.43	208.1	54.30	-19.08	363.9
12	60.80	61.62	1.35	1.81	51.56	-15.19	230.9	56.22	-7.53	56.7	53.20	-12.50	156.3
13	60.60	54.63	-9.85	96.95	47.12	-22.25	494.9	50.74	-16.27	264.7	52.65	-13.12	172.1
14	59.60	64.11	7.57	57.35	51.28	-13.96	195.0	49.22	-17.42	303.3	49.95	-16.19	262.2
15	60.40	58.11	-3.80	14.42	51.98	-13.94	194.2	48.74	-19.30	372.7	45.27	-25.05	627.4
16	56.90	55.08	-3.20	10.22	51.37	-9.73	94.59	45.84	-19.43	377.5	45.27	-20.44	417.7
17	65.60	63.90	-2.59	6.69	59.87	-8.73	76.24	52.01	-20.71	429.0	54.88	-16.34	266.9
18	70.20	72.82	3.73	13.91	66.88	-4.74	22.43	59.81	-14.80	219.1	62.46	-11.02	121.5
19	64.30	61.40	-4.51	20.33	59.42	-7.59	57.67	55.14	-14.25	203.0	48.55	-24.49	600.0
20	66.20	75.50	14.05	197.5	70.89	7.09	50.27	65.37	-1.26	1.58	50.98	-22.99	528.6
21	66.50	74.27	11.68	136.5	69.36	4.30	18.52	66.56	0.08	0.01	54.20	-18.50	342.1
22	63.40	67.85	7.02	49.33	68.88	8.64	74.71	66.55	4.96	24.64	66.26	4.51	20.3
23	71.20	76.42	7.34	53.83	73.74	3.56	12.68	72.88	2.36	5.55	69.77	-2.01	4.10
24	70.80	70.16	-0.90	0.81	66.58	-5.96	35.57	68.55	-3.18	10.09	78.56	10.96	120.1
		IP_{2012}		1593	IP_{2012}		7145	IP_{2012}		6369	IP_{2012}		10303






Fig. 7.2.6. Analiza comparativă a rezultatelor pentru anul 2013

Tabelul 7.2.24. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₃	1593	7145	6369	10303
Eroare maximă [%]	14.7	29.4	22.0	31.7

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA;
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, așa cum rezultă pe baza datelor din tabelul 7.2.24 (clasamentul relativ fiind RLM, CF, AD, cu valori de același ordin de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate foarte slabe și pentru RNA (sub 15 %), cele pentru RLM, CF și AD ajungând până la 29.4 %, 22.0 %, 31.7 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Deva – 7.2.3, UTR Timișoara – 7.2.5) și ansamblul Enel Distribuție Banat (paragraful 7.2.6), rezultatele pentru Reșița sunt cele mai slabe, la fel ca în subcapitolul 7.1 (cauza fiind legată și de această dată de gradul foarte redus de corelare a datelor cunoscute și, posibil, gradul de încredere îndoielnic);
- în particular, aceste rezultate sunt cele mai slabe din întreg subcapitolul 7.2.

7.2.5. UTR Timișoara

7.2.5.1. Anul 2012

În tabelul 7.2.25 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2012 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2012.

În tabelul 7.2.26 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2012. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.


Tabelul 7.2.26. Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	111.1	7	99.8	13	113.1	19	105.8
2	102.5	8	101.2	14	110.2	20	107.9
3	99.8	9	107.0	15	108.5	21	121.5
4	99.6	10	111.2	16	108.3	22	134.2
5	99.3	11	111.1	17	107.6	23	129.4
6	98.5	12	113.7	18	106.4	24	116.4

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.27. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2012$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.7.

Tabelul 7.2.27. Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	111.1	113.7	2.32	5.36	92.3	-16.90	285.7	107.2	-3.51	12.32	111.7	0.54	0.29
2	102.5	104.5	1.91	3.64	90.3	-11.87	140.9	93.2	-9.07	82.32	95.2	-7.15	51.14
3	99.8	99.88	0.08	0.01	88.3	-11.50	132.3	91.1	-8.72	75.99	92.1	-7.69	59.06
4	99.6	98.62	-0.98	0.96	89.0	-10.63	113.0	90.3	-9.32	86.81	93.4	-6.22	38.75
5	99.3	96.99	-2.33	5.42	88.7	-10.63	113.1	89.3	-10.07	101.4	91.5	-7.83	61.38
6	98.5	98.66	0.16	0.03	87.4	-11.25	126.5	88.9	-9.75	94.99	90.3	-8.29	68.80
7	99.8	102.5	2.74	7.52	87.3	-12.50	156.2	89.8	-9.99	99.83	92.7	-7.07	50.04
8	101.2	106.1	4.83	23.29	90.6	-10.52	110.7	93.5	-7.59	57.54	94.2	-6.92	47.84
9	107.0	111.3	3.97	15.76	94.9	-11.33	128.4	98.1	-8.31	69.04	103.9	-2.94	8.61
10	111.2	115.4	3.80	14.44	99.7	-10.37	107.6	102.6	-7.74	59.90	103.2	-7.19	51.76
11	111.1	114.5	3.02	9.13	101.3	-8.81	77.67	103.4	-6.97	48.54	105.7	-4.86	23.62
12	113.7	116.9	2.83	8.01	104.8	-7.87	61.86	106.4	-6.39	40.81	107.8	-5.15	26.56
13	113.1	116.3	2.78	7.75	106.0	-6.28	39.46	107.0	-5.37	28.88	107.2	-5.26	27.68
14	110.2	113.7	3.20	10.23	106.9	-2.98	8.86	107.1	-2.77	7.67	107.8	-2.16	4.66
15	108.5	109.9	1.30	1.69	106.6	-1.71	2.93	106.0	-2.32	5.40	107.8	-0.62	0.38
16	108.3	110.2	1.72	2.97	108.2	-0.06	0.00	107.2	-1.06	1.12	107.8	-0.43	0.19
17	107.6	110.4	2.60	6.76	109.8	2.05	4.22	108.3	0.65	0.43	107.8	0.22	0.05
18	106.4	110.3	3.69	13.64	110.6	3.93	15.47	108.5	1.97	3.87	103.9	-2.39	5.70
19	105.8	109.9	3.89	15.13	111.2	5.13	26.30	108.4	2.48	6.15	103.9	-1.83	3.36
20	107.9	112.7	4.41	19.45	114.5	6.08	37.02	111.6	3.45	11.90	107.8	-0.06	0.00
21	121.5	127.2	4.67	21.85	126.6	4.16	17.28	125.1	2.94	8.66	116.0	-4.53	20.57
22	134.2	141.4	5.37	28.89	136.5	1.74	3.04	136.1	1.38	1.90	134.7	0.41	0.17
23	129.4	133.9	3.52	12.38	130.9	1.16	1.34	129.5	0.07	0.01	118.5	-8.42	70.96
24	116.4	122.2	4.97	24.73	124.1	6.60	43.56	120.8	3.82	14.61	115.9	-0.44	0.20
		IP_{2012}		259.0	IP_{2012}		1753	IP_{2012}		920.1	IP_{2012}		621.8






Fig. 7.2.7. Analiza comparativă a rezultatelor pentru anul 2012

În tabelul 7.2.28 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.28. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₂	259.0	1753	920.1	621.8
Eroare maximă [%]	5.37	16.9	10.1	8.42

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA;
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, unele încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.28 (clasamentul relativ fiind AD, RLM, CF cu valori de același ordin de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate bune pentru RNA (sub 5,4 %), cele pentru AD, RLM și CF ajungând până la 8.4 %, 10.1 %, 16.9 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Deva – 7.2.3, UTR Reșița – 7.2.4) și ansamblul Enel Distribuție Banat (paragraful 7.2.6), se poate afirma că aceste rezultate sunt cele mai bune.

7.2.5.2. Anul 2013

În tabelul 7.2.29 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2013 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2013.

În tabelul 7.2.30 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2013. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.

Tabelul 7.2.30. Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	117.5	7	107.0	13	113.1	19	113.4
2	112.2	8	108.1	14	113.7	20	115.4
3	107.4	9	110.2	15	114.2	21	126.8
4	104.2	10	112.1	16	115.0	22	136.5
5	100.1	11	112.8	17	114.2	23	132.4
6	102.9	12	113.1	18	113.4	24	121.7


Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea

pătratică relativă – sunt prezentate în tabelul 7.2.31. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2013$, definit ca suma abaterilor pătratică relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.8.

În tabelul 7.2.32 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.31. Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	117.5	118.5	0.91	0.82	105.7	-10.05	101.1	107.3	-8.71	75.83	106.7	-9.21	84.80
2	112.2	108.6	-3.21	10.29	102.6	-8.58	73.67	104.2	-7.13	50.84	106.7	-4.94	24.37
3	107.4	104.1	-3.11	9.66	99.7	-7.16	51.27	102.9	-4.24	17.95	99.3	-7.52	56.60
4	104.2	101.4	-2.65	7.04	94.9	-8.96	80.34	99.7	-4.28	18.32	99.1	-4.88	23.77
5	100.1	101.7	1.63	2.66	93.4	-6.68	44.58	94.2	-5.90	34.78	97.4	-2.67	7.13
6	102.9	103.8	0.86	0.74	93.9	-8.73	76.23	96.3	-6.42	41.19	97.2	-5.52	30.52
7	107.0	104.5	-2.36	5.58	95.3	-10.93	119.5	99.3	-7.18	51.50	98.3	-8.13	66.09
8	108.1	107.7	-0.35	0.12	96.0	-11.18	125.1	102.4	-5.27	27.80	98.5	-8.93	79.69
9	110.2	110.0	-0.22	0.05	96.7	-12.21	149.2	102.9	-6.67	44.48	98.5	-10.66	113.7
10	112.1	112.1	-0.04	0.00	98.2	-12.38	153.3	103.7	-7.46	55.62	101.2	-9.69	93.85
11	112.8	112.5	-0.28	0.08	99.0	-12.22	149.2	104.2	-7.61	57.86	102.3	-9.31	86.65
12	113.1	113.4	0.30	0.09	99.1	-12.41	154.0	105.9	-6.36	40.41	103.1	-8.82	77.86
13	113.1	111.0	-1.82	3.30	100.0	-11.55	133.5	104.7	-7.43	55.16	103.8	-8.22	67.61
14	113.7	110.8	-2.57	6.62	101.5	-10.71	114.7	105.2	-7.46	55.63	103.4	-9.06	82.06
15	114.2	113.3	-0.76	0.58	103.7	-9.20	84.59	107.3	-6.04	36.51	103.9	-8.98	80.72
16	115.0	113.5	-1.30	1.70	105.3	-8.51	72.36	107.0	-7.00	49.04	104.2	-9.40	88.40
17	114.2	115.9	1.46	2.13	107.1	-6.21	38.59	105.3	-7.82	61.21	106.7	-6.57	43.13
18	113.4	114.8	1.22	1.50	108.6	-4.24	18.00	106.6	-6.00	36.02	108.9	-3.96	15.65
19	113.4	113.1	-0.24	0.06	109.9	-3.06	9.34	108.0	-4.70	22.08	110.1	-2.87	8.25
20	115.4	109.7	-4.98	24.78	110.6	-4.20	17.62	109.7	-4.96	24.62	105.7	-8.39	70.37
21	126.8	122.0	-3.76	14.10	125.0	-1.41	1.99	120.8	-4.73	22.39	118.6	-6.50	42.28
22	136.5	138.3	1.30	1.68	127.3	-6.76	45.71	127.5	-6.59	43.47	121.2	-11.17	124.8
23	132.4	134.3	1.43	2.06	122.9	-7.21	51.96	123.4	-6.77	45.81	125.2	-5.47	29.91
24	121.7	119.8	-1.53	2.33	117.7	-3.23	10.44	118.2	-2.83	8.01	122.3	0.56	0.31
		IP_{2012}			IP_{2012}			IP_{2012}			IP_{2012}		
			97.97			1876			976.5			1398	






Fig. 7.2.8. Analiza comparativă a rezultatelor pentru anul 2013

Tabelul 7.2.32. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₃	98.0	1876	976.5	1398
Eroare maximă [%]	5.0	12.4	8.7	11.2

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA (similar cu 2011);
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, dar încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.32 (clasamentul relativ fiind RLM, AD, CF cu valori de același ordine de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate bune pentru RNA (sub 5 %), cele pentru RLM, AD și CF ajungând până la 8.7 %, 11.2 %, 12.4 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Deva – 7.2.3, UTR Reșița – 7.2.4) și ansamblul Enel Distribuție Banat (paragraful 7.2.6), se poate afirma că aceste rezultate sunt cele mai bune, la fel ca și cele pentru anul 2012 (dar mai bune decât acelea).

7.2.6. Ansamblul Enel Distribuție Banat

7.2.6.1. Anul 2012

În tabelul 7.2.33 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2012 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2012.

În tabelul 7.2.34 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2012. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.


Tabelul 7.2.34. Curba de sarcină pentru 1 septembrie 2012 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	361.2	7	342.8	13	375.6	19	363.3
2	346.3	8	352.5	14	383.0	20	372.4
3	349.8	9	366.9	15	363.5	21	395.3
4	350.3	10	376.2	16	350.4	22	429.6
5	339.4	11	372.4	17	360.5	23	414.0
6	347.5	12	373.5	18	354.0	24	379.9

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.35. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2012$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.9.

Tabelul 7.2.35. Curbele de sarcină prognozate pentru 1 septembrie 2012 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	361.2	374.6	3.71	13.76	313.8	-13.14	172.6	333.5	-7.67	58.80	380.7	5.40	29.11
2	346.3	358.6	3.56	12.69	312.4	-9.79	95.88	326.8	-5.63	31.74	325.2	-6.11	37.30
3	349.8	356.8	2.00	3.99	313.3	-10.42	108.7	328.4	-6.10	37.23	325.2	-7.03	49.47
4	350.3	365.1	4.22	17.81	315.2	-10.02	100.4	330.7	-5.60	31.31	325.2	-7.18	51.51
5	339.4	349.6	2.98	8.89	312.0	-8.08	65.35	328.4	-3.25	10.58	322.1	-5.10	25.98
6	347.5	353.9	1.85	3.42	312.8	-9.98	99.61	329.9	-5.06	25.60	325.3	-6.38	40.74
7	342.8	350.4	2.23	4.96	311.7	-9.07	82.31	328.7	-4.11	16.92	323.6	-5.60	31.37
8	352.5	351.8	-0.20	0.04	313.2	-11.15	124.3	332.3	-5.73	32.84	325.9	-7.55	56.94
9	366.9	378.4	3.13	9.82	317.4	-13.50	182.2	336.2	-8.37	70.10	327.5	-10.74	115.4
10	376.2	389.1	3.43	11.76	319.2	-15.15	229.4	339.4	-9.78	95.69	328.8	-12.60	158.8
11	372.4	381.3	2.39	5.73	313.3	-15.88	252.2	341.2	-8.38	70.19	327.5	-12.06	145.4
12	373.5	387.0	3.63	13.16	318.1	-14.84	220.3	342.3	-8.35	69.78	329.4	-11.81	139.4
13	375.6	386.4	2.87	8.26	320.6	-14.65	214.7	344.2	-8.36	69.89	330.3	-12.06	145.5
14	383.0	402.1	5.00	24.99	317.0	-17.22	296.7	347.5	-9.27	85.91	338.5	-11.62	135.0
15	363.5	380.8	4.76	22.65	323.9	-10.89	118.6	333.4	-8.29	68.66	337.3	-7.21	51.95
16	350.4	362.6	3.48	12.12	327.6	-6.51	42.37	330.7	-5.62	31.61	308.6	-11.93	142.4
17	360.5	373.3	4.11	16.85	354.7	-1.62	2.62	353.1	-2.05	4.19	361.0	0.15	0.02
18	354.0	365.6	3.28	10.74	346.4	-2.13	4.56	345.7	-2.33	5.41	334.8	-5.42	29.33
19	363.3	376.2	3.57	12.71	354.9	-2.31	5.31	357.2	-1.68	2.81	333.7	-8.13	66.09
20	372.4	382.3	2.66	7.07	360.8	-3.11	9.66	363.2	-2.47	6.10	343.6	-7.74	59.95
21	395.3	401.1	1.47	2.15	409.2	3.51	12.35	401.8	1.66	2.74	382.4	-3.26	10.60
22	429.6	444.6	3.49	12.19	437.1	1.74	3.02	431.6	0.47	0.22	462.7	7.72	59.52
23	414.0	430.8	4.06	16.47	427.5	3.26	10.62	419.8	1.39	1.93	396.1	-4.33	18.77
24	379.9	394.0	3.71	13.78	413.9	8.95	80.05	402.4	5.92	35.10	373.4	-1.72	2.95
		IP_{2012}		266.0	IP_{2012}		2533	IP_{2012}		865.4	IP_{2012}		1603






Fig. 7.2.9. Analiza comparativă a rezultatelor pentru anul 2012

În tabelul 7.2.36 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.36. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₂	266.0	2533	865.4	1603
Eroare maximă [%]	5.00	15.9	9.78	12.6

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA;
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, unele încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.36 (clasamentul relativ fiind RLM, AD, CF cu valori de același ordin de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate bune pentru RNA (sub 5 %), cele pentru RLM, AD și CF ajungând până la 9.8 %, 12.6 %, 15.9 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Deva – 7.2.3, UTR Reșița – 7.2.4, UTR Timișoara – 7.2.4), rezultatele obținute sunt bune, în imediata apropiere a celor pentru UTR Timișoara.

7.2.6.2. Anul 2013

În tabelul 7.2.37 (Anexa CD), sunt prezentate curbele de sarcină zilnice pentru perioada 1 ianuarie – 31 august 2013 (243 de curbe de sarcină). Ele vor fi utilizate la efectuarea prognozei pentru ziua de 1 septembrie 2013.

În tabelul 7.2.38 sunt prezentate datele referitoare la curba de sarcină pentru ziua de 1 septembrie 2013. Ele vor fi utilizate pentru verificarea rezultatelor prognozei.


Tabelul 7.2.38. Curba de sarcină pentru 1 septembrie 2013 (puterile în MW)

Ora	P [MW]	Ora	P [MW]	Ora	P [MW]	Ora	P [MW]
1	378.5	7	364.4	13	368.3	19	368.3
2	370.5	8	364.6	14	368.6	20	383.6
3	353.4	9	382.4	15	371.3	21	402.0
4	355.0	10	395.6	16	363.4	22	414.8
5	354.3	11	383.9	17	371.6	23	405.4
6	359.3	12	373.1	18	371.7	24	384.1

Rezultatele obținute cu diverse metode de prognoză – valorile prognozate, diferențele față de valorile cunoscute (abatere relativă procentuală) și abaterea pătratică relativă – sunt prezentate în tabelul 7.2.39. În partea de jos a tabelului este dată valoarea indicelui de performanță pentru anul i (IP_i), $i = 2013$, definit ca suma abaterilor pătratice relative pentru cele 24 de valori orare. Grafic, aceste rezultate sunt prezentate comparativ, pentru toate metodele utilizate, în Fig. 7.2.10.

Tabelul 7.2.39. Curbele de sarcină prognozate pentru 1 septembrie 2013 (puterile în MW)

Ora	Valoare cunoscută	RNA			CF			RLM			AD		
		Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	378.5	393.7	4.04	16.30	345.8	-8.62	74.38	361.8	-4.40	19.36	355.6	-6.04	36.49
2	370.5	380.2	2.61	6.79	341.7	-7.78	60.47	356.1	-3.89	15.11	355.6	-4.02	16.19
3	353.4	352.2	-0.33	0.11	338.7	-4.15	17.26	338.7	-4.16	17.30	355.6	0.62	0.38
4	355.0	359.1	1.16	1.34	337.4	-4.96	24.58	329.5	-7.18	51.60	355.6	0.17	0.03
5	354.3	359.7	1.52	2.32	339.3	-4.25	18.05	327.4	-7.59	57.66	355.6	0.36	0.13
6	359.3	361.2	0.52	0.27	340.3	-5.31	28.18	332.9	-7.36	54.16	355.6	-1.04	1.09
7	364.4	368.8	1.22	1.48	342.1	-6.12	37.42	343.5	-5.73	32.87	355.6	-2.41	5.83
8	364.6	362.3	-0.64	0.41	338.4	-7.19	51.75	340.6	-6.59	43.43	355.6	-2.48	6.15
9	382.4	364.4	-4.72	22.29	339.3	-11.29	127.4	348.2	-8.95	80.07	355.6	-7.02	49.22
10	395.6	384.6	-2.78	7.75	352.4	-10.91	119.0	362.1	-8.46	71.55	355.6	-10.10	102.1
11	383.9	368.6	-3.99	15.90	349.3	-9.02	81.27	357.2	-6.96	48.40	355.6	-7.38	54.42
12	373.1	368.5	-1.22	1.49	340.7	-8.67	75.20	356.2	-4.52	20.40	355.6	-4.68	21.91
13	368.3	373.2	1.34	1.78	341.2	-7.35	53.96	361.9	-1.72	2.97	339.4	-7.83	61.29
14	368.6	375.3	1.84	3.38	342.5	-7.07	50.00	363.2	-1.45	2.12	338.7	-8.09	65.51
15	371.3	374.2	0.76	0.58	343.4	-7.52	56.54	364.3	-1.89	3.57	339.2	-8.65	74.83
16	363.4	376.6	3.64	13.25	341.2	-6.10	37.24	361.4	-0.54	0.30	335.2	-7.75	60.12
17	371.6	376.6	1.34	1.78	343.9	-7.47	55.84	354.6	-4.59	21.02	334.7	-9.94	98.80
18	371.7	378.1	1.72	2.95	344.2	-7.40	54.83	358.2	-3.64	13.24	341.4	-8.16	66.60
19	368.3	382.9	3.97	15.78	335.5	-8.89	79.06	336.3	-8.68	75.40	342.5	-6.99	48.91
20	383.6	375.3	-2.16	4.68	354.7	-7.54	56.89	350.9	-8.51	72.39	343.6	-10.42	108.5
21	402.0	387.8	-3.53	12.43	373.3	-7.13	50.87	369.3	-8.14	66.28	352.3	-9.88	97.53
22	414.8	399.0	-3.80	14.43	378.2	-8.81	77.64	377.1	-9.08	82.46	408.3	-1.56	2.45
23	405.4	409.2	0.94	0.89	382.3	-5.69	32.43	384.1	-5.26	27.72	408.3	0.72	0.52
24	384.1	380.4	-0.96	0.93	375.0	-2.35	5.54	367.1	-4.42	19.57	382.3	-0.47	0.22
		IP_{2012}	149.3		IP_{2012}	1325		IP_{2012}	898.9		IP_{2012}	979.2	






Fig. 7.2.10. Analiza comparativă a rezultatelor pentru anul 2013

În tabelul 7.2.40 s-au reunit indicii de performanță și erorile maxime de prognoză pentru cele 4 metode utilizate.

Tabelul 7.2.40. Valoarea comparativă a indicilor de performanță și a erorilor maxime

	RNA	CF	RLM	AD
IP₂₀₁₃	149.3	1325	898.9	979.2
Eroare maximă [%]	4.7	11.3	9.1	10.4

Analiza comparativă a rezultatelor obținute cu cele 4 metode de prognoză utilizate evidențiază următoarele concluzii:

- cele mai bune rezultate sunt obținute cu metoda utilizând RNA (similar cu anul 2011);
- metodele clasice de prognoză (CF, RLM, AD) oferă rezultate mai slabe, dar încă acceptabile, așa cum rezultă pe baza datelor din tabelul 7.2.40 (clasamentul relativ fiind RLM, AD, CF cu valori de același ordin de mărime ale indicelui de performanță);
- analiza erorilor maxime de prognoză indică rezultate bune pentru RNA (sub 5 %), cele pentru RLM, AD și CF ajungând până la 9.1 %, 10.4 %, 11.3 %;
- comparativ cu celelalte UTR (UTR Arad – paragraful 7.2.2, UTR Deva – 7.2.3, UTR Reșița – 7.2.4, UTR Timișoara – 7.2.5), rezultatele obținute sunt bune, în imediata apropiere a celor pentru UTR Timișoara.

7.2.7. Analiza comparativă a rezultatelor

În cadrul acestui paragraf se efectuează o analiză comparativă a rezultatelor obținute, pe baza valorii indicelui global (total) de performanță. Se iau în considerare pentru fiecare caz rezultatele obținute cu RNA, respectiv cele cu RLM (în marea majoritate a cazurilor cele mai bune obținute cu metode clasice).

În tabelul 7.2.41 se prezintă sinteza analizei, centralizând rezultatele pentru cele 4 UTR și ansamblul Enel Banat. Clasamentul s-a întocmit pe baza valorii indicelui echivalent de performanță, obținut prin împărțirea valorii indicelui global de performanță la 24. Utilizarea unui indice specific oferă și posibilitatea comparării calității rezultatelor din acest subcapitol cu cele prezentate în subcapitolul 7.1).

Tabelul 7.2.41. Indicii specifici de performanță

Nr. crt.	UTR	RNA		RLM		Raport indici specifici
		Total	Specific	Total	Specific	
1	UTR Timișoara 2013	98.0	4.08	976.5	40.69	9.97
2	Enel Banat 2013	149,3	6.22	898.9	37.45	6.02
3	UTR Timișoara 2012	259.0	10.79	920.1	38.34	3.55
4	Enel Banat 2012	266.0	11.08	865.4	36.06	3.25
5	UTR Deva 2012	289.4	12.06	817.8	34.08	2.83
6	UTR Deva 2013	420.6	17.52	2205	91.87	5.24
7	UTR Arad 2012	592.5	24.69	729.2	30.38	1.23
8	UTR Arad 2013	654.2	27.26	1627	67.91	2.49
9	UTR Reșița 2012	867.3	36.14	2617	109.0	3.02
10	UTR Reșița 2013	1593	66.37	6369	265.4	3.99

În tabelele 7.2.42 și 7.2.43 se prezintă aceleași date doar pentru anul 2012, respectiv pentru anul 2013. În tabelul 7.2.44 sunt prezentate rezultatele reunite, pe UTR și ansamblul Enel Distribuție Banat, obținute prin însumarea indicilor globali de performanță pentru cei 2 ani (evident, indicii specifici se obțin prin împărțire la 48).

Tabelul 7.2.42. Indicii specifici de performanță pentru anul 2012

Nr. crt.	UTR	RNA		RLM		Raport indici specifici
		Total	Specific	Total	Specific	
1	UTR Timișoara 2012	259.0	10.79	920.1	38.34	3.55
2	Enel Banat 2012	266.0	11.08	865.4	36.06	3.25
3	UTR Deva 2012	289.4	12.06	817.8	34.08	2.83
4	UTR Arad 2012	592.5	24.69	729.2	30.38	1.23
5	UTR Reșița 2012	867.3	36.14	2617	109.0	3.02

Tabelul 7.2.43. Indicii specifici de performanță pentru anul 2013

Nr. crt.	UTR	RNA		RLM		Raport indici specifici
		Total	Specific	Total	Specific	
1	UTR Timișoara 2013	98.0	4.08	976.5	40.69	9.97
2	Enel Banat 2013	149,3	6.22	898.9	37.45	6.02
6	UTR Deva 2013	420.6	17.52	2205	91.87	5.24
8	UTR Arad 2013	654.2	27.26	1627	67.91	2.49
10	UTR Reșița 2013	1593	66.37	6369	265.4	3.99

Tabelul 7.2.44. Indicii specifici de performanță cumulați (2012, 2013)

Nr. crt.	UTR	RNA		RLM		Raport indici specifici
		Total	Specific	Total	Specific	
1	UTR Timișoara	357.0	7.44	1897	39.52	5.31
2	Enel Banat	415.3	8.65	1764	36.75	4.25
6	UTR Deva	710.0	14.79	3023	62.98	4.26
8	UTR Arad	1247	25.98	2356	49.08	1.89
10	UTR Reșița	2460	51.25	9013	187.8	3.59

Analiza rezultatelor prezentate mai sus evidențiază o serie de concluzii, unele cu caracter particular, altele cu caracter general:

- clasamentele din tabelele de mai sus, pe baza rezultatelor obținute cu RNA, au pe primul loc UTR Timișoara, urmată îndeaproape de ansamblul Enel Distribuție Banat și, la o distanță ceva mai mare, de UTR Deva și UTR Arad, UTR Reșița fiind, la mare distanță, pe ultimul loc;
- având în vedere bazele de date diferite utilizate, clasamentele prezintă mici diferențe față de cele din subcapitolul anterior - practic ansamblul Enel Distribuție Banat și UTR Timișoara și-au schimbat pozițiile între ele (locurile 1 și 2), la fel și UTR Deva cu UTR Arad (locurile 3 și 4);

- din punctul de vedere al ansamblului Enel Distribuție Banat rezultatul menționat este din nou logic – prin însumare erorile se pot atenua, datorită semnelor contrare;
- indicii specifici de performanță pentru RLM acoperă o plajă relativ largă de valori, de la 4.02 (UTR Timișoara 2012) până la 66.37 (UTR Reșița 2013);
- valoarea indicelui specific de performanță este condiționată de datele inițiale (curbele zilnice de sarcină din perioada 1 ianuarie - 31 august), de gradul de corelare a curbelor de sarcină, de evoluția reală a consumului în ziua de 1 septembrie (pentru care s-a efectuat confruntarea cu prognoza) și de păstrarea formei curbelor de sarcină comparativ cu perioada anterioară;
- valorile mari ale indicelui specific de performanță semnaleză prezența unor date probabil eronate de consum (total "discrepante"), prin eliminarea ("corectarea") cărora s-ar ajunge la o situație mai plauzibilă;
- în acest context, se remarcă din nou valorile foarte proaste obținute pentru UTR Reșița (previzibile, similar cu subcapitolul precedent);
- explicația plajei mai largi de valori pentru indicii specifici de performanță, în comparație cu subcapitolul 7.1 (valoare maximă practic dublă), poate fi legată de faptul că acum datele cunoscute se referă la toate zilele săptămânii, pe când în subcapitolul anterior vizau doar zilele lucrătoare (cea mai apropiată zi lucrătoare de ziua cea mai semnificativă de vară);
- în ultimele coloane ale tabelelor 7.2.41 - 7.2.44 sunt date valorile raportului dintre cei doi indici specifici de performanță (RLM / RNA), explicațiile și concluziile fiind similare cu cele din subcapitolul 7.1;
- din nou se remarcă faptul că gradul de corelare a curbelor de sarcină din punctul de vedere al formei, respectiv al valorilor, constituie două elemente distincte, cu influențe diferite asupra rezultatelor prognozei;
- în tabelul 7.2.45 se prezintă o situație comparativă sintetică a erorilor maxime de prognoză;

Tabelul 7.2.45. Valoarea comparativă a erorilor maxime de prognoză

Nr. crt.	UTR	RNA	CF	RLM	AD
1	UTR Timișoara 2013	5.0	12.4	8.7	11.2
2	Enel Banat 2013	4.7	11.3	9.1	10.4
3	UTR Timișoara 2012	5.37	16.9	10.1	8.42
4	Enel Banat 2012	5.00	15.9	9.78	12.6
5	UTR Deva 2012	6.00	10.6	10.2	12.3
6	UTR Deva 2013	6.70	23.1	20.6	18.0
7	UTR Arad 2012	7.68	12.3	11.8	13.4
8	UTR Arad 2013	7.86	12.2	11.3	14.5
9	UTR Reșița 2012	10.8	14.1	16.8	14.7
10	UTR Reșița 2013	14.7	29.4	22.0	31.7

- concluzia globală este similară cu cea din paragrafele anterioare: metoda utilizând RNA produce rezultate bune sau acceptabile, metodele clasice – în cel mai bun caz acceptabile (RLM);
- erorile maxime de prognoză de ordinul de mărime până la 5 % se consideră a fi bune, cele în plaja 5-10 % - acceptabile, iar cele peste 10 % nesatisfăcătoare;
- erorile maxime de prognoză sunt de același ordin de mărime cu cele prezentate în subcapitolul 7.1;
- pentru UTR Reșița concluziile sunt similare cu cele din subcapitolul precedent.

7.3. Concluzii

Capitolul 7 constituie principala parte aplicativă a lucrării. În acest capitol se prezintă rezultatele obținute privind prognoza curbelor de sarcină utilizând tehnici bazate pe inteligența artificială (IA) – rețele neuronale artificiale (RNA). Elementele teoretice, metodologiile de calcul elaborate și instrumentele soft dezvoltate, care au constituit obiectul capitolelor anterioare, au fost aplicate și utilizate la obținerea prognozelor menționate pentru o gamă largă de studii de caz.

Prima parte a capitolului se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: UTR Timișoara, UTR Arad, UTR Deva și UTR Reșița. Se realizează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie. Datele cunoscute acoperă 10 ani (2001 – 2010), iar verificarea rezultatelor vizează 3 ani (2011-2013).

A doua parte a capitolului se referă tot la ansamblul Enel Distribuție Banat și la principalele UTR menționate mai sus. Se realizează prognoza curbei de sarcină pentru ziua de 1 septembrie (o curbă de sarcină), pe baza celor din perioada 1 ianuarie – 31 august (243 de curbe de sarcină). Sunt prezentate rezultatele pe 2 ani – 2012 și 2013.

Prognozele s-au efectuat cu metodele prezentate în capitolele anterioare (rețele neuronale artificiale – RNA, regresie liniară multiplă – RLM, arbori de decizie – AD, "curve fitting" – CF), utilizând instrumentul soft propriu descris în capitolul 6.

La finele fiecărui subcapitol în parte și la sfârșitul capitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau mai general, vizând atât rezultatele concrete ale prognozelor cât și metodele utilizate.

În continuare se prezintă o sinteză a contribuțiilor personale, în contextul în care capitolul este în întregime original, reprezentând principala parte aplicativă a tezei:

- completarea și verificarea unei baze de date cuprinzătoare cuprinzând curbele zilnice de sarcină la nivelul Enel Distribuție Banat și a UTR componente;
- efectuarea prognozelor utilizând modelele matematice prezentate în capitolele teoretice, utilizând un instrument soft de concepție proprie (capitolul 6);
- realizarea unor studii extinse de prognoză pentru Enel Distribuție Banat și pentru alți operatori de distribuție și agenți economici;
- formularea unor concluzii practice 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 metodologia de efectuare a prognozelor și instrumentele soft necesare cât și rezultatele obținute pentru cazurile concrete analizate.

8. CONCLUZII GENERALE. CONTRIBUȚII PERSONALE

Acest ultim capitol sintetizează o serie de concluzii generale rezultate în urma elaborării tezei de doctorat, contribuțiile originale aduse în cadrul tezei, modul de valorificare a rezultatelor obținute și direcțiile posibile de continuare și aprofundare a cercetărilor în domeniul abordat.

Elementele teoretice și practice prezentate în cadrul tezei de doctorat evidențiază următoarele concluzii și comentarii cu caracter mai general:

- Pe baza analizei evoluției sectorului energetic și al SEE, cu referire și la sistemul electroenergetic al României se pot afirma următoarele:
 - evoluția sectorului energetic, în general, și a sistemelor electroenergetice, în particular, prezintă o serie de particularități complexe. Asigurarea securității cu energie "curată", ținând cont de influența puternică a sectorului energetic asupra altor sectoare, de limitarea schimbărilor climatice, escaladarea cererii globale de energie și de viitorul nesigur al accesului la resursele energetice devine provocarea majoră pentru Uniunea Europeană;
 - necesitatea dezvoltării unui sistem energetic puternic și fiabil care să fie în concordanță cu problemele de mediu și care să asigure accesul consumatorilor la sursele de energie la prețuri accesibile, de siguranță în alimentare, care să facă față cererii de energie electrică în continuă creștere;
 - prognoza consumului de energie electrică constituie o preocupare extrem de importantă, atât în contextul planificării dezvoltării rețelei de transport și a celei de distribuție a energiei electrice cât și în cel al existenței unei piețe complet liberalizate a energiei, atât la nivelul Uniunii Europene, cât și al României;
 - datele privind evoluția consumului acoperă o plajă largă de valori prognozate, cu diferențe sensibil mari între valorile "pesimiste" și cele "optimiste". De asemenea, în cazul noilor capacități "verzi" de producere a energiei electrice, unele sunt mai realiste, altele ușor "fanteziste".
- Elaborarea modelelor matematice destinate prognozei consumului de energie (putere) electrică și a curbilor de sarcină și utilizarea lor a condus la următoarele concluzii:
 - tehnicile de inteligență artificială se pretează foarte bine la soluționarea unei game largi de probleme de specialitate din domeniul ingineriei energetice, prognoza consumului fiind un exemplu elocvent din acest punct de vedere;
 - s-a realizat un modelul matematic eficient al prognozei consumului de energie electrică și al curbilor de sarcină, utilizând rețele neuronale artificiale de tip perceptron multistrat, cu algoritmul backpropagation;
 - gradul slab de corelare a datelor de prognoză poate pune probleme foarte serioase în privința gradului de credibilitate a rezultatelor obținute;
 - este extrem de importantă testarea metodelor elaborate pentru un număr foarte mare de aplicații practice, rezultând o serie de concluzii privind posibilitățile de îmbunătățire;
 - este absolut necesară o analiză atentă a datelor de consum disponibile, pentru eliminarea unor informații clar eronate.

- Din punct de vedere al instrumentelor soft dezvoltate pentru scopul propus, se pot evidenția următoarele concluzii:
- în literatura de specialitate se remarcă o mare diversitate de preocupări legate de prognoza consumului, pe termen scurt, mediu și lung;
 - o atenție aparte se acordă utilizării tehnicilor de inteligență artificială și abordării fuzzy, utilizându-se instrumente soft corespunzătoare;
 - în condițiile actuale ale performanțelor sistemelor de calcul și a mediilor de programare implementarea modelului pentru soluționarea tuturor aspectelor legate de prognoză trebuie să devină o practică comună;
 - majoritatea instrumentelor soft utilizează pachete de programe standard, 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 realizat adaptarea și dezvoltarea unor nuclee de program existente, astfel încât instrumentul soft realizat să răspundă cerințelor specifice legate de prognozele din domeniul ingineriei energetice.

În continuare se prezintă sinteza principalelor contribuții originale, teoretice și aplicative, cuprinse în cadrul tezei de doctorat.

- Obiectivul capitolului 2 constă în realizarea unei sinteze privind stadiul actual și perspectivele evoluției sectorului energetic, în general, și a sistemelor electro-energetice, în particular, o atenție specială fiind acordată consumului și producerii de energie electrică. Se evidențiază următoarele contribuții:
- prezentarea, într-o manieră sintetică a obiectivelor politicii energetice la nivelul UE și reliefaarea evoluției cadrului legal actual în domeniu, în concordanță cu legislația comunitară corespunzătoare;
 - realizarea unei sinteze documentate, în viziunea proprie a autorului, privind stadiul actual al evoluției consumului de energie pe plan mondial, european și național;
 - prezentarea unei sinteze documentate, a situației utilizării surselor regenerabile de energie în cadrul UE și pe plan național, cu evidențierea avantajelor obținute în reducerea emisiilor de CO₂;
 - realizarea unei sinteze documentate, în viziunea proprie a autorului, asupra conceptului Smart Grid, cu expunerea actorilor implicați, a rolului și a responsabilităților acestora, și cu evidențierea beneficiilor produse de generarea distribuită, dar și a repercursiunilor negative prin încălcarea unor restricții de sistem;
 - prezentarea sintetică a modelului conceptual european și a cadrului modelului arhitectural Smart Grid SGAM, cu evidențierea priorităților de implementare și realizarea unei paralele între rețelele clasice și Smart Grids;
 - evidențierea necesității unei atenții sporite acordate activității de prognoză a consumului (și a producerii), în contextul unor evoluții de multe ori contradictorii (înregistrarea unor perioade de scădere, urmate de creștere).
- Obiectivul capitolului 3 constă în prezentarea sistematizată a aspectelor generale legate de cercetările privind prognoza consumului de energie electrică, a metodelor utilizate, cu accent pe cele care fac uz de o serie de tehnici de inteligență artificială. Contribuțiile aduse sunt următoarele:
- realizarea unei sinteze documentate, în viziune proprie, bazată pe un amplu studiu bibliografic, a metodelor utilizate pentru prognoza consumului de energie electrică 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, SVM, data mining etc.);
 - focalizarea unei atenții speciale asupra metodelor de soluționare bazate pe tehnici de inteligență artificială;

- realizarea unei sinteze documentate, în viziune proprie, bazată pe un studiu bibliografic consistent, a metodelor utilizate pentru amplasarea și dimensionarea optimă a surselor de generare distribuită, ca element conex al tematicii principale a tezei de doctorat;
 - pregătirea elementelor pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate.
- Capitolul 4 are ca obiect prezentarea, într-un cadru mai larg, a tehnicilor de inteligență artificială utilizate în cadrul tezei de doctorat. El furnizează elementele teoretice necesare pentru capitolele următoare, care se referă la metodele concrete utilizate în lucrare și la studiile de caz realizate. Pot fi enumerate următoarele contribuții:
- realizarea unei sinteze originale asupra utilizării tehnicilor de inteligență artificială în domeniul electroenergeticii;
 - realizarea unei sinteze originale asupra unei game largi de aspecte legate de rețelele neuronale artificiale;
 - pregătirea elementelor teoretice necesare pentru modelul de prognoză utilizat în cadrul tezei: RNA cu structură perceptron multistrat, algoritm de învățare de tip backpropagation.
- Capitolul 5 are ca obiectiv prezentarea modelelor matematice ale metodelor utilizate efectiv în lucrare pentru prognoza consumului de energie electrică și putere și a curbelor de sarcină. Prima parte a capitolului prezintă modelul Regresiei Liniare Multiple (RLM), iar partea a doua descrie modelul Arborilor de Decizie (AD). În partea a treia se tratează modelul de aproximare Curve Fitting (CF), ultima parte a capitolului referindu-se la metodele utilizând Rețele Neuronale Artificiale (RNA). Contribuțiile aduse sunt următoarele:
- realizarea unei succinte sinteze teoretice asupra regresiei liniare multiple;
 - elaborarea unui model propriu ce aplică regresia liniară multiplă;
 - realizarea unei succinte sinteze teoretice referitoare la arborii de decizie;
 - elaborarea unui model propriu bazat pe arborii de decizie;
 - realizarea unei succinte sinteze teoretice ce prezintă Curve Fitting;
 - elaborarea unui model propriu ce folosește aproximarea Curve Fitting
 - realizarea unei succinte sinteze teoretice referitoare la RNA;
 - elaborarea unui model propriu ce utilizează rețelele neuronale.
- Capitolul 6 prezintă un instrument software de prognoză a consumului de energie electrică (curbelor de sarcină) și analiză statistică a indicatorilor de performanță. Instrumentul soft, care implementează toate metodele de prognoză prezentate în capitolul 5 (regresie liniară multiplă, "curve fitting", arbori de decizie și rețele neuronale de tip perceptron multistrat cu algoritm de învățare de tip backpropagation), a fost conceput în mediul Matlab. Se evidențiază următoarele contribuții:
- implementarea unui algoritm de prognoză ce aplică regresia liniară multiplă, adaptând o funcție care face parte din Statistics Toolbox;
 - implementarea unui algoritm ce folosește arborii de decizie pentru prognoza curbelor de sarcină;
 - implementarea unui algoritm ce aplică o formă adaptată a funcțiilor disponibile în Curve Fitting;
 - implementarea unui algoritm ce folosește RNA, utilizând o variantă adaptată scopului propus a instrumentelor disponibile în Neural Network Toolbox;
 - realizarea unui instrument soft pentru prognoza consumului și a curbelor de sarcină, utilizând mediul de programare Matlab, care integrează practic algoritmi enumerați mai sus.

- Capitolul 7 este în întregime original, constituind principala parte aplicativă a tezei. Prima parte a capitolului se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: Timișoara, Arad, Deva și Reșița. Se realizează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie. Datele cunoscute acoperă 10 ani (2001 –2010), iar verificarea rezultatelor vizează 3 ani (2011-2013). A doua parte a capitolului se referă tot la ansamblul Enel Distribuție Banat și la UTR menționate mai sus. Se realizează prognoza curbei de sarcină pentru ziua de 1 septembrie (o curbă de sarcină), pe baza celor din perioada 1 ianuarie – 31 august (243 de curbe). Sunt prezentate rezultatele pentru 2 ani – 2012 și 2013. Se pot evidenția următoarele contribuții:
- completarea și verificarea unei baze de date cuprinzătoare cuprinzând curbele zilnice de sarcină la nivelul Enel Distribuție Banat și a UTR componente;
 - efectuarea prognozelor utilizând modelele matematice prezentate în capitolele teoretice, utilizând un instrument soft de concepție proprie (capitolul 6);
 - realizarea unor studii extinse de prognoză pentru Enel Distribuție Banat și pentru alți operatori de distribuție și agenți economici;
 - formularea unor concluzii practice 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 metodologia de efectuare a prognozelor și instrumentele soft necesare cât și rezultatele obținute pentru cazurile concrete analizate.

Rezultatele obținute au fost și vor fi valorificate în cadrul unor contracte de cercetare științifică încheiate între Universitatea Politehnică Timișoara, Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor SEE, și Operatorul Național de Transport și de Sistem, C.N.T.E.E. Transelectrica S.A., operatorii de distribuție (Enel, Electrica, CEZ, Eon) și o serie de agenți economici care se ocupă de implementarea în sistem a resurselor regenerabile de energie. Contractele derulate și finalizate sunt prezentate în lista lucrărilor proprii de la finele tezei ([UPT2014a], [UPT2014b], [UPT2014c], [UPT2014d], [UPT2014e]).

De asemenea, o parte a rezultatelor obținute în cadrul tezei au fost publicate și sunt în curs de publicare: 13 lucrări publicate până la ora actuală, 1 lucrare în curs de publicare, 2 referate științifice și 5 de contracte de cercetare. Așa cum rezultă din lista lucrărilor proprii de la finele tezei de doctorat, 9 au fost publicate în țară și 4 în străinătate. Se remarcă faptul că 2 lucrări sunt indexate ISI Journal, 5 lucrări sunt indexate în BDI – Scopus, Compendex, Inspec, IEEE Explore etc. și o lucrare acceptată la o conferință indexată ISI (aprilie 2016).

Analizele teoretice și practice realizate în cadrul tezei de doctorat, precum și rezultatele obținute, deschid o serie de perspective și direcții de continuare și aprofundare ulterioară a cercetărilor în domeniul prognozei consumului de energie electrică și a curbelor de sarcină:

- rafinarea metodelor de soluționare bazate pe RNA, în scopul creșterii eficienței și ameliorării performanțelor acestora;
- utilizarea unor alte tehnici de inteligență artificială în cadrul studiilor de prognoză din domeniul ingineriei energetice;
- implementarea unor alte clase de metode de soluționare bazate pe tehnici de inteligență artificială și logică fuzzy;
- elaborarea unor metode care să depisteze unele date evident eronate în istoricul consumului;
- introducerea în modelul matematic a unor factori suplimentari, pe lângă evoluția în timp a consumului: condițiile meteo, elemente legate de dezvoltarea economică, influența producerii distribuite etc.

BIBLIOGRAFIE

1. [AlbertWeb] Albert H., Golovanov N., Golovanov C., Rășcanu V., Elefterescu L., Monitorizarea Calității Energiei Electrice, <http://www.sier.ro/>
2. [AIRashidi2010] AIRashidi M.R., El-Naggar K.M., Long term electric load forecasting based on particle swarm optimization, Elsevier ScienceDirect Applied Energy, 2010, pp.320-326
3. [Ameli2010] Ameli M.T., Shokri V., Shokri S., Using Fuzzy Logic & Full Search for Distributed Generation Allocation to Reduce Losses and Improve Voltage Profile, International Conference on Computer Information Systems and Industrial Management Applications (CISIM), Krakow, 2010, pp. 626-630
4. [Amjady2001] Amjady N., Short-term hourly load forecasting using time-series modeling with peak load estimation capability, IEEE Transactions on Power Systems, Vol. 16, Issue 3, 2001, pp. 498-505
5. [Amjady2008] Amjady N., Keynia F., Mid-term load forecasting of power systems by a new prediction method, Elsevier ScienceDirect Energy Conversion and Management, 2008, pp. 2678-2687
6. [ANRE2013] Raport național ANRE 2013, <http://www.anre.ro>
7. [ANRE2014] Raport anual ANRE 2014, <http://www.anre.ro/ro/despre-anre/rapoarte-anuale>
8. [Atwa2010] Atwa Y.M., El-Saadany E.F., Salama M.M.A., Seethapathy R., Optimal Renewable Resources Mix Distribution System Energy Loss Minimization, IEEE Transactions on Power Systems, Vol. 25, 2010, pp. 360-370
9. [Bakirtzis1996] Bakirtzis A.G., Petridis V., Kiartzis S.J., Alexiadis M.C., Maissis A.H., A neural network short term load forecasting model for the Greek power system, IEEE Transactions on Power Systems, Vol. 11, 1996, pp. 858-863
10. [Bala2011] Băla C., **Chiș V.**, Crăciun M.D., Considerations on the management of preventive maintenance to electrical transformers, Annals of the Oradea University., Fascicle of Management and Technological Engineering, Volume X (XX), nr. 1, 2011, pp. 5-8
11. [Bala2011a] Băla C., **Chiș V.**, Crăciun M.D., The use of databases in the assessment of power transformers, Proceedings of the International Conference on Theory and Applications in Mathematics and Informatics ICTAMI 2011, Acta Universitatis Apulensis, Special Issue, pp. 445-452
12. [Barin2010] Barin A., Canha L.N., Abaide A.R., Magnago K.F., A critical analysis of CDM projects concerning sustainability: The use of fuzzy logic for CDM project selection, Energy Market (EEM), 2010 7th International Conference on the European, 2010, pp. 1-5
13. [Bădulescu2005] Bădulescu L.A., Decision Tree – Predictive Model in Data Mining, Electrotehnica, Electronica, Automatica, Vol. 53, Nr. 4, 2005, pp.31-34
14. [Bălăceanu1983] Bălăceanu M., Probleme de arhitectură și reprezentare a cunoștințelor în sistemele expert în inteligența artificială și robotică, Editura Academiei București, 1983

15. [Bărbulescu2015] Bărbulescu C., Kilyeni St., Deacu A., **Chiş V.**, Enhanced ANN approach for load curve forecast, *Engineering Science and Technology: An International Journal (ESTIJ)*, Vol. 5, Nr. 4, 2015, pp. 279-284
16. [Bărbulescu2016] Bărbulescu C., Kilyeni St., Deacu A., **Chiş V.**, Power Consumption Forecast Quality Assessment, *Proceedings of the 18th IEEE Mediterranean Electrotechnical Conference MELECON, Limassol, Cyprus, 2016* (lucrare acceptată)
17. [Beni1989] Beni G., Wang J., *Swarm intelligence in cellular robotic systems*, Dario P., Sandini G., Aebischer P., *Robotics and biological systems: Towards a new bionics*, NATO ASI Series, Series F: Computer and System Science, Springer, Vol.102, 1993, pp.703-712
18. [Berian2010] Berian S., *Cercetări Privind Potenţialul Transdisciplinar al Mecatronicii*, Teză de doctorat, Universitatea Tehnică din Cluj-Napoca, 2010
19. [Bonnet1984] Bonnet, A., *L' intelligence artificielle: Promesses et réalités*, Inter-éditions Paris, 1984
20. [Brumar2012] Brumar C.I., Fabian R.D., Manolescu M.J., **Chis V.**, Memetic Engineering for Permanent Education in Line with Sustainable Growth, *International Journal of Computers Communications & Control*, Vol. 7, Issue 5, 2012, pp. 807-815
21. [Bucerzan2010] Bucerzan D., Crăciun M., **Chiş V.**, Raţiu C., Stream Ciphers Analysis Methods, *International Journal of Computers Communications & Control*, Vol. 5, Issue 4, 2010, pp. 483-489
22. [Carpinelli2001] Carpinelli G., Celli G., Pilo F., Russo A., *Distributed Generation Siting and Sizing under Uncertainty*, *Power Tech Proceedings, 2001 IEEE Porto*, Vol. 4, 2001
23. [Carpinelli2005] Carpinelli G., Celli G., Mocci S., Pilo F., Russo A., *Optimisation of embedded generation sizing and siting by using a double trade-off method*, *IEE Proceedings - Generation, Transmission and Distribution*, Vol. 152, Issue 4, 2005, pp. 503-513,
24. [Cârţină1994] Cârţină Gh, Georgescu Ghe., Gavrilăş M., Bonciu C., *Reţele neuronale artificiale şi sisteme expert în energetică*, Editura Gheorghe Asachi, Iaşi, 1994
25. [Cârţină2002] Cârţină Gh., Grigoraş Gh., *Tehnici moderne de optimizare. Aplicaţii în energetică*, Editura Venus, Iaşi, 2002
26. [Cârţină2004] Cârţină Gh., Grigoraş Gh., *Tehnici de Inteligenţă Artificială în electroenergetică*, Editura SETIS, Iaşi, 2004
27. [Cârţină2005] Cârţină Gh., Grigoraş Gh., Bobric E. C., *Tehnici de Clustering în modelarea fuzzy*, Editura Venus, Iaşi, 2005
28. [CCCE2013] *Provocările şi politica în domeniul Energiei, Contribuţia Comisiei la reuniunea CE din data de 22 mai 2013*, <http://ec.europa.eu/europe2020>
29. [Celli2001] Celli G., Pilo F., *MV Network Planning under Uncertainty on Distributed Generation Penetration*, *Proceedings of the IEEE PES Summer Meeting*, Nr. 1, 2001, pp. 485-490
30. [Celli2005] Celli G., Ghiani E., Mocci S., Pilo F., *A multiobjective evolutionary algorithm for the sizing and siting of distributed generation*, *IEEE Transactions on Power Systems*, Vol. 20, nr.2, 2005, pp. 750-757
31. [Charytoniuk1998] Charytoniuk W., Chen M.S., Van Olinda P., *Nonparametric Regression Based Short-Team Load Forecasting*, *IEEE Transaction on Power Systems*, Vol. 13, No. 3, 1998, pp. 735-730

32. [Chauhan2005] Chauhan B.K., Sharma A., Hanmandlu M., Neuro-Fuzzy Approach Based Short Term Electric Load Forecasting, IEEE Transmission and Distribution Conference and Exhibition, 2005, pp. 1-5
33. [Chen1995] Chen J.F., Wang W.M., Huang C.-M., Analysis of an adaptive timeseries autoregressive moving-average (ARMA) model for short-term load forecasting, Electric Power Systems Research, Vol. 34, 1995, pp. 187-196
34. [Chen1996] Chen C.S., Tzeng Y.M., Hwang J.C., The Application of Artificial Neural Networks to Substation Load Forecasting, Electric Power System Research, Vol. 38, No. 2, 1996, pp. 153-16
35. [Chen2001] Chen H., Canizares A.C., Ajit S., ANN based Short-Term Load Forecasting in Electricity markets, Proceedings of the IEEE Power Engineering Society Winter Meeting, Vol. 2, 2001
36. [Chen2004] Chen B.-J., Chang M.-W., Lin C.-J., Load forecasting using support vector Machines: a study on EUNITE competition 2001, IEEE Transactions on Power Systems, Vol. 19, 2004, pp. 1821-1830
37. [Chiş2008] **Chiş V.**, A graphical user interface for plotting data, Bulletins for Applied & Computer Mathematics, BAM-CXII/2008, Nr 2366, Technical University of Budapest, Zentralblatt MATH, 2008, pp. 135-141
38. [Chiş2009] **Chiş V.**, Modeling transformers in Matlab-Simulink, Annals of the Oradea University, Volume VIII (XVIII), 2009, pp. 161-167
39. [Chiş2009a] **Chiş V.**, Electrical thermography for predictive maintenance, Annals of the Oradea University, Volume VIII (XVIII), 2009, pp. 168-173 (BDI)
40. [Chiş2011] **Chiş V.**, Velicescu C., Modeling Transmission Lines Energization with PSCAD/EMTDC, Proceedings of the 6th IEEE International Symposium on Applied Computational Intelligence and Informatics SACI, Timișoara, Romania, 2011, pp.155-158 (Proceedings ISI)
41. [Chiş2011a] **Chiş V.**, Crăciun M., Băla C, Comparision of two program packages for switching overvoltages simulation, Proceeedings of International Conference on Innovative Technologies, IN-TECH Bratislava, 2011, pp. 207-210
42. [Chiş2014] **Chiş V.**, Deacu A., Fuzzy logic applications in power systems, Proceedings of the International Symposium Research and Education in Innovation Era, 5th Edition, Arad, 2014, pp. 21-27
43. [Chiş2015] **Chiş V.**, Raport științific nr. 1 cu rezultate intermediare ale cercetării, Universitatea Politehnica Timișoara, Facultatea de Electrotehnică și Electroenergetică, Departamentul de Electroenergetică, Timișoara, 2015
44. [Chiş2015a] **Chiş V.**, Raport științific nr. 2 cu rezultate intermediare ale cercetării, Universitatea Politehnica Timișoara, Facultatea de Electrotehnică și Electroenergetică, Departamentul de Electroenergetică, Timișoara, 2015
45. [Cho1995] Cho M.Y., Hwang J.C., Chen C.S., Customer short-term load forecasting by using ARIMA transfer function model, Proceedings of the International Conference on Energy Management and Power Delivery, EMPD, 1995, pp. 317-322
46. [Chow1997] Chow M.Z., Tram H., Application of Fuzzy Logic Technology for Spatial Load Forecasting, IEEE Transactions on Power Systems, Vol. 13, Nr. 3, 1997, pp. 1360-1366
47. [Chow1997a] Chow Y.L., Lin C.C., Interactive Fuzzy Satisfyng Method for Optimal Multi-Objective VAR Planing in Power Systems, IEEE Proceedings Generation Transmission Distribution, Vol. 4, No. 6, 1994, pp. 554-559
48. [Christiansen1971] Christiansen W., Short Term Load Forecasting Using General Exponential Smoothing, IEEE Transactions on PAS, 1971, pp. 900-910

49. [CIGRE1992] Panorama sur le pratique actuelles concernant la prevision de consommation et la gestion de la charge, Raport CIGRE, GT 39.03, Electra Nr. 5, 145, 1992
50. [Crăciun2011] Crăciun M.D., **Chiș V.**, Băla C., Methods for discretizing continuous variables within the framework of bayesian networks, Proceedings of the International Conference on Theory and Applications in Mathematics and Informatics ICTAMI 2011, Acta Universitatis Apulensis, Special Issue, pp. 433-443
51. [Deacu2015] Deacu A., Prognoza consumului de energie electrică utilizând rețele neuronale artificiale, Teză de doctorat, Universitatea Politehnica Timișoara, 2015
52. [Deacu2015a] Deacu A., Kilyeni Șt., Bărbulescu C., Schiopu R., Simo A., ANN based Load Forecasting, Proceedings of the UPEC International Conference, Staffordshire, UK, 2015, pp. 1-6
53. [Dimitrovski2000] Dimitrovski A.D., Matos M.A., Fuzzy Engineering Economic Analysis, IEEE Tranzactions on Power Systems, Vol. 15, Nr. 1, 2000, pp. 1360-1366
54. [Dir2009/72] Directiva 2009/72/CE a Parlamentului European și a Consiliului privind normele comune pentru piața internă a energiei electrice și de abrogare a Directivei 2003/54/CE
55. [Djukanovic1993] Djukanovic M., Sobajic D.J., Pao Y., Unsupervised / supervised learning concept for 24-house load forecasting, IEE Proceedings – C Generation, Transmission and Distribution, Vol. 140, 1993, pp. 11-318
56. [Drezga1999] Drezga I., Rahman S., Short-term load forecasting with local ANN predictors, IEEE Transactions on Power Systems, Vol. 14, 1999, pp. 844-850
57. [Dumitrescu1996] Dumitrescu D., Costin H., Rețele neuronale. Teorie și aplicații, Editura Teora, București, 1996
58. [Dumitrescu2000] Dumitrescu D., Principiile inteligenței artificiale, Editura Albastră, Cluj Napoca, 2000
59. [Dumitrescu2006] Dumitrescu D., Algoritmi genetici și strategii evolutive – aplicații în Inteligența Artificială și în domenii conexe, Editura Albastră, Cluj Napoca, 2006
60. [Eckerson2007] Eckerson W., Predictive Analytics, TDWI Best Practices Report, 2007
61. [Engle1992] Engle R.F., Mustafa C., Rice J., Modeling peak electricity demand, Journal of Forecasting, Vol. 11, 1992, pp. 241-251
62. [EnISA2007] Energy Independence and Security Act of 2007, Public Law 110-140-Dec.19.2007, USA
63. [EnSTR2020] Energie 2020 Strategie pentru o energie competitivă, durabilă și sigură, <http://ec.europa.eu/transparency>
64. [ENTSO2015] Electricity in Europe 2014, Synthetic overview of electric system consumption, generation and exchanges in The ENTSO-E Area, ENTSO-E, Brussels, 2015
65. [Eremia2001] Eremia M., Petricică D., Bulac C, Tristiu I., Tehnici de inteligență artificială. Concepte și aplicații în sistemele electroenergetice, Editura Agir, București, 2001
66. [Eremia2006] Eremia M., Cârțină Gh., Petricică D., Bulac A.I., Bulac C., Tristiu I., Grigoraș Gh., Tehnici de inteligență artificială în conducerea sistemelor energetice, Editura AGIR, București, 2006
67. [EREGEG2009] European Regulators' Group for Electricity and Gas, Position Paper on Smart Grids – An EREGEG Public Consultation Paper, Ref: E09-EQS-30-40, 10 December 2009

68. [Espinoza2007] Espinoza M., Suykens J.A.K., Belmans R., De Moor B., Electric Load Forecasting, IEEE Control Systems Magazine, Vol. 27, 2007, pp. 43-57
69. [EUCTF2010] EU Commission Task Force for Smart Grids, Expert Group 1: Functionalities of smart grids and smart meters, Final Deliverable, 2010
70. [Falaghi2011] Falaghi H., Singh C., Haghifam M.R, Ramezani M., DG integrated multistage distribution system expansion planning, International Journal of Electrical Power & Energy Systems, Vol. 33, Issue 8, 2011, pp. 1489-1497
71. [Fan1994] Fan J.Y., McDonald J.D., A real-time implementation of short – term load forecasting for distribution power systems, IEEE Transactions on Power Systems, 1994, pp. 988-994
72. [Farahat2004] Farahat M. A., Long-Rerm industrial load forecasting and planning using neural networks technique and fuzzy interference method, UPEC, International Universities Power Engineering Conference, Vol.1, 2004, pp. 368-372
73. [Frantti2009] Frantti T., Mahonen P., Fuzzy logic-based forecasting model, Engineering Applications of Artificial Intelligence, Vol. 14, No. 2, 2001, pp. 189-201
74. [Fu2003] Fu C.W., Nguyen T.T., Models for Long-Term Energz Forecasting, Power Engineering Society General Meeting, Vol. 1, 2003, pp.1-6
75. [Fu-yuan2006] Fu-yuan H., Rong-jun L., Liu Han-xia R., A Modified Particle Swarm Algorithm Combined with Fuzzy Neural Network with Application to Financial Risk Early Warning, Proceedings of the 2006 IEEE Asia-Pacific Conference on Services Computing (APSCC'06), 2006
76. [Gandomkar2005] Gandomkar M., Vakilian M., Ehsan M., Optimal distributed generation allocation in distribution network using Hereford Ranch algorithm, Proceedings of the Eighth International Conference on Electrical Machines and Systems, Vol. 2, 2005, pp. 916 - 918
77. [Gavrilaş2005a] Gavrilaş M., Inteligență artificială și aplicații în energetică, Vol. I Teorie, Editura Politehniun, Iași, 2005
78. [Ghelardoni2013] Ghelardoni L., Ghio A., Anguita D., Energy Load Forecasting Using Empirical Mode Decomposition and Support Vector Regression, IEEE Transaction on Smart Grid, Vol. 4, No.1, 2013, pp. 549-556
79. [Ghosh2010] Ghosh A., Ledwich G., Dewadasa M., Fold back current control and admittance protection scheme for a distribution network containing distributed generators, Generation, Transmission & Distribution, IET, Vol. 4, Nr. 8, 2010, pp. 952-962
80. [Gold1985] Goldemberg D.E., Genetic Algorithms and Rule Learning in Dynamic System Control, Proceedings of the First International Conference on Genetic Algorithms and Theier Applications, Pittsburgh,1985, pp. 8-15
81. [Gorunescu2006] Gorunescu F., Data mining. Concepte, modele și tehnici, Editura Alabastră, Cluj-Napoca, 2006
82. [Gou2006] Gou Y.G., Niu D.X., Chen Y.X., Support Vector Machine Model in Electricity Load Forecasting, IEEE Conference on Machine Learning and Cybernetics, 2006, pp. 2892-2896
83. [Greatbanks2003] Greatbanks J.A., Popovic D.H., Begovic M., Pregelj A., Green T., On optimization for security and reliability of power systems with distributed generation, IEEE Power Tech Conference Proceedings, Bologna, Vol. 1, 2003
84. [Gross1987] Gross G., Galiana F.D., Short-term load forecasting, Proceedings of the IEEE, Vol. 75, 1987, pp. 1558-1573

85. [Hadar2004] Hadar A., Marin C., Petre C., Voicu A., Metode numerice în inginerie, Editura Politehnica Press, București, 2004
86. [Hayati2007] Hayati M., Short Term Load Forecasting Using Artificial Neural Networks for the West of Iran, *Journal of Applied Sciences*, Vol. 7, 2007, pp. 1582-1588
87. [Haida1994] Haida T., Muto S., Regression Based Load Forecasting Using a Transformation Technique, *IEEE Transaction on Power Systems*, Vol. 9, No. 4, 1994, pp. 1788-1794
88. [Haykin1994] Haykin S., *Neural Networks: A Comprehensive Foundation*, Macmillan College, IEEE Press Book, New York, 1994
89. [He2006] HeY.J., Zhu Y.C., Duan D.X., SunW., 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*, 1987, pp. 3152-3156
90. [Heinemann1966] Heinemann G.T., Nordman D.A., Plant E.C., The relationship between summer weather and summer loads – a regression analysis, *IEEE Transactions on Power Apparatus and Systems*, Vol. PAS-85, No. 11, 1966, pp. 1144-1154
91. [Hippert2004] Hippert H.S., Pedreira C.E., Estimating temperature profiles for short term load forecasting: neural networks compared to linear models, *IEE Proceedings – Generation, Transmission and Distribution*, Vol. 151, 2004, pp. 543- 547
92. [Ho1990] Ho K.I., Hsu Y.I., Chen C.F., Lee T.E., Liang C.C., Lai T.S., Chen K.K., Short Term Load Forecasting of Taiwan Power System Using a Knowledge Based Expert System, *IEEE Transactions on Power Systems*, Vol. 5, no.4, 1990, pp. 1214-1221
93. [Ho1992] Ho K.-L., Hsu Y.-Y., Yang C.-C., Short term load forecasting using a multilayer neural network with an adaptive learning algorithm, *IEEE Transactions on Power Systems*, Vol. 7, 1992, pp. 141-149
94. [Hong2012] Hong W.C., Dong Y., Chen L.Y., Wei S.Y., Seasonal Support vector Regression with Chaotic Genetic Algorithm in Electric Load, *ICGEC 6th International Conference on Genetic and Evolutionary Computing*, August 2012, pp.124-127
95. [Hor2005] Hor C.L., Watson S.J., Majithia S., Analyzing the Impact of Weather Variables on Monthly Electricity Demands, *IEEE Transactions on Power Systems*, Vol. 20, Nr. 4, pp. 2078-2085
96. [Huan1996] Huang S.J., Huang C.L., Genetic based multilayered perceptron for Taiwan power system, *Electric Power Systems Research*, 1996, pp. 69-74
97. [Hyde1997] Hyde O., Hodnett P.F., An Adaptable Automated Procedure for Short-Term Electricity Load Forecasting, *IEEE Transaction on Power Systems*, Vol. 12, No. 1, 1997, pp. 84-93
98. [Islam2011] Islam B.U., Comparison of Conventional and Modern Load Forecasting Techniques based on Artificial Intelligence and Expert Systems, *International Journal of Computer Science Issues*, Vol. 8, Issue 5, 2011, pp. 504-513
99. [Ismail2011] Ismail Z., Efendy R., Enrollment forecasting based on modified weight fuzzy time series, *Journal of Artificial Intelligence*, Vol. 4, Issue 1, 2011, pp. 110-118
100. [Jacobs1988] Jacobs R.A., Increased Rates of Convergence Through Learning Rate Adaptation, *Neural Networks*, Vol. I, No. 4, 1988, pp. 295-307

101. [Janiček2015] Janiček F., Cerman A., Kubica J., Sunt adevărate miturile actuale din sectorul energetic?, Mesagerul energetic, Editura Electra, Nr. 160, 2015, pp. 2-4
102. [Jigoria2009] Jigoria-Oprea D., Lustrea B., Borlea I., Kilyeni St., Barbulescu C., 2009, Short term daily load forecasting using recursive ANN, Proceedings of the IEEE International Conference EUROCON, Saint-Petersburg, Rusia, 2009, pp. 646-65
103. [Jigoria2010] Jigoria-Oprea D., Kilyeni St., Dan F., 2011, Electric energy forecast for residential user, Journal of Sustainable Energy, Nr. 2, 2011, pp. 85-90
104. [Jigoria2011] Jigoria-Oprea D., Kilyeni St., Barbulescu C., Solomonesc F., Cristian D., 2011, Power Systems Expansion Considering Large Wind Farms. Case Study: Western Romania Power System, Proceedings of the 3rd IEEE International Symposium on Exploitation of Renewable Energy Sources (EXPRES), 2011, Subotica, Serbia, pp. 95-100
105. [Jin2004] Jin L., Lai Y.J., Long T.X., Peak Load Forecasting Based on Robust Regression, Proceedings of the 8th International Conference on Probabilistic Methods Applied to Power Systems, Ames, USA, 2004, pp. 123-128
106. [Jin2010] Jin X., Dong Y., Wu J., Wang J., An Improved Combined Forecasting Method for Electric Power Load Based on Autoregressive Integrated Moving Average Model, International Conference of Information Science and Management Engineering (ISME), Vol. 2, 2010, pp. 476-480
107. [Karapidakis2007] Karapidakis S., Machine learning for frequency estimation of power systems, Applied Soft Computing, Vol. 7, No 1, 2007, pp. 105-114
108. [Keane2006] Keane A., O'Malley M., Impact of distributed generation capacity on losses, IEEE Power Engineering Society General Meeting, 2006
109. [Keane2007] Keane A., Denny E., O'Malley M., Quantifying the Impact of Connection Policy on Distributed Generation, Energy Conversion, IEEE Transactions, Vol. 22, Issue 1, 2007, pp. 189-196
110. [Khotanzad1997] Khotanzad A., Afkhami-Rohani R., Lu T.-L., Abaye A., Davis M., Maratukulam D.J., ANNSTLF - A neural-network-based electric load forecasting system, IEEE Transactions on Neural Networks, 1997, pp. 835-846
111. [Kilyeni2010] Kilyeni Șt., Tehnici numerice de analiză asistată de calculator a regimurilor de funcționare a sistemelor electroenergetice, Ed. a 2-a, Editura Orizonturi Universitare, Timișoara, 2010
112. [Kilyeni2011] Kilyeni Șt., Metode numerice. Algoritme, programe de calcul, aplicații în energetică, Ed. a 4-a, Orizonturi Universitare, Timișoara, 2011
113. [Kim1998] Kim J.O., Park S.K., Park K.W., Singh C., Dispersed generation planning using improved Hereford Ranch algorithm, Evolutionary Computation Proceedings, IEEE World Congress on Computational Intelligence, 1998, pp. 678-683
114. [Kung1991] Kung S.Y., Diamantaras K., Mao W.D., Taur J.S., Generalized Perceptron Networks with nonlinear Discriminant Functions, Neural Networks Theory and Applications, Academic Press, Boston, 1991, pp.245-279
115. [Lame1996] Lamedica R., Prudenzi A., Sforza M., et all, A neural network based technique for short-term forecasting of anomalous load periods, IEEE Transactions on Power Systems, Vol. 11, Issue 4, 1996, pp. 1749-1756
116. [Leca2015] Leca A., Un punct de vedere privind dificultățile majore și șansele de consolidare ale sectorului energetic românesc, Mesagerul energetic, Editura Electra, Nr. 158, 2015, pp. 3-9

117. [Li2002] Li Y., Fang T., Yu E., Short-term electrical load forecasting using least squares support vector machines, International Conference on Power System Technology, 2002, pp. 230-233
118. [Lijesen1971] Lijesen D.P., Rosing J., Adaptive forecasting of hourly loads based on load measurements and weather information, IEEE Transactions on Power Apparatus and Systems, Vol. PAS-90, No. 4, 1971, pp.1757-1767
119. [Liu2011] Liu J., Yu J., Short-term load forecasting system using data mining, 17th International Conference on Automation and Computing (ICAC), 2011, pp. 183-188
120. [Lu2004] Lu J.C., Niu D.X., Jia Z.Y., A study of Short-Term Load Forecasting Bades on ARIMA-ANN, Proceedings of the 3rd Intrenational Conference on Machine Learning and Cybernetics, 2004, pp. 3183-3187
121. [Luștrea2001] Luștrea B., Prognoza consumului de energie, Editura AGIR, București, 2001
122. [Luștrea2004] Luștrea B., Elemente de inteligență artificială cu aplicații în energetică, Universitatea Politehnica Timișoara, 2004
123. [Matlab] Users guide, <http://www.mathworks.com/>
124. [Minsky1975] Minsky, M.L., A framework for representing knowledge, The Psychology of Computer Vision, 1975, pp. 211-277
125. [Mohammed2008] Mohammed E.T, Fawwaz E.K., Short-term forecasting of Jordanian electricity demand using particle swarm optimization, Electric Power Systems Research, Vol. 78, 2008, pp. 425-433
126. [Momoh1995] Momoh J.A., MA X.W., Tomsovic K., Overview and literature survey of fuzzy set theory in power systems, IEEE Transactions Power Systems,1995, pp. 1676-1690
127. [Mordjaoui2010] Mordjaoui, M., Boudjema, B., Bouabaz, M., Daira, R., Short-Term Electric Load Forecasting Using Neuro-Fuzzy Modeling for Nonlinear System Identification, Proceedings of International 3rd Conference on Nonlinear Science and Complexity (NSC'10), Ankara, No. 64, 2010
128. [Mori1996] Mori H., Kobayashi H., Optimal Fuzzy Inference for Short-term Load Forecasting, IEEE Transactions on Power System, 11(1), 1996, pp. 390-396
129. [Mori2001] Mori H., Kosemura N., Optimal regression tree based rule discovery for short-term load forecasting, Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference, 2001, pp.421-426
130. [Mori2002] Mori H., Kosemura N., Kondo T., Numa K., Data mining for short-term load forecasting, IEEE Power Engineering Society, Vol. 1, 2002, pp. 623-624
131. [Mușatescu2012] Mușatescu V., Leca A, Vlădescu A., Impactul investițiilor din domeniul energetic asupra creșterii economice, Editura Economică București, 2012
132. [Nazarco1999] Nazarco J., Zalewski W., The Fuzzy Regresion Aproach to Peak Load Estimation on Power Distributions Systems, IEEE Tranzactions on Power Systems, Vol. 14, Nr. 3, 1999, pp. 809-814
133. [Neagoe2011] Neagoe M., Inteligență Artificială și Sisteme Expert, Reprografia Universității Transilvania, Brașov, 2011
134. [Negrea2006] Negrea R., Modelare statistică și stochastică, Editura Politehnica, Timișoara, 2006
135. [Ochoa2008] Ochoa L.F, Dent C.J., Harrison G.P., Maximisation of intermittent distributed generation in active networks, SmartGrids for Distribution, IET-CIRED, CIRED Seminar, Frankfurt, 2008, pp. 1-4

136. [Pandian2006] Pandian S.C., Duraiswamy K., Rajan C.C.A., Kanararaj N., Fuzzy approach for short term load forecasting, *Electric Power Systems Research*, Vol. 76, 2006, pp. 541-548
137. [Papalex1990] Papalexopoulos A.D., Hesterberg T.C., A Regression Based Approach to Short Term Load Forecasting, *IEEE Transactions on Power Systems*, 5(1), 1990, pp. 40-45
138. [Parizad2010] Parizad A., Khazali A., Kalantar M., Optimal placement of distributed generation with sensitivity factors considering voltage stability and losses indices, *Electrical Engineering (ICEE)*, 2010 18th Iranian Conference, 2010, pp. 848-855
139. [Park1991] Park D.C., El-Sharkawi M.A., Marks II R.J., Atlas L.E., Damborg M.J., Electric load forecasting using an artificial neural network, *IEEE Transactions on Power Systems*, Vol. 6, No. 2, 1991, pp. 442-449
140. [Parlos1994] Parlos A.G., Fernandez B., Atiya A.F., Muthusami J., Tsai W.K., An Accelerated Learning Algorithm for Multilayer Perceptron Networks, *IEEE Transactions on Neural Networks*, Vol. 5, No. 3, 1994, pp.493-497
141. [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, 1992, pp. 250-257
142. [Peng1993] Peng T.M., Hubele N.F., Karady G.G., An adaptive neural network approach to one-week ahead load forecasting, *IEEE Transactions on Power Systems*, Vol. 8, Issue 3, 1993, pp. 1195-1203
143. [Qingle2010] Qingle P., Min Z., Very Short-Term Load Forecasting Based on Neural Network and Rough Set, *International Conference on Intelligent Technology and Automation*, 2010, pp. 1132-1135
144. [Quaiyum2011] Quaiyum S., Khan Y.I., Rahman S., Barman P., Artificial Neural Network based Short Term Load Forecasting of Power System, *International Journal of Computer Applications*, Vol. 30, No.4, 2011, pp. 1-7
145. [Quezada2006] Quezada V.H.M., Abbad J.R., Román T.G.S., Assessment of energy distribution losses for increasing penetration of distributed generation, *Power Systems*, IEEE, 2006, Vol. 21, Issue 2, pp. 533-540
146. [Rahim2008] Rahim S.R.A., Rahman T.K.A., Musirin I., Azmi S.A., Mohammed M.F., Hussain M.H., Faridun M., Comparing the Network Performance between the Installation of DG and Compensating Capacitor Using EP, *International Journal of Power, Energy and Artificial Intelligence*, Vol. 1, 2008, pp. 14-20
147. [Rahman1996] Rahman S., Hazim O., Load Forecasting for Multiple Sites Development of an Expert System-Based Technique, *Electric Power Systems Research*, Nr. 3, 1996, pp. 161-169
148. [Ranaweera1995] Ranaweera D.K., Hubele N.F., Papalexopoulos A.D., Application of radial basis function neural network model for short-term load forecasting, *Generation, Transmission and Distribution IEE Proceedings*, Vol. 142, 1995, pp. 45-50
149. [Rădășanu2000] Rădășanu D., Posibilități de utilizare a inteligenței artificiale în studiul rețelelor electrice, Teză de doctorat, Universitatea Tehnică Gheorghe Asachi Iași, 2000
150. [Riedmiller1993] Riedmiller M., Braun H., A direct Adaptive Method for Faster Backpropagation Learning: the Rprop Algorithm, *Proceedings of the 1993 IEEE International Conference on Neural Networks*, San Francisco, Vol. 1, 1993, pp. 586-591

151. [Rumelhart1986] Rumelhart D., Hinton G., Williams R., Learning Internal Representations by Error Propagation, *Parallel Distributed Processing - Explorations in the Microstructure of Cognition*, The MIT Press: Cambridge, Vol. 1, 1986, pp. 318-364
152. [Ruzic2003] Ruzic S., Vuckovic A., Nikolic N., Weather Sensitive Method for Short Term Load Forecasting in Electric Power Utility of Serbia, *IEEE Transaction on Power Systems*, Vol. 18, No. 4, 2003, pp. 1581-1586
153. [Saksornchai2005] Saksornchai T., Lee W.-J., Methaprayoon K., Liao J.R., Ross R.J., Improve the unit commitment scheduling by using the neural-network-based short-term load forecasting, *IEEE Transactions on Industry Applications*, Vol. 41, 2005, pp. 169-179
154. [SE2007] Strategia Energetică a României în perioada 2007-2020, Ministerul Economiei, Comerțului și Turismului, varianta 16, Mai 2007
155. [SEN2014] Strategia Energiei Naționale, Servicii de consultanță specializate necesare pentru elaborarea Strategiei Energetice Naționale pentru perioada 2014-2035 și perspective pentru 2050, <http://energie.gov.ro>
156. [Senjyu1998] Senjyu T., Higa S., Uezato K., Future Load Curve Shaping Based on Similarity Using Fuzzy Logic Approach, *IEEE Generation, Transmission and Distribution*, Vol. 145, 1998, pp. 375-380
157. [Senjyu2004] Senjyu T., Mandal P., Uezato K., Funabashi T., Next Day Load Curve Forecasting using Recurrent Neural Network Structure, *IEEE Proceedings - Generation, Transmission and Distribution*, Vol. 151, Issue 3, 2004, pp.388-394
158. [Sheikh2012] Sheikh S.K., Unde M.G., Short-Term Load Forecasting Using ANN Technique, *International Journal of Engineering Sciences & Emerging Technologies*, Vol. 1, Issue 2, 2012, pp. 97-107
159. [Simo2014] Simo A., Bărbulescu C., Kilyeni Șt., Deacu A., PSO based transmission network expansion planning, *Proceedings of the 17th IEEE Mediterranean Electrotechnical Conference, MELECON, Beirut, 2014*, pp. 1-6
160. [Simo2014a] Simo A, Planificarea dinamică a extinderii rețelelor de transport al energiei electrice utilizând tehnici de inteligență artificială, Teză de doctorat, Universitatea Politehnica Timișoara, 2014
161. [Singh2010] Singh D., Misra R.K., Multi-objective feeder reconfiguration in different tariff structures, *IET Generation, Transmission & Distribution*, Vol. 4, Nr. 8, 2010, pp. 974-988
162. [Soare2006] Soare C., Iliescu S.St., Făgărășan I., Tudor V., Niculescu O.F., Proiectare asistată de calculator în Matlab și Simulink. Modelarea și simularea proceselor, Editura Agir, București, 2006
163. [Srinivasan1999] Srinivasan D.S., Tan S.S., Cheng C.S., Chan E.K., Parallel neural network-fuzzy expert system strategy for short-term load forecasting: system implementation and performance evaluation, *IEEE Transactions on Power Systems*, Vol. 14, No. 3, 1999, pp. 1100-1106
164. [StEn35] Strategia energetică 2011-2035, www.bursa.ro/strategia-energetica-2011-2035
165. [SumIm2009] Sum-Im T., A Novel Differential Evolution Algorithmic Approach to Transmission Expansion Planning, Teză de doctorat, Department of Electronic and Computer Engineering, Brunel University, Uxbridge, 2009
166. [Sun2000] Sun H.B., Yu D.C., A multiple-objective optimization model of transmission enhancement planning for independent transmission company, *Proceedings IEEE Power Engineering Society Summer Meeting*, Vol.4, 2000, pp. 2033-2038

167. [Șchiopu2015] Șchiopu R., Bărbulescu C., Kilyeni St., Deacu A., Vernica A., ANN Backpropagation Power Consumption Forecasting, Proceedings of the IEEE International Conference EUROCON, Salamanca, Spain, pp. 426-431
168. [Tan2005] Tan P.N., Steinbach M., Kumar V., Introduction to Data Mining, Addison-Wesley, 2005
169. [Trans2014] Planul de dezvoltare a RET. Perioada 2014-2023, CNTEE Transelectrica S.A., București, 2013
170. [Trans2014a] Raport Anual CNTEE Transelectrica S.A, București, 2014
171. [Vapnik1995] Vapnik V.N., The Nature of Statistical Learning Theory, New York, Springer Verlag, 1995
172. [Varikuti2009] Varikuti R., Damodar Reddy, M. Optimal Placement of DG Units Using Fuzzy and Real Coded Genetic, Algorithm. Journal of Theoretical and Applied Information Technology, Vol. 7, 2009, pp. 145-151
173. [Vatră2014] Vatră F., Vatră C.A., Postolache P., Poida A., Smart Grids. Introducere pentru profesioniști, Editura SIER, București, 2014
174. [Villalba2000] Villalba S.A., Bel C.A., Hybrid demand model for load estimation and short-term load forecasting in distribution electrical systems, IEEE Transactions on Power Delivery, 15(2), 2000, pp. 764-769
175. [Vilt2010] Vilt C.R., SMART GRIDS - Retelele Energetice ale Viitorului se dezvoltă acum în România, Conferința Mediafax Talks about Energy, București, 2010, <http://www.vlab.pub.ro/resources/>
176. [Vilt2015] Vilt C.R., Influența surselor regenerabile de energie în prețul energiei electrice la utilizatorii finali, Mesagerul energetic, Editura Electra, Nr. 158, 2015, pp. 28-31
177. [VLER2014] VLER, Document de Poziție al tinerilor VLER din cadrul CNR--CME privind Fundamentarea Strategiei Energetice a României pentru perioada 2014-2035, Mesagerul energetic, Editura Electra, Nr 151-152, 2014, pp. 22-27
178. [Vuc2001] Vuc Gh., Managementul energiei electrice, Editura Agir, București, 2001
179. [Wang2004] Wang C., Nehrir M.H., Analytical Approaches for Optimal Placement of Distributed Generation Sources in Power Systems. IEEE Transactions on Power Systems, Vol. 19, 2004, pp. 2068-2076
180. [Wang2005] Wang Z.Y., Guo C.Y., Cao Y.J., A new method for short-term load forecasting integrating fuzzy-rough sets with artificial neural network, Proceedings of the 7th International Power Engineering Conference IPEC, 2005, pp. 1-173
181. [WebA] Comunicare a Comisiei catre Parlamentul European, Energia din surse regenerabile: o prezență majoră pe piața energetică europeană, <http://www.instalnews.ro/energia-din-surse-regenerabile>
182. [WebEco] <http://ecoprofit.ro/europa-energii-regenerabile-crestere-emisii-co2-scadere/>
183. [Werbos1974] Werbos P.J., Beyond Regression: New Tools for Prediction and analysis in the behavioral sciences, PhD Thesis, Harvard University, 1974
184. [White1989] White H., Learning artificial networks: A statistical perspective, Neural Computation, Vol. 1, Issue 4, 1989, pp. 425-464
185. [World2013] World Energy Outlook 2013, <http://www.worldenergyoutlook.org>
186. [Xinhui2010] Xinhui D., Liang W., Jiancheng S., Yan Z., 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

187. [Yang1996] Yang H.T., Huang C.M., Huang C.L., Identification of ARMAX model for short-term load forecasting. An evolutionary programming approach, IEEE Transactions on Power Systems, Vol. 11, 1996, pp. 403-408
188. [Yang1998] Yang H.T., Huang C.M., A New Short-Term Load Forecasting Approach using Self – Organizing Fuzzy ARMAX Model, IEEE Transaction on Power Systems, Vol. 13, 1998, pp. 217-225
189. [Yang2004] Yang J., Cheng H., Application of SVM to power system short-term load forecast, Power System Automation Equipment China, Vol. 24, Issue 4, 2004, pp. 30-32
190. [Yun-Feng2010] Yun-Feng D.; Qi H., Notice of Violation of IEEE Publication Principles Optimal Placement of Distributed Generation on a Radial Feeder, 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM), 2010, pp. 1-5
191. [Zhang2008] Zhang D., Song H., Chen P., Stock Market Forecasting Model Based on A Hybrid ARMA and Support Vector Machines, IEEE 15th International Conference on Management Science & Engineering, USA, September 2008, pp. 1312-1317
192. [Zheng2010] Zheng X., Electric Load Forecasting Using Bayesian Least Squares Support Vector Machine, ICNC, 6th International Conference on Natural Computation, 2010, pp.880-883
193. [Zivanovic2001] Zivanovic R., Local Regression-Based Short-Term Load Forecasting, Journal of Intelligent and Robotic Systems, Nr. 1, 2001, pp. 115-127
194. [UPT2014a] Contract UPT 45/2014, Analiza și optimizarea regimurilor de funcționare pentru rețeaua electrică de 110 kV din zona Dobrogea, Enel Distribuție Dobrogea
195. [UPT2014b] Contract UPT 11,12,13/2013, Studiu privind integrarea în sistemul electroenergetic a centralelor fotovoltaice din zona Lugoj-Făget, Enel Distribuție Banat
196. [UPT2014c] Contract UPT 24,32,84/2014, Studiu privind integrarea in sistemul electroenergetic a centralelor fotovoltaice din zona Timișoara, Enel Distribuție Banat
197. [UPT2014d] Contract UPT 70/2014, Studiu privind racordarea la SEN a microhidrocentralei MHC3, Topleț, Enel Distribuție Banat
198. [UPT2014e] Contract UPT 93/2014, Studiu privind integrarea în sistemul electroenergetic a centralei cu biomasă din localitatea Ghiroda, Enel Distribuție Banat, CNTEE Transelectrica SA

SINTEZĂ PRIVIND LUCRĂRILE PROPRII

1. [Bala2011] Băla C, **Chiş V.**, Crăciun M.D., Considerations on the management of preventive maintenance to electrical transformers, Annals of the Oradea University,, Fascicle of Management and Technological Engineering, Volume X (XX), nr. 1, 2011, pp. 5-8
2. [Bala2011a] Băla C, **Chiş V.**, Crăciun M.D., The use of databases in the assessment of power transformers, Proceedings of the International Conference on Theory and Applications in Mathematics and Informatics ICTAMI 2011, Acta Universitatis Apulensis, Special Issue, pp. 445-452
3. [Barbulescu2015] Barbulescu C., Kilyeni St., Deacu A., **Chiş V.**, Enhanced ANN approach for load curve forecast, Engineering Science and Technology: An International Journal (ESTIJ), vol. 5, nr. 4, 2015, pp. 279-284
4. [Barbulescu2016] Barbulescu C., Kilyeni St., Deacu A., **Chiş V.**, Power Consumption Forecast Quality Assessment, Proceedings of the 18th IEEE Mediterranean Electrotechnical Conference MELECON, Limassol, Cyprus, 2016, pp. 1-6 (lucrare acceptată)
5. [Brumar2012] Brumar C.I., Fabian R.D., Manolescu M.J., **Chiş V.**, Memetic Engineering for Permanent Education in Line with Sustainable Growth, International Journal of Computers Communications & Control, Vol. 7, Issue 5, 2012, pp. 807-815
6. [Bucerzan2010] Bucerzan D., Crăciun M., **Chiş V.**, Raţiu C., Stream Ciphers Analysis Methods, International Journal of Computers Communications & Control, Vol. 5, Issue 4, 2010, pp. 483-489
7. [Chiş2008] **Chiş V.**, A graphical user interface for plotting data, Bulletins for Applied & Computer Mathematics, BAM-CXII/2008, Nr 2366, Technical University of Budapest, Zentralblatt MATH, 2008, pp. 135-141
8. [Chiş2009] **Chiş V.**, Modeling transformers in Matlab-Simulink, Annals of the Oradea University, Volume VIII (XVIII), 2009, pp. 161-167
9. [Chiş2009a] **Chiş V.**, Electrical thermography for predictive maintenance, Annals of the Oradea University, Volume VIII (XVIII), 2009, pp. 168-173
10. [Chiş2011] **Chiş V.**, Velicescu C., Modeling Transmission Lines Energization with PSCAD/EMTDC, Proceedings of the 6th IEEE International Symposium on Applied Computational Intelligence and Informatics SACI, Timișoara, Romania, 2011, pp.155-158 (Proceedings ISI)
11. [Chiş2011a] **Chiş V.**, Crăciun M., Băla C, Comparision of two program packages for switching overvoltages simulation, Proceedings of International Conference on Innovative Technologies, IN-TECH Bratislava, 2011, pp. 207-210
12. [Chiş2014] **Chiş V.**, Deacu A., Fuzzy logic applications in power systems, Proceedings of the International Symposium Research and Education in Innovation Era, 5th Ed., Arad, 2014, pp. 21-27
13. [Chiş2015] **Chiş V.**, Raport științific nr. 1 cu rezultate intermediare ale cercetării, Universitatea Politehnică Timișoara, Facultatea de Electrotehnică și Electroenergetică, Departamentul de Electroenergetică, Timișoara, 2015

14. [Chiş2015a] **Chiş V.**, Raport științific nr. 2 cu rezultate intermediare ale cercetării, Universitatea Politehnică Timișoara, Facultatea de Electrotehnică și Electroenergetică, Departamentul de Electroenergetică, Timișoara, 2015
15. [Crăciun2011] Crăciun M.D., **Chiş V.**, Băla C., Methods for discretizing continuous variables within the framework of bayesian networks, Proceedings of the International Conference on Theory and Applications in Mathematics and Informatics ICTAMI 2011, Acta Universitatis Apulensis, Special Issue, pp. 433-443
16. [UPT2014a] Contract UPT 45/2014, Analiza și optimizarea regimurilor de funcționare pentru rețeaua electrică de 110 kV din zona Dobrogea, Enel Distribuție Dobrogea
17. [UPT2014b] Contract UPT 11,12,13/2013, Studiu privind integrarea în sistemul electroenergetic a centralelor fotovoltaice din zona Lugoj-Făget, Enel Distribuție Banat
18. [UPT2014c] Contract UPT 24,32,84/2014, Studiu privind integrarea în sistemul electroenergetic a centralelor fotovoltaice din zona Timișoara, Enel Distribuție Banat
19. [UPT2014d] Contract UPT 70/2014, Studiu privind racordarea la SEN a microhidrocentralei MHC3, Topleț, Enel Distribuție Banat
20. [UPT2014e] Contract UPT 93/2014, Studiu privind integrarea în sistemul electroenergetic a centralei cu biomasă din localitatea Ghiroda, Enel Distribuție Banat, CNTEE Transelectrica SA