


Ing. Adrian STOIAN

CONTRIBUȚII PRIVIND PROGNOZA CONSUMULUI DE ENERGIE
ELECTRICĂ ȘI A CERERII DE PUTERE PENTRU UTILIZATORI DE
ENERGIE ELECTRICĂ

TEZĂ DE DOCTORAT

BIBLIOTECA CENTRALĂ
UNIVERSITATEA "POLITEHNICA"
TIMIȘOARA



Conducător științific:

Prof. dr. ing. Ioan ȘORA

TIMIȘOARA - 2003

CUPRINS

INTRODUCERE	1
1. IMPORTANȚA ACTIVITĂȚII DE PROGNOZĂ	4
1.1. Considerații generale	4
1.2. Utilizarea prognozei în energetică	5
1.3. Prognoza pe termen scurt	6
1.4. Prognoza pe termen mediu	7
1.4.1. Stabilirea prețurilor și cantităților contractuale	8
1.4.2. Model de prognoză pe termen mediu	9
1.5. Concluzii	12
Bibliografie	13
2. PROGNOZA CONSUMULUI DE ENERGIE ȘI PUTERE	14
2.1. Probleme generale. Clasificări și definiții.	14
2.2. Componentele modelului matematic al consumului de energie electrică	17
2.2.1. Modele matematice folosite pentru trend	20
2.3. Metode directe de prognoză	20
2.3.1. Principiul metodelor directe	20
2.3.2. Modelarea trendului	22
2.3.3. Aprecierea calității trendului. Analiza de corelație	22
2.4. Metode indirecte de prognoză	24
2.5. Prognoza pe termen scurt a sarcinii electrice	24
2.6. Concluzii	27
Bibliografie	28
3. METODE MODERNE DE PROGNOZĂ A ENERGIEI ELECTRICE. FOLOSIREA INTELIGENȚEI ARTIFICIALE	31
3.1. Modele și structuri de rețele neuronale artificiale	32
3.1.1. Aspecte generale	32
3.1.2. Arhitectura tipică a unei rețele neuronale artificiale	32
3.1.3. Caracteristici principale și clasificarea RNA	35
3.1.4. Rețele neuronale de tip Perceptron Multistrat	38
3.1.4.1. Algoritm standard Back – Propagation pentru antrenarea PMS	40
3.1.4.2. Algoritm Back Propagation cu momentum	43
3.1.4.3. Algoritm de învățare Batch Back Propagation	43
3.1.4.4. Algoritm Resilient Propagation	44
3.1.5. Rețele de tip Perceptron Multistrat cu conexiuni feedback (Back Propagation Through Time)	45
3.1.6. Rețele Kohonen	47

3.2. Tratarea seriilor de timp cu metode statistice și rețele neuronale artificiale. Analiză comparativă.	49
3.2.1. Proces autoregresiv	49
3.2.2. Proces cu medie mobilă	50
3.2.3. Proces autoregresiv cu medie mobilă	51
3.3. Avantajele prognozei sarcinii electrice folosind rețele neuronale artificiale în raport cu metodele statistice	51
3.4. Utilizarea rețelelor neuronale artificiale în prognoza pe termen scurt a sarcinii electrice	54
3.5. Concluzii	55
Bibliografie	56
4. PROGNOZA CURBELOR DE SARCINĂ	58
4.1. Curbe de sarcină – elemente caracteristice ale consumatorilor	58
4.2. Obținerea curbelor de sarcină	59
4.3. Sectorizarea suprafeței curbelor de sarcină	60
4.4. Mărimi caracteristice ale curbelor de sarcină	61
4.5. Modelarea curbelor de sarcină	64
4.6. Utilizarea curbelor de sarcină	68
4.7. Metode de prognoză a curbelor de sarcină	69
4.7.1. Serii de timp; definiții, clasificări, modele matematice	70
4.7.2. Modele folosite în studiul seriilor de timp	73
4.7.3. Prognoza seriilor de timp	79
4.7.4. Metodă de prognoză a curbelor de sarcină bazată pe folosirea seriilor de timp	81
4.7.5. Aplicație a metodei prognozei curbelor de sarcină folosind seriile de timp	82
4.8. Concluzii	84
Bibliografie	87
5. TEHNICI DE PROGNOZĂ A CONSUMULUI DE ENERGIE ELECTRICĂ ȘI A CURBELOR DE SARCINĂ	88
5.1. Serii Fourier. Probleme generale	88
5.2. Descompunerea curbelor de sarcină în serii Fourier	91
5.2.1. Stabilirea numărului de intervale din curba de sarcină	92
5.2.2. Stabilirea numărului minim de coeficienți Fourier luați în considerare	95
5.3. Prognoza coeficienților Fourier	100
5.3.1. Analiza influenței abaterilor coeficienților Fourier asupra reziduurilor	107
5.4. Compensarea erorilor	112
5.5. Algoritmi pentru efectuarea prognozei	113
5.5.1. Energia consumată săptămânal	113
5.5.2. Prognoza energiilor zilnice	116
5.5.2.1. Gruparea puterilor zilnice raportate	116
5.5.2.2. Exemplu de aplicare	122
5.5.2.3. Analiza spectrală și prognoza coeficienților Fourier	124
5.5.3. Prognoza curbelor de sarcină zilnice	127
5.6. Concluzii	138
Bibliografie	143

6. PROGRAM PENTRU PROGNOZA ENERGIEI ȘI PUTERII PE TERMEN SCURT - PRENPS	146
6.1. Introducere	146
6.2. Modele matematice	146
6.2.1. Algoritm pentru prognoza energiei săptămânale	147
6.2.2. Algoritm pentru prognoza energiei zilnice	147
6.2.3. Prognoza curbelor de sarcină zilnică	147
6.3. Prezentarea programului	147
6.4. Concluzii	148
Bibliografie	149
Anexa 6.1.	150
7. CONCLUZII GENERALE ȘI CONTRIBUȚII	176

INTRODUCERE

Tendențele actuale de liberalizare a pieței de energie, de privatizare a sectorului energetic, precum și necesitatea unei planificări mai atente a achizițiilor și stocurilor de resurse energetice vor avea ca rezultat creșterea complexității activităților de planificare, exploatare și conducere a rețelelor electrice. Funcții operaționale fundamentale, ca planificarea puterii generate și a rezervei de putere la nivelul sistemului, coordonarea producției hidro- termo, programarea mentenanței, monitorizarea securității sistemului sau planificarea tranzacțiilor cu energie, cer o prognoză sigură a sarcinii pe termen scurt. Datorită importanței prognozei sarcinii pe termen scurt, cercetările în acest domeniu din ultimii 40 de ani au condus la dezvoltarea a numeroase metode de prognoză. Aceste metode sunt în principal clasificate în două categorii: metode clasice și tehnici bazate pe inteligență artificială. Dintre metodele clasice se amintesc: modelele liniare și/sau neliniare ale seriilor de timp, tehnici de regresie, modele de aproximare cu funcții spline, cu netezire exponențială, filtre Kalaman sau sisteme expert. Dintre acestea, cel mai larg spațiu acordat în literatura de specialitate revine seriilor de timp: modele staționare sau nestaționare, autoregresive sau cu medie mobilă, de tip liniar sau neliniar.

Cele mai recente cercetări și rezultate publicate în literatura de specialitate în ultimii ani arată o deplasare a interesului legat de prognoza consumului de energie electrică către modelele care folosesc rețele neuronale artificiale. Studiile întreprinse au arătat că o rețea neuronală artificială (RNA), cu sau fără neuroni ascunși, cu funcții de activare liniare sau de tip sigmoid, furnizează rezultate superioare celor obținute cu modelele clasice.

Într-o economie aflată în proces de tranziție cauzele, factorii și tendințele, care au determinat evoluția consumului de energie în trecut, nu se mai păstrează și în viitor; pe durata prognozei pot să intervină schimbări bruște care să influențeze evoluția consumului.

În acest context, în cadrul tezei de doctorat este prezentată o metodă originală de prognoză a curbilor de sarcină zilnice prin descompunerea în serii Fourier, metodă care vine să completeze în mod eficient aplicațiile transformatei Fourier în domeniul tehnic, într-o direcție complet diferită de aceea a tehnicii semnalelor. Sistemul de prognoză funcționează pe baza unor corelații dintre energia săptămânală, zilnică, palierele curbei de sarcină și diferiți indicatori. Această funcționare se efectuează etapizat: săptămână – zi – oră, fiecare etapă sprijinindu-se pe aceea anterioară, dar este posibilă și funcționarea distinctă în cadrul fiecărei etape.

Procedura de prognoză reclamă cunoașterea unor date despre consum (puterile orare zilnice pentru fiecare zi din săptămână), pe parcursul a 5 săptămâni. Seria de timp scurtă pentru baza de date elimină o parte din erorile cauzate de schimbările bruște și semnificative ale condițiilor, care conduc la violarea ipotezelor inițiale de lucru.

Lucrarea tratează atât problemele teoretice ale domeniului, cu scopul de a face o sinteză a conceptelor și metodelor, deja foarte numeroase și diverse, dar în același timp prezintă doi algoritmi originali pentru prognoza consumurilor de energie săptămânală și pentru prognoza consumului de energie zilnică pe termen scurt, încorporați într-un program de prognoză pe termen scurt numit PRENPS(PRognoza ENergiei și Puterii Săptămânale). Unul dintre algoritmi are la bază sensibilitatea termică a consumului de energie electrică, celălalt distanța termică limită care marchează grupele de consum valoric.

Lucrarea încearcă să asigure un caracter unitar prin construirea aplicațiilor în jurul tehnicilor prezentate în fiecare dintre capitole.

Teza de doctorat este structurată pe șase capitole, dintre care două prezintă contribuțiile originale ale autorului la dezvoltarea metodelor de prognoză pe termen scurt. Capitolul introductiv și cel de concluzii vin să întregescă conținutul tezei. Pe ansamblu, teza se întinde pe 203 pagini și conține 160 referințe bibliografice.

Capitolul 1 prezintă utilitatea prognozei în energetică și mai ales în condițiile liberalizării pieței de energie electrică. Sunt prezentați principalii factori care influențează consumul de energie electrică pe termen scurt și mediu, precum și modul de stabilire a cantităților de energie și a prețurilor pe piața de energie electrică.

Capitolul 2 trece în revistă problemele generale pe care le comportă activitatea de prognoză a consumului de energie și putere, insistându-se asupra metodelor clasice de prognoză și a modului în care acestea se regăsesc actualmente în unele metodologii de prognoză folosite de companiile de electricitate.

Capitolul 3 realizează o prezentare detaliată a principalelor aspecte teoretice privind rețelele neuronale artificiale. Sunt redate detaliat câteva tipuri de rețele neuronale artificiale, precum și algoritmi lor de învățare. Se prezintă și o analiză comparativă privind tratarea seriilor de timp cu metode statistice și rețele neuronale artificiale. Capitolul se încheie cu o aplicație utilizând o rețea neuronală artificială de tip Perceptron Multistrat cu un strat ascuns.

Capitolul 4 prezintă câteva probleme introductive legate de curbele de sarcină, necesare abordării prognozelor. Astfel, se fac referiri la mărimile caracteristice, modelarea și utilizarea curbelor de sarcină, metodele de prognoză, cu detalierea metodelor ce folosesc seriile de timp iar, în final, este redată o aplicație a metodei prognozei curbelor de sarcină ce utilizează seriile de timp, aplicație utilizată de către Operatorul Comercial în activitatea de prognoză a curbei de sarcină la nivelul sistemului energetic național.

Capitolul 5 prezintă contribuțiile autorului privind elaborarea unor tehnici noi originale de prognoză a necesarului de energie și a curbelor de sarcină, tehnici pe baza cărora s-au elaborat algoritmi de prognoză constituiți într-un program de calcul complex. În acest sens, pentru început, s-au prezentat câteva elemente generale privind descompunerea funcțiilor în serii Fourier: condiții necesare a fi îndeplinite, relații de calcul pentru coeficienți, număr de armonici luate în considerare. Apoi s-a trecut la analiza problemelor pe care le ridică descompunerea curbelor de sarcină în serii Fourier.

Capitolul 6 prezintă modelele matematice care au stat la baza elaborării programului pentru prognoza energiei și puterii pe termen scurt (PRENPS). Sunt trecuți în revistă algoritmi, care reprezintă contribuțiile originale ale autorului, iar în anexă este prezentat manualul de operare.

Capitolul 7 prezintă concluziile desprinse din lucrare și contribuțiile originale ale autorului.

Demn de menționat este faptul că realizarea acestei lucrări este rezultatul firesc al activității desfășurate de către autor în cadrul societății ELECTRICA SA București – Direcția Furnizarea Energiei Electrice- Serviciul Furnizarea Energiei Electrice.

Cu această ocazie autorul lucrării s-a preocupat de implementarea unor tehnici de prognoză a consumurilor de energie electrică, urmărirea și analiza rezultatelor obținute și, nu în ultimul rând, de elaborarea, comunicarea și publicarea unor lucrări științifice la manifestări specifice de nivel național sau internațional.

Modul în care au fost percepute metodele propuse pentru prognoza pe termen scurt a curbelor de sarcină și a consumurilor de energie de către specialiști, aprecierile date de către aceștia în cadrul IASTED sau CIREC, conferă o garanție pentru calitatea algoritmilor propuși și, firește, pentru programul întocmit.

Realizarea lucrării a fost posibilă datorită sprijinul competent din partea domnului prof. dr. ing. Ioan Șora, în calitate de conducător științific. Pe această cale aduc mulțumiri deosebite domniei sale pentru îndrumarea permanentă acordată, sprijinul consecvent și îndemnurile adresate mereu pentru finalizarea tezei.

Mulțumiri deosebite se cuvin domnului prof. dr. ing. Adrian Buta pentru ajutorul acordat în cadrul colaborărilor contractuale pe care le-am avut cu Universitatea Politehnica Timișoara pe linia prognozelor consumurilor de energie electrică și curbelor de sarcină, precum și pentru însemnatul material bibliografic pus la dispoziție.

Nu în ultimul rând, mulțumesc familiei mele pentru încurajările date pe toată perioada elaborării tezei de doctorat și pentru faptul că au făcut tot posibilul să-mi creeze condiții optime pentru lucrul acasă.

IMPORTANȚA ACTIVITĂȚII DE PROGNOZĂ

1.1. Considerații generale

Prognoza poate fi definită ca o aproximare a unor evenimente viitoare necunoscute. Justificarea acesteia este dată de existența unor evenimente care nu se cunosc, dar care sunt importante pentru luarea unor decizii; evident nu va fi posibilă eliminarea incertitudinilor. Prognoza este un instrument care încearcă să minimizeze aceste incertitudini.

Din cele mai vechi timpuri, din motive practice, Omul a fost preocupat de prognoza vremii, a mișcării astrilor pe bolta cerească, iar din motive existențiale a căutat să prospecteze viitorul. Prognoza este o activitate specific umană, având profunde aspecte filozofice și practice. Răspunsurile la întrebările fundamentale:

- Poate fi realitatea înconjurătoare cunoscută?
- Care sunt mijloacele de cunoaștere a realității (lumii) ?
- Care este raportul dintre cauzalitate și întâmplare în derularea implacabilă a timpului ?

au fost preocupări ale Religiei, Filozofiei și Științelor Naturii. Desigur, răspunsurile posibile au fost multiple, câteva din ele fiind fundamentale, dar nici unul din ele definitiv și irevocabil. Ele au marcat evoluția gradului de cunoaștere și înțelegere umană în decursul timpului.

Dezvoltarea industrială puternică și accelerată a adus schimbări importante în toate domeniile, care s-au reflectat atât în mediul înconjurător, cât și la nivel de individ și societate. Singura posibilitate de a menține cât de cât controlul asupra rapidelor și importantelor transformări este recurgerea la un comportament adaptiv în raport cu aceste schimbări. Aceasta presupune într-o primă etapă determinarea prin prognoză a evoluției viitoare și aprecierea corectă a impactului factorilor și deciziilor actuale asupra viitorului, în etapa a doua, finală, cea a deciziilor, introducându-se corecțiile necesare atingerii scopurilor propuse. Trebuie remarcat că în acest scenariu există o strânsă interdependență între cele două faze ale lui și anume :

- Pe baza situației actuale, inclusiv a propunerilor de decizii, prognoza prefigurează viitorul posibil, ținând cont de incertitudinea introdusă de fenomenele întâmplătoare;
- Corecția deciziilor impuse de atingerea viitorului dorit, stabilite pe baza prognozei, va avea ca rezultat modificarea datelor acesteia, care în noile condiții va diferi de cea inițială, apropiindu-se de situația dorită.

Se înțelege de la sine că, datorită faptului că prognoza și luarea deciziilor sunt procese care se desfășoară în timp în condițiile unor perturbații aleatoare, procesul de adaptare trebuie să fie permanent, manifestându-se prin prognoze și corecții repetate care să mențină traiectoria evoluției spre ținta propusă. Mai mult, pe măsura apropierii de țintele dorite, în viitor se prefigurează noi ținte mai îndepărtate, care presupun noi orizonturi de prognoză și noi decizii.

1.2. Utilizarea prognozei în energetică

Prognoza sarcinii electrice reprezintă estimarea formei și valorilor curbelor de sarcină. Ea presupune un studiu aprofundat privind necesarul de energie pentru diferite utilizări finale. Importanța prognozei în managementul performant este fundamentală. Prognoza cererii de energie înseamnă prognoza caracteristicilor acestei cereri: mărime, evoluție în timp (curbe de sarcină, structuri de cereri (pe purtători, pe categorii de consum ș.a.). Aceasta presupune un studiu aprofundat, nu numai privind cantitatea, ci și calitatea energiei necesare pentru diferite utilizări finale. Managementul energiei electrice implică răspunderea necesităților energetice în baza unui set fixat de criterii. Există cel puțin două scopuri ale managementului sarcinii electrice. Pe de-o parte, managementul energiei electrice este mijlocul prin care se obțin importante avantaje economice în funcționarea centralelor și rețelelor electrice și în investiții necesare pentru noi centrale și rețele. Pentru a atinge acest scop, compania de electricitate trebuie să încerce să aibă o curbă de sarcină aplatizată sau - în anumite cazuri, în special în hidrocentrale - să adapteze curba de sarcină la curba debitului de apă. Această formă de management a sarcinii electrice poate conduce la :

- economii de investiții în transportul și producerea energiei electrice ;
- o mai bună utilizare a centralelor electrice:
 - evitarea pornirilor și opririlor grupurilor electrice;
 - necesitate mai mică de reglaj ;
 - funcționarea optimă un timp mai îndelungat;
- micșorarea costurilor de transport.

Un alt scop al managementului sarcinii electrice este să evite răspândirea stării de urgență în situații ca :

- dezechilibru între sarcina generală și cea consumată în sistem în timp real;
- suprasolicitarea actuală a echipamentelor în anumite părți din sistem;
- dezechilibru neprevăzut în viitor, între cerere și ofertă.

În cadrul funcționării sistemului electroenergetic un rol important revine prognozei consumului de energie și a cererii de putere pe termen scurt (de la o oră până la câteva ore), aceasta furnizând informații referitor la planificarea rezervei de putere, a gradului de încărcare a elementelor de rețea și la eventualele contingente care pot surveni.

Prognoza energiei electrice este influențată de diferiți factori: economici, de timp, meteorologici, politici, etc., cei meteorologici având un rol important în cadrul prognozei pe termen scurt. Această influență este cu atât mai pronunțată cu cât ponderea marilor consumatori în consumul final este mai redusă.

O altă categorie de factori foarte importanți în activitatea de prognoză a necesarului de energie pe termen scurt sunt aceia de timp (temporali): ciclurile zilnice, săptămânale, sezoniere. Ciclul săptămânal de lucru, necesitatea zilelor de lucru, odihnă, a celor dinainte sau după zilele de odihnă, asigură o anumită formă a curbelor de sarcină, nuanțându-le în funcție de anotimp. Aceste influențe au fost considerate ca fiind determinante în cadrul metodei de prognoză și a algoritmilor de calcul elaborați

Prognoza consumului de energie electrică are un impact asupra exploatării eficiente a sistemului energetic național, a dezvoltării acestuia și alimentării în condiții sigure și de o calitate corespunzătoare a consumatorilor. În particular, în sectorul distribuție - furnizare, prognozele consumului de energie electrică reprezintă instrumente utile pentru gestionarea tranzacțiilor cu energie pe termen scurt (una, două zile) – în cazul pieței spot – sau pe termen mediu (un an) – în cazul contractelor bilaterale cu producătorii, pentru piața angro.

În țara noastră, Autoritatea Națională de Reglementare în domeniul Energiei (ANRE) a emis o serie de decizii și reglementări care au ca obiectiv general deschiderea pieței de energie electrică și crearea condițiilor și mediul general de funcționare a acestei piețe. O parte

dintre aceste decizii privesc reglementarea condițiilor de contractare a energiei vândute între producători și furnizori/distribuitori (S.C. Electrica S.A.) [1.1.,1.2.], respectiv programarea și dispecerizarea sistemului electroenergetic național [1.3.]. Conform acestor decizii, contractele cadru de portofoliu între producătorii de energie electrică, pe de-o parte, și S.C. Electrica S.A. – în calitate de furnizor și distribuitor – pe de altă parte, au la bază prognozele pe termen mediu sub forma graficelor de sarcină orare pentru 48 zile caracteristice din cursul unui an (câte 4 zile caracteristice pentru fiecare lună). Pe de altă parte, prognoza pe termen scurt pentru următoarele două zile trebuie transmisă Operatorului Comercial, în vederea programării și dispecerizării SEN.

Cele mai recente cercetări și rezultate publicate în literatura de specialitate [1.4.,1.5.,1.6.] indică o deplasare importantă a interesului pentru problema prognozei consumului de energie electrică către modele care folosesc rețele neuronale artificiale. Astfel, studiile întreprinse au arătat că o rețea neuronală artificială cu sau fără neuroni ascunși, cu funcții de activare liniare sau de tip sigmoid, produce aceleași rezultate ca și un proces liniar sau neliniar autoregresiv cu medie mobilă. În plus, rețelele neuronale artificiale permit modelarea unor procese complexe, care – în cazul seriilor de timp – nu pot fi descrise de modele suficient de simple.

1.3. Prognoza pe termen scurt

Conform reglementărilor în vigoare în țara noastră [1.3.], fiecare furnizor trebuie să transmită la operatorul Comercial, până la ora 10:00 a zilei anterioare celei dispecerizate, prognoza consumului net de energie electrică pentru următoarele două zile energetice (48 ore). Prognoza cuprinde valorile medii orare estimate ale consumului de energie electrică activă și reactivă la nivelul furnizorului. Operatorul Comercial prelucrează prognozele pe care le centralizează de la furnizori, pe baza consumurilor medii orare înregistrate în aceeași zi calendaristică a anului anterior, a valorilor medii orare ale consumului înregistrat în zilele precedente și a prognozei meteorologice.

La dezvoltarea oricărui model de prognoză pe termen scurt a consumului de energie electrică se pornește de la caracteristicile generale ale sarcinii din zona analizată. Aceste caracteristici se referă la caracterul nestaționar al consumului de energie electrică, forma de principiu a curbelor de sarcină, comportarea sarcinii în zilele speciale și principalii factori care influențează nivelul consumului de energie.

Principalii factori care determină caracterul nestaționar al curbelor de sarcină sunt: temperatura și alți factori meteo, unele evenimente speciale (manifestări, greve, etc.) și caracterul aleatoriu al consumului de tip industrial. Luarea în considerație a evenimentelor speciale și a consumatorilor industriali este foarte dificilă și literatura de specialitate nu menționează încă asemenea abordări, astfel încât, cel mai important factor de influență rămâne temperatura [1.7.].

Forma curbelor de sarcină respectă cicluri zilnice și săptămânale. Această periodicitate nu înseamnă reproducerea exactă a curbelor de sarcină, ci înregistrarea unor mici abateri determinate de comportarea specifică a consumatorilor industriali și de condițiile meteo. Dacă se dorește clasificarea graficelor de sarcină după forma lor și se folosește ca referință săptămâna, se disting: zilele lucrătoare (de luni, până vineri) și zilele de repaus (sâmbăta și duminica). În funcție de caracteristicile fiecărei zone, zilele de sâmbătă și duminică pot fi tratate distinct [1.8.], iar zilele lucrătoare sunt separate în trei grupe, și anume: luni, marți – joi și vineri [1.8.,1.9.]. În ultimul caz, formele curbelor de sarcină sunt asemănătoare pentru toate cele 5 zile lucrătoare cu excepția dimineții de luni și serii de vineri, când sarcina este mai redusă datorită tranziției (figura 1.1.)

Zilele speciale (zilele de repaus și sărbători legale) se caracterizează prin reducerea consumului, iar forma graficelor de sarcină diferă semnificativ în raport cu restul zilelor. În

general, fie că este vorba de zilele de repaus, fie de sărbătorile legale, numărul zilelor de acest tip, din istoricul de care se dispune, este în general destul de mic, iar modelele dezvoltate întâmpină greutăți la realizarea prognozei pentru asemenea zile.

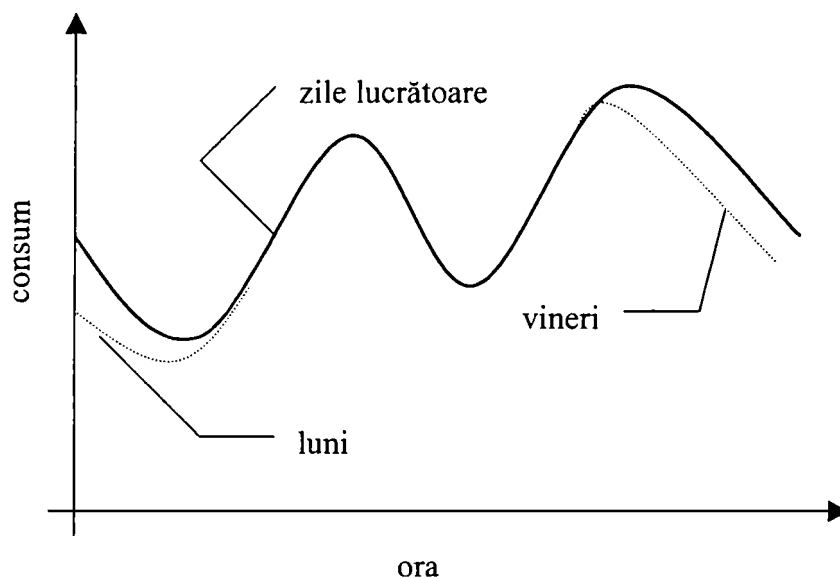


Figura 1.1. Curbe de sarcină tipice pentru zile lucrătoare

1.4. Prognoza pe termen mediu

Pentru furnizorii de energie electrică, prognoza pe termen mediu reprezintă o informație esențială pentru fundamentarea contractelor bilaterale cu producătorii. Totodată, în condițiile tranziției, când funcționarea pieței are loc mai mult după reglementări și mai puțin după mecanismele specifice unei piețe libere (așa cum este cazul țării noastre), prognoza pe termen mediu este elementul principal care, la începutul fiecărui an, stă la baza stabilirii veniturilor totale provenite din vânzarea energiei electrice și la alocarea acestor venituri între entitățile pieței.

În contextul actual al pieței de energie din țata noastră, principala formă de vânzare/cumpărare a energiei electrice, o reprezintă contractele cadru de portofoliu. În general, un contract de portofoliu - numit și asigurator - reprezintă un contract pe deplin și necondiționat garantat, care se încheie între producător și un distribuitor/furnizor de energie electrică, pentru o perioadă de timp mai lungă (de exemplu 5 ani), prin care – pentru fiecare an – se stabilesc ferm cantitățile de energie electrică și limitele de variație a prețurilor la vânzarea /cumpărarea acestor cantități. Contractul de portofoliu stabilește cantități ferme de energie electrică, profilate pe intervale bază de decontare (o oră) și zile standard. Prețurile prevăzute în contract sunt ferme și profilate, de asemenea, la nivel orar.

Zilele standard menționate în definiția contractului cadru de portofoliu reprezintă zile caracteristice pentru consumul de energie electrică din sistemul electroenergetic național. Deoarece cererea de energie variază sezonier și în cursul săptămânii, pentru fiecare lună din an se definesc patru zile standard diferite, după cum urmează : luni și vineri (Zi Standard 1), marți, miercuri și joi (Zi Standard 2), sâmbătă (Zi Standard 3), respectiv duminică și sărbătorile legale (Zi Standard 4).

1.4.1. Stabilirea prețurilor și cantităților contractuale

În contractele cadru de portofoliu încheiate între producători și distribuitori /furnizori sunt prevăzute ferm cantitățile de energie electrică și prețurile de vânzare/cumpărare, profilate la nivel orar, pentru fiecare zi standard. Procedura folosită pentru determinarea prețurilor și cantităților de energie electrică, conform [1.2.], este prezentată sintetic în figura 1.2. . Prima etapă a acestei proceduri se desfășoară la nivelul furnizorilor.

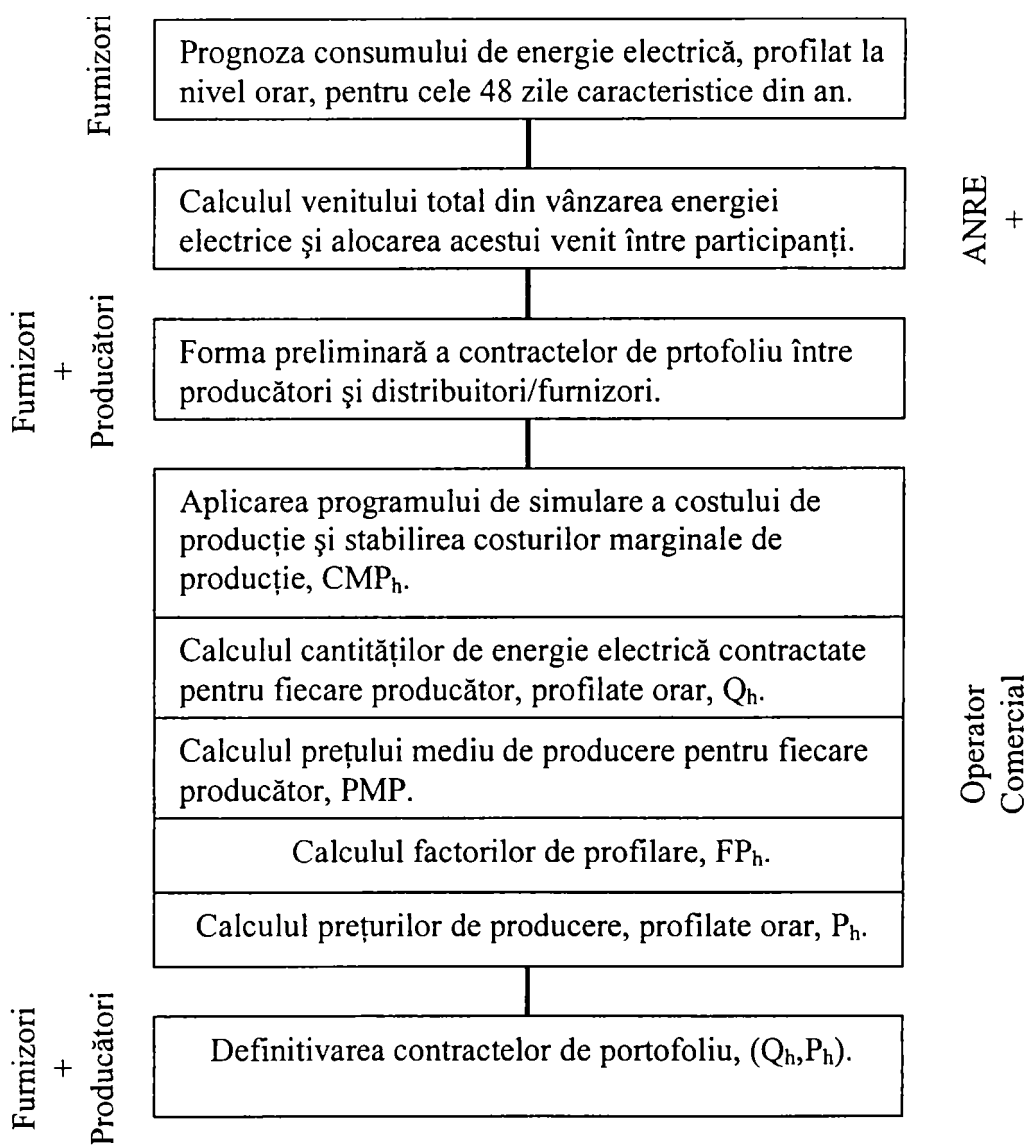


Figura 1.2. Procedura pentru determinarea cantităților și prețurilor pentru energia electrică

Fiecare furnizor elaborează prognoza consumului de energie electrică la nivelul teritoriului pe care îl deservește; această prognoză se realizează sub formă de grafice de sarcină zilnice, cu paliere orare, pentru fiecare din cele 48 zile caracteristice ale anului (câte 4 zile caracteristice pentru fiecare lună). Prognozele furnizorului țin seama și de contractele

bilaterale ale consumatorilor eligibili cu producătorii și de pierderile în rețea. Pe baza acestor prognoze, organismele abilitate stabilesc veniturile totale ce vor rezulta din vânzarea energiei electrice și fac alocarea acestor venituri între entitățile pieței. Fiecărui producător i se alocă un venit V . În paralel, folosind prognozele furnizorilor, se stabilesc formele preliminare ale contractelor de portofoliu între producători și distribuitorul/furnizorul de energie electrică, reprezentat de S.C. Electrica S.A. Aceste contracte reprezintă principalele date de intrare ale procedurii de stabilire a prețurilor și cantităților contractuale. Astfel, operatorul comercial preia datele preliminare din contractele cadru și, prin rularea unui program de simulare a costului de producție, determină pentru fiecare grup/centrală din portofoliul producătorilor cantitățile orare de energie electrică livrate în sistem. Programul folosit calculează repartiția optimă a sarcinii pe grupuri/centrale, în funcție de consumul prognozat, ținând seama de restricțiile de producere și furnizează, de asemenea, costurile marginale de producție, profilate orar (CMP_h).

În continuare, pentru fiecare producător, cantitățile de energie electrică contractate, profilate orar (Q_h), se determină pe baza cantităților de energie electrică livrată de fiecare grup/centrală din portofoliu, în fiecare interval bază de decontare (o oră), pentru fiecare din cele 48 zile standard, multiplicat cu numărul de zile standard din fiecare lună. Cantitatea totală de energie contractată de producătorul respectiv se obține prin însumarea cantităților profilate orar: $Q = \sum_h Q_h$. Raportul dintre venitul alocat aceluia producător V și energia contractată Q permite stabilirea prețului mediu de producere a energiei pentru producătorul respectiv (PMP).

Pentru reflectarea costurilor marginale de producție determinate prin rularea programului de simulare, prețul mediu de producere se profilează la nivel orar. În acest scop, pentru fiecare producător și fiecare zi standard, se calculează factorul de profilare FP_h , pentru fiecare oră.

$$FP_h = \frac{CMP_h}{\frac{\sum_{zi\ st.} CMP_h * Q_h}{\sum_{zi\ st.} Q_h}}$$

În sfârșit, profilarea prețului mediu de producere, pentru fiecare zi standard, se face cu ajutorul acestor factori de profilare. Astfel, se determină prețurile de producere P_h care se vor regăsi, împreună cu cantitățile de energie electrică Q_h , în contractele de portofoliu încheiate de producători cu furnizorii:

$$P_h = PMP * FP_h$$

În cazul în care, după încheierea contractului se înregistrează diferențe între energia contractată și cea livrată, acestea sunt tratate distinct, în funcție de sensul în care se înregistrează diferența. Astfel, dacă energia contractată nu este consumată în totalitate, furnizorul plătește întreaga energie contractată producătorului, la prețurile contractuale. Pe de altă parte, consumul ce depășește producția contractată ar trebui plătit la prețul marginal de sistem stabilit de piața spot.

1.4.2. Model de prognoză pe termen mediu

Prognoza pe termen mediu a consumului de energie electrică se referă la estimarea graficelor de sarcină cu paliere orare pentru cele 48 zile standard ale anului. În cazul prognozei pe termen scurt, marea majoritate a tehnicilor de abordare propuse și aplicate folosesc ca variabile independente – adică parametrii care influențează nivelul consumului –

anumite informații privind condițiile meteorologice, cum ar fi temperatura, umiditatea relativă, nebulozitatea sau viteza vântului. Pentru prognoza pe termen mediu, având în vedere intervalul de prognoză mult mai larg (un an), precizia previziunilor meteo ar avea mult de suferit astfel încât, luarea în considerare ca variabile independente a unor asemenea factori este imposibilă, fie total neproductivă. În plus, creșterea perioadei de referință face ca nivelul consumului de energie pentru un interval dat să fie influențat în mai mare măsură de parametri cu un caracter exogen mai pronunțat. Asemenea parametri pot fi unii indicatori macroeconomici, cum ar fi : indicele prețului de consum (IPC), venitul salarial mediu (VSM) sau rata cursului de schimb valutar (RCV).

Măsura în care consumul de energie este influențat de indicatorii macroeconomici menționați poate fi apreciată pe baza unui studiu de corelații. În cadrul acestui studiu se analizează posibilele corelații care există între sarcinile maxime pe un anumit interval de timp și indicatorii macroeconomici. Având în vedere modul de profilare a valorilor indicatorilor macroeconomici (lunar sau zilnic), pentru indicatorii IPC (prețuri) și VSM (venituri), sarcina maximă corespunde unui interval de o lună, iar pentru indicatorul RCV (curs valutar), sarcina maximă corespunde unui interval de o zi. Astfel, pentru o bază de date ce conține valori lunare pentru indicatorii IPC (prețuri) și VSM (venituri) și valori zilnice pentru indicatorul RCV (curs valutar), precum și curbele zilnice de sarcină profilate orar pentru o sucursală de distribuție și furnizare din cadrul S.C. Electrica S.A., corespunzător unui interval de doi ani și câteva zile (între 01.04.1998 și 13.04.2000), rezultatele studiului de corelații sunt prezentate în tabelul 1.1. [1.4.].

Tabelul 1.1. Corelațiile între sarcina maximă lunară/zilnică și indicatorii macroeconomici (IPC – indicele prețului de consum; VSM - venit salarial mediu; RCV – rata cursului de schimb valutar)

Decalaj lunar	IPC	VSM	Decalaj zilnic	RCV
0	+0,1131	+0,0018	0	+0,0007
-1	+0,0801	+0,0603	-30	+0,0287
-2	-0,2352	-0,1507	-60	-0,0970
-3	-0,6922	-0,3180	-90	-0,3117
-4	-0,7554	-0,5210	-120	-0,5610
-5	-0,5848	-0,4111	-150	-0,5592
-6	-0,3148	-0,3502	-180	-0,4703

Din considerente de uniformitate, coeficienții de corelație pentru indicatorul RCV (curs valutar) din tabelul 1.1. sunt indicați pentru ultima zi din fiecare lună. Corespunzător valorilor maxime ale coeficienților de corelație din tabelul 1.1., se poate afirma că efectul modificării valorilor indicatorilor macroeconomici asupra sarcinii maxime se face simțit cu o anumită inerție, de 4 luni. Pe de altă parte, valorile negative ale coeficienților de corelație indică o dependență descrescătoare a sarcinii maxime în raport cu indicatorii macroeconomici considerați. Cele două particularități constatate – inerția la 4 luni și dependența descrescătoare – descriu suficient de bine realitățile economice și sociale din România, din punctul de vedere al consumului de energie electrică. Ca urmare, cei trei indicatori macroeconomici (aplicați cu un decalaj de 4 luni) pot fi utilizați ca variabile independente pentru prognoza pe termen mediu.

Pe de altă parte, pentru o anumită lună există mai multe grafice de sarcină zilnice și doar câte o singură valoare pentru indicatorii IPC (prețuri) și VSM (venituri). Este de așteptat ca, folosirea unei singure valori pentru un indicator macroeconomic în scopul estimării a 4

grafice de sarcină zilnice (corespunzătoare celor 4 zile standard) cu 24 paliere orare, să nu conducă la rezultate foarte bune.

Prin urmare, pentru creșterea diversității la nivelul valorilor indicatorilor macroeconomici, se poate folosi interpolarea sau regresia liniară pentru estimarea unor valori zilnice. În ambele cazuri, procesul folosește trei valori ale indicatorului macroeconomic, corespunzătoare lunii curente (pentru care se face estimarea), respectiv cu o lună înainte și după. Principiul acestei tehnici de estimare este prezentat sub formă grafică în figura 1.3.




Figura 1.3. Estimarea valorilor zilnice pentru indicatorii IPC și VSM folosind interpolarea parabolică(a) sau regresia liniară (b)

Aproape peste tot în lume, atât în țările industrializate cât și în cele în curs de dezvoltare, se constată anumite tendințe care conduc la schimbarea fundalului pe care există și evoluează componentele unui sistem energetic: supravegherea și conducerea consumurilor energetice, dezvoltarea schimburilor de energie electrică între sistemele tradiționale, liberalizarea pieței energiei, liberalizarea accesului la rețeaua de transport și distribuție, privatizarea sectorului energetic, impactul instalațiilor energetice asupra mediului înconjurător etc.

Toate aceste tendințe vor avea ca rezultat creșterea complexității activităților de planificare, exploatare și conducere a rețelelor electrice, precum și interferența problemelor de natură tehnică cu cele economice.

Lucrarea de față se înscrie în tendința actuală a preocupărilor științifice privind introducerea celor mai noi tehnici în domeniul prognozei.

1.5. Concluzii

În acest capitol s-a evidențiat faptul că activitatea de prognoză nu este altceva decât o aproximare a unor evenimente viitoare, necunoscute, pe baza modului în care s-au desfășurat aceste evenimente în trecut și se desfășoară în prezent.

Prognoza consumului de energie electrică are un impact semnificativ asupra exploatarei eficiente a sistemului energetic național, a dezvoltării acestuia și alimentării în condiții sigure și de o calitate corespunzătoare a consumatorilor. În particular, în sectorul distribuție – furnizare, prognozele consumului de energie electrică reprezintă instrumente utile pentru gestionarea tranzacțiilor cu energie pe termen scurt (una, două zile) – în cazul pieței spot- sau pe termen mediu (un an) – în cazul contractelor de vânzare/cumpărare energie electrică cu producătorii, pentru piața angro.

Pe lângă cele menționate în cadrul acestui capitol, se subliniază rolul caracteristicilor consumului de energie din zona analizată asupra modelului de prognoză pe termen scurt. Aceste caracteristici au în vedere caracterul nestaționar al consumului de energie electrică, forma de principiu a curbelor de sarcină, particularitățile evoluției sarcinii, în zilele speciale și, nu în ultimul rând, principalii factori care caracterizează nivelul consumului de energie electrică.

Demne de remarcat sunt, fără îndoială, particularitățile pe care le prezintă curbele de sarcină din zilele săptămânii și anume gruparea lor în trei categorii pentru zilele lucrătoare: luni, marți - joi și vineri, iar pentru zilele de odihnă (repaus) firește, sâmbăta și duminica. Condiționările care apar între zile, precum și anumite relații stabilite între consumurile zilelor de lucru, de lucru și de repaus, vor fi determinante în logica algoritmilor de prognoză.

În finalul acestui capitol, în scopul de a arăta locul pe care îl are prognoza pe termen scurt în cadrul întregii activități de prognoză, s-au făcut referiri și la prognoza pe termen mediu, în particular la stabilirea cantităților și prețurilor contractuale precum și la principiile care se au în vedere la elaborarea unui model de prognoză pe termen mediu.

BIBLIOGRAFIE

- 1.1. *** - Contracte cadru de furnizare a energiei electrice; Cod1.2.534.0.01.08/03/99;ANRE
- 1.2. *** - Procedură pentru determinarea prețurilor și cantităților de energie electrică din contractele cadru de portofoliu (interimare)de vânzare /cumpărare; Cod 17.2.310.0.01.07/06/99; ANRE
- 1.3. *** - Regulament de programare și dispecerizare a sistemului electroenergetic național; Cod 18.1.216.0.01.10/06/99; ANRE
- 1.4. GAVRILAȘ, M., CIUTEA, I., TĂNASĂ, C. - Medium-Term Load Forecasting With Artificial Neural Networks Models; 16th International Conference and Exhibition on Electricity Distribution, CIRED 2001, Amsterdam, 18-21 July 2001.
- 1.5. KHOTANZAD ,A., AFKHAMI-ROHANI, R., - ANNSTLF- Artificial Neural Network Short- Term Load Forecaster – Generation Three; IEEE Trans. On Power Systems, No. 4 1998, pp. 1413-1422.
- 1.6. *** - Neural Networks Theory, Technology and Applications, IEEE TAB, New York, 1996.
- 1.7. KASSAEI, H.R., - A Hibrid Fuzzy Neural Network Bus Load Modeling and Predictions; IEEE Trans. On Power Systems, No. 2,May 1999, pp.718-724.
- 1.8. KHOTANZAD, A., HWANG,R.C.,ABAYE,A, MARATUKULAM, D. - An Adaptive Modular Artificial Neural Network Hourly Load Forecasting and its Implementation at Electric Utilities; IEEE Trans. On Power Systems, No. 3, Aug. 1995, pp. 1716-1722.
- 1.9. *** - Codul Comercial al pieței angro de energie electrică; Cod ANRE 22.2.130.1.02.05/07/99.
- 1.10. GAVRILAȘ,M., SFINTEȘ,C.V., FILIMON M.N. - Prognoza pe termen mediu, instrument pentru fundamentarea contractelor cadru de portofoliu între producători și furnizori; Energetica, nr. 12, Decembrie 2001

PROGNOZA CONSUMULUI DE ENERGIE ȘI PUTERE

În cadrul acestui capitol vor fi trecute în revistă problemele generale pe care le comportă activitatea de prognoză a consumului de energie și putere, precum și metodele clasice de prognoză .

2.1. Probleme generale. Clasificări și definiții.

Problema consumului de energie și putere este 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 (previzionate) și cele efectiv realizate [2.1.], [2.2.].

Activitatea de prognoză a consumului de energie joacă un rol fundamental în activitatea internă a oricărei companii de electricitate, facilitând procesul de planificare a întregilor activități și mai ales pe cea de management. Obiectivul principal al activității de prognoză a energiei este minimizarea incertitudinilor în legătură cu realizarea unor anumite consumuri de energie, puterii medii sau maxime.

Necesitatea activităților de prognoză derivă din caracterul aleator al multitudinii unor factori care condiționează consumul de energie. Caracterul acestor factori poate fi foarte diferit. O clasificare a acestor factori se prezintă în figura 2.1., clasificare care are drept scop pe de-o parte sistematizarea problemelor, pe de altă parte evidențierea complexității problemelor abordate.

De la bun început trebuie evidențiat faptul că prognoza pe termen foarte scurt și scurt este influențată în mare măsură de condițiile atmosferice. În cazul prognozelor pe termen mediu și lung conjunctura economică este foarte importantă. La acestea trebuie considerate și evenimentele speciale, care pot influența nivelul consumului de energie. Asemenea evenimente pot fi: zilele de sărbătoare, greve, manifestări publice, campionate europene sau mondiale, olimpiade, vizitele unor personalități etc.

Un alt aspect care trebuie luat în considerare la efectuarea prognozei consumului de energie este natura consumatorilor considerați: urbani, rurali, industriali, zonali, regionali sau naționali-finali. Prin urmare, considerarea diferiților factori ce influențează evoluția consumului de energie electrică este condiționată de [2.1.] ÷ [2.10.].

- durata la care se referă prognoza;
- natura consumatorilor;
- mărimea prognozată (energie, putere medie, maximă etc).

Față de cele prezentate mai sus trebuie făcute următoarele observații:

- ambientul economic, în care funcționează sistemul energetic și în primul rând centralele electrice, are o influență semnificativă asupra consumului de energie electrică;
- unele evenimente stagionale, cum ar fi reînceperea activității școlare sau universitare pot determina modificări bruște în curba de sarcină;

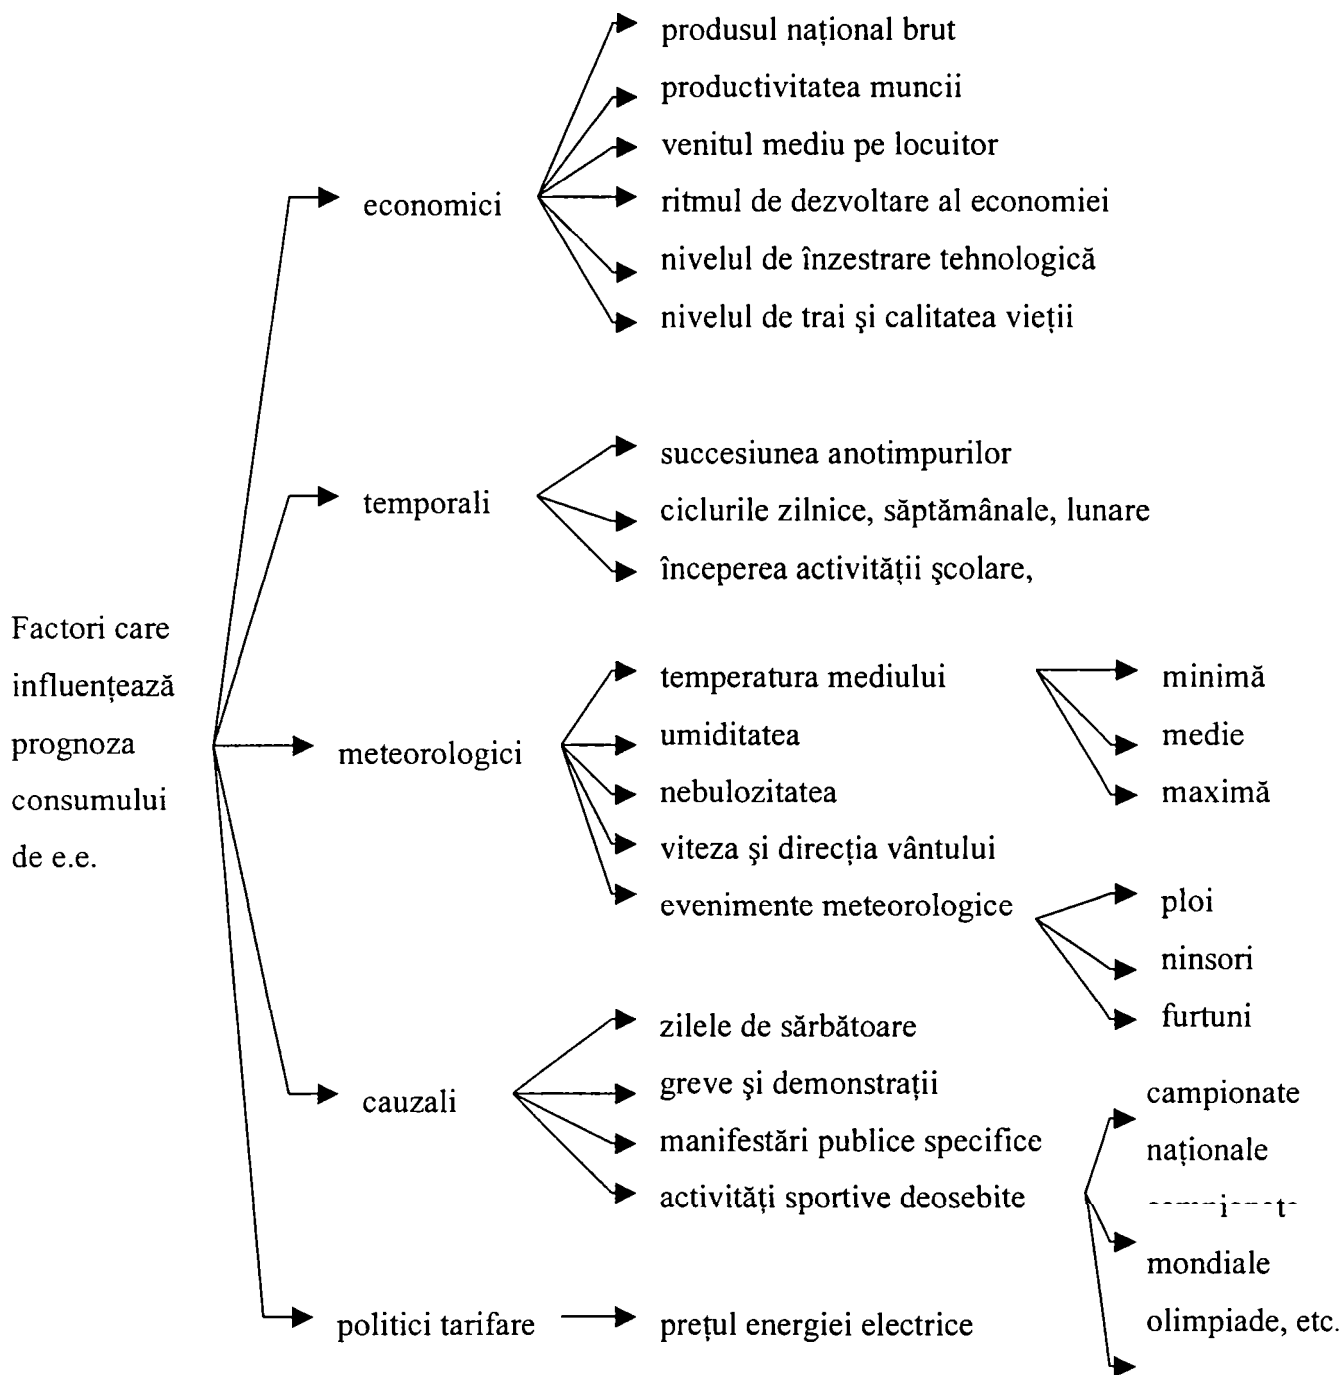


Figura 2.1. Clasificarea factorilor care influențează prognoza consumului de energie electrică

- ciclul de lucru săptămânal al populației poate determina anumite corelații specifice în curba de sarcină a puterilor medii, zilnice, săptămânale;
- nivelul consumului de energie electrică în majoritatea țărilor dezvoltate prezintă o corelație evidentă cu temperatura. Atunci când temperatura se modifică substanțial deasupra sau dedesubtul unei valori care asigură confortul termic, nivelul consumului de energie electrică este mai mare decât cel firesc. Fără

îndoială că această creștere este influențată de utilizarea pe scară largă a surselor de energie pentru încălzirea și răcirea locuințelor;

- prelevarea temperaturii folosite în prognoza sarcinii este foarte importantă, existând mai multe practici uzuale, dintre care se remarcă: măsurarea temperaturii în câteva puncte geografice importante, utilizarea temperaturii medii pe zone geografice, utilizarea temperaturilor minime și maxime din cursul unei zile și altele.

Dar, factorii care determină evoluția consumului de energie electrică se pot clasifica nu numai după natura lor, ci și după alte criterii, cum ar fi cele prezentate în figura 2.2.

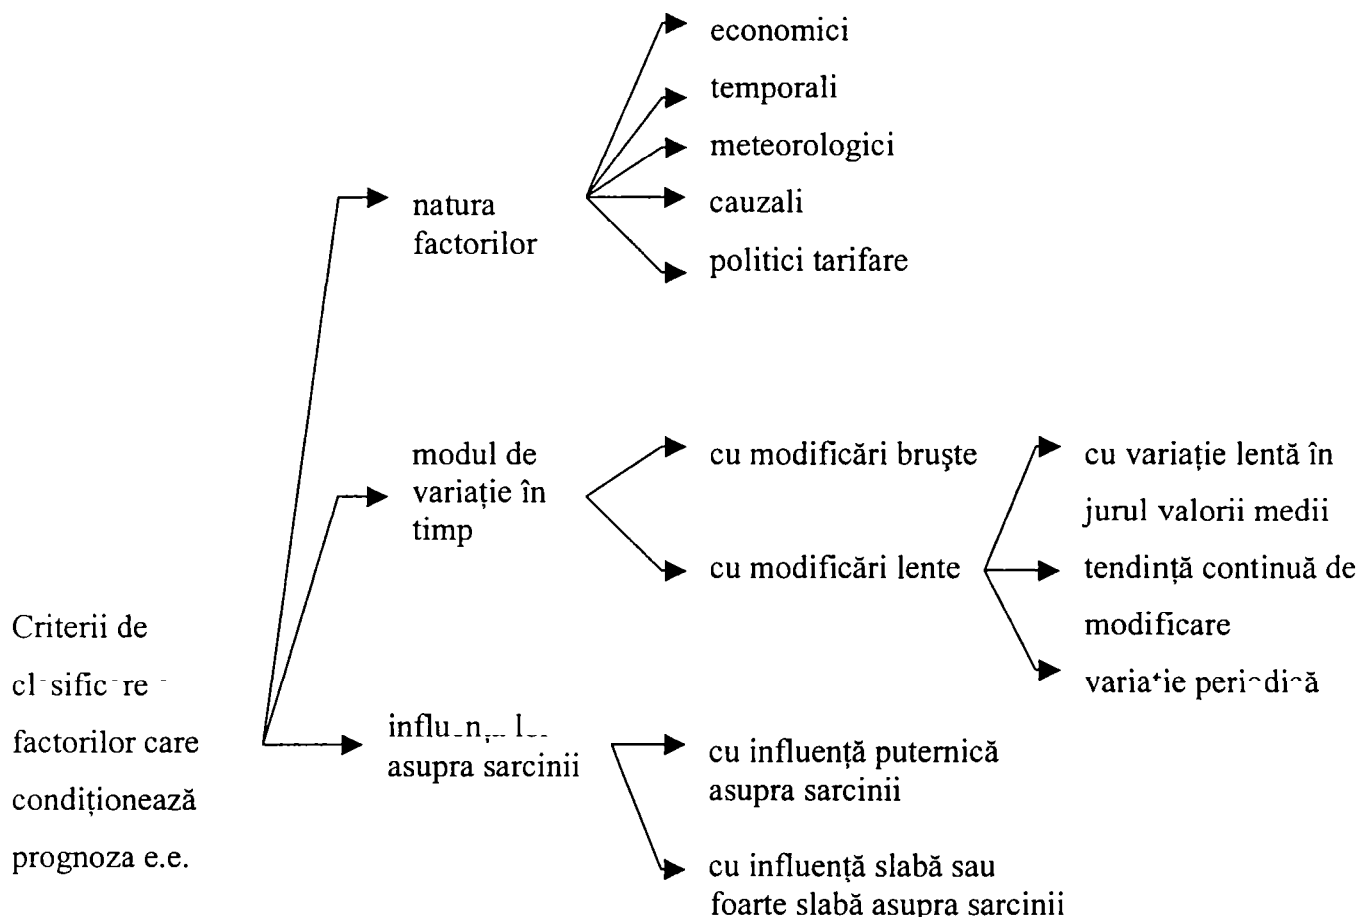


Figura 2.2. Criterii de clasificare a factorilor ce condiționează consumul de energie electrică

Clasificarea activităților de prognoză a consumului de energie electrică se realizează după mai multe criterii și anume: orizontul (perioada) de prognoză, extinderea spațială a consumului de energie electrică, scopul prognozei, natura metodei matematice utilizate, tipul metodei, natura variabilelor independente, numărul componentelor etc. Schematic o astfel de clasificare se prezintă în figura 2.3. [2.1.], [2.2.], [2.5.], [2.6.].

De remarcat însă că cel mai important criteriu de prognoză este cel referitor la orizontul de prognoză [2.3.]. Din acest punct de vedere se deosebesc:

- prognoza pe termen foarte scurt (20-30 minute), care realizează o estimare instantanee a necesarului de energie;
- prognoza pe termen scurt (de la o oră la câteva zile), care realizează estimarea puterilor medii orare, a curbelor de sarcină zilnică și a consumurilor zilnice;
- prognoza pe termen mediu (de la o lună la un an), care furnizează consumurile zilnice, săptămânale și lunare, curbe de sarcină în zile semnificative;
- prognoza pe termen lung (peste un an).

Orizontul de prognoză este strâns legat însă de scopul prognozei, fapt relevat de cele prezentate în tabelul 2.1.

Tabelul 2.1. Corelația dintre scopul prognozei consumului de energie electrică și orizontul acesteia

Nr. crt.	Scopul prognozei	Durata prognozei				
		f.scurtă	scurtă	medie	lungă	f.lungă
1.	Dispecerizarea economică a rețelelor de distribuție	*				
2.	Asigurarea siguranței în funcționarea rețelelor de distribuție	*				
3.	Planificarea rezervei de putere		*			
4.	Stabilirea gradului de încărcare a rețelei		*	*		
5.	Planificarea aprovizionării cu combustibil			*		
6.	Programarea operațiilor de mentenanță			*		
7.	Planificarea operațiilor financiare		*	*	*	
8.	Planificarea funcționării centralelor electrice				*	*
9.	Construcția de noi centrale și rețele de transport					*

2.2. Componentele modelului matematic al consumului de energie electrică

Curba de consum reprezintă variația în timp a consumului de energie, sau a acestuia din urmă în raport cu alt parametru. Ea poate fi de regulă descompusă în mai multe componente. Experiența de prognoză evidențiază existența a patru componente principale care determină curba de consum și anume (figura 2.4.):

- componenta de trend sau tendința (T), reprezintă componenta principală a consumului de energie, determinând forma esențială de modificare a consumului de energie;

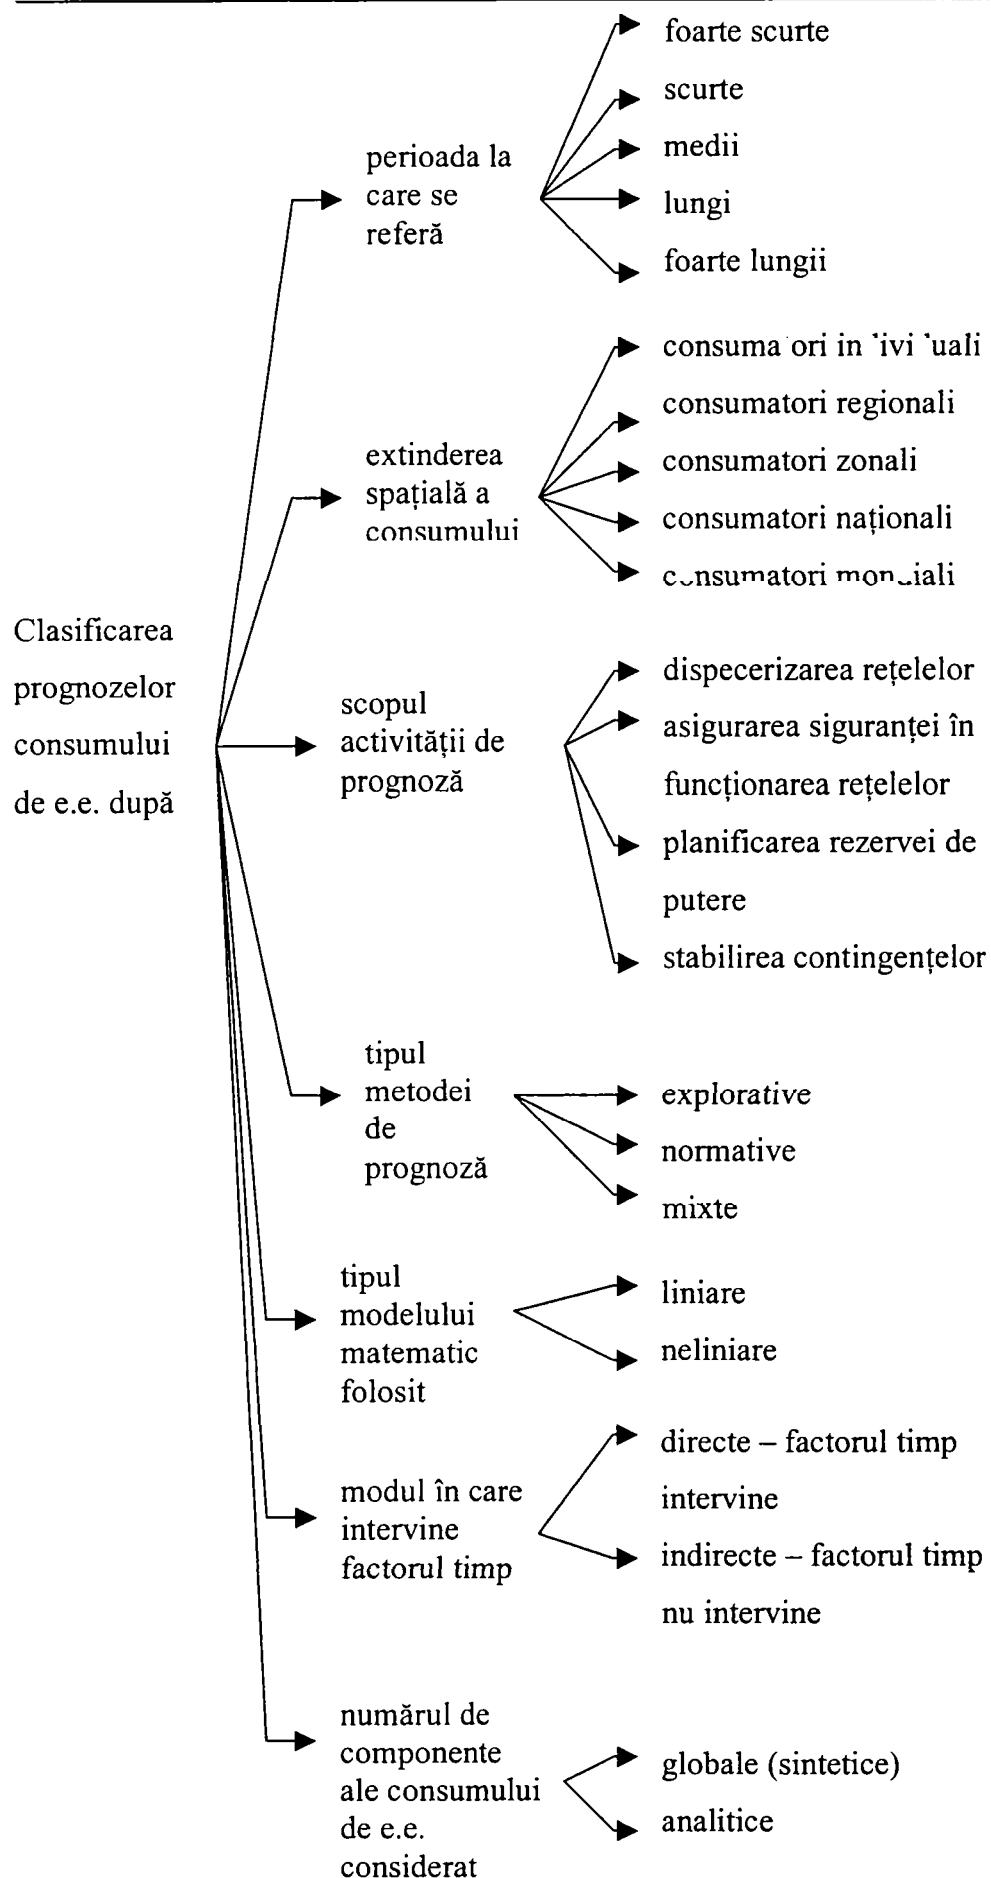


Figura 2.3. Clasificarea activităților de prognoză a consumului de energie electrică

- componenta ciclică (C), corespunde existenței unor factori cu acțiune fluctuantă, dar lentă, cum ar fi corelația cerere-ofertă; de regulă are forma unei sinusoide (sau sumă de sinusoide) cu perioada mai mare de un an;
- componenta sezonieră (S) este cauzată de modificarea consumului de energie în diferite perioade ale anului calendaristic, ca urmare a schimbărilor condițiilor de climă; această componentă are o perioadă de variație de câteva luni și o formă asemănătoare pentru toți anii luați în considerare;
- componenta aleatorie (ϵ) sau zgomot este determinată de cauze întâmplătoare, care nu intră în nici una din categoriile mai sus menționate.

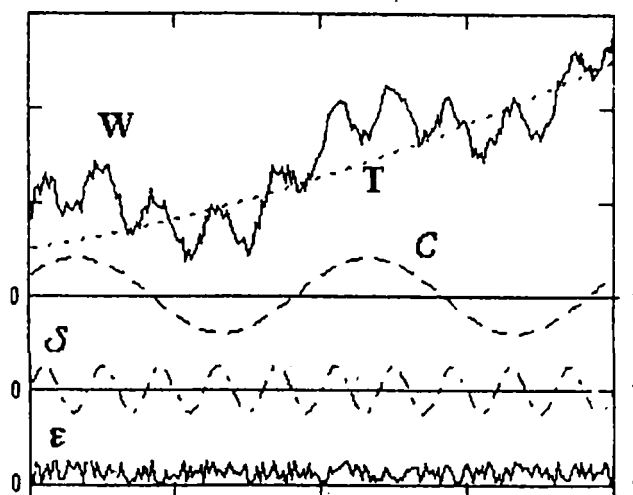


Figura 2.4. Componentele modelului matematic al curbei consumului de energie

Ca urmare, la un anumit moment valoarea consumului de energie se poate exprima cu relațiile:

$$W = T + C + S + \epsilon \text{ sau } W = T \cdot C \cdot S \cdot \epsilon \quad (2.1)$$

De multe ori, în calculele practice, nu se apelează decât la două componente și anume: trendul și componenta aleatoare, adică:

$$W = T + \epsilon \text{ sau } W = T \cdot \epsilon \quad (2.2)$$

Oricum, atunci când se efectuează prognoza consumului de energie, ideea de bază folosită este de a estima separat variația fiecărei componente a consumului, rezultatul final obținându-se prin însumarea rezultatelor prognozelor componentelor. Separarea componentelor este una din problemele principale ale teoriei statisticii matematice. Ea se efectuează mai simplu pentru componenta ciclică și sezonieră, atunci când se folosesc metode de uniformizare a curbei de consum și este mai dificilă pentru componenta aleatoare. Din acest motiv, pentru situațiile în care nu interesează explicit forma componentei aleatoare, au fost dezvoltate metode probabilistice de prognoză, care apreciază limitele așa numitului interval de încredere, în care tendința poate să devieze de la valoarea estimată determinist, ca urmare a acțiunii factorilor întâmplători, fără a se depăși un anumit nivel de încredere prestabilit.

2.2.1. Modele matematice folosite pentru trend [2.7.], [2.9.], [2.10.], [2.12.], [2.14.]

Dintre modele pentru componenta de tendință a consumului de energie se pot menționa modelele econometrice, analitice, condiționale, modele care consideră participarea la piață a surselor de energie, modele de prognoză care țin cont de influența echipamentului energetic folosit, modele de prognoză care încorporează factori de producție. O clasificare completă a modelelor matematice utilizate pentru trend se prezintă în figura 2.5.

2.3. Metode directe de prognoză [2.1.], [2.2.], [2.30.]

Se mai numesc și metode de prognoză prin extrapolare și ele au la bază ipoteza conform căreia pe perioada de prognoză, factorii și tendințele care determină evoluția consumului de energie rămân neschimbați cu cei din trecut.

Această ipoteză, esențială de fapt, justifică extrapolarea tendinței de evoluție a consumului din trecut pentru perioada viitoare și reduce problema de prognoză la determinarea legii de variație a consumului de energie valabilă pentru perioada trecută și viitoare.

2.3.1. Principiul metodelor directe

Metodele directe presupun stabilirea unui model matematic sub forma unei funcții de una sau mai multe variabile, care să aproximeze cât mai bine tendința trecută. Determinarea coeficienților funcției se efectuează rezolvând un sistem de ecuații, de regulă liniar, ai cărui coeficienți se calculează cu ajutorul consumurilor de energie din perioada trecută. Odată stabilită funcția, ea se extrapolează.

Etapile de lucru ce se parcurg la prognoza directă sunt prezentate sintetic în schema din figura 2.6.

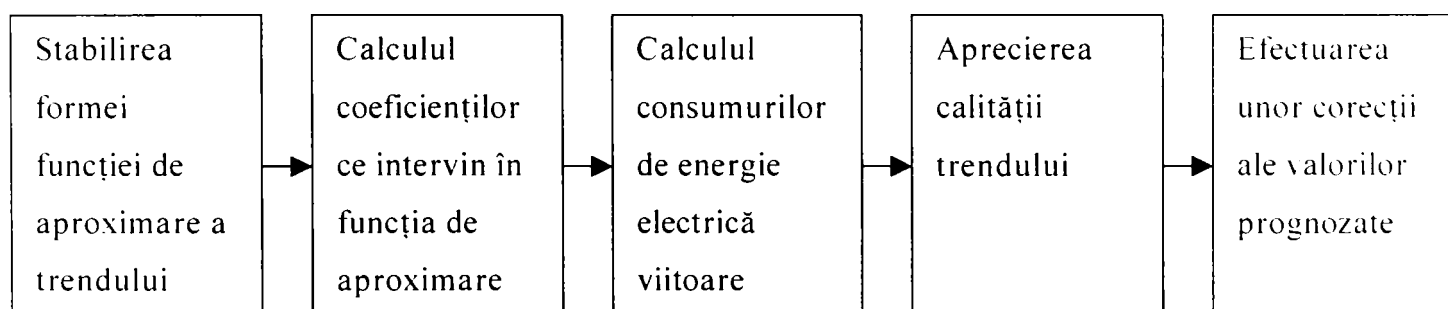
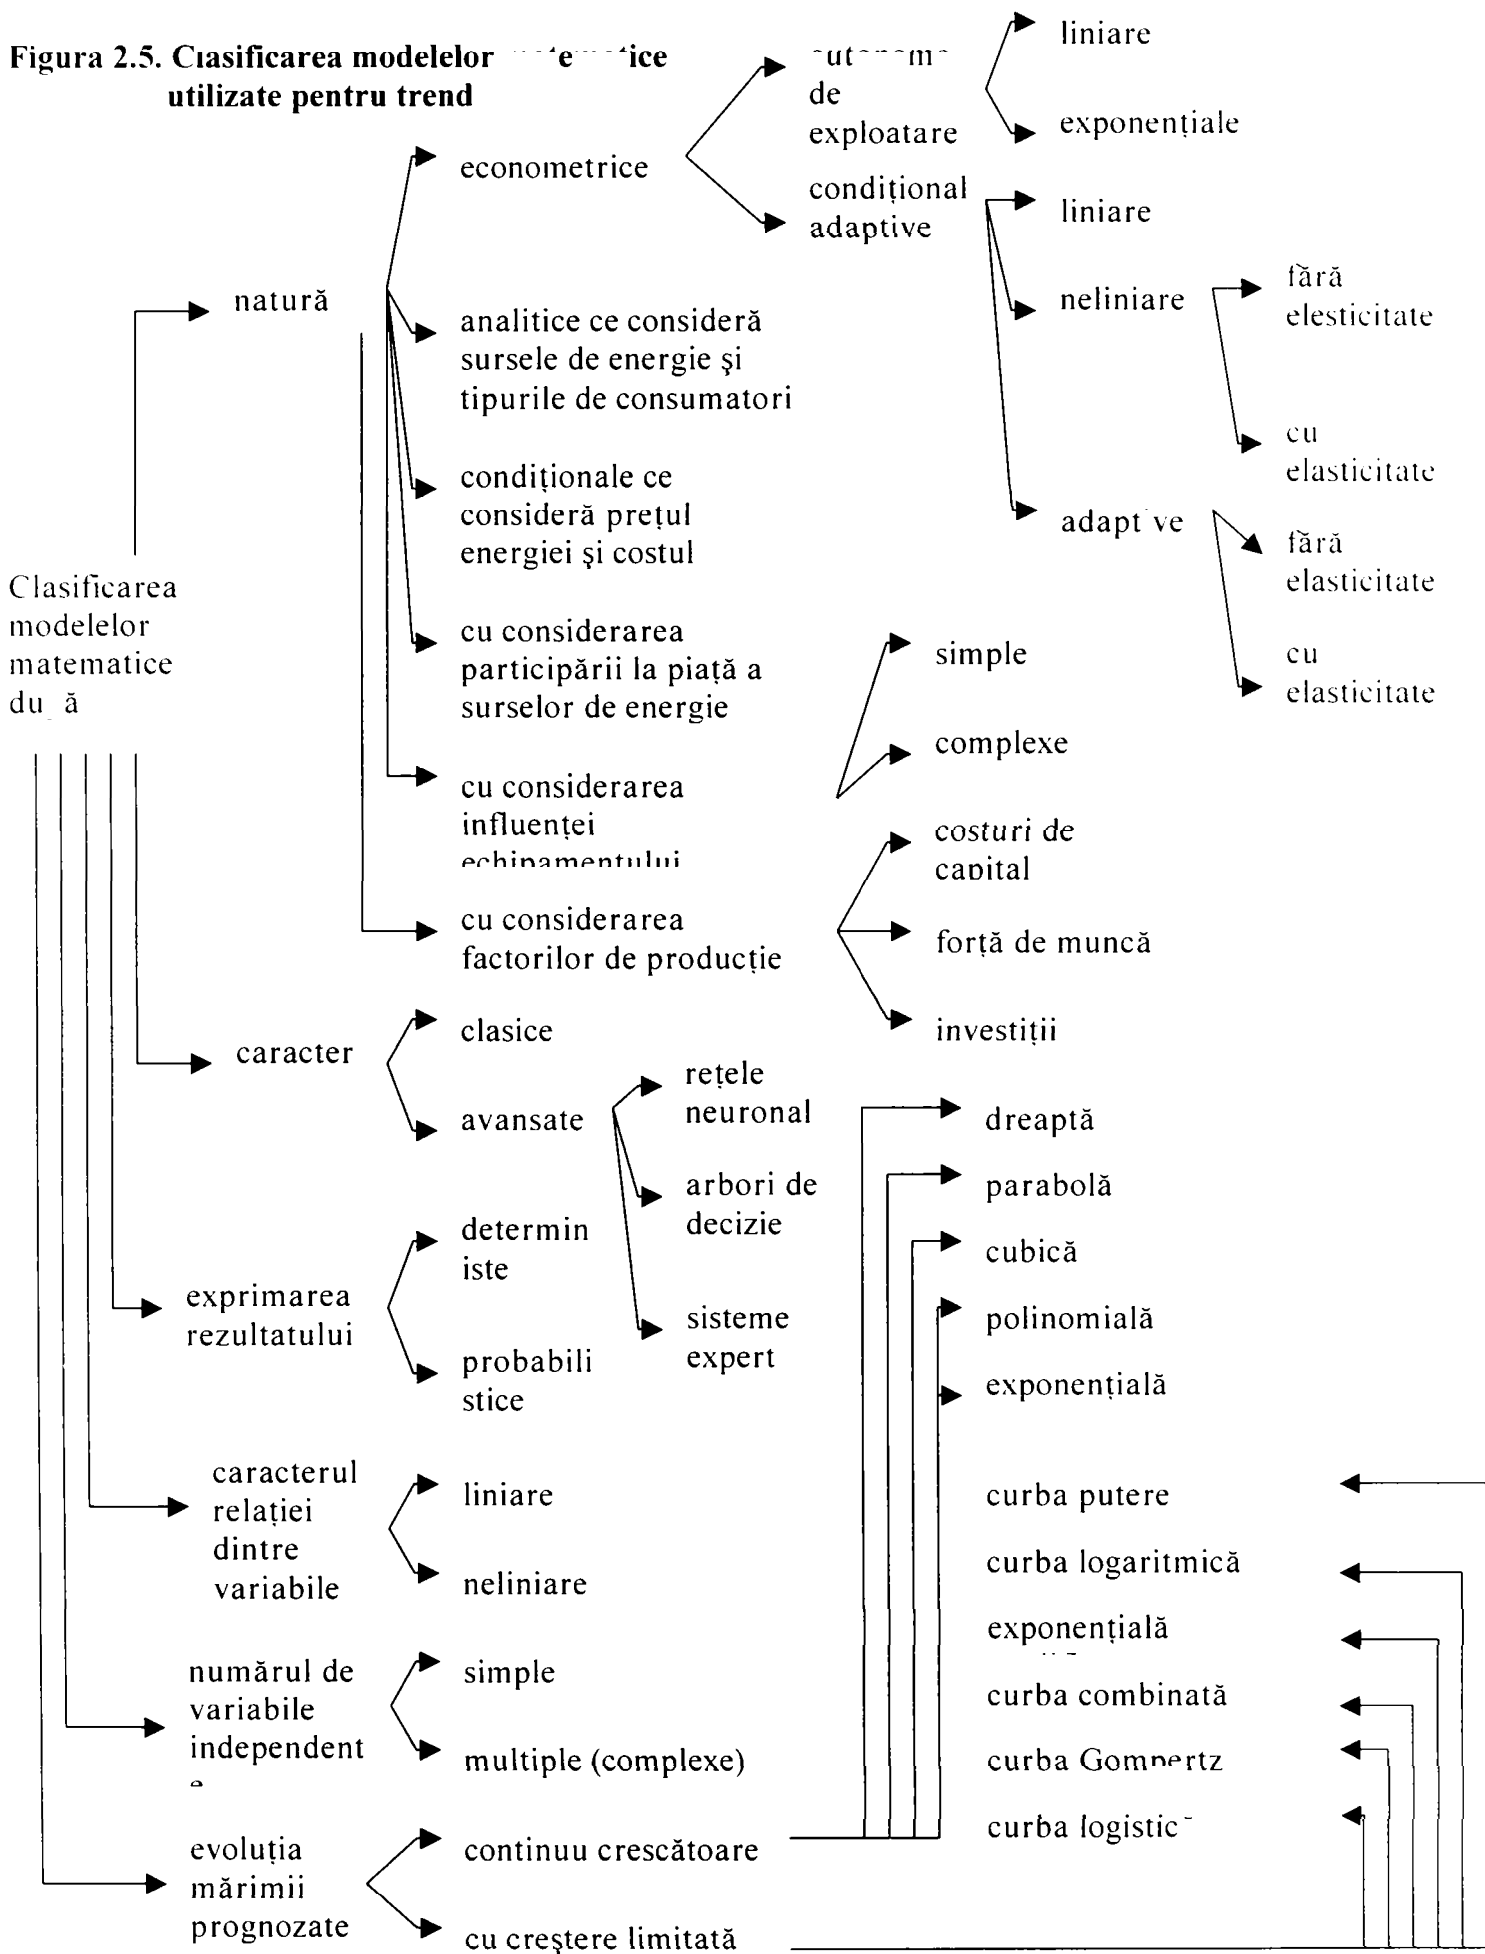


Figura 2.6. Etapele parcurse în activitatea de prognoză efectuată prin metode directe

Avantajele aplicării acestor metode sunt următoarele:

- sunt relativ simple și intuitive, putând fi transpuse în cadrul unor programe dedicate;
- rezultatele obținute sunt suficient de corecte dacă ipotezele de lucru își păstrează valabilitatea în viitor;
- se recomandă a fi aplicate pentru prognoza consumului de energie pentru zone extinse sau cu multe componente, unde eventualele variații bruște să fie compensate.

Figura 2.5. Clasificarea modelelor matematice utilizate pentru trend



2.3.2. Modelarea trendului [2.1.], [2.2.]

Pentru modelarea cât mai corectă a trendului se folosesc legi cât mai simple, acestea având o probabilitate de a fi asigurate mai ridicată decât legile complicate.. Dintre acestea se menționează cele corespunzătoare figurii 2.7.

De remarcat următoarele:

- în majoritatea situațiilor, consumul de energie electrică are tendința generală de creștere, deci trebuie apelat la curbe cu creștere continuă;
- saturații impuse de restricții de natură tehnică, economică sau ecologică sunt mai rar întâlnite, în acest caz apelându-se la curbe cu tendință limitată;
- prin transformări algebrice simple majoritatea legilor de variație pot fi aduse la forma unui polinom;
- funcția exponențială reprezintă variația consumului la o rată de creștere constantă.

În cadrul modelării trendului se pun câteva probleme și anume:

- adaptarea funcției de modelare, care de cele mai multe ori poate fi redusă la un polinom;
- stabilirea gradului optim al polinomului de aproximare;
- estimarea coeficienților modelului;
- aprecierea calității trendului.

2.3.3. Aprecierea calității trendului. Analiza de corelație

Aprecierea calității modelului de prognoză adoptat se efectuează pe baza unor indicatori care exprimă “gradul de împrăștiere” a datelor inițiale față de tendința considerată. În mod obișnuit, cu cât aproximarea tendinței de evoluție a consumului este mai bună, cu atât împrăștierea datelor reale ale consumului de energie este mai mică, iar indicatorii de calitate vor avea valori mai reduse. Sunt posibil de definit numeroși indici, cei mai des utilizați fiind următorii: [2.1.],[2.34.],[2.35.].

a) Media valorilor absolute ale abaterilor:

$$I_1 = \frac{1}{n} \sum_{k=1}^n \left| \hat{y}_k - y_k \right| \quad (2.3)$$

b) Media valorilor absolute ale abaterilor procentuale:

$$I_2 = \frac{1}{n} \sum_{k=1}^n \left| \frac{\hat{y}_k - y_k}{y_k} \right| * 100 \quad [\%] \quad (2.4)$$

c) Media valorilor absolute ale abaterilor față de valoarea medie:

$$I_3 = \frac{1}{n} \sum_{k=1}^n \left| y_k - \bar{y} \right| \quad (2.5)$$




Figura 2.7. Modele de trend pentru prognoze directe

d) Dispersia selecției:

$$I_4 = \sigma^2 = \frac{1}{n-m-1} \sum_{k=1}^n (y_k - \hat{y}_k)^2 \quad (2.6)$$

e) Abaterea pătratică medie a selecției:

$$I_5 = \sigma = \left[\frac{1}{n-m-1} \sum_{k=1}^n (y_k - \hat{y}_k)^2 \right]^{\frac{1}{2}} \quad (2.7)$$

f) Coeficientul de corelație:

$$I_6 = r = \frac{\sum_{k=1}^n (x_k - \bar{x})(y_k - \bar{y})}{\pm \sqrt{\sum_{k=1}^n (x_k - \bar{x})^2 * \sum_{k=1}^n (y_k - \bar{y})^2}} \quad (2.8)$$

Semnul din fața radicalului se alege astfel încât $r \in (0,1)$. Cu cât r este mai apropiat de 1, cu atât corelația dintre y și x este mai apropiată de o dreaptă.

g) Raportul de corelație:

$$I_7 = \rho = \sqrt{\frac{\sum_{k=1}^n (\hat{y}_k - \bar{y})^2}{\sum_{k=1}^n (y_k - \bar{y})^2}} \quad (2.9)$$

Intervalul de variație pentru ρ este $\rho \in (0,1)$; cu cât ρ este mai aproape de 1, cu atât și corelația este mai intensă.

2.4. Metode indirecte de prognoză [2.2.], [2.4.], [2.5.], [2.6.], [2.7.]

Metodele indirecte de prognoză a consumului de energie folosesc corelația dintre consumul de energie W și factorii demografici, climatici, economici (notați cu x_i , $i = 1, \dots, p$). Modelul matematic folosit este de forma:

$$W = W [x_1(t), x_2(t), \dots, x_p(t)] \quad (2.10)$$

Problemele ridicate de metodele indirecte se prezintă sintetic în schema din figura 2.8.

2.5. Prognoza pe termen scurt a sarcinii electrice

Avându-se în vedere conținutul acestei lucrări s-a considerat util a prezenta în încheierea metodelor clasice de prognoză tehnicile și în general problematica prognozelor pe termen scurt a sarcinii electrice. Sintetic, problematica aferentă acestei metode de prognoză este prezentată în figura 2.9.

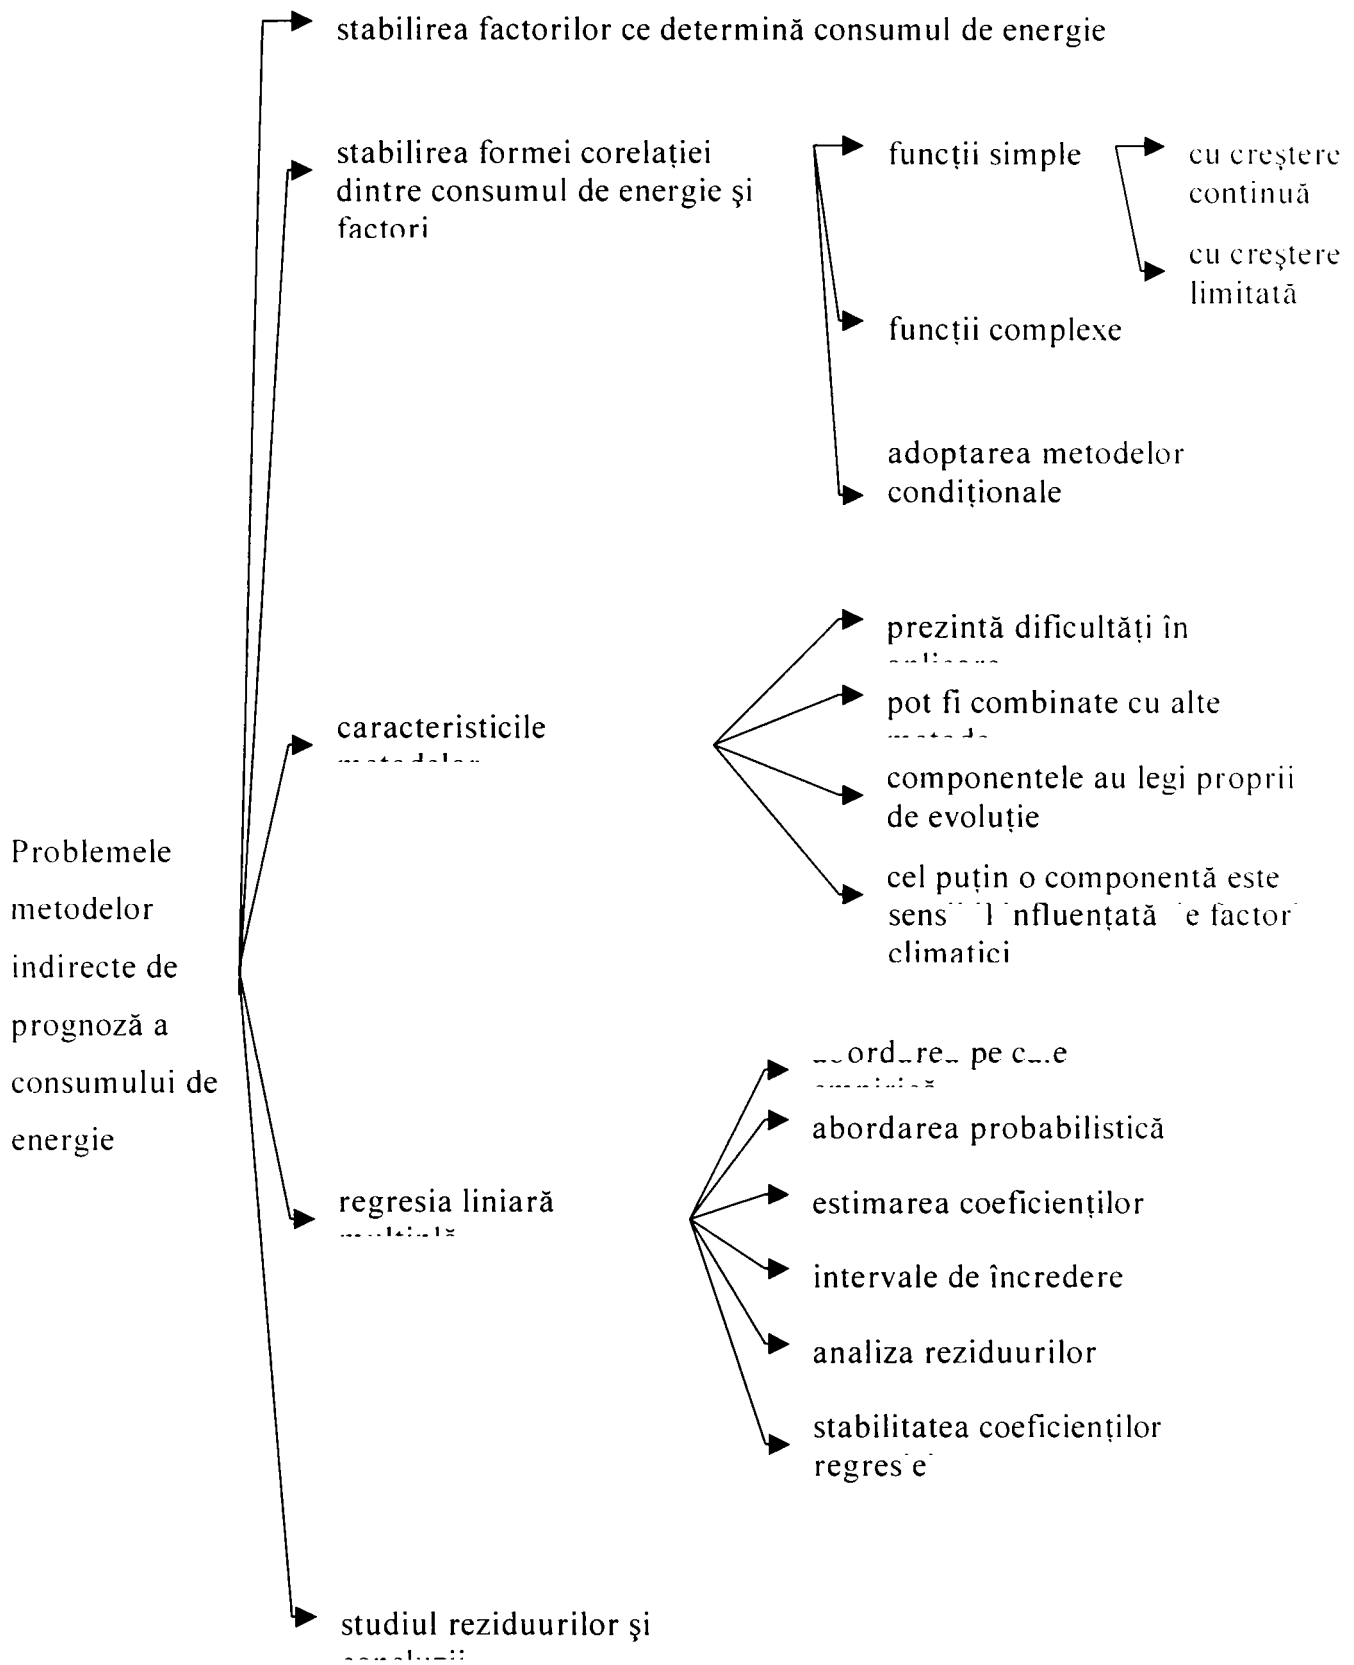


Figura 2.8. Problemele pe care le comportă utilizarea metodelor indirecte de prognoză

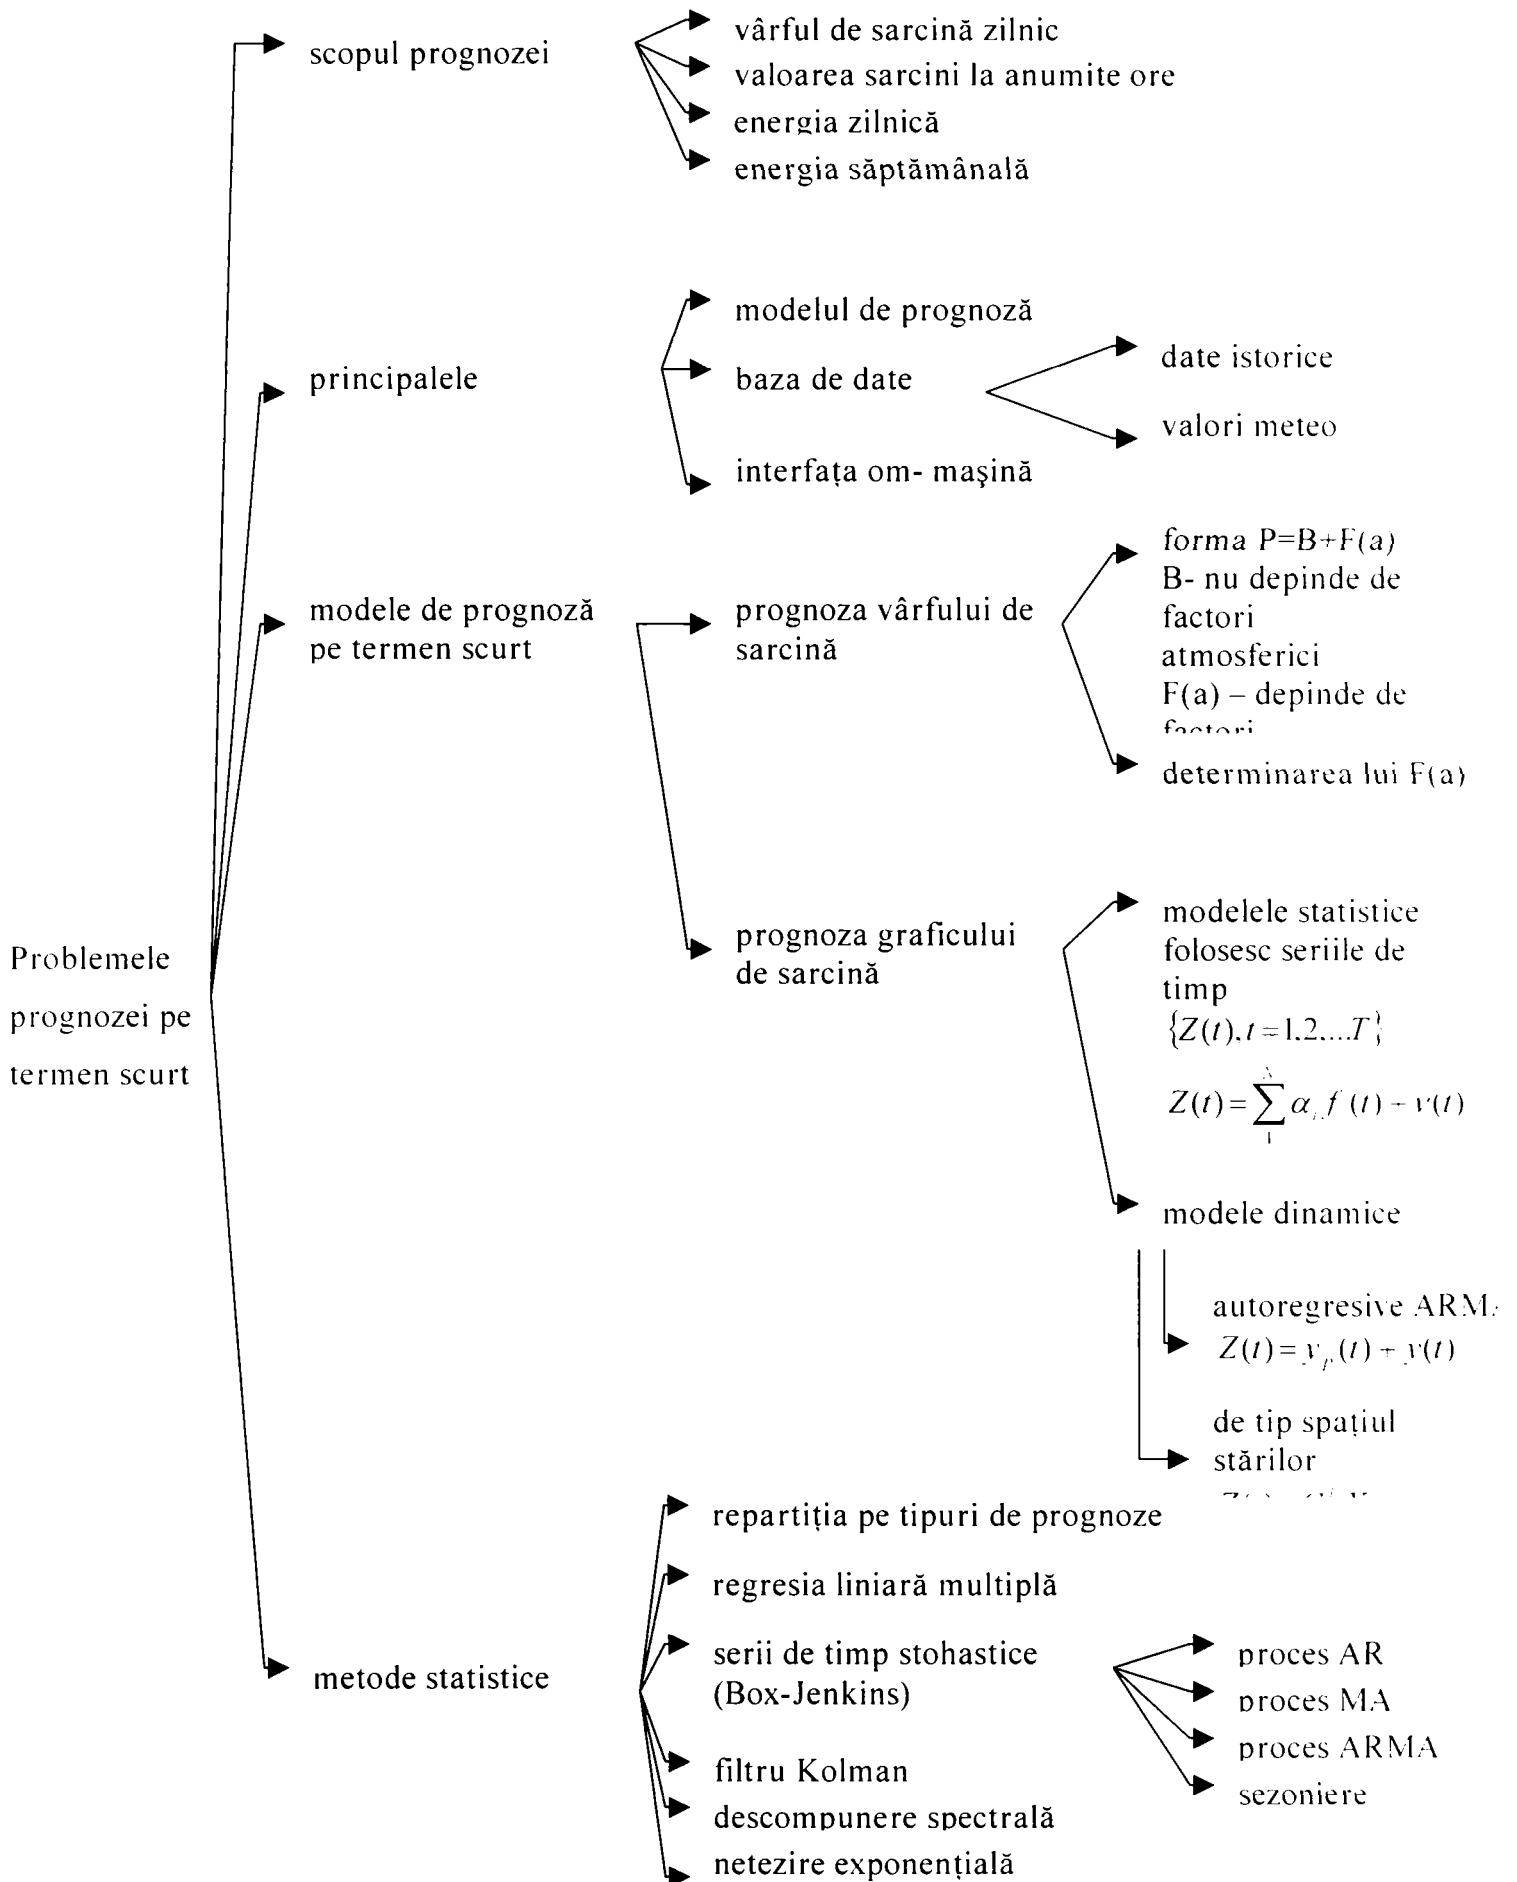


Figura 2.9. Problemele prognozei pe termen scurt

2.6. Concluzii

Scopul acestui capitol a fost acela de a prezenta aspectele generale pe care le comportă abordarea problemelor aferente activității de prognoză a consumurilor de energie, insistându-se asupra problemelor clasice. Aceste probleme stau de fapt la baza rezultatelor și experienței uriașe cumulate de companiile de electricitate pe de-o parte, pe de altă parte, ele stau la baza apariției și dezvoltării metodelor moderne, larg folosite astăzi.

În acest sens, de la bun început, s-a dorit a se evidenția faptul că activitatea de prognoză a consumurilor de energie nu este o activitate singulară, ea nu poate fi concepută separat, pe de-o parte, față de întreaga activitate care se desfășoară în cadrul sistemului energetic național, iar pe de altă parte, față de întreaga viață social economică și politică a societății. Consumul de energie, evoluția sa este condiționată de aceste aspecte prin anumiți factori, factori care stau apoi la baza clasificării și diferențierii metodelor de prognoză.

Clasificarea metodelor de prognoză, precum și a componentelor acestora se poate efectua după multe criterii, fapt ce a fost relevat încă de la începutul capitolului, precizându-se caracterul direct sau indirect, global sau analitic, liniar sau neliniar al modelului și altele.

Un element, deloc de neglijat în cadrul desfășurării efective a activității de prognoză, este adoptarea celor mai adecvate modele pentru efectuarea prognozei. Stabilirea criteriilor pentru aprecierea calității modelelor matematice adoptate este fundamentală în acest sens și aceasta, după cum a rezultat, va influența hotărâtor nivelul reziduurilor obținute.

În ultima parte a capitolului s-a insistat asupra metodelor indirecte de prognoză și, legat de acestea, s-a evidențiat problematica lor, insistându-se pe necesitatea abordării corespunzătoare a regresei liniare multiple, element ce, ulterior în lucrare, va mai fi regăsit. De asemenea s-a considerat util a introduce și câteva elemente introductive legate de prognoza pe termen scurt a necesarului de energie.

Desigur, contribuțiile aduse de autor în acest capitol se referă la sistematizarea unui volum de informații deosebit de vast, de evidențiere a unor elemente specifice și fundamentale în activitatea de prognoză a necesarului de energie electrică și, nu în ultimul rând, la pregătirea elementelor necesare abordărilor ulterioare din lucrare.

BIBLIOGRAFIE

- 2.1. LUȘTREA,B - Prognoza consumului de energie, Editura AGIR, București 2001;
- 2.2. BUTA, A. - Energetică generală și conversia energiei, Litografia IPTVT, Timișoara 1982;
- 2.3. CRIȘAN, O. - Optimizări decizionale în sistemele electroenergetice, Editura Facla, Timișoara, 1975;
- 2.4. GEORGESCU,GH.
RĂDĂȘANU,D. - Transportul și distribuția energiei electrice vol.I, Editura Gh.Asachi, Iași, 2000;
- 2.5. NIȚU,V.ș.a. - Energetică generală și casieria energiei, Editura Didactică și Pedagogică, București, 1980;
- 2.6. NIȚU, V. - Economia energiei, vol.I, Editura tehnică, București, 1981;
- 2.7. HORE,R.A. - Metode moderne de calcul și proiectarea sistemelor electrice, traducere din lb.engleză, Editura tehnică, București, 1970;
- 2.8. CSABAN ș.a. - Folosirea corelațiilor multiple pentru planificarea de energie în întreprinderile industriale, Energetica nr.2, 1967, pp.79-82;
- 2.9. COSTIN,E. - Considerații privind evoluția consumului global de energie electrică, Energetica nr.12, 1967, pp.551-561;
- 2.10. COGĂLNICEANU A,
EGYEA, E. - Preliminarea formei curbelor de sarcină. Studii și cercetări de Energetică și Electrotehnică, nr.2, 1970, pp.237-251;
- 2.11. CARACUDOVICI,V.ș.a. - Îmbunătățirea calității prognozelor energetice prin modificarea exponenților funcțiilor de modelare, Studii și cercetări de Energetică și Electrotehnică, nr.1, 1971, pp.3-13;
- 2.12. MANEA,S, LICIU,N. - Prognoza consumului de energie electrică, prin comparații cu alte țări, Studii și cercetări de ENERGETICĂ și ELECTROTEHNICĂ, nr.4, 1971, pp.713-731;
- 2.13. COSTIN, E.,
BORDEANU , S. - Clasificarea curbelor de sarcină prin metode statistice, Energetica, nr.2, vol.21, februarie 1973, pp.65-68;
- 2.14. CARACUDOVICI, V.ș.a. - Contribuții la îmbunătățirea calității prognozelor consumului de energie în industrie, Studii și cercetări de ENERGETICĂ și ELECTROTEHNICĂ, nr.3, 1970, pp.515-525;
- 2.15. CÂRTINA, GH.,
GAVRILAȘ,M.
GEORGESCU,GH.,
BONCIU,C. - Rețele neuronale artificiale și sisteme expert în energetică, Editura “Gheorghe Asachi”, Iași, 1994;
- 2.16. CIVANLADAR, S,
GRAINEGER,J.J. - Forecasting distribution feeder loads: modelling and application to VOLT/VAR control, IEEE Trans.on Pwer distribution, vol.3, no.1, 1988, pp.255;
- 2.17. CRIȘAN,O., BUTA A.,
LUȘTREA,B.,
KILYENI,ȘT - Prognoza consumului de energie electrică, Energetica, vol.XXII, nr.10-11-12, 1974, pp.405-414;

- 2.18. CRIȘAN,O., BUTA A., LUȘTREA,B., KILYENI,ȘT - Organizarea activității de prognoză pentru consumul de energie electrică, Buletinul Științific și tehnic al IPTVT, tom 20, fasc1, 1975, pp.70-72;
- 2.19. CRIȘAN,O., BUTA A., LUȘTREA,B., KILYENI,ȘT. - Propuneri privind organizarea sistemului informațional în cadrul IRE-urilor, în vederea asigurării datelor necesare activității de prognoză pentru consumul de energie electrică și putere de vârf, Buletinul Științific și Tehnic al IPTVT, tom 20, fasc.1, 1975, pp.177-179;
- 2.20. KEZHANI, A., MIRI,S,M - On line weather sensitive and industrial group bus load forecasting for microprocesor based algorithms, IEE Power App.and Systems, PAS-102, vol.8, no.12, 1983, pp.3808-3826;
- 2.21. KILYENI,ȘT., LUȘTREA,B., CRIȘAN,O., BUTA A. - Metodă de obținere și de selectare a prognozelor de consum cu ajutorul calculatoarelor numerice, Buletinul Științific și Tehnic al IPTVT, tom 21, fasc 1, 1976, pp.67-69;
- 2.22. KILYENI,ȘT., LUȘTREA,B., CRIȘAN,O., BUTA A. - Prognoza consumului de energie electrică și putere de vârf efectuată în zona unui IRE utilizând calculatorul FELIX C256, Datele, modelul matematic și programele utilizate, Energetica, vol. XXV, m 6, 1977, pp 201-206;
- 2.23. KILYENI,ȘT., LUȘTREA,B., CRIȘAN,O., BUTA A. - Prelucrarea și prezentarea rezultatelor pentru consumul de energie electrică, Energetica, vol.XXV, m 7, 1977, pp. 245-252;
- 2.24. KLEINPETER,M. - Energy planning and policy, John Wilwy & Sons, New York, 1996;
- 2.25. LUȘTREA,B., KILYENI,ȘT. BUTA A., CRIȘAN,O. - Analiza rezultatelor prognozelor de energie electrică și putere de vârf efectuate pentru o zonă de consum, Buletinul Științific și Tehnic al IPTVT, tom 21, fasc 2, 1976, pp 189-191;
- 2.26. MOHAMMED,O., PARK,D. MERCHANT, R, DINH, T., TONG,C., AZEEM, A. - Practical experience with an adaptive neural network short term. load forecasting system, IEEE Trans.on Power Systems, vol.10, no 1, February 1995, pp 254-265;
- 2.27. MOHGRAM,I., RAHMAN,S - Analysis and evaluation of five short-term load forecasting techniques, IEEE Transactions on Power Systems, vol.4, October 1989, pp 484-490;
- 2.28. MONTGOMERY,D,C., PECK E.,A. - Introduction to linear regression analysis, second Edition, John Wilwy & Sons, New York, 1992;
- 2.29. MUELLER,H., MOGHADDAS,T. AFRESHI S-M., PETRISCH,G. - Energy and load forecasting by fuzzy-neural networks, EUFIT'98, vol.3, pp 1925-1929;
- 2.30. POPESCU,TH., DEMETRIU,S. - Practica modelării și predicției seriilor de timp, Metodologia Box-Jenkins, Editura Tehnică, București, 1991;
- 2.31. RAHMAN,S., HAZIM,O. - A generalised knowledge-based short-term load-forecasting technique, IEEE Transactions on laser systems, vol.8,no.2,May 1993, pp 505-514;

- 2.32. SAPORTA,G. - Probabilites; analyse desdannees et statistique, Edition TECHNIP, Paris, 1990;
- 2.33. SATOM RYO, EIICHI, TANAKA, JUNHASEGAWA - Daily load forecasting using neural network combined with regression analysis, ISAP'94, pp 345-349;
- 2.34. TERTISCO,M., STOICA,P. - Identificarea și estimarea parametrilor sistemelor, Editura Academiei, București, 1980;
- 2.35. TERTISCO,M., STOICA,P., POPESCU,TH. - Modelarea și predicția seriilor de timp, Editura Academiei, București, 1985.
- 2.36. BUTA, A, MOGA, M, ȘURIANU, FL, - Prognoza energiei prin comparații internaționale, Conferința Națională de Energetică, vol.13, Timișoara 1982 pp35 – 44,
- 2.37. ***, - Energie mondiale, Dossier statistique, EDF, Direction de l' Equipement, mars 1981, p 35-37,
- 2.38. JEAN- ROMAIN, FRISCH, - L'équilibre mondial entre besoins et resurces d' énergie à l'horizont 2000, Revue de l' Energie, mars 1977, pp. 32-35,
- 2.39. BAUMIER, ș.a., - Les tendances économiques à longue terme des générateurs et leurs place dans les contextes énergétiques, RGN, No 6, Novembre- Décembre, 1980, pp. 570-581,
- 2.40. MASTERS, E, F, BERRIES, T, W, - Problem solving using technology, economics and politics, 11 the World Energy conference, 1980, München, pp. 538-558,
- 2.41. COCÂRLĂ, T, - Consumul de energie și economia de energie , Energetica în următoarele trei decenii, editura Academiei Române, 1979, pp. 31-39,
- 2.42. PAPALEXOPOULOS, A, D, MESTERBERG, T, C, - A regression based approach to short- term system load forecasting, IEEE Trans on Power Systems vol PWRS –5, No 4, November 1990, pp. 135-154,
- 2.43. CRMRISTIAANSE,W,R, - Short- terms load forecasting using general exponential smoothing, IEEE Trans. On Power App and Systems, vol PAS – 90. No 2. March/April 1971. pp. 900-911,
- 2.44. TOYODA, J, CHEN, M, INOVE, Y, - An application of state estimation to short- term load forecasting, I and II, IEEE Trans. On Power App and Systems,vol Pas-89, september 1970, pp 1678-1688,
- 2.45. MAGAN, M, T, BEMR, S, M, - The time series approach to short- term load forecast, IEEE Trans. On Power App and Systems, vol Pas-2, No 3, Aug. 1987, pp. 785-791,
- 2.46. RAHMAN, S, HAZIM, O, - A generalized knowledge based short- term load forecasting technique, IEEE Trans. On Power Systems, vol PWRS 8, No 2, May 1993, pp. 508-514,
- 2.47. LUNGU, I, SILVAȘ, I, PĂUN, M, STEPHENSON, P, - Evaluarea procesului de restructurare a sectorului energetic român în comparație cu experiența din marea Britanie, SNRE–2000,vol 1, pp. 11-21,

METODE MODERNE DE PROGNOZĂ A ENERGIEI ELECTRICE. FOLOSIREA INTELIGENȚEI ARTIFICIALE.

Problemele noi apărute pe care trebuie să le rezolve societățile de electricitate sunt multiple, cele mai importante fiind: îmbunătățirea calității energiei electrice furnizate și creșterea siguranței în alimentarea consumatorilor, reducerea costurilor de investiții / exploatare, planificarea rațională a mentenanței, reducerea impactului asupra mediului etc.

Pentru a găsi soluțiile cele mai raționale se recurge la simulare și modelare matematică. Modelarea matematică a sistemelor complexe cum este cazul celor din electroenergetică, este adesea dificilă, mai ales în condițiile utilizării unui număr mare de variabile dintre care unele greu de cuantificat. Aceste impedimente pot fi depășite prin utilizarea tehnicilor adecvate de inteligență artificială, aplicabile în absența unui model funcțional riguros al sistemului. De altfel, în prezent, o clasă mare de probleme din domeniul energetic este soluționată de către experți umani, pe bază de experiență sau raționament bazat pe experiență în conjuncție cu rezultatele obținute de analiza numerică. Aceste probleme sunt caracterizate frecvent prin:

- Imposibilitatea dezvoltării unor modele matematice riguroase;
- O parte din condițiile de funcționare, mai ales restricțiile, nu pot fi întotdeauna formalizate matematic;
- Metodologiile de soluționare aplicate de experți umani nu pot fi întotdeauna exprimate sub o formă matematică sau printr-un algoritm . De asemenea, experiența se obține de-a lungul mai multor ani de activitate și implică multă euristică și formulare empirică.

Aplicațiile operaționale ale inteligenței artificiale, realizate până în prezent în electroenergetică, acoperă o arie întinsă de probleme, de la prognoză la planificare până la control și diagnostic.

A defini complet și precis inteligența este imposibil, aspectele acesteia fiind inepuizabile . Există numeroase definiții ale conceptului de inteligență artificială. N. Findler, cercetător cunoscut în acest domeniu, arată că „ un sistem este considerat a avea proprietatea de inteligență, pe baza observării comportării sistemului, dacă se poate adapta singur la noi situații, are capacitatea de a raționa, de a înțelege legăturile dintre fapte, de a descoperi înțelesuri și de a recunoaște adevărul. De asemenea, ne așteptăm ca un sistem inteligent să învețe, cu alte cuvinte, să-și îmbunătățească nivelul performanțelor pe baza experienței trecute”.

O altă definiție dată de J. Mc. Carty și P.J. Hayes consideră că „, o entitate este inteligentă dacă ea are un model adecvat al lumii (inclusiv lumea intelectuală a matematicii, înțelegerea obiectelor sale proprii și alte procese mentale), dacă este destul de înzestrată pentru a răspunde unei largi varietăți de întrebări pe baza acestui model, dacă poate să-și procure informațiile din lumea exterioară când are nevoie și poate să realizeze anumite operații în mediul înconjurător, cerute de obiectivele sale și permise de posibilitățile sale fizice”. Deci, inteligența unui sistem se definește nu prin modul în care este el construit, ci prin modul în care se comportă.

Este de așteptat ca, în numeroase situații proiectarea, construcția și exploatarea rețelelor electrice să impună respectarea unor restricții mult mai severe ca până în prezent. În acest context, rezolvarea unui număr mare de probleme practice va implica, într-un fel sau altul, elaborarea unor soluții bazate pe diferitele forme ale inteligenței artificiale, ca de exemplu sistemele expert, rețelele neuronale artificiale, algoritmi genetici sau sistemele fuzzy.

Cea mai mare parte a metodelor de prognoză studiate și propuse în literatura de specialitate, în ultimul deceniu, au la bază rețelele neuronale artificiale RNA.

Interesul acordat RNA are la bază următoarele aspecte : pot fi modelate, antrenate și exploatare simplu, fiind cunoscute ca „aproximanți universali”, se adaptează ușor unor noi situații, pot memora relații complexe, chiar în absența oricărui model funcțional, fiind concepute în special pentru tratarea problemelor.

3.1. Modele și structuri de rețele neuronale artificiale

3.1.1. Aspecte generale

La originea dezvoltării cercetărilor în domeniul rețelelor neuronale (RNA) se găsește o constatare simplă : există sarcini cărora calculatoarele numerice convenționale le pot face față cu dificultate, în timp ce sistemul nervos al celor mai simple organisme găsește un răspuns fără a face eforturi evidente. Acestea sunt, de exemplu, cazurile recunoașterii formelor sau coordonării mișcărilor. Performanțele remarcabile ale creierului uman au lăsat să se întrevadă unele avantaje ce s-ar putea obține folosind modele de inspirație biologică.

Studiul RNA a început în 1943 cu prezentarea primului model de neuron artificial propus de W. Mc. Culloch și W. Pitts. Cercetările întreprinse de Von Neumann au pus bazele teoretice ale construcției primelor calculatoare. Arhitectura calculatorului descoperită de Von Neumann, care folosea pentru aceasta mașina concepută de Turing, reflectă ideea că în creierul uman există două părți diferite, una dedicată „gândirii” (sau procesării, dacă vorbim despre calculatoare) și o alta dedicată memorării. În realitate acest lucru nu a fost niciodată confirmat experimental. Unul din aspectele fundamentale ale modelului lui Von Neumann este tratarea simbolică a informației. După crearea primului model de neuron formal, în 1962 este introdus conceptul de perceptron de către F. Rosenblatt [3.1.] . Aceste modele au stat la baza apariției și dezvoltării structurilor cunoscute în prezent sub numele de RNA. O expansiune importantă a cercetărilor în domeniul RNA s-a înregistrat începând cu anul 1986, după dezvoltarea unor modele de rețele și algoritmi de învățare suficient de performanți pentru rezolvarea unor probleme practice de complexitate sporită [3.2.].

Neuronul formal este un element de procesare a informației care modelează, de o manieră simplificată, neuronul real. Cea mai simplă versiune de neuron formal este un automat binar cu două stări : activ (+1) și inactiv (-1)(figura 3.1.). Starea neuronului se actualizează periodic după următorul mecanism : se determină potențialul neuronal v_i , calculând suma ponderată a intrărilor x_j (care reprezintă ieșirile altor neuroni din rețea sau informații provenind de la neuronii de intrare); acest potențial este comparat cu un prag θ_i neuronul activându-se ($y_i = +1$) dacă $v_i \geq \theta_i$ sau devenind pasiv ($y_i = -1$) dacă $v_i < \theta_i$. Această prelucrare a informației în interiorul neuronului corespunde unei funcții de transfer de tip treaptă (Heaviside), denumită frecvent funcție de activare.

O variantă îmbunătățită a neuronului formal folosește ca funcție de activare o funcție de tip sigmoid (figura 3.2.). În acest caz, în apropierea pragului θ_i , variația stării neuronului între +1 și -1 este graduală. Principalul avantaj al unei asemenea funcții de activare îl reprezintă proprietatea de continuitate pe întregul interval de definiție, proprietate esențială dacă se dorește aplicarea unor algoritmi de învățare performanți și eficienți. Există două tipuri de

funcții folosite mai frecvent : funcția tangent hiperbolic, care ia valori în intervalul (-1, +1) (figura 3.2.) și funcția sigmoid logistic, care ia valori în intervalul (0, +1), având expresia:

$$f(v_i) = \frac{1}{1 + e^{-kv_i}} \quad (3.1)$$




Figura 3.1. Modelul neuronal formal

În unele cazuri, neuronul poate folosi o funcție de activare liniară, caz în care neuronul se reduce la un sumator.




Figura 3.2. Funcția de activare de tip sigmoid

3.1.2. Arhitectura tipică a unei rețele neuronale artificiale

Neuronul formal calculează suma ponderată a intrărilor, care este trecută apoi prin funcția de activare, cu o formă în general neliniară. Îndeplinirea unor funcții care să facă posibilă abordarea unor probleme complexe, de interes practic, este posibilă numai dacă neuronii sunt asociați într-un sistem numit rețea neuronală.

RNA sunt formate din neuroni (elemente de procesare), organizați pe straturi și legați prin conexiuni sinaptice (căile de transmitere a informației între neuroni, caracterizate de anumite

ponderi. Figura 3.3. ilustrează structura tipică a unei RNA . Rețeaua din figura 3.3. conține trei straturi de neuroni, dintre care primul este stratul de intrare [x], iar ultimul stratul de ieșire [z], stratul intermediar numindu-se și strat ascuns [y].

Singurele straturi care realizează procesarea propriu-zisă a informației sunt stratul ascuns și cel de ieșire. 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 de activare identitate ($y_i = v_i$). Legăturile dintre straturile RNA se realizează prin conexiuni sinaptice ponderate. Pentru RNA din figura 3.3., fiecare neuron dintr-un strat este legat cu toți neuronii din stratul următor și nu există legături între straturile neconsecutive (de exemplu, intrare-ieșire). O asemenea structură este cunoscută sub numele de RNA complet conectată.

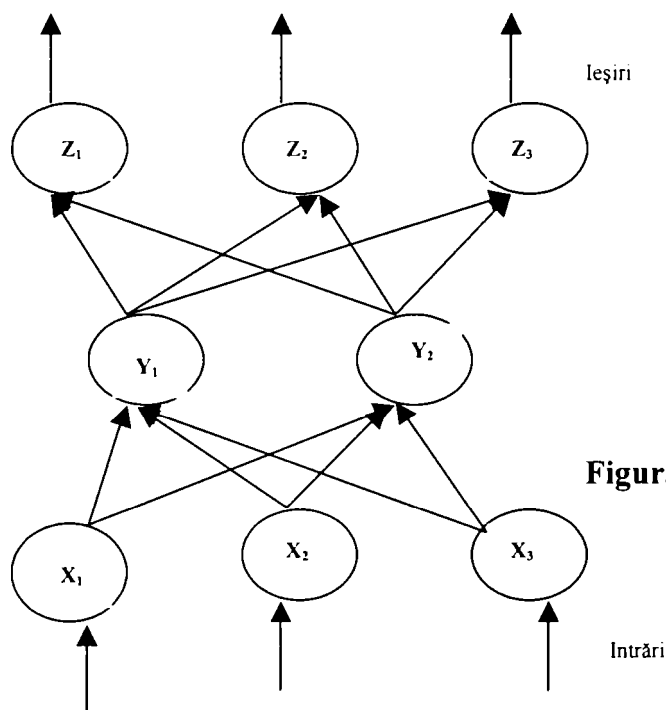


Figura 3.3. Arhitectura tipică a unei RNA

Structura RNA este descrisă complet de matricele ponderilor conexiunilor dintre două straturi consecutive $|W|$, 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 au caracter excitatoriu, ponderile negative - caracter inhibitoriu, iar ponderile nule indică absența conexiunii între cei doi neuroni. Totodată, 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 figura 3.3. are anumite proprietăți care se aplică unei categorii largi de rețele neuronale:

- 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.

3.1.3. Caracteristici 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:

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

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 3 mari categorii.

- Rețele feedforward (statice);
- Rețele feedback (dinamice);
- Rețele de tip celular (plasă).

În rețelele feedforward (numite și nebuclate) informația circulă într-un sens, de la intrare către ieșire. Prin urmare, RNA nebuclate sunt structuri statice, folosite cu precădere pentru rezolvarea unor probleme de clasificare sau de identificare a proceselor statice. Din această categorie fac parte rețelele de tipul Perceptronului multistrat (figura 3.4.).

Rețelele feedback (numite și buclate) sunt acele rețele ale căror grafuri de conexiuni conțin cicluri; circulația informației are loc de această dată în ambele sensuri (intrare – ieșire, respectiv ieșire – intrare), astfel încât starea neuronilor la un moment dat este determinată de starea curentă și de starea la momentul anterior. Prin urmare RNA buclate au proprietățile unor sisteme dinamice ; ele sunt utilizate ca memorii asociative și pentru identificarea sau controlul sistemelor dinamice. Una din rețelele buclate folosită mai des în aplicațiile practice este rețeaua Hopfield (figura 3.5.).

Rețelele de tip celular 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 (figura 3.6.).

Există, de asemenea, rețele hibrid, care folosesc atât legături feedforward, cât și legături feedback, un exemplu fiind rețeaua Hamming (figura 3.7.), numită și clasificator după similaritate maximă.

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. În acest caz stratul unic joacă rol dublu intrare- ieșire. Totodată, absența altor straturi impune ca aceste RNA să aibă o topologie buclată . În această categorie se înscriu rețelele Hopfield (figura 3.5.), precum și variante ale acestora, care se deosebesc în funcție de modul de conectare a neuronilor.




Figura 3.4. Perceptonul Multistrat

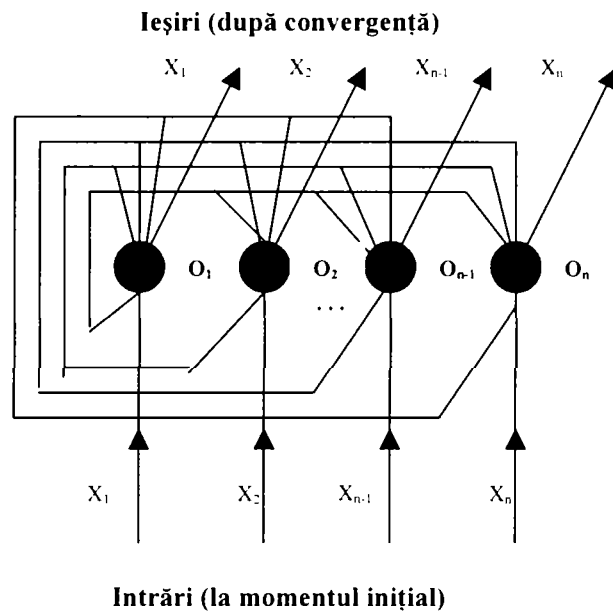


Figura 3.5. Rețea Hopfield

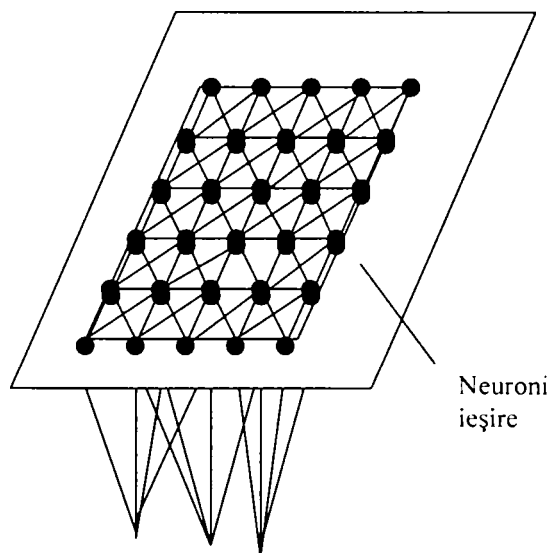


Figura 3.6. Rețea Kohonen

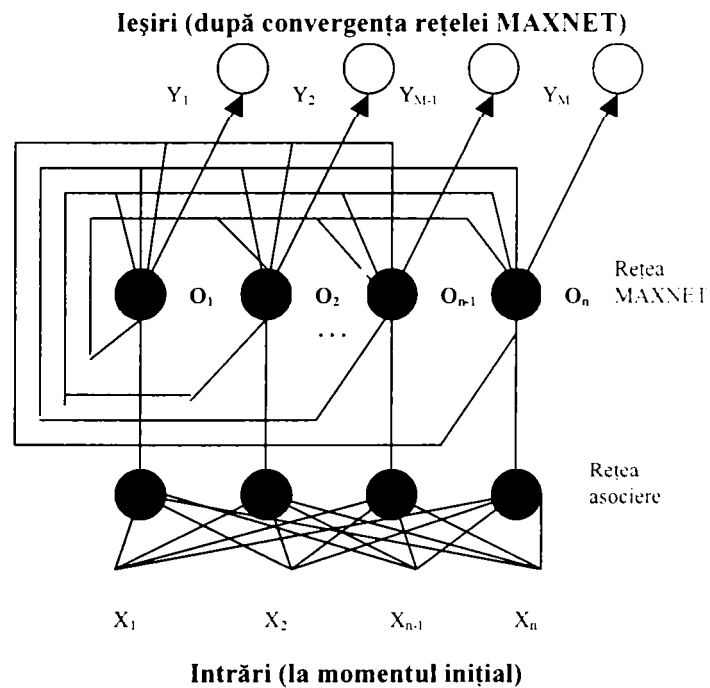


Figura 3.7. Rețea Hamming

- RNA cu două straturi. În acest caz, primul strat este stratul de intrare, iar al doilea cel de ieșire, neexistând un strat ascuns. În funcție de topologia lor, se disting RNA feedforward (figura 3.8.) sau RNA hibride feedforward-feedback (figura 3.9.).
- RNA multistrat. Rețelele din această categorie pot avea, în principiu, un număr nelimitat de straturi. Toate straturile, cu excepția primului și ultimului, sunt straturi ascunse. Structura generală a unei asemenea RNA a fost indicată în figura 3.4. Majoritatea RNA multistrat utilizate în diverse aplicații practice fac parte din

categoria rețelelor feedforward (nebuclate), iar răspândirea cea mai mare o are Perceptronul multistrat.




Figura 3.8. RNA cu două straturi de tip feedforward




Figura 3.9. RNA cu două straturi de tip hibrid

În general, RNA sunt caracterizate nu numai prin arhitectura lor, ci și prin tipul neuronilor utilizați și prin procedura de învățare. Metodele de antrenare pot fi clasificate în două mari categorii : antrenare supravegheată și nesupravegheată.

Antrenarea supravegheată, numită uneori și învățare neadaptivă, prezintă următoarele particularități :

- Informația prelucrată are caracter global ;
- Setul de date de învățare conține un număr finit de modele de învățare, cunoscute în prealabil;
- Necesită supravegherea din exterior a procesului de adaptare a ponderilor și pragurilor, prin calculul abaterii între ieșirile rețelei și cele dorite;
- Încheierea etapei de antrenare se face la hotărârea „supraveghetorului”, care decide unilateral dacă, în acel moment, performanțele rețelei sunt sau nu satisfăcătoare.

Schematic învățarea supravegheată este reprezentată în figura 3.10.

De obicei, procedura utilizată pentru corecția ponderilor este de tipul gradientului descendent al funcției eroare. Această procedură necesită un număr substanțial de modele intrare- ieșire, numit set de antrenare. Antrenarea nesupravegheată, numită și învățare adaptivă sau auto- organizare, prezintă următoarele particularități:

- Informația prelucrată are caracter local;
- Setul de date de învățare poate conține un număr nelimitat de exemplare, care se adaugă la setul inițial pe măsura rafinării performanțelor rețelei;
- Procesul de adaptare a ponderilor și a pragurilor nu necesită supravegherea din exterior, deoarece rețeaua își organizează singură informația;
- Etapa de antrenare se încheie în momentul în care se definitivează organizarea datelor din setul de învățare inițial; ea poate fi reluată oricând, dacă apar noi caracteristici ale datelor din acest set.

În figura 3.11. este reprezentat schematic principiul învățării nesupravegheate.

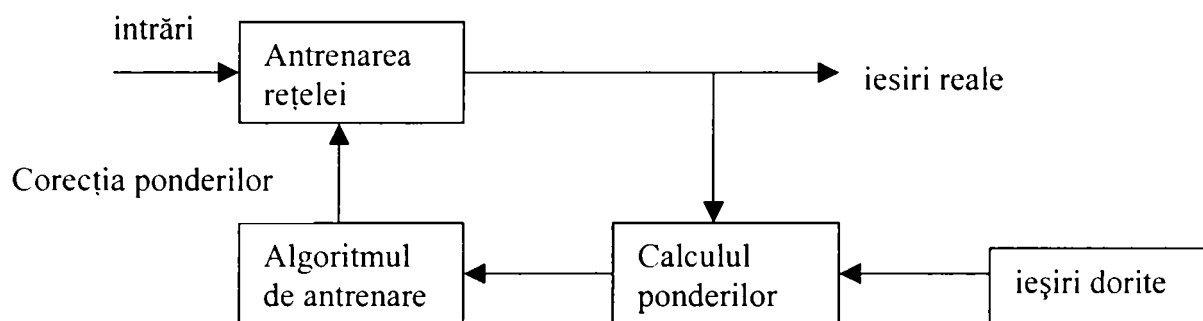


Figura 3.10. Învățarea supravegheată

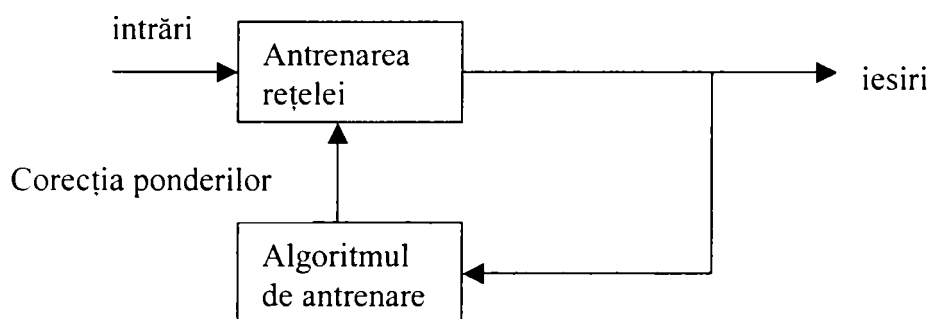


Figura 3.11. Învățarea nesupravegheată

În literatură sunt menționate o varietate largă de arhitecturi și câteva tipuri principale de RNA [3.3.,3.4.,3.5.]. Astfel, se folosesc structuri de tipul perceptronului multistrat (PMS), rețelele Kohonen, modele neuronale, modele neuronale adaptive sau rețele recurente BPTT (Back Propagation Throught Time).

Dintre aceste arhitecturi, singurele care au condus la rezultate pozitive și care au suportat îmbunătățiri succesive în timp, sunt primele două.


3.1.4. Rețele neuronale de tip Perceptron Multistrat

Rețelele de tip Perceptron Multistrat (PMS) reprezintă o clasă largă de RNA feedforward, cu neuronii aranjați pe straturi. În general, toți neuronii de pe un strat sunt conectați cu toți neuronii straturilor adiacente, prin conexiuni unidirecționale, numite și ponderi sinaptice. În figura 3.12. este reprezentat schematic PMS cu un singur strat ascuns.

I_0 , I_1 și I_2 indică numărul neuronilor de pe fiecare strat. Neuronii de pe primul strat (numit uneori și strat de intrare) nu realizează nici o procesare a informației, ci asigură doar transmiterea semnalelor de intrare (x_i) către neuronii de pe al doilea strat, numit strat ascuns.

Se notează cu $u_j^{[s]}$ valoarea semnalului neuronului j , de pe stratul s . Suma ponderată a intrărilor acestui neuron este calculată cu relația:

$$u_j^{[s]} = \sum_{i=0}^{I_s-1} w_{ji}^{[s]} * o_i^{[s-1]} \quad (3.2)$$


Figura 3.12. Perceptonul Multistrat

unde: $w_{ji}^{[s]}$ sunt ponderile conexiunilor prin care neuronul j multiplică intrările $x_i^{[s]} = o_i^{[s-1]}$, $o_i^{[0]} = x_i$, I_L este numărul neuronilor din stratul s și $o_i^{[s-1]}$ ieșirea neuronului i , de pe stratul $s-1$.

Ieșirea neuronului este calculată trecând suma ponderată a intrărilor sale ($u_j^{[s]}$) printr-o funcție de activare limitată neliniară $\psi_j^{[s]}$:

$$O_j^{[s]} = \psi_j^{[s]}(u_j^{[s]}) = \psi_j^{[s]} \left[\sum_{i=0}^{I_s-1} w_{ji}^{[s]} O_i^{[s-1]} \right] \quad (3.3)$$

Simbolurile utilizate pentru descrierea RNA de tip PMS sunt:

$s =$ indice strat; $0 \leq s \leq L$, unde $L =$ numărul de straturi și $s = 0$ reprezintă stratul de intrare;

$i =$ indice neuron de pe stratul s ; $1 \leq i \leq I_s$, unde: $I_s =$ numărul neuronilor de pe stratul s ;

$I_o =$ numărul intrărilor;

$I_L =$ numărul neuronilor de ieșire;

$i = 0$ indică pragul (bias);

$O_i^{[s]} =$ ieșirea neuronului i de pe stratul s ; $0 \leq o_i^{[s]} \leq 1$, unde: $o_i^{[s]} = x_i$ este intrarea i a rețelei;

$w_{ji}^{[s]} =$ ponderea sinaptică pentru conexiunea dintre neuronul i de pe stratul s și neuronul j de pe stratul $s-1$; $w_{ji}^{[s]} \in \mathfrak{R}$, $s \geq 1$, unde $w_{j0}^{[s]} =$ pragul neuronului j de pe stratul s ;

$d_i =$ valoarea dorită (target) pentru ieșirea neuronului i de pe stratul de ieșire;

$Q =$ numărul total de conexiuni; $Q = \sum_{s=1}^L I_s * (I_{s-1} + 1)$;

$P =$ numărul total de modele (pattern-uri); $1 \leq p \leq P$.

Când semnalele de intrare se propagă înainte prin rețea, pe fiecare strat, ieșirile sunt calculate succesiv și sunt apoi furnizate ca intrări stratului următor până la stratul de ieșire.

Fiecare strat al rețelei poate fi reprezentat prin relația:

$$o^{[s]} = \psi^{[s]} \left[W^{[s]} x^{[s]} \right], \quad (3.4)$$

unde: $o^{[s]} = [o_1^{[s]}, o_2^{[s]}, \dots, o_{I_s}^{[s]}]^T$ este vectorul de ieșire,

$x^{[s]} = [x_1^{[s]}, x_2^{[s]}, \dots, x_{l_{s-1}}^{[s]}]^T$ este vectorul de intrare,

$x^{[s]} = o^{[s-1]}$,

$W^{[s]} = [w_{ji}^{[s]}]_{l_s \times (l_{s-1}+1)} \in \mathfrak{R}^{l_s \times (l_{s-1}+1)}$ este matrice de interconexiuni a ponderilor sinaptice dintre stratul s și $s-1$,

$\psi^{[s]}[\cdot]$ este un operator neliniar cu funcții de activare de tip sigmoidal.

Toate intrările rețelei neuronale sunt valori reale, normalizate (scalate) într-un interval care poate fi unipolar sau bipolar, de exemplu $[0,1]$ sau $[-1,1]$. În prezent, cea mai utilizată funcție de activare este sigmoidul logistic, care are proprietatea că este continuă și derivabilă. Algoritmul de antrenare al rețelei de tip PMS este cunoscut sub numele de Generalised Delta Rule sau Error Back Propagation (propagare înapoi a erorii) și este primul care a rezolvat problema separației neliniare a datelor de intrare [3.2.], [3.6.].

3.1.4.1. Algoritmul standard Back – Propagation 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 x_i și m ieșiri dorite corespunzătoare d_j . Antrenarea Perceptronului Multistrat 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 curentă 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, ce minimizează funcția eroare, funcție care pentru modelul p de antrenare este dată de relația:

$$E_p = \frac{1}{2} \sum_{j=1}^m (d_{jp} - y_{jp})^2 = \frac{1}{2} \sum_{j=1}^m e_{jp}^2 \quad (3.5)$$

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

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \sum_{p=1}^P \sum_{j=1}^m (d_{jp} - y_{jp})^2 \quad (3.6)$$

unde d_{jp} și y_{jp} sunt ieșirea dorită, respectiv curentă 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 exemplul cu exemplul în care modelele de antrenare sunt prezentate secvențial, de obicei în ordine aleatorie. După fiecare model de antrenare prezentat ponderile sinaptice $w_{ji}^{[s]}$ ($s = 1..L$) sunt modificate cu o valoare $\Delta w_{ji}^{[s]}$ proporțională cu valoarea negativă a gradientului momentan al funcției de eroare (locală) corespunzătoare E_p care poate fi scris matematic astfel:

$$\Delta w_{ji}^{[s]} = -\eta \frac{\partial E_p}{\partial w_{ji}^{[s]}}, \eta > 0 \quad (3.7)$$

S-a demonstrat că, dacă parametrul de învățare η este suficient de mic, această procedură minimizează funcția globală de eroare E . Bineînțeles că regula gradientului prezentată anterior poate fi înlocuită cu ecuații diferențiale continue, care pot fi modelate practic folosind circuite analogice:

$$\frac{dw_{ji}^{[s]}}{dt} = -\mu \frac{\partial E_p}{\partial w_{ji}^{[s]}}, \mu > 0 \quad (3.8)$$

În cea de-a doua tehnică, numită învățare globală (batch learning), funcția de eroare globală E este minimizată după ce toate modelele au fost prezentate, 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 $w_{ji}^{[s]}$. Astfel, ecuația (3.7) poate fi scrisă:

$$\Delta w_{ji}^{[s]} = -\eta \frac{\partial E_p}{\partial w_{ji}^{[s]}} = -\frac{\partial E_p}{\partial u_j^{[s]}} \frac{\partial u_j^{[s]}}{\partial w_{ji}^{[s]}} \quad (3.9)$$

Luând în considerație că:

$$u_j^{[s]} = \sum_{i=1}^m w_{ji}^{[s]} x_i^{[s]} = \sum_{i=1}^m w_{ji}^{[s]} o_i^{[s-1]} \quad (3.10)$$

și definind termenul eroare prin relația :

$$\delta_j^{[s]} = -\frac{\partial E_p}{\partial u_j^{[s]}} = -\frac{\partial E_p}{\partial e_{jp}} \frac{\partial e_{jp}}{\partial u_j^{[s]}} = e_{jp} \frac{\partial \psi_j^{[s]}}{\partial u_j^{[s]}} \quad (3.11)$$

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

$$\Delta w_{ji}^{[s]} = \eta \delta_j^{[s]} x_i^{[s]} = \eta \delta_j^{[s]} o_i^{[s-1]} \quad (3.12)$$

unde,

$$\delta_j^{[s]} = e_{jp} \left(\psi_j^{[s]} \right)' = (d_{jp} - y_{jp}) \frac{\partial \psi_j^{[s]}}{\partial u_j^{[s]}} \quad (3.13)$$

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 :

$$\Delta w_{ji}^{[s-1]} = -\eta \frac{\partial E_p}{\partial w_{ji}^{[s-1]}} = -\frac{\partial E_p}{\partial u_j^{[s-1]}} \frac{\partial u_j^{[s-1]}}{\partial w_{ji}^{[s-1]}} = \eta \delta_j^{[s-1]} x_i^{[s-1]} = \eta \delta_j^{[s-1]} o_i^{[s-2]} \quad (3.14)$$

unde termenul eroare pentru ultimul strat ascuns este dat de :

$$\delta_j^{[s-1]} = -\frac{\partial E_p}{\partial u_j^{[s-1]}} \quad (3.15)$$

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

$$\delta_j^{[s-1]} = -\frac{\partial E_p}{\partial u_j^{[s-1]}} = -\frac{\partial E_p}{\partial o_j^{[s-1]}} \frac{\partial o_j^{[s-1]}}{\partial u_j^{[s-1]}} \quad (3.16)$$

Luând în considerație că:

$$o_j^{[s-1]} = \psi_j^{[s-1]}(u_j^{[s-1]}) \quad (3.17)$$

avem :

$$\delta_j^{[s-1]} = -\frac{\partial E_p}{\partial o_j^{[s-1]}} \frac{\partial \psi_j^{[s-1]}}{\partial u_j^{[s-1]}} \quad (3.18)$$

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

$$-\frac{\partial E_p}{\partial o_i^{[s-1]}} = -\sum_{i=1}^m \frac{\partial E_p}{\partial u_i^{[s]}} \frac{\partial u_i^{[s]}}{\partial o_i^{[s-1]}} = \sum_{i=1}^m \left(-\frac{\partial E_p}{\partial u_i^{[s]}} \right) \frac{\partial}{\partial o_i^{[s-1]}} \left(\sum_{k=1}^m w_{ik}^{[s]} x_k^{[s]} \right) =$$

$$= \sum_{i=1}^m \delta_i^{[s]} \frac{\partial}{\partial o_i^{[s-1]}} \left(\sum_{k=1}^m w_{ik}^{[s]} o_k^{[s-1]} \right) = \sum_{i=1}^m \delta_i^{[s]} w_{ii}^{[s]}$$

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

$$\delta_i^{[s-1]} = \frac{\partial \psi^{[s-1]}}{\partial u_i^{[s-1]}} \sum_{i=1}^m \delta_i^{[s]} w_{ii}^{[s]} \quad (3.20)$$

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 $\delta_i^{[s]}$ ($s = 1 \dots L$).

Algoritmul de învățare Back- Propagation este prezentat în figura 3.13.

Toate modelele de antrenare sunt prezentate iterativ până când ponderile conexiunilor sunt stabilizate, de exemplu până când eroarea pe întregul set este acceptabilă și rețeaua converge. 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 Perceptronului Multistrat poate fi interpretată astfel: rețeaua neuronală realizează o mapare neliniară între spațiul intrărilor și cel al ieșirilor. Antrenarea Perceptronului Multistrat 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 (modele de antrenare). Din acest punct de vedere, generalizarea nu este altceva decât interpolarea setului test pe hipersuprafața reconstruită.

Pasul 1 Inițializarea ponderilor $w_{ii}^{[s]}$, cu valori mici, aleatorii.

Pasul 2 Prezentarea unui model

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

Pentru anumite implementări, extragerea modelului curent se face în mod aleatoriu.

Pasul 3 Propagarea înainte

Modelul ales se aplică la intrarea rețelei și, folosind ponderile $w_{ii}^{[s]}$ se realizează propagarea înainte, în vederea determinării valorilor reale la ieșirea rețelei (conform ecuațiilor 3.2-3.4).

Pasul 4 Adaptarea ponderilor prin propagarea înapoi

Se folosește un algoritm iterativ care, pornind de la neuronii de ieșire, propagă gradientul erorii înapoi, către neuronii de intrare, realizând adaptarea ponderilor:

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

$$\Delta w_{ii}^{[s]} = \eta \delta_i^{[s]} x_i^{[s]}$$

unde : η este rata de învățare ; $\delta_i^{[s]}$ este termenul de eroare care se calculează cu relația (3.20), pentru straturile ascunse și cu relația (3.11), pentru stratul de ieșire.

Pasul 5 Test convergență

Se prezintă un nou model și algoritmul de adaptare a ponderilor continuă, prin revenirea la Pasul 2, până când eroarea globală într-un ciclu scade sub o valoare impusă.

Figura 3.13. Algoritmul de învățare Back - Propagation

3.1.4.2. Algoritmul Back Propagation cu momentum

Algoritmul de învățare descris anterior are anumite dezavantaje. Mai întâi, rata de învățare η ar trebui să fie aleasă 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 convergența 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 suprarelaxare, de exemplu, adăugând un termen moment:

$$\Delta w_{\mu}^{[s]}(k) = \eta \delta_{\mu}^{[s]} o_{\mu}^{[s-1]} + \alpha \Delta w_{\mu}^{[s]}(k-1) \quad (3.21)$$

unde: $\eta > 0$, $0 \leq \alpha < 1$ (de obicei) $\alpha = 0,9$).

Al doilea termen al ecuației (3.21) este așa numitul termen momentum 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 $\partial E / \partial w_{\mu}$ va fi aceeași la fiecare pas, iar ecuația (3.21) poate fi scrisă astfel:

$$\Delta w_{\mu}^{[s]}(k) = -\eta \frac{\partial E_p}{\partial w_{\mu}^{[s]}(k)} + \alpha \Delta w_{\mu}^{[s]}(k-1) \cong \frac{\eta}{1-\alpha} \frac{\partial E_p}{\partial w_{\mu}^{[s]}(k)} \quad (3.22)$$

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

3.1.4.3. Algoritm de învățare Batch Back Propagation

În algoritmul de învățare on-line descris anterior un model p , din setul de învățare, este prezentat la intrare și apoi toate ponderile sunt actualizate, înainte ca următorul model să fie prezentat. În algoritmul batch, modificările ponderilor $\Delta_p w_{\mu}$ sunt sumate pentru un anumit număr de modele (de obicei după prezentarea tuturor modelelor din setul de antrenare) și apoi se realizează actualizarea ponderilor cu relația :

$$\Delta w_{\mu}^{[s]} = \sum_{p=1}^P \Delta_p w_{\mu}^{[s]} = -\eta \frac{\partial E}{\partial w_{\mu}^{[s]}} = \eta \sum_{p=1}^P \delta_{\mu p}^{[s]} o_{\mu p}^{[s-1]} \quad (3.23)$$

unde indicele p indică faptul că variabila corespunzătoare este calculată pentru modelul p din setul de antrenare. În timpul procesului de antrenare, fiecare iterație este definită a fi o parcurgere completă a tuturor modelelor din lotul de antrenare. La sfârșitul fiecărei iterații ponderile sunt actualizate.

În practică, acest algoritm ia o formă mult mai complicată decât cea dată de ecuația (3.23). Modificarea fiecărei ponderi este adesea realizată cu o relație de

$$\text{forma: } \Delta w_{\mu}^{[s]}(k) = \frac{\eta}{I_{s-1}} \sum_{p=1}^P \delta_{\mu p}^{[s]} o_{\mu p}^{[s-1]} + \alpha \Delta w_{\mu}^{[s]}(k-1) - \gamma w_{\mu}^{[s]}(k) \quad (3.24)$$

unde: η este rata de învățare, α este termenul momentum, γ este factorul de compresie, iar I_{s-1} numărul neuronilor de pe stratul $s-1$. Factorul de compresie γ (cu valori tipice între 10^{-3} și 10^{-5}) previne algoritmul de la generarea unor ponderi foarte mari, care pot deveni o barieră în minimizarea funcției eroare, încât soluția nu mai poate fi găsită într-un timp rezonabil. Mai

mult. factorul de compresie poate îmbunătăți capacitatea de generalizare a RNA. Se poate sublinia că rata de învățare efectivă $\eta_{ef}^{[s]} = \eta / [I_{s-1}(1 - \alpha)]$ este invers proporțională cu numărul neuronilor care trimit intrări spre un anumit neuron. Într-o rețea de tip PMS complet conectată, fiecare neuron de pe un strat primește un număr de intrări egal cu numărul neuronilor de pe stratul inferior, de exemplu I_{s-1} .

După cum s-a subliniat deja, una din problemele serioase ale algoritmului de retropropagare este aceea că poate fi „prins” într-un minim local al funcției eroare. O tehnică simplă și eficientă care permite adesea evitarea minimelor locale constă în prezentarea modelelor de antrenare într-o ordine aleatorie; în acest fel se generează un „zgomot” care permite depășirea minimelor locale. O altă tehnică promițătoare, care îmbunătățește performanțele rețelei neuronale, constă în adăugarea unei mici perturbații peste datele de antrenare. Acest zgomot perturbă algoritmul gradientului descendent de la tendința sa de coborâre către minime și adesea este suficient pentru a îndepărta rețeaua de minimele locale.

3.1.4.4. Algoritmul Resilient Propagation

O soluție foarte eficientă pentru creșterea vitezei de convergență a algoritmului de antrenare este oferită de algoritmul Resilient PROPagation (RPROP) [3.7.] , propus în anul 1993 de doi cercetători germani Martin Riedmiller și Heinrich Braun de la Universitatea Karlsruhe. În locul introducerii termenului momentum, ei au propus alte tehnici pentru accelerarea convergenței procesului, câteva dintre ele fiind bazate pe variația adoptivă 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 $\partial E / \partial w_{\mu}^{[s]}$. 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 că derivata funcției eroare este foarte mică.

Aspectul inovativ al algoritmului RPROP constă în faptul că nu se iau în considerare 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 praguri) are atașat un factor de corecție, indicat prin $\Delta_{\mu}^{[s]}$, care determină adaptarea parametrului respectiv:

$$\Delta_{\mu}^{[s]}(k) = \begin{cases} \eta^+ \Delta_{\mu}^{[s]}(k-1), & \frac{\partial E(k-1)}{\partial w_{\mu}^{[s]}} \frac{\partial E(k)}{\partial w_{\mu}^{[s]}} > 0 \\ \eta^- \Delta_{\mu}^{[s]}(k-1), & \frac{\partial E(k-1)}{\partial w_{\mu}^{[s]}} \frac{\partial E(k)}{\partial w_{\mu}^{[s]}} < 0 \\ \Delta_{\mu}^{[s]}(k-1), & \frac{\partial E(k-1)}{\partial w_{\mu}^{[s]}} \frac{\partial E(k)}{\partial w_{\mu}^{[s]}} = 0 \end{cases} \quad (3.25)$$

unde: $0 < \eta^- < 1 < \eta^+$.

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, $\Delta_{\mu}^{[s]}$ este scăzut prin înmulțirea cu η^- . Dacă derivatele în două iterații succesive își păstrează semnul, $\Delta_{\mu}^{[s]}$ 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 :

$$w_{\mu}^{[s]}(k+1) = w_{\mu}^{[s]}(k) + \Delta w_{\mu}^{[s]}(k) \quad (3.26)$$

unde:

$$\Delta w_{\mu}^{[s]}(k) = \begin{cases} -\Delta_{\mu}^{[s]}(k), & \frac{\partial E(k)}{\partial w_{\mu}^{[s]}} > 0 \\ \Delta_{\mu}^{[s]}(k), & \frac{\partial E(k)}{\partial w_{\mu}^{[s]}} < 0 \\ 0, & \frac{\partial E(k)}{\partial w_{\mu}^{[s]}} = 0 \end{cases} \quad (3.27)$$

Valorile ponderilor sunt modificate după prezentarea întregului set de modele de antrenare. Corecția inițială $\Delta_{\mu}(0) = 0,1$, iar rezultatele cele mai bune se obțin pentru $\eta^{-} = 1,2$ și $\eta^{+} = 0,5$. Principiul algoritmului RPROP este descris schematic în figura 3.14.

3.1.5. Rețele de tip Percepton Multistrat cu conexiuni feedback (Back Propagation Through Time)

O clasă particulară de rețele de tip PMS este aceea formată din rețele neuronale care necesită ca intrări și una sau mai multe ieșiri ale iterațiilor anterioare, pentru a calcula pasul curent. Chiar dacă este adevărat că o rețea formată din straturi cu neuroni având funcții de activare continue și neliniare este capabilă să aproximeze o funcție cu variabile vectoriale, nu este posibil să se coreleze ieșirile care corespund unor momente de timp diferite. Soluția pentru această limitare este utilizarea unei variante foarte interesante a regulii clasice de antrenare Error Back Propagation, cunoscută sub numele de Back Propagation Through Time (BPTT) sau retropropagare în timp.

Retropropagarea este o metodă eficientă și exactă pentru calculul tuturor derivatelor unei funcții de eroare în raport cu un mare set de parametri (de exemplu, ponderile și biasii). BPTT extinde această metodă, astfel încât să poată fi aplicată la sisteme dinamice. Algoritmul




Figura 3.14. Principiul algoritmului RPROP

BPTT permite calculul derivatelor necesare pentru optimizarea unei rețele neuronale cu memorie. BPTT este utilizat cel mai adesea în recunoașterea modelelor. În anumite aplicații, ca de exemplu recunoașterea vitezei sau detectarea submarinelor, clasificarea la momentul t va fi mult mai exactă dacă se poate lua în considerație ceea ce s-a întâmplat la momentele anterioare. Figura 3.15. prezintă o reprezentare schematică generală a unei rețele neuronale desfășurată în timp.

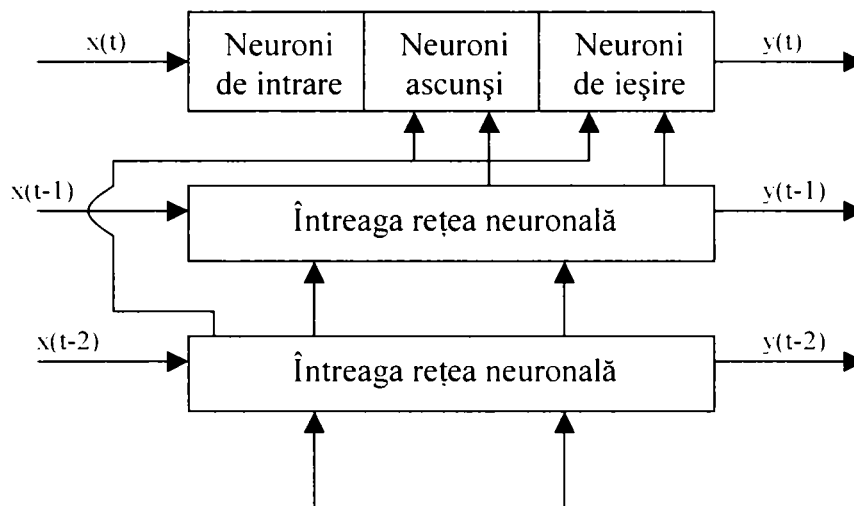


Figura 3.15. Rețea neuronală desfășurată în timp

În unele aplicații, „memoria” perioadelor de timp anterioare este foarte importantă. De exemplu, este foarte ușor să se recunoască obiecte în mișcare, dacă rețeaua neuronală ia în considerație schimbările produse de la momentul $(t-1)$ la momentul t , lucru pentru care este necesară „memoria” rețelei de la momentul $(t-1)$. Mulți dintre algoritmi cei mai performanți de recunoaștere a modelelor înglobează o tehnică de relaxare, prin care reprezentarea fenomenelor la momentul t se bazează pe o adaptare a reprezentării de la momentul $(t-1)$: acest lucru necesită memorarea variabilelor interne ale rețelei la momentul $(t-1)$.

Retropropagarea poate fi aplicată oricărui sistem cu o ordine bine definită a calculelor, chiar dacă aceste calcule depind de alte calcule anterioare realizate în însăși rețeaua neuronală. În figura 3.15, fiecare neuron, la momentul t , primește intrări de la toți neuronii (inclusiv cei de intrare) din aceeași rețea, dar la momente de timp $(t-1)$ și $(t-2)$. Transpunerea matematică a unei astfel de rețele se poate realiza cu relația :

$$net_i(t) = \sum_{j=1}^{t-1} w_{ij} x_j(t) + \sum_{j=1}^{N+n} w'_{ij} x_j(t-1) + \sum_{j=1}^{N+n} w''_{ij} x_j(t-2) \quad (3.28)$$

unde: $(N+n)$ reprezintă toți neuronii din rețea, inclusiv cei de intrare.

Anumite ponderi pot fi fixate la valoarea 0 pentru a simplifica rețeaua. În multe aplicații ponderile w' și w'' sunt fixate 0, cu excepția valorii w''_{ij} din motive de simplitate sau legate de istoric. Pentru algoritmul BPTT cel mai natural mod de a modifica ponderile rețelei este de adaptare a acestora global. Pentru aceasta este necesară stocarea multor informații intermediare (lucru care este în neconcordanță cu adaptarea în timp real). Acest lucru poate fi evitat printr-un program inteligent de calcul, mai ales dacă matricele w' și w'' sunt matrice rare.

3.1.6. Rețele Kohonen

Rețelele Kohonen folosesc algoritmi de învățare care asigură auto-organizarea informației de la intrarea rețelei în așa numitele „hărți de trăsături”, specifice setului de date considerat. Într-o rețea Kohonen, prezentată anterior în figura 3.6., neuronii de ieșire, care prelucrează informația, sunt organizați într-o „plasă” bidimensională, în interiorul căreia există conexiuni numai între neuronii vecini. Intrările rețelei sunt complet conectate cu neuronii de ieșire .

Algoritmul Kohonen crează un „cuantificator vectorial” format din ponderile conexiunilor celor M neuroni de ieșire cu cele N intrări. Aceste ponderi sunt determinate prin aplicarea unor corecții succesive care urmăresc „comprimarea” anumitor caracteristici ale datelor de intrare tocmai în valorile acestor ponderi. Algoritmul de învățare organizează, de fapt, neuronii de ieșire în grupe formate în vecinătatea unor neuroni centrali. Aceste grupe joacă rolul unor clasificatori de „trăsături” ale datelor de intrare.

Principiul după care se desfășoară învățarea în rețeaua Kohonen poate fi rezumat astfel:

- Se inițializează ponderile conexiunilor dintre neuronii de intrare și ieșire;
- La intrarea rețelei se aplică un vector din setul de învățare;
- Se caută neuronul care aproximează cel mai bine vectorul de intrare – vectorul de intrare se compară cu fiecare vector format din ponderile conexiunilor de la un neuron din plasa bidimensională la toți neuronii de intrare și se declară „câștigător” acel neuron pentru care deosebirile dintre cei doi vectori sunt cele mai mici ;
- Se mărește similaritatea acestui neuron și a neuronilor vecini în raport cu vectorul de intrare prin modificarea corespunzătoare a ponderilor.

În figura 3.16. este prezentat algoritmul de învățare al rețelei Kohonen.

Rețeaua Kohonen, în varianta de bază, este foarte ușor de utilizat datorită simplității algoritmului, actualizării liniare a ponderilor și aplicării la un număr relativ mare de probleme de clasificare nesupervizată. Principalele neajunsuri ale rețelelor Kohonen sunt legate de funcționarea lor euristică, strategia de oprire a algoritmului fiind artificială, algoritmul nefiind bazat pe optimizarea vreunui proces sau a datelor. De asemenea, vectorii pondere finali depind adesea de secvența de intrare și de condițiile inițiale. O serie de parametrii (de exemplu, rata de învățare sau mărimea vecinătății) și strategia modificării lor depind de setul de date . De exemplu, deși procesul de clasificare este convergent, soluția obținută nu este optimală în raport cu rata erorii.

Dezavantajele rețelelor Kohonen standard au condus la încorporarea tehnicilor fuzzy în varianta de bază, cu scopul de a include rata de învățare $\eta(t)$ și vecinătățile neuronilor de ieșire $V_i(t)$ într-un singur coeficient global $\eta_{ik}(t)$. Se consideră o mulțime formată din N modele: $X=[X_1 X_2 \dots X_N]$, fiecare model având dimensiunea p ($X_k=[x_{1k} x_{2k} \dots x_{pk}]$). În [3.8.] se propune o variantă fuzzy de actualizare a ponderilor:

$$w_{ik}(t+1) = w_{ik}(t) + u_{ik}(t)[X_i(t) - w_{ik}(t)] \quad (3.29)$$

în care $u_{ik}=u_i(x_k)$ sunt c mulțimi fuzzy (neuroni clasă) ce formează o partiție fuzzy a lui X.

Coeficientul global este definit de relația:

$$\eta_{ik}(t) = [u_{ik}(t)]^{m_t} \quad (3.30)$$

unde $m_t=(m_0-1)/t_{\max}$, iar $u_{ik}(t)$ se calculează cu formula:

$$u_{ik}(t) = \left[\sum_{z=1}^c \left(\frac{\|X_k - W_i(t)\|}{\|X_k - W_z(t)\|} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (3.31)$$

în care t_{\max} este numărul maxim de iterații și $m>1$ este un parametru real. Coeficientul global $\eta_{ik}(t)$ este asociat neuronului clasă i și modelului k(i=1..c, k=1..N).

În figura 3.17. se prezintă algoritmul de grupare fuzzy pentru rețeaua Kohonen [3.9.].

Pasul 1 Inițializarea rețelei

Se inițializează ponderile conexiunilor dintre cei N neuroni de intrare și cei M neuroni de ieșire w_{ij} cu valori mici, aleatorii. Se inițializează, de asemenea, mărimea vecinătății fiecărui neuron de ieșire.

Pasul 2 Prezentarea unui nou vector de intrare

La intrarea rețelei se aplică cele N componente ale unui vector din setul de învățare.

Pasul 3 Calculul distanței față de neuronii de ieșire

Se calculează distanțele euclidiene d_j dintre vectorul de intrare și vectorul format din ponderile conexiunilor asociate fiecărui neuron de ieșire:

$$d_j = \sum_i [x_i - w_{ij}(t)]^2$$

unde x_i este intrarea neuronului i la momentul t , iar w_{ij} este ponderea conexiunii dintre neuronii i și j la momentul t .

Pasul 4 Alegerea neuronului câștigător

Se alege distanța minimă dintre distanțele calculate la pasul 3 (d_j^*), iar nodul j^* este declarat nod câștigător.

Pasul 5 Alegerea ponderilor conexiunilor în vecinătatea nodului j^*

Se realizează adaptarea ponderilor conexiunilor către nodul j^* și toate celelalte noduri din vecinătatea acestuia cu relația:

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t)(x_i - w_{ij}(t))$$

unde $\eta(t)$ este o rată de învățare descrescătoare în timp.

Pasul 6 Se trece la un nou vector de antrenare

Se reia antrenarea pentru un nou vector, revenind la pasul 2.

Pasul 7 Verifică condiția de oprire

Dacă $\Delta w_{ij} = \|w_{ij}(t) - w_{ij}(t-1)\|^2 \leq \varepsilon$ atunci STOP. Dacă nu, se micșorează $\eta(t)$ și se actualizează vecinătatea (se scade cu 1), apoi se trece la pasul 2.

Figura 3.16. Algoritmul de învățare al rețelei

Pasul 1 Se aleg c neuroni clasă și $\varepsilon > 0$.

Pasul 2 Se inițializează ponderile $W_0 \in \mathbb{R}^p$. Se aleg $m_0 > 1$ și t_{\max} .

Pasul 3 Pentru $t=1, 2, \dots, t_{\max}$

- Se calculează ratele de instruire η_{ik} cu formulele (3.30) și (3.31)
- Se actualizează cei c vectori W_i cu formula:

$$W_i(t+1) = W_i(t) + \frac{\sum_{k=1}^N \eta_{ik}(t)(X_k - W_i(t))}{\sum_{k=1}^N \eta_{ik}(t)} \quad i = \overline{1, c}$$

- Se calculează eroarea : $E_t = \|W(t+1) - W(t)\|^2$
- Dacă $E_t \leq \varepsilon$ atunci STOP. Dacă nu, se reia pasul 3.

Figura 3.17. Algoritm de grupare fuzzy pentru rețeaua Kohonen

Algoritm de mai sus nu este secvențial, reactualizările având loc pentru toți cei c neuroni de ieșire după fiecare trecere prin mulțimea de date X . Astfel, procedura nu este dependentă de mulțimea datelor și nici de ordinea de prezentare a lor la intrarea rețelei neuronale. Algoritm prezentat conduce la îmbunătățirea convergenței și la reducerea erorii de clasificare. Auto-organizarea rețelei constă în ajustarea automată, în timpul instruirii, a mărimii vecinătății și a ratei de învățare pentru stratul competitiv (de ieșire).

3.2. Tratarea seriilor de timp cu metode statistice și rețele neuronale artificiale. Analiză comparativă.

În acest paragraf se va pune în evidență analogia dintre metodele statistice și rețelele neuronale artificiale, demonstrând în același timp, cum o rețea neuronală cu propagare înapoi, fără neuroni pe stratul ascuns și în care funcțiile de activare sigmoide sunt înlocuite cu funcții liniare, conduce la aceleași rezultate ca și un proces autoregresiv cu medie mobilă, iar prin introducerea funcțiilor de activare sigmoide și eventual a unui număr mai mare de neuroni, se ajunge la formularea procesului neliniar autoregresiv cu medie mobilă. De asemenea, se vor pune în evidență avantajele utilizării rețelelor neuronale în locul metodelor statistice, în rezolvarea problemelor neliniare, cum este și prognoza sarcinii electrice.

3.2.1. Proces autoregresiv

Modelul statistic autoregresiv AR poate fi descris de relația :

$$y(t) = \phi_1 y(t-1) + \phi_2 y(t-2) + \dots + \phi_p y(t-p) + a(t) \quad (3.32)$$

Făcând referire la un model de ordinul 3, relația devine:

$$y(t) = \phi_1 y(t-1) + \phi_2 y(t-2) + \phi_3 y(t-3) + a(t) \quad (3.33)$$

Coefficienții ϕ_i sunt estimați prin metoda celor mai mici pătrate. Aceeași metodă este folosită pentru estimarea ponderilor unei rețele neuronale cu propagare înapoi. Construind o rețea neuronală cu structura din figura 3.18., se poate reprezenta același model descris de ecuația (3.32). Rețeaua din figura 3.18. este fără strat ascuns, iar neuronul de ieșire are funcția de activare liniară, fiind un simplu combinator liniar al intrărilor. Aceste importante

simplificări, necesare a fi făcute pentru a echivala un proces autoregresiv printr-o rețea neuronală, sunt o confirmare a faptului că un model neuronal poate fi mai puternic decât unul statistic. Unica diferență între cele două modele este dată de faptul că metoda statistică găsește soluția exactă folosind pseudo-inversa, în timp ce rețeaua neuronală ajunge la soluție printr-un proces iterativ, folosind algoritmul Back- Propagation, descris în 3.1.4.1. Odată ce rețeaua a fost antrenată, valorile ponderilor sunt analoge cu cele ale coeficienților $\varphi_1, \varphi_2, \varphi_3$.




Figura 3.18. Rețeaua neuronală care descrie un proces autoregresiv de ordinul 3

3.2.2. Proces cu medie mobilă

Modelul statistic cu medie mobilă Ma are următoarea formulare matematică:

$$y(t) = a(t) - \theta_1 a(t-1) - \theta_2 a(t-2) - \dots - \theta_q a(t-q) \quad (3.34)$$

Referindu-ne la un model de ordinul 3, relația (3.34) devine:

$$y(t) = a(t) - \theta_1 a(t-1) - \theta_2 a(t-2) - \theta_3 a(t-3) \quad (3.35)$$

Coefficienții sunt estimați prin metoda celor mai mici pătrate, metodă folosită și pentru estimarea ponderilor unei rețele neuronale cu propagare înapoi. Acest caz, în raport cu cel precedent, conduce la dificultăți majore cauzate de recurența care se stabilește utilizând ca intrări eroarea comisă în pașii precedenți. Pentru a modela un astfel de proces, este deci necesar să se recurgă la o rețea recurentă, cum este cea prezentată în figura 3.19.

Pentru a rezolva o astfel de rețea se utilizează un algoritm care minimizează suma pătratelor erorilor dintre valorile actuale și cele dorite pe ieșirea rețelei neuronale. În acest algoritm se mențin fixe toate necunoscutele (ponderile) exceptând una care este variată până se ajunge la o valoare care minimizează funcția eroare. Acest procedeu este repetat pentru toate necunoscutele rămase. Odată ce s-a determinat o valoare pentru toate variabilele, algoritmul se reia iterativ până când nu mai este posibilă modificarea soluției. În figura 3.20. este reprezentată organigrama acestui algoritm.

Pentru a obține valorile w_i , ponderile sunt incrementate cu o valoare dependentă de semnul primei derivate a funcției eroare în raport cu aceste ponderi și de precizia dorită. Acest algoritm conduce la soluția dorită chiar dacă timpul de convergență este mare. Abordarea statistică, în schimb, pentru a găsi soluția sistemului recurent, folosește algoritmul Seidel-Gauss, care converge în timp mult mai scurt.

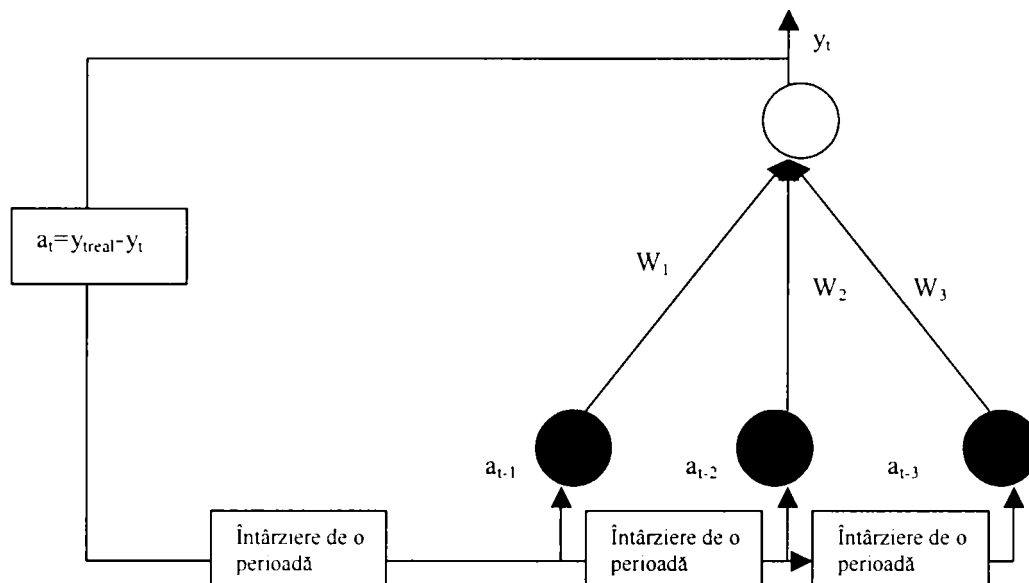


Figura 3.19. Rețeaua neuronală care descrie un proces cu medie mobilă de ordinul 3

3.2.3. Proces autoregresiv cu medie mobilă

Dacă într-un proces se dorește să se țină cont atât de componenta autoregresivă cât și de cea cu medie mobilă, prin unirea celor două procese descrise anterior se obține un model autoregresiv cu medie mobilă ARMA(p,q):

$$y(t) = \phi_1 y(t-1) + \dots + \phi_p y(t-p) - \theta_1 a(t-1) - \dots - \theta_q a(t-q) + a(t) \quad (3.36)$$

În cazul particular al unui proces ARMA(2,2) relația anterioară devine:

$$y(t) = \phi_1 y(t-1) + \phi_2 y(t-2) - \theta_1 a(t-1) - \theta_2 a(t-2) + a(t) \quad (3.37)$$

Rețeaua neuronală care descrie același model este ilustrată în figura 3.21.

Deși prezintă intrări autoregresive, rețeaua neuronală utilizează același algoritm prezentat pentru rețele recurente și în consecință convergența se produce după un interval de timp destul de mare.

3.3. Avantajele prognozei sarcinii electrice folosind rețele neuronale artificiale în raport cu metodele statistice

Pentru problema prognozei sarcinii electrice s-au folosit numeroase tehnici. Aceste tehnici folosesc de obicei două modele de bază : modele pentru sarcina la vârf și modele statice sau dinamice ale curbei de sarcină. Aceste modele variază în complexitate, necesarul de date, flexibilitate și posibilitatea de a răspunde cerințelor utilizatorului. Aceste cerințe impun, de obicei, ca programele de prognoză să fie suficient de precise pentru toate anotimpurile, pentru perioade de timp caracterizate prin condiții climaterice netipice(cum ar fi, perioade calde în timpul iernii sau perioade reci din timpul verii) și de asemenea, să răspundă cu o precizie bună la modificările din rețeaua electrică.

Experiența practică bogată acumulată în domeniul metodelor statistice convenționale a confirmat limitările lor teoretice care reduc posibilitatea îmbunătățirii performanțelor lor și incapacitatea acestor metode de a răspunde la unele sau toate cerințele amintite. Aceste limitări sunt:

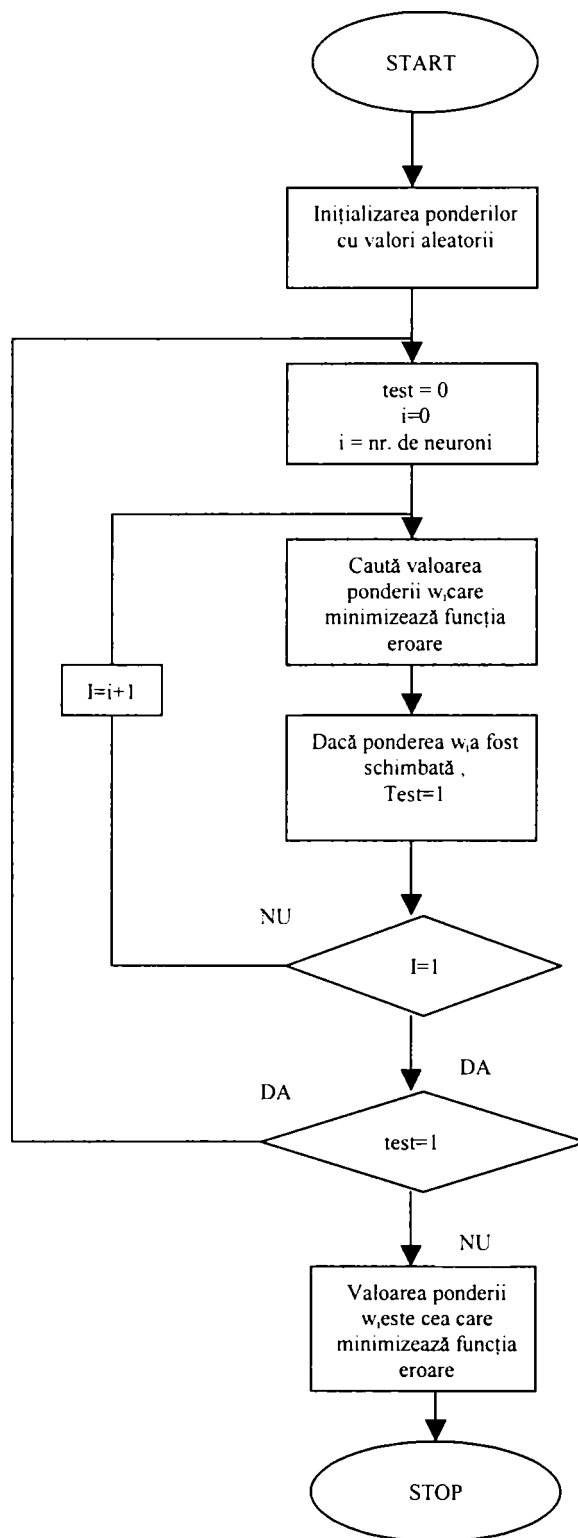


Figura 3.20. Organigrama algoritmului folosit pentru antrenarea rețelei recurente




Figura 3.21. Rețeaua neuronală care descrie un proces ARMA(2,2)

- dependența neliniară dintre mărimile de intrare și cele de ieșire este dificil de aproximat;
- problema coliniarității variabilelor de intrare limitează numărul variabilelor ce pot fi utilizate în aceste modele;
- modelele nu sunt prea flexibile față de schimbările rapide ale sarcinii în rețea.

Atât pentru modelele statistice, cât și pentru rețelele neuronale artificiale este necesară realizarea unei analize statistice a mărimilor cunoscute, care să permită deciderea fie a variabilelor ce urmează a fi introduse în model, fie a transformărilor care trebuie efectuate asupra seriei în discuție. În cazul utilizării metodelor statistice liniare este absolut obligatoriu ca seria de timp să fie staționară, în timp ce utilizarea unei rețele neuronale nu necesită acest lucru, evitând astfel, prelucrarea greoaie a datelor.

RNA cu propagare înapoi au avantajul notabil de a putea modela adecvat serii foarte complexe, care nu pot fi descrise de un simplu model liniar. Flexibilitatea inerentă a tehnologiei RNA este în oarecare măsură contrabalansată de o serie de cerințe ale acestora. Rețeaua neuronală necesită pe lângă un set considerabil de date și o antrenare destul de lungă, lucru datorat în mare parte, procesului euristic folosit în faza de identificare a structurii celei mai adecvate a rețelei. Folosirea RNA cu propagare înapoi este utilă când fenomenul care urmează a fi descris este generat de procese puțin cunoscute sau greu de studiat. Nu este însă necesară folosirea unei RNA de acest tip dacă fenomenul este cunoscut și bine aproximat prin intermediul unui model liniar.

O mare problemă cu care se confruntă RNA este aceea că nu sunt capabile să extrapoleze datele care se situează în afara hiperspațiului acoperit de setul de antrenare. Pentru a obține rezultate performante cu ajutorul RNA este necesar ca setul de antrenare să acopere cât mai bine hiperspațiul de definiție al problemei analizate, deci să cuprindă un număr considerabil de date.

Problema prognozei sarcinii pe termen scurt este inclusă în categoria proceselor dinamice. O rețea neuronală cu conexiuni feedback poate simula un sistem dinamic în timp discret. Arhitecturile de rețele neuronale feedforward generale cu ponderi împărțite, pot conține conexiuni feedback, dacă rețeaua de bază este desfășurată în timp. În acest fel, rețelele feedforward generale pot simula sisteme dinamice.

O clasă particulară de rețele neuronale recurente este formată din rețele cu arhitecturi multistrat, formate din neuroni statici și dinamici (cu conexiuni feedback). Aceste rețele s-au dovedit a fi foarte eficiente; de fapt ele se bazează pe comportarea bine-cunoscută de discriminare în clase în structurile multistrat, în același timp furnizând și caracteristici temporale ca intrări. Mai mult, aceste rețele prezintă și alte caracteristici temporale remarcabile, cum ar fi: capacitatea de a-și aminti succesiuni de înregistrări nu foarte îndepărtate în timp și ulterior capacitatea de a uita pe cele care sunt considerate prea îndepărtate pentru a introduce informații folositoare în semnalele de intrare.

3.4. Utilizarea rețelelor neuronale artificiale în prognoza pe termen scurt a sarcinii electrice

Tehnicile de prognoză pe termen scurt oferite de inteligența artificială, în special rețelele neuronale artificiale (RNA), sunt foarte performante și ușor de manevrat. În ultimii ani, PMS și algoritmul Back Propagation au fost intens utilizate în aplicații în energetică, dar cea mai de succes aplicație a lor pare să fie prognoza sarcinii electrice. Motivarea acestui succes se găsește în capacitatea RNA de a descoperi interdependențele care se manifestă între componentele unei serii de date, fără intervenția expertului uman, în simplitatea construcției lor, a antrenării și a utilizării acestora în comparație cu mult mai complexa analiză statistică. Mai mult, RNA pot memora relații complexe, chiar în absența oricărui model funcțional, fiind concepute în special pentru tratarea problemelor neliniare (majoritatea problemelor de interes din analiza rețelelor electrice).

Cea mai mare parte a aplicațiilor ce folosesc RNA pentru prognoza sarcinii electrice pe termen scurt utilizează PMS, ca tehnică de recunoaștere a modelelor, cu o mare capacitate de generalizare. Dintr-o bază de date formată din toate sarcinile posibile provenite din istoric se alcătuieste un set de învățare a RNA, pentru realizarea unei antrenări preliminare. Mai mult, acest set de antrenare este mereu actualizat, pe măsură ce noi modele sunt disponibile, pentru o viitoare reantrenare. Această abordare poate prezenta două dezavantaje:

(a) Setul de antrenare nu este inițial suficient de cuprinzător;

(b) Setul de antrenare nu acoperă suficient de bine spațiul de definiție al problemei, pe măsură ce vechile modele sunt înlocuite de altele noi;

În cele ce urmează s-au testat performanțele realizării prognozei sarcinii electrice cu ajutorul RNA de tip Perceptron Multistrat cu un strat ascuns. Mărimile de intrare sunt sarcinile din zilele precedente, tipul zilei (luni-duminică) și opțional date meteo (temperaturi). Metoda de antrenare folosită în această versiune este backpropagation cu momentum și rată de antrenare constantă.

Programul utilizat prognozează sarcina pe 24 de ore înainte. Datele de sarcină au fost grupate în fișiere text editabile cu orice editor text sau de nivel mai înalt. Fiecare rând al fișierului de sarcină reprezintă o înregistrare de sarcină (data și 24 de sarcini orare), iar fiecare rând al fișierului de date meteo cuprinde data și 12 date meteo (temperaturi). Fișierele de date meteo cuprind mărimi reale înregistrate în trecut și mărimi prognozate pentru ziua următoare.

Inițial, a fost nevoie de date pe o perioadă însemnata de timp din trecut (un an este o perioadă minimă, chiar insuficientă). După constituirea fișierelor s-a procedat la antrenarea rețelei neurale.

S-a folosit un model care are ca intrări: tipul zilei, ziua D-1, ziua D-7 și 24-48 de neuroni pe stratul ascuns. Antrenarea lui s-a realizat cu date de pe anul anterior, pentru a surprinde cât mai bine evoluția sarcinii. Precizia sa este mulțumitoare pentru cel puțin 6-12 luni fără reantrenare, chiar și pentru o prognoză pe 48 de ore; totuși, o reantrenare semestrială este recomandată pentru scăderea erorilor. Au fost disponibile și date meteo, corelația dintre acestea și sarcină, prin folosirea lor ca intrări în RN, a îmbunătățit precizia prognozei. S-au

utilizat temperaturile extreme zilnice din zona de consum. De obicei erorile minime se ating după 2000-3000 de cicluri de antrenare.

Ca date de intrare s-au folosit aceleași date utilizate la tehnicile de prognoză prezentate în capitolul 5, pentru consumatorul AT1- Stația electrică Moșnița din Timișoara.

Pentru comparații s-au ales aceleași perioade de prognoză și anume: 14.02-20.02.2000 și 06.03-12.03.2000.

În tabelul 3.1 se prezintă valorile puterilor medii zilnice prognozate și realizate precum și erorile corespunzătoare .

Tabelul 3.1. Puterile medii zilnice din săptămânile 06.03. – 12.03.2000 și 14.02. – 20.02.2000 prognozate și realizate și erorile obținute

SĂPTĂ MĂNA		LUNI	MARTI	MIER CURI	JOI	VINERI	SĂMBĂ TĂ	DUMINI CĂ
06.03.- 12.03.00	PROGNOZAT	2.273	2.385	2.425	2.307	2.283	2.276	2.295
	REALIZAT	2.211	2.228	2.219	2.418	2.204	1.913	1.789
	EROARE	-2.8041	-7.0466	-9.2834	4.5905	-3.5843	-18.9754	-28.2839
14.02.- 20.02.00	PROGNOZAT	2.431	2.481	2.477	2.485	2.342	2.193	2.389
	REALIZAT	2.289	2.391	2.430	2.495	2.267	2.121	1.920
	EROARE	-6.2036	-3.7641	-1.9342	0.4008	-3.3083	-3.3946	-24.4271

Din tabel se constată că erori mari apar în zilele de sâmbătă și duminică. În general, erorile sunt mai mari decât cele obținute prin tehnicile de prognoză prezentate în capitolul 5, tabelul 5.21.

3.5. Concluzii

În capitol sunt trecute în revistă principalele componente ale tehnicilor de inteligență artificială, centrul de greutate fiind concentrat pe rețele neuronale artificiale (RNA).

Legat de acestea, se prezintă arhitectura tipică a unei rețele, caracteristici principale, clasificarea unei RNA, antrenarea acestora, precum și rețele neuronale de tip Perceptron multistrat.

Sunt prezentate câțiva algoritmi specifici pentru antrenarea rețelelor Standard Back, Back Propagation, Resilient Propagation.

S-a pus în evidență analogia dintre metodele statistice și rețelele neuronale artificiale, demonstrând în același timp cum o rețea neuronală cu propagare înapoi conduce la aceleași rezultate ca și un proces autoregresiv cu medie mobilă.

Sunt prezentate avantajele și dezavantajele utilizării rețelelor neuronale în raport cu modelele statistice . De reținut este faptul că RNA pot modela serii foarte complexe, care nu pot fi descrise de un simplu model liniar.

Cu datele existente pentru consumatorul Stația electrică Moșnița Timișoara s-a realizat prognoza orară a puterilor utilizând o RNA de tip Perceptron Multistrat cu un strat ascuns. Erorile care apar sunt foarte mari (18,9% - 28,2%) pentru zilele de sâmbătă și duminică și în general mai mari decât cele care apar în cazul descompunerii Fourier.

BIBLIOGRAFIE

- 3.1. ROSENBLATT,F - Principles of Neurodynamics. Spartan, New York, 1962;
- 3.2. RUMELHART,D,E, - Parallel Distributed Processing. Vol1:Foundations.MIT
MCCLELLAND,J,L, Press, Cambridge, MA,1986;
- 3.3. *** - Neural networks Theory, Technology and Applications, IEEE Technical Activities Board, New York, 1996
- 3.4. C.N.LU, H.T.WU, - Neural Networks Based Short Term Load Forecasting,
VEMURI, S. IEEE Power Engineering Society 1992 Winter Meeting,
1992 WM 125-5 PWRS
- 3.5. DILLON,T.S.,SISTITO,S., - An Adaptive Neural Network Approach in Load
LEUNG, S. Forecasting in Power Systems, 1st International Forum
on Applications of Neural Networks in Power Systems,
Seattle, 1991.
- 3.6. PARKER D.B. - Learning-Logic. Technical Report TR-47,
Massachussets Institute of Technology, Center for
Computational Research in Economics and
Management Sciences, Cambridge, MA,1985
- 3.7. RIEDMILLER M., - A Direct Adaptive Method for faster Backpropagation
BRAUN H., Learning: The RPROP Algorithm, University of
Karlsruhe, Preceedings of the IEEE International
Conference on Neural Networks, San Francisco, CA,
Marck 28- Aprilie 1, 1993.
- 3.8. HUNTSBERGER - Parallel Self-Organizing Feature Maps for Unsupervised
T.L.,AJJIMARANJSEE P. Pattern Recognition, Int. J. General Systems, 16,1990,
pp.357-372
- 3.9. DUMITRESCUD.COSTIN - Inteligența artificială. Rețele neuronale. Teorie și
H. aplicații,Editura Teora, București,1996
- 3.10. CHEN S., TZENG Y. M., - The application of artificial neural networks to
HWANG J.C, substation load forecasting, Electric Power Systems
Research 38 pp. 153-160.
- 3.11. CHOW T.W.S., LEUNG - Neuronal Network based Short – Term Load
C.T., Forecasting Using Weather Compensation, IEEE
Transactions on Power Systems, Vol. 11, No. 4, 1996,
pp.1736-1742.
- 3.12. CONNOR, J.T. , MARTIN - Recurrent Neural Networks and Robust Time Series
R.D., ATLAS L.E., Prediction, IEEE Transaction on Neural Networks, Vol.
5, No.2, 1994, pp. 240-253.
- 3.13. RĂDĂȘANU, D. - Posibilități de utilizare a inteligenței artificiale în studiul
rețelelor electrice, teză de doctorat, Iași, 2000
- 3.14. FAN J.Y., - A Real Time Implementation of Short Term Load
Forecasting for Distribution Power Systems, IEEE
Transaction on Power Systems, Vol.9, No.2, May, 1994
- 3.15. GAVRILAȘ ,M., - Artificial intelligence based model for the short term
GEORGESCU G., load forecasting in power systems. Experince with
Suceava Utility, Simpozionul Internațional de Eficiență
Energetică, oct. 1999, Cluj- Napoca, lucrarea 13.
- 3.16. GEORGESCU, G., - Previziunea pe termen scurt și mediu a puterii folosind
GAVRILAȘ ,M., rețele neuronale artificiale, Energetica, aug.-sept.,1999,
RĂDĂȘANU, D. pag.351-356.

- 3.17. GROSS G., GALINA F., - Short Term load Forecasting, Proceedings of the IEEE, Vol. 75, No.12, 1987, pp. 1558-1573.
- 3.18. HIDE O., HODNETT P.F., - An Adaptable Automated Procedure for Short Term Load forecasting, IEEE Trans. On Power Systems, Vol. 12, No.1, February 1997, pp. 84-93.
- 3.19. HUANG S.R., - Short term load forecasting using threshold autoregressive models, IEE Proc.-Gener. Transm. Distrib. Vol.144, No. 5,1997, pag.4777-481.
- 3.20. KHOTANZAD, A., HWANG ,R.C., ABAYE A., - An Adaptive Modular Artificial Neural Network Hourly Load Forecaster and its Implementation at Electric Utilities, IEEE Transactions on Power Systems, Vol. 10, No.3, Aug. 1995, pp. 1716-1721
- 3.21. KIM, K. H., PARK J.K., HWANG K.J. - Implementation of Hibrid Short term Load Forecasting System Using Artificial Neural Networks and Fuzzy Expert Systems, IEEE Transactions on Power Systems, Vol. 10, No.3 Aug. 1995, pp.1534-1539
- 3.22. LAMEDICA, R. MAZZARO, M., MODESTO, C., - Enhancing the performances of a basic neural network tool for short term forecasting of italian electric load, IEEE, sept.,pp.863- 866,1996.
- 3.23. MOGHRAM, I., RAHMAN ,S., - Analysis and Evaluation of Five Short Term Load Forecasting Techniques, IEEE Transaction on Power Systems, Vol. 4, No.4, Oct.,1989.
- 3.24. RĂDĂȘANU, D., GAVRILAȘ, M., GEORGESCU ,G., - Previziunea pe termen scurt a sarcinilor în rețelele de distribuție folosind un sistem de tip neuronal, Simpozionul național de Rețele Electrice, Pitești, 1998, pag. 1049-1055.
- 3.25. SARGUNARAJ, S., SEN GUPTA D.P., - Short term load forecasting for demand side management, IEE Proc.-Gener. Transm. Distrib., Vol.144, No.1, January 1997, pp. 68-74.
- 3.26. TODOREANU, G., COSTEIU, M., - Rețele neuronale; ed. Microinformatica, Cluj.

PROGNOZA CURBELOR DE SARCINĂ

În vederea prezentării problemelor legate de prognoza curbelor de sarcină se vor aborda mai întâi câteva probleme introductive legate de curbele de sarcină.

4.1. Curbe de sarcină – elemente caracteristice ale consumatorilor

Consumatorii de energie electrică răspund și participă la orice modificare a parametrilor electrici ai sistemului electroenergetic, influențând comportarea în ansamblu a acestuia. Indiferent de caracterul consumatorului, locul, nivelul la care este considerat, participarea consumatorilor la modificările mărimilor electrice este descrisă de caracteristicile consumatorilor și de curbele de sarcină. Curbele de sarcină exprimă variația puterilor activă și reactivă, a sarcinii (curentului) în funcție de timp. Ele pot fi clasificate din mai multe puncte de vedere și anume: după durată, locul unde sunt ridicate, caracterul consumatorului etc. O clasificare a curbelor de sarcină din punct de vedere a mai multor criterii se prezintă în figura 4.1. [4.1.], [4.2.], [4.3.].

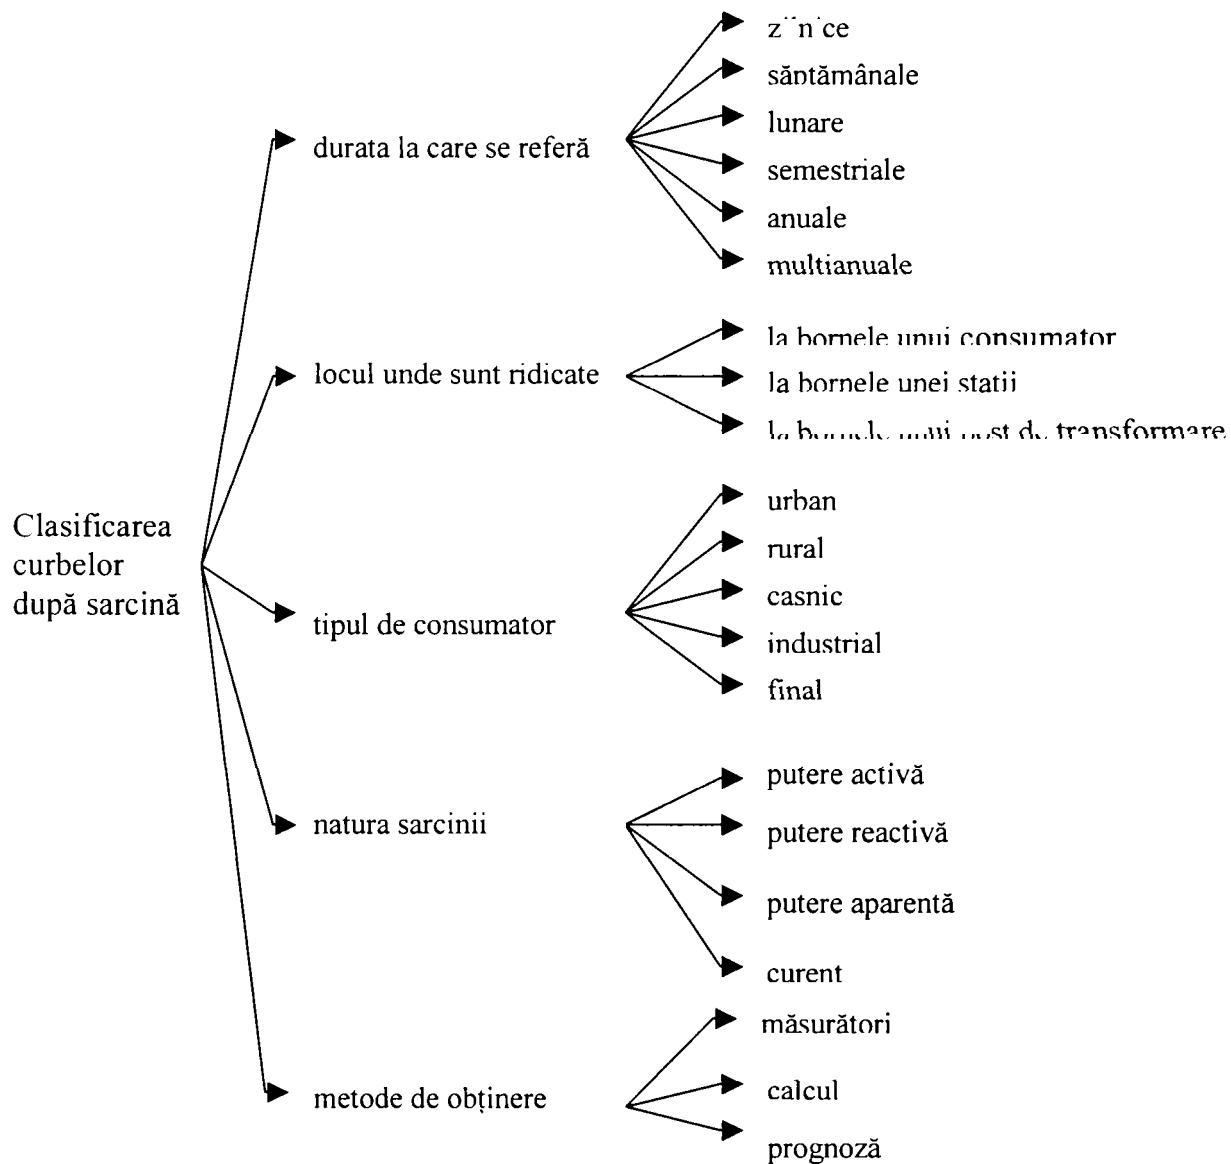


Figura 4.1. Clasificarea curbelor de sarcină – prezentare schematică

4.2. Obținerea curbelor de sarcină [4.1.] ÷ [4.4.], [4.10.], [4.12.], [4.13.]

Desigur, un aspect esențial în studiul și analiza curbelor de sarcină este fără îndoială obținerea curbelor de sarcină. Una dintre căi este, așa cum rezultă din figura 4.1., prognoza curbelor de sarcină, obiectul principal al acestei lucrări. Din acest motiv se cuvine să prezentăm în prealabil câteva aspecte legate de obținerea curbelor de sarcină. Făcând o extensie a criteriului ultim de clasificare din figura 4.1. se obțin cele prezentate în figura 4.2.

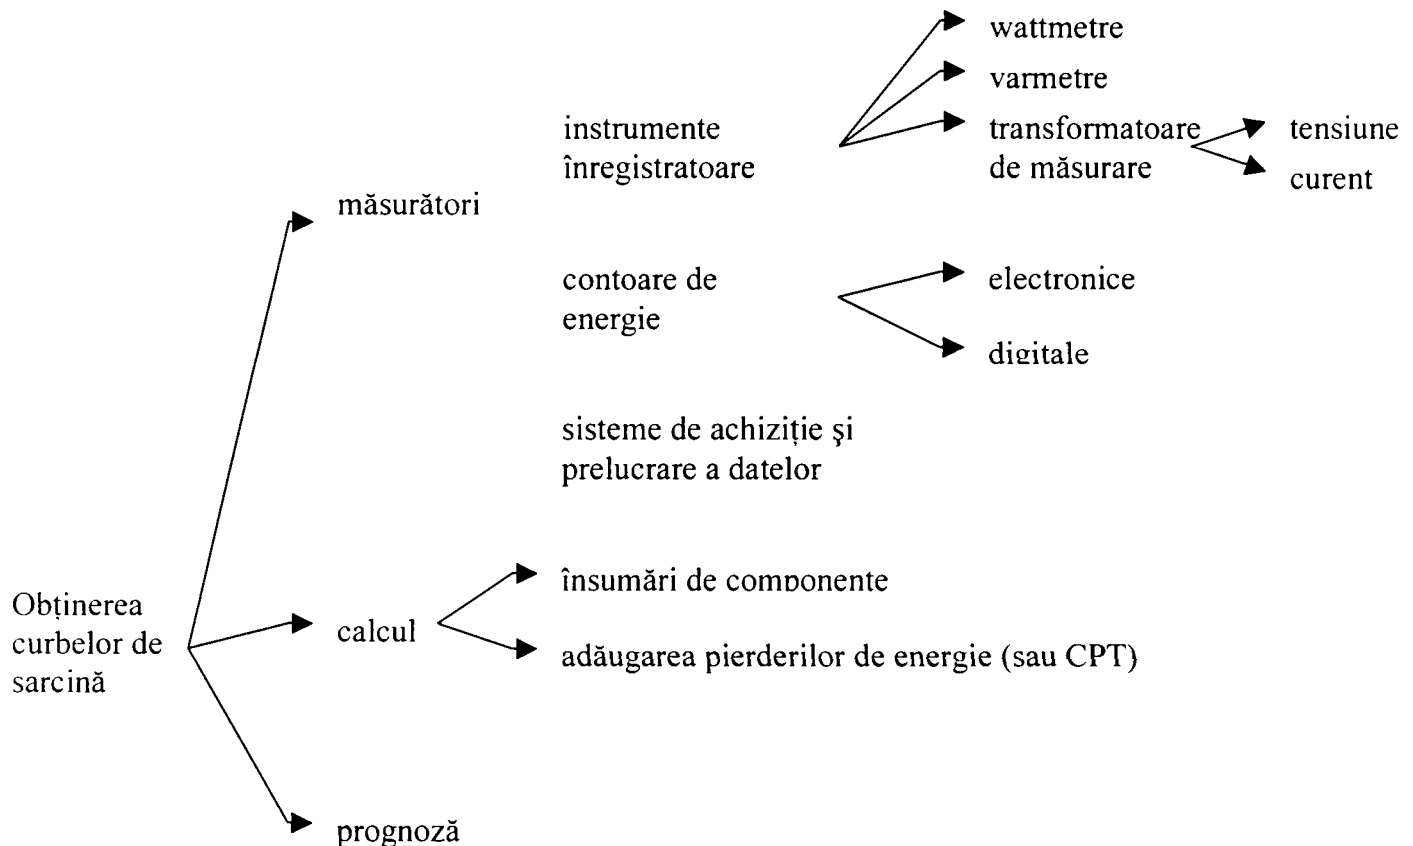


Figura 4.2. Obținerea curbelor de sarcină – prezentare schematică

Desigur, dintre metodele prezentate, un rol deosebit îl prezintă folosirea sistemelor de achiziție și prelucrare. Actualmente se manifestă o îmbunătățire spectaculoasă și accelerată a caracteristicilor echipamentelor, datorată realizărilor tehnologice de vârf din domeniul circuitelor integrate, combinată cu creșterea performanțelor obținute de tehnica de calcul și de telecomunicații.

Avantajele achiziției numerice a măsurătorilor sunt importante și ele se referă la [4.1.], [4.18.], [4.19.]:

- automatizarea totală a procesului de măsurare;
- posibilitatea prelevării unui număr mare de măsurători într-un interval de timp scurt; în prezent, în condiții de cost rezonabil, rata de eșantionare a semnalelor numerice este de ordinul μs ;
- dispar erorile de apreciere subiectivă a indicațiilor instrumentelor analogice și cele generate de greșelile inerente activității umane;
- posibilitatea prelucrării complexe, în timp real, a măsurătorilor de către controlerul sau calculatorul numeric care preia măsurătorile;

- posibilitatea transmiterii la distanță a datelor măsurate și prin aceasta, de a furniza în timp real toate informațiile necesare conducerii operative a sistemului energetic de la un dispecer central.

Aceste avantaje conduc la o nouă filozofie de abordare a tuturor problemelor legate de proiectarea și exploatarea sistemului energetic, ca urmare a bogăției și calității informației disponibile. Specificul folosirii achiziției numerice pentru măsurarea curbelor de sarcină electrică constă în transformarea contoarelor clasice de măsurare a energiei electrice în contoare cu impulsuri, prin adaptarea discului rotitor al contorului la un dispozitiv electronic de generare a unor impulsuri electrice, câte un impuls pentru fiecare rotație completă a discului. Aceste impulsuri sunt preluate de un măsurător de impulsuri care este citit periodic de interfața de achiziție a măsurătorii. Această soluție este preferată față de una clasică (traductor de putere + CAN) datorită următoarelor considerente:

- contoarele de energie activă și reactivă sunt dispozitive robuste, precise, fiabile, tehnologia lor de fabricație fiind foarte bine elaborată;
- prețul lor de cost este rezonabil;
- fabricarea contoarelor cu impulsuri presupune investiții minime;
- tehnologia și instalațiile existente pentru producerea contoarelor analogice pot fi folosite cu mici modificări;
- prin trecerea de la sistemul analogic de măsurare a energiei la cel bazat pe achiziție numerică, modificările de infrastructură sunt minime. Schema sistemului de achiziție a energiei consumate pentru un utilizator se prezintă ca în figura 4.3.




Figura 4.3. Schema sistemului de achiziție a energiei consumate pentru un utilizator.

4.3. Sectorizarea suprafeței curbelor de sarcină [4.1.], [4.3.]

Suprafața delimitată de curba de sarcină și axele de coordonate, se împarte în mai multe zone, fie orizontale fie verticale (figura 4.4.).

Definirea zonelor pe orizontală este importantă sub aspectul modului în care sunt ele acoperite de către diferite tipuri constructive de centrale electrice. Sub acest aspect există trei categorii de centrale și anume [4.1.], [4.3.]:




Figura 4.4. Delimitarea curbelor de sarcină: a) pe orizontală; b) pe verticală.

- centrale de bază, sunt centrale care funcționează la sarcină constantă, de regulă foarte apropiată de aceea nominală, pe durata unei zile; ele trebuie să fie foarte performante pentru a produce energia electrică la un preț cât mai scăzut; de regulă, ele sunt centrale nucleare sau centrale termoelectrice pe bază de cărbune energetic, mai rar pe bază de gaz metan;
- centrale de semibază, sunt centrale care au sarcina variabilă în timp, producând energia la un preț mai ridicat decât al centralelor de bază; funcționează în general folosind gaze naturale sau petrol, sau sunt centrale hidroelectrice pe firul apei, cu lac mic de acumulare a apei;
- centrale de vârf, sunt centrale cu pornire rapidă; ele pot produce energia la un preț ridicat – fiindcă pe durata vârfului de sarcină cererea crește mult în comparație cu oferta limitată tehnic – folosind resurse care se epuizează rapid; din această categorie fac parte hidrocentralele cu lac de acumulare a apei, centrale cu turbine cu gaz sau cu motoare Diesel.

Definirea zonelor pe verticală este utilă celor care conduc sistemul energetic, adică dispecerilor, care trebuie să asigure sistemului condiții de lucru specifice zonei în cauză, de exemplu:

- în zona vârfului de dimineață și a celui de seară trebuie asigurată rezerva corespunzătoare de putere;
- în zona golului de noapte se poate planifica scoaterea din funcțiune a unor instalații pentru reparații și revizii minore, se pot realiza manevre în instalații fără riscuri mari de pierdere a stabilității.

4.4. Mărimi caracteristice ale curbelor de sarcină [4.1.], [4.2.], [4.3.], [4.22.]

Mărimile caracteristice ale curbelor de sarcină zilnice sunt:

- energia activă zilnică:

$$W_a = \int_0^{24} P dt \quad [\text{kWh, MWh}]$$

- energia reactivă zilnică:

$$W_r = \int_0^{24} Q dt \quad [\text{kVAr}, \text{MVar}]$$

- puterea maximă absorbită:

$$P_{\max} [\text{kW}, \text{MW}] ; Q_{\max} [\text{kVAr}, \text{MVar}]$$

- puterea minimă absorbită:

$$P_{\min} [\text{kW}, \text{MW}] ; Q_{\min} [\text{kVAr}, \text{MVar}]$$

- puterea medie zilnică P_{med} (Q_{med}) este puterea care, presupusă constantă în cursul unei zile, determină aceeași energie ca și variația reală a puterii, adică:

$$P_{\text{med}} = \frac{\int_0^{24} P dt}{24} \quad \text{sau} \quad Q_{\text{med}} = \frac{\int_0^{24} Q dt}{24}$$

(Se mai poate folosi și notația \bar{P} sau \bar{Q})

- indicele (coeficientul) de aplatizare zilnică; k_{zi} ; este raportul dintre puterea medie zilnică și puterea maximă zilnică, adică:

$$k_{zi} = P_{\text{med}}/P_{\max}$$

- durata de utilizare a puterii maxime zilnice: T_u ; este timpul în care puterea maximă zilnică determină aceeași energie ca și puterea reală, adică:

$$T_u = W_u / P_{\max} = \int_0^{24} P(t) dt / P_{\max}$$

Dacă T_u se înmulțește cu numărul de zile dintr-un an se obține durata de utilizare anuală a puterii maxime, adică $T_{u \text{ an}} = 365 T_u$;

- timpul de pierderi: τ ; este timpul în care consumatorul, funcționând la sarcina maximă, determină în rețeaua de alimentare aceleași pierderi ca și în cazul când ar funcționa după curba reală de sarcină. Se poate defini și un timp de pierderi corespunzător circulației de puteri active τ_p , unul corespunzător circulației puterii reactive τ_Q și în fine, unul corespunzător puterii aparente (curentului) τ_S (τ).

Dacă R este rezistența rețelei de alimentare a consumatorului, U tensiunea lui, iar puterile P_{\max} , Q_{\max} (S_{\max}), din definirea timpului de pierderi rezultă:

$$\tau_p * \frac{P_{\max}^2}{U^2} R = \frac{1}{U^2} R \int_0^{24} P^2 dt \quad \text{sau}$$

$$\tau_p = \frac{1}{P_{\max}^2} \int_0^{24} P^2 dt \quad \text{și analog} \quad \tau_Q = \frac{1}{Q_{\max}^2} \int_0^{24} Q^2 dt$$

$$\text{iar} \quad \tau_S = \frac{1}{S_{\max}^2} \int_0^{24} S^2 dt$$

Dacă lui S_{\max} îi corespund P_{\max} și Q_{\max} , relația dintre cele trei mărimi τ_p , τ_Q , τ_S este:

$$\tau_S * S_{\max}^2 = \tau_P * P_{\max}^2 + \tau_Q * Q_{\max}^2$$

Dacă P_{\max} și Q_{\max} nu sunt simultane, relația de mai sus devine:

$$\tau_S * S_{\max}^2 = \tau_P * P_{\max}^2 + k_S * \tau_Q * Q_{\max}^2$$

unde $k_S < 1$ este un coeficient de nesimultaneitate a celor două maxime. De multe ori în calculele practice se lucrează cu un singur timp de pierderi considerând $\tau_P = \tau_Q = \tau_S = \tau$.

Timpul de pierderi este o mărime foarte importantă în special la determinarea pierderilor de energie [4.32.], determinarea lui efectuându-se prin mai multe metode (figura 4.5.).

- factorul de putere mediu:

$$k_{med} = 1 / \sqrt{1 + W_r^2 / W_a^2}$$

- factorul de putere maxim:

$$k_{\max} = P_{\max} / \sqrt{P_{\max}^2 + Q_{\max}^2}$$

- puterea activă medie pătratică:

$$\bar{P}^2 = \frac{1}{T} \int_0^{24} P^2(t) dt$$

- puterea reactivă medie pătratică:

$$\bar{Q}^2 = \frac{1}{T} \int_0^{24} Q^2(t) dt$$

- factorul de formă:

$$k_F = \frac{\bar{I}^2}{\bar{I}} \text{ sau } k_F = \frac{\bar{I}^2}{I_{med}}, \text{ adică este raportul dintre sarcina medie pătratică și sarcina medie.}$$

- coeficientul de variație al puterii active:

$$c_P = \frac{\sqrt{\bar{P}^2 - (\bar{P})^2}}{\bar{P}}$$

- coeficientul de variație al puterii reactive:

$$c_Q = \frac{\sqrt{\bar{Q}^2 - (\bar{Q})^2}}{\bar{Q}}$$

În ultima vreme, unii cercetători [4.15.] au introdus timpul de pierderi aferent curbilor de sarcină în unități relative. Aceste curbe de sarcină se obțin raportând curbele de sarcină în unități absolute $P(t)$ și $Q(t)$ la puterea de bază S_b . Ca urmare, rezultă următoarea relație de calcul a timpului de pierderi asociat puterii de bază S_b :

$$\tau_{Sb}^* = \tau_{P.Sb}^* + \tau_{Q.Sb}^*$$

unde $\tau_{P.Sb}^*$ și $\tau_{Q.Sb}^*$ au semnificațiile consacrate, astfel:

$$\tau_{Sb}^* = \frac{1}{T_s} \int_0^{T_s} (S/Sb)^2 dt ; \tau_{P.Sb}^* = \frac{1}{T_s} \int_0^{T_s} (P/Sb)^2 dt ; \tau_{Q.Sb}^* = \frac{1}{T_s} \int_0^{T_s} (Q/Sb)^2 dt$$

T_s (T) fiind timpul de funcționare în sarcină. Pe lângă acest timp se mai introduce și timpul de funcționare sub tensiune T_f .

În încheierea acestui paragraf, în tabelul 4.1.se prezintă principalii indicatori ai graficelor de sarcină ai unor consumatori din mediul urban care au sistem de termoficare și gaze naturale la bucătărie.

Tabelul 4.1. Valorile principalilor indicatori ai graficelor de sarcină ai unor consumatori urbani prevăzuți cu sistem de termoficare și gaze naturale la bucătărie [4.10.]

Denumire indicator	Valori medii	Valori extreme	Coefficient de variație Cv [%]
Puterea activă medie la vârful de sarcină/apartament P_{max} [kW]	0,4	0,15-0,69	21,6
Puterea reactivă medie la vârful de sarcină/apartament Q_{max} [kW]	0,14	0,08-0,2	23,2
Puterea medie instalată/apartament P_i [kW]	3,2	2,3-3,7	12,5
Timpul de utilizare a puterii active maxime T_{UP} [h/an]	3500	1446-5900	26,5
Timpul de utilizare a puterii reactive maxime T_{UQ} [h/an]	5000	2640-7000	26,0
Factorul de putere mediu în cursul zilei k_p	0,79	0,7-0,87	6,6

4.5. Modelarea curbelor de sarcină [4.1.], [4.10.], [4.11.], [4.12.]

Modelarea curbelor de sarcină se efectuează pe baza curbelor de sarcină tip ale consumatorilor. Curbele de sarcină tip constituie o informație primară cu ajutorul căreia se pot modela cu ușurință graficele de sarcină din nodurile rețelelor electrice de distribuție (dar nu numai), dacă se dispune de un număr minim de informații acumulate, cum ar fi necesarul de energie pe o anumită perioadă, sarcina activă din nod, măsurată la o anumită oră din zi, valoarea medie statistică a coeficienților de încărcare ai transformatoarelor din posturi la sarcina medie sau maximă, curentul absorbit de consumator la o anumită oră din zi etc.

De menționat că graficele tip de sarcină, reprezintă variația probabilă a sarcinii pe un interval de 24 ore și se întocmesc pe grupe de consumatori: casnici, social-culturali, edilitari, la nivelul posturilor de transformare, a stațiilor de alimentare, pe anumite zone etc. Ridicarea acestor grafice de sarcină se efectuează prin prelucrarea statistică a unui mare număr de date extrase din graficele de sarcină înregistrate de la diverse categorii de consumatori.




Figura 4.5. Metode pentru determinarea timpului de pierderi

Măsurătorile de curbe de sarcină la diverși consumatori din rețelele de distribuție spre exemplu, măsurători efectuate pe o perioadă de mai mulți ani, precum și studiile de analiză statistică, au permis să se evidențieze anumite constante în forma curbelor de sarcină ale acestora.

Aceste constatări au condus la concluzia în a considera curba de sarcină a unui consumator ca un ansamblu de două caracteristici distincte și chiar complementare și anume:

- o caracteristică de formă, care reflectă modularea relativă a puterilor consumate;
- o caracteristică de nivel, care ține seama de cantitatea de energie electrică consumată într-un anumit interval de timp.

Asocierea efectuată a fost următoarea:

- plecând de la campaniile de măsurători efectuate asupra eșantionului ales, se adoptă o clasificare statistică a curbelor de sarcină, bazată pe forma acestor grafice de sarcină;
- în funcție de caracteristicile proprii ale fiecărui consumator se definește:
 - procedura de afectare a unui consumator dat la o anumită clasă de curbe de sarcină;
 - tehnica de trecere de la graficul tip reținut la o curbă de sarcină la nivelul propriu al consumatorului considerat.

Curba de sarcină tip este deci un grafic mediu de sarcină pentru o categorie de consumatori reflectând cu o anumită probabilitate caracteristicile esențiale ale acestor grafice.

La stabilirea curbelor de sarcină tip, s-a plecat de la ipoteza că sarcinile din nodurile rețelei pentru diferite momente (de fapt ore), constituie mărimi aleatoare, care respectă legea de distribuție normală.

Pentru determinarea caracteristicilor probabile ale sarcinilor orare, în regimurile caracteristice (iarnă și vară, zile lucrătoare și de repaus), folosind informațiile din diferite puncte ale rețelei de alimentare, legea de distribuție a sarcinilor orare se scrie sub forma:

$$F = \alpha_1 \varphi_1 + \alpha_2 \varphi_2 + \dots + \alpha_n \varphi_n \quad \text{unde} \quad \sum_1^n \alpha_i = 1 \quad (4.1)$$

Relația (4.1) ne permite ca valoarea medie, iregularitatea, dispersia și abaterea standard să se determine cu relațiile următoare:

$$\bullet \text{ valoarea medie : } \bar{P}_F = \int_{-\infty}^{+\infty} P(\alpha_1 \varphi_1 + \alpha_2 \varphi_2 + \dots + \alpha_n \varphi_n) dP = \alpha_1 \bar{P}_1 + \alpha_2 \bar{P}_2 + \dots + \alpha_n \bar{P}_n \quad (4.2)$$

$$\bullet \text{ iregularitatea : } (\bar{P}^2)_F = \sum_{j=1}^n \alpha_j (\bar{P}_j^2) = \sum_{j=1}^n \alpha_j (1 + k_{v,j}^2) (\bar{P}_j)^2 \quad (4.3)$$

$$\bullet \text{ dispersia : } D_F(P) = \sum_{j=1}^n \alpha_j (\bar{P}_j) - \left(\sum_{j=1}^n \alpha_j \bar{P}_j \right)^2 \quad (4.4)$$

$$\bullet \text{ abaterea standard : } \alpha_F(P) = \left[\sum_{j=1}^n \alpha_j (\bar{P}_j^2) - \left(\sum_{j=1}^n \alpha_j \bar{P}_j \right)^2 \right]^{1/2} \quad (4.5)$$

În continuare se vor face câteva referiri la criteriile care permit alocarea unei curbe de sarcină tip unui consumator racordat la rețeaua de distribuție.

Astfel, la baza stabilirii curbelor de sarcină tip, ca date de bază se folosesc curbele de sarcină în puteri medii la 10 minute, pentru o serie de consumatori luați individual, într-una sau mai multe zile consecutiv.

Avându-se în vedere aceste rezultate ale măsurătorilor se elaborează pentru fiecare consumator considerat individual, curbele de sarcină în puteri medii la ½ ore, respectiv 48 valori P_j pe zi asupra cărora se vor efectua prelucrările.

Ca urmare, puterea medie \bar{P} a zilei considerate va fi:

$$\bar{P} = \frac{1}{48} \sum_{j=1}^{48} P_j \text{ iar puterea raportată la ora } j \text{ se va putea scrie sub forma: } \alpha_j = P_j / \bar{P}$$

Căutarea graficului tip care reprezintă curba de sarcină raportată, conduce la stabilirea curbelor de sarcină mai puțin sub aspectul puterilor raportate, care fac ca doi consumatori să poată fi comparați. Curba de sarcină raportată (în unități relative) se obține împărțind fiecare valoare reală de putere semi-orară prin puterea medie a zilei lucrătoare din săptămâna considerată. Pe acest suport se procedează la o analiză statistică completă, care comportă trei faze și anume:

- clasificarea consumatorilor prin similitudinea formei curbei de sarcină;
- interpretarea topologiei obținute cu ajutorul variabilelor caracteristicilor fiecărui consumator;
- căutarea printr-o analiză discriminantă a celor mai bune criterii de afectare a unui consumator din eșantionul ales la o clasă de curbe tip de sarcină.

Sortarea curbelor de sarcină tip se face după coeficientul de variație k_v și după coeficienții de corelație r_F .

- Coeficientul de variație k_v se definește ca fiind raportul dintre valoarea dispersiei sau abaterii standard și valoarea medie, iar în cazul puterilor active avem:

$$k_v(P) = \sigma(P) / \bar{P} \tag{4.7}$$

În cazul în care se consideră și dispersiile valorilor orare din graficele de sarcină, coeficientul de variație a sarcinii active se determină cu relația:

$$k_v(P) = \left[\frac{1}{24} \sum_{j=1}^{24} [P_j^{\bullet 2} + \sigma(P_j^{\bullet})^2] - 1 \right]^{1/2} \tag{4.8}$$

unde:

P_j^{\bullet} - valoarea relativă a sarcinii la ora j din graficul tip de sarcină;

$\sigma(P_j^{\bullet})$ -dispersia sarcinilor la ora j din graficul tip de sarcină.

- Coeficientul de corelație dintre sarcinile active, P_1 și P_2 a două grafice se determină cu relația:

$$r_F(P_1, P_2) = \frac{(\bar{P}_1, \bar{P}_2) - (\bar{P}_1^{\bullet} * \bar{P}_2^{\bullet})}{\sigma(P_1) * \sigma(P_2)} \tag{4.9}$$

Dacă pentru două curbe de sarcină se constată că valoarea coeficientului de corelație este apropiată de unitate, iar coeficienții de variație pentru cele două curbe de sarcină au valori aproximativ egale, se poate afirma că diagramele sunt de același tip.

4.6. Utilizarea curbelor de sarcină [4.1.], [4.2.], [4.13.], [4.17.], [4.18.], [4.22.]

Curbele de sarcină sunt elemente foarte utile, utilizate în faza de proiectare, dezvoltare și exploatare a sistemului electroenergetic, ele oferind informația completă despre consumatori.

Se poate afirma că, curbele de sarcină servesc următoarelor scopuri:

- permit alegerea momentului de conectare sau deconectare a agregatelor, abaterile în minus conducând la creșterea cheltuielilor de exploatare, iar cele în plus la suprasolicitări și chiar pierderi de stabilitate;
- asigură posibilitatea optimizării prealabile a regimurilor de funcționare prin repartizarea economică a sarcinii între centralele electrice în funcțiune din cadrul sistemului;
- se poate determina consumul de energie pe o perioadă de timp viitoare și deci se poate estima cantitatea necesară de purtători de energie, asigurându-se aprovizionarea optimă, la timp, a centralelor electrice cu combustibil;
- cunoscându-se evoluția zi de zi, pe durata unui an, a vârfului de sarcină, se poate întocmi un program realist de întreținere și reparație a echipamentului energetic;
- din curbele de sarcină se poate construi curba clasată a puterilor. Această curbă reprezintă puterile consumate în funcție de duratele cumulate ale lor. Curba clasată (figura 4.6.) a puterilor permite dimensionarea optimă a rezervei de putere din sistem;




Figura 4.6. Curba clasată a puterilor active

- o altă curbă caracteristică a consumatorilor, care se poate obține prin citirea la intervale egale de timp a indicațiilor contorului de energie este curba energiilor. Ea permite determinarea: puterilor medii orare, puterii medii la un anumit moment dat și puterii momentane.
- folosind graficul puterilor maxime zilnice (figura 4.7.) se poate stabili numărul de grupuri necesare a se găsi în funcțiune în diferite perioade ale anului. În figura 4.7. cu P_n s-a notat puterea nominală a grupului, ea fiind presupusă identică pentru toate grupurile din sistem.

- Puterile cerute de consumatori servesc ca date de intrare în activitatea de proiectare a instalațiilor pentru: stabilirea arhitecturii rețelelor, dimensionarea căilor de curent, alegerea aparatajului din stațiile de transformare de înaltă și medie tensiune și din posturile de transformare la joasă tensiune.

4.7. Metode de prognoză a curbelor de sarcină [4.1.], [4.2.], [4.3.], [4.7.], [4.8.], [4.19.], [4.22.]

Metodele de prognoză a curbelor de sarcină pot fi împărțite în două mari categorii: clasice și moderne. Modelele clasice la rândul lor pot fi directe și indirecte, primele prognozând palierele curbei, a doua categorie mărimile caracteristice ale curbei de sarcină. În acest sens, în figura 4.8. se prezintă o tentativă de clasificare a metodelor de prognoză a curbelor de sarcină.




Figura 4.7. Curba puterilor maxime zilnice

Dintre cele două categorii de metode prezentate se remarcă componentele care se realizează folosind seriile de timp, respectiv Rețelele Neuronale Artificiale (RNA). Cele două categorii de metode au proprietăți complementare, fapt deosebit de important pentru activitatea de prognoză. Astfel, seriile de timp se rezumă la identificarea unui model matematic al seriei, stabilind legități pentru evoluția seriei de timp, fără însă să pună accentul pe cauzele interne ale procesului, care conduc la evoluția lui [4.1.]. Metoda dă rezultate bune atunci când sistemul fizic este invariant sau lent variant în timp. RNA acordă o mare atenție cauzelor care conduc la modificări ale evoluției procesului, considerându-le ca mărimi de intrare, dar forma matematică a legăturilor dintre ieșiri și intrări nu este evidențiată explicit, ea fiind stabilită cu ajutorul unui proces de antrenare. RNA se pretează foarte bine la modelarea proceselor în care cauzele se pot modifica brusc [4.1.], [4.2.].

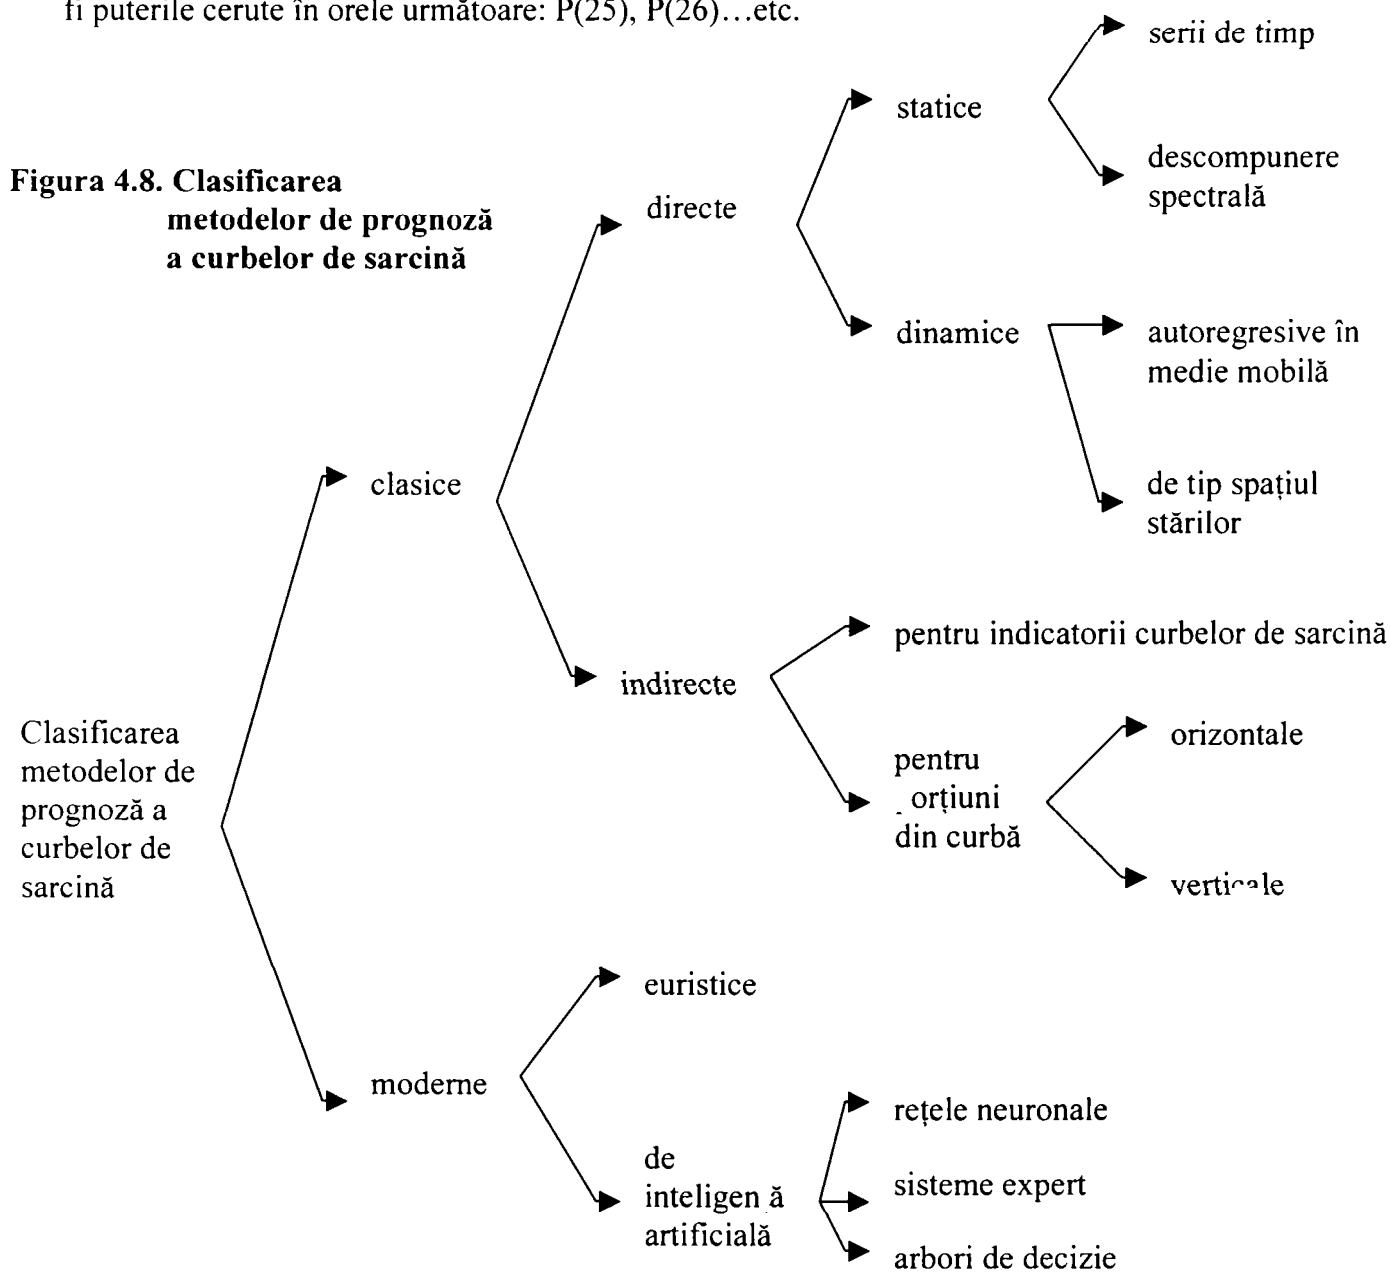
În cele ce urmează s-a considerat util a fi prezentate câteva elemente despre metoda seriilor de timp.

4.7.1. Serii de timp; definiții, clasificări, modele matematice [4.4.], [4.5.], [4.6.], [4.23.], [4.24.], [4.26.]

Seria de timp este o secvență ordonată în timp de observații efectuate asupra unei variabile, care se succed în ordinea apariției lor. Seria de timp poate fi privită și ca un șir finit de variabile aleatoare $y(1), y(2), \dots, y(n)$, care reprezintă de fapt o variabilă aleatoare multidimensională.

Caracteristic seriei de timp este faptul că toate variabilele aleatoare care formează seria se referă la același fenomen fizic, biologic, social etc. Prin urmare, între valorile seriei de timp există interdependențe ce trebuie evidențiate cu ocazia analizei seriei de timp în vederea sintezei unei legități, care să permită predicția valorilor viitoare ale procesului stocastic $y(n+1), y(n+2), \dots$ pe baza realizărilor existente $y(1), y(2), \dots, y(n)$.

Spre exemplu, dacă procesul stocastic observat este o sarcină dintr-o rețea electrică, atunci o realizare a acestui proces se poate obține măsurând timp de o zi puterile medii orare în cauză: $P(1), P(2), \dots, P(24)$. Puterea electrică reclamată de consumator este evident un proces stocastic, fiindcă pe baza cunoașterii seriei de timp nu se poate afirma cu certitudine care vor fi puterile cerute în orele următoare: $P(25), P(26), \dots$ etc.



Calsificarea seriilor de timp din considerente practice (de utilizare) se prezintă în figura 4.9.

În ceea ce privește metodologia de modelare a seriilor de timp, trebuie menționat că obiectivul principal al analizei seriilor de timp este realizarea unei reprezentări cât mai bune, de regulă matematică, a mecanismului care guvernează procesul ce a produs realizarea respectivă. Reprezentarea menționată nu este altceva decât modelul. Modelul trebuie însă să dispună de o calitate corespunzătoare, asigurată prin [4.4.]:

- număr redus de parametri de stare;
- independența reziduurilor;
- aproximarea satisfăcătoare a datelor realizării;
- producerea unor valori suficient de precise pentru predicție etc.

Deci, modelul trebuie foarte bine corelat cu procesul și cu realizările din cadrul acestuia.

Schema structurală a dependențelor dintre cele trei elemente: proces-realizare-model se prezintă în figura 4.10.

Etapele ce trebuie parcurse la identificarea modelului sunt următoarele:

- stabilirea structurii modelului folosind ca instrumente funcția de autocorelație și funcția de autocorelație parțială;

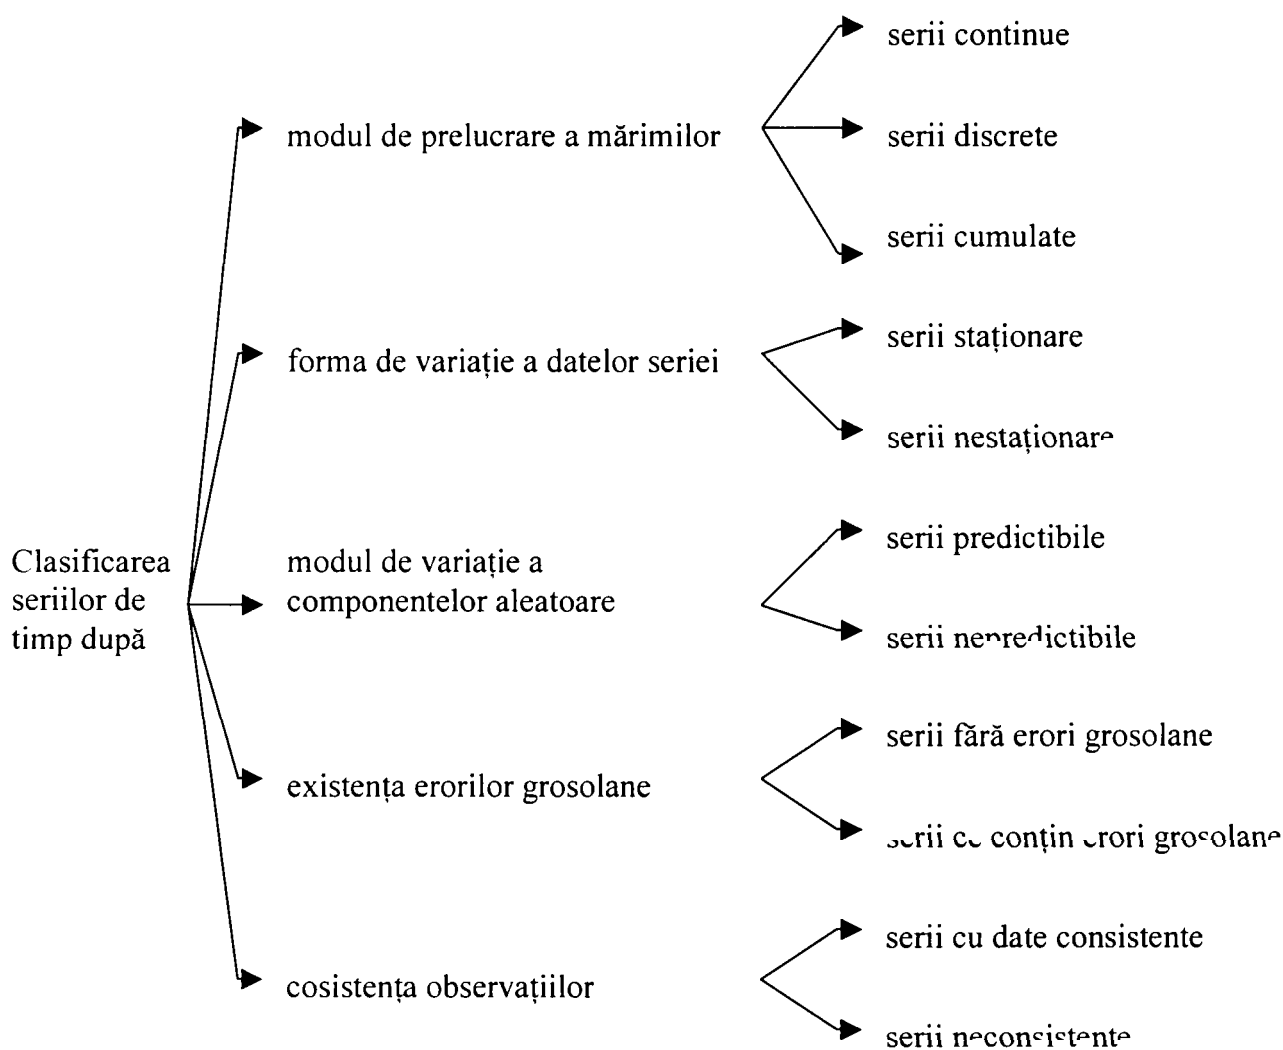


Figura 4.9. Clasificarea seriilor de timp

- identificarea componentelor seriei de timp: tendință, componentă ciclică, componentă aleatoare;
- estimarea parametrilor modelului matematic folosind metode și proceduri dedicate (cum ar fi spre exemplu metoda celor mai mici pătrate);
- validarea și diagnoza modelului; se realizează prin testarea modelului obținut în primele două faze. Dacă modelul nu trece de faza de validare se caută îmbunătățirea lui și ciclul de identificare-estimare se reia.

Pentru prognozarea valorilor viitoare ale seriei de timp, se introduc în model valorile disponibile ale seriei la momentul curent de timp. Pe baza lor, printr-un calcul recursiv se stabilesc valorile viitoare, prognozate.

Trebuie menționat în finalul prezentării acestor probleme că modelul care se pretează cel mai bine la prognoza curbilor de sarcină este de tipul Autoregresiv Integrat cu Medie Alunecătoare (ARIMA). Tehnica de modelare și predicția seriilor de timp bazată pe acest model este cunoscută în literatură sub denumirea de metodologia Box-Jenkins Error: [4.23.], [4.24.], [4.26.], [4.27.].

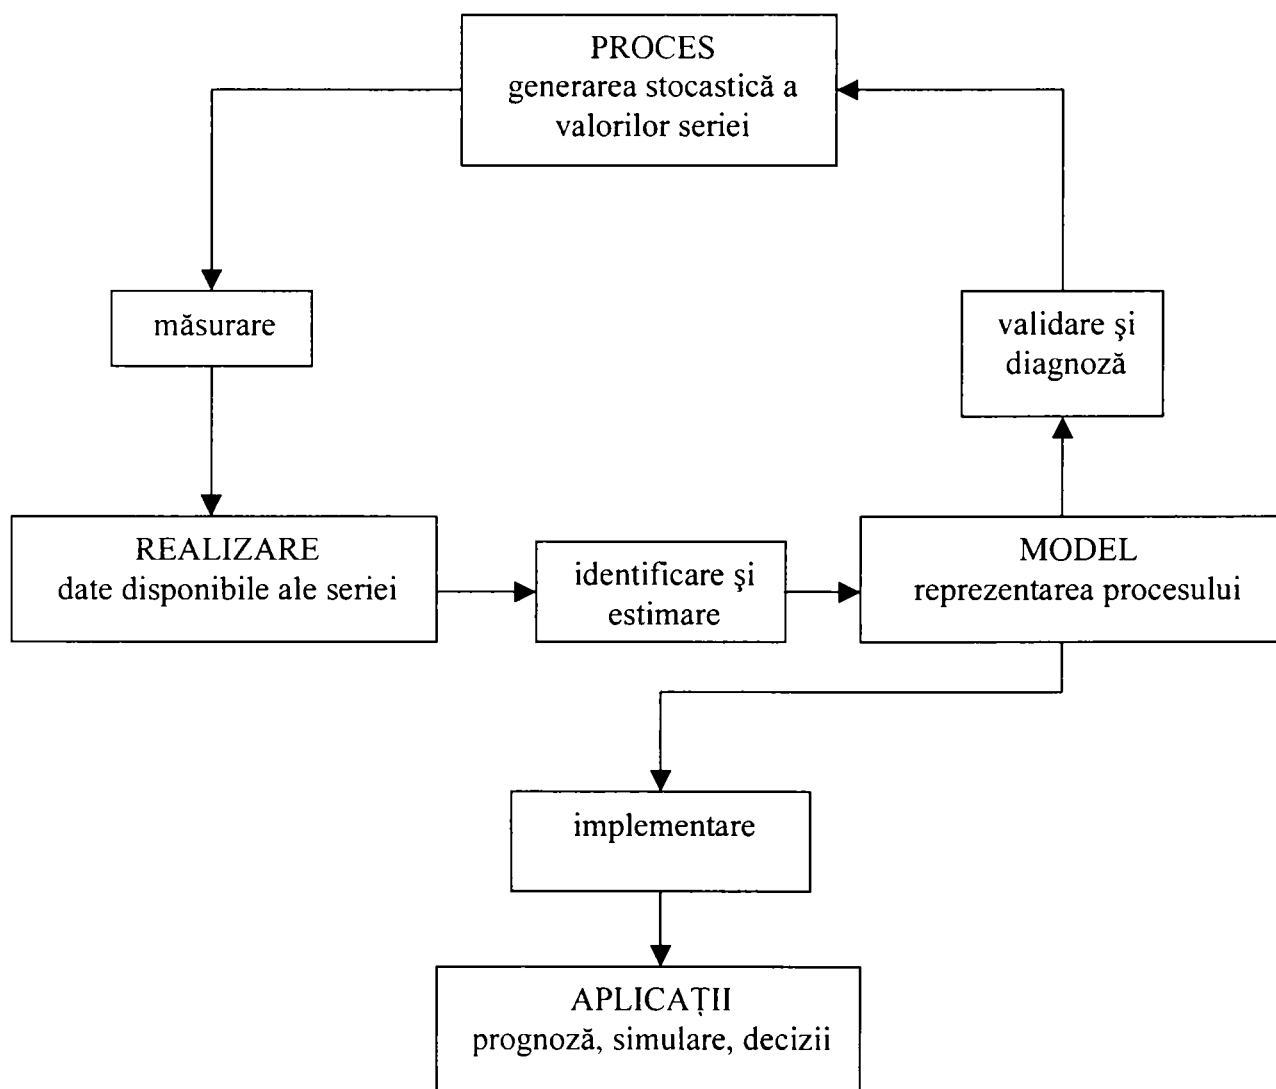


Figura 4.10. Prezentarea schematică a corelației: proces – realizare - model

4.7.2. Modele folosite în studiul seriilor de timp [4.2.], [4.3.], [4.4.], [4.9.]

Alegerea modelului matematic utilizat în studiul seriilor de timp este foarte important. O clasificare a acestor modele este prezentată în figura 4.11.

În continuare, se va introduce pentru procesul stocastic un model discret, suficient de general, valabil pentru majoritatea aplicațiilor, inclusiv pentru cele legate de estimarea valorilor viitoare. Alegerea modelului discret este justificată de evitarea dificultăților legate de introducerea zgomotului alb continuu și de faptul că modelele discrete pot fi implementate foarte simplu într-un program de calcul numeric. Pe lângă acestea, soluția modelului discret nu restrânge generalitatea abordării, toate rezultatele obținute fiind principal valabile și pentru modelele continue.

Conform teoremei de reprezentare spectrală (4.4), un proces stocastic staționar poate fi obținut dintr-un zgomot alb $\varepsilon(t)$, cu media nulă $E(\varepsilon) = 0$ și dispersia $V(\varepsilon) = E(\varepsilon^2) = \sigma^2$, trecut printr-un filtru rațional stabil, adică:

$$y(t) = H(q^{-1}) * \varepsilon(t - k) \quad (4.10)$$

unde:

t - este timpul discret, $t = 1, 2, 3, \dots, k, \dots, -\infty$. Timpul continuu se calculează pe baza relației $t_c = t * T$; T fiind durata de eșantionare a semnalului, timp ce trebuie să respecte teorema eșantionării: $T < 0,5 T_{\min}$, T_{\min} fiind cea mai mică constantă de timp aferentă procesului considerat;

q^{-1} - operatorul de întârziere, are semnificația $y(t-1) = q^{-1} * y(t)$;

k - timpul mort discret al procesului analizat; el respectă principiul cauzalității $k \geq 0$; evident $\varepsilon(t-k) = q^{-1} * \varepsilon(t)$.

$H(q^{-1})$ - funcție de transfer discretă (FDT), având forma:

$$H(q^{-1}) = B(q^{-1}) / A(q^{-1}) \quad (4.11)$$

$A(q^{-1})$; $B(q^{-1})$ - plinoame prime între ele, cu $n_a \geq n_b$ având forma:

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_{n_a} q^{-n_a} = 1 + \sum_{i=1}^{n_a} a_i q^{-i} \quad (4.12)$$

$$B(q^{-1}) = b_0 + b_1 q^{-1} + \dots + b_{n_b} q^{-n_b} = b_0 + \sum_{i=1}^{n_b} b_i q^{-i}$$

Pentru a asigura condiția de stabilitate, rădăcinile ecuației caracteristice $A(x) = 0$ trebuie să aibe modulul supraunitar, adică să se găsească în exteriorul cercului unitar al planului complex.

De menționat că, pentru asigurarea unei bune identificări a modelului, la măsurarea mărimilor seriei de timp, $y(1), y(2), \dots, y(n)$, trebuie luată precauția ca semnalul util să fie cât mai mare. Unul dintre mijloacele cele mai facile de atingere a scopului propus, constă în reglarea nivelului de zero al instrumentelor de măsură, astfel încât el să coincidă cu valoarea medie a semnalului, ceea ce înseamnă de fapt că $y(t)$ reprezintă o abatere față de medie iar $E[y(t)] = 0$.

Dacă condiția de mai sus nu este asigurată, este util ca seria abaterilor să fie

$$y(t) = y_m(t) - \bar{y}_m, \quad y_m(t), \text{ corespunzând valorilor măsurate efectiv.}$$

Analiza formei generale a modelului (relația (4.10)) ne permite identificarea următoarelor situații și anume:

a) $n_b = 0, b_0 = 1$, deci $B(q^{-1}) = 1$ iar polinomul $A(q^{-1})$ nu conține factori de forma $(1-q^{-1})$, rezultând astfel modelul Autoregresiv de ordinul n_a -AR(n_a) având expresia:

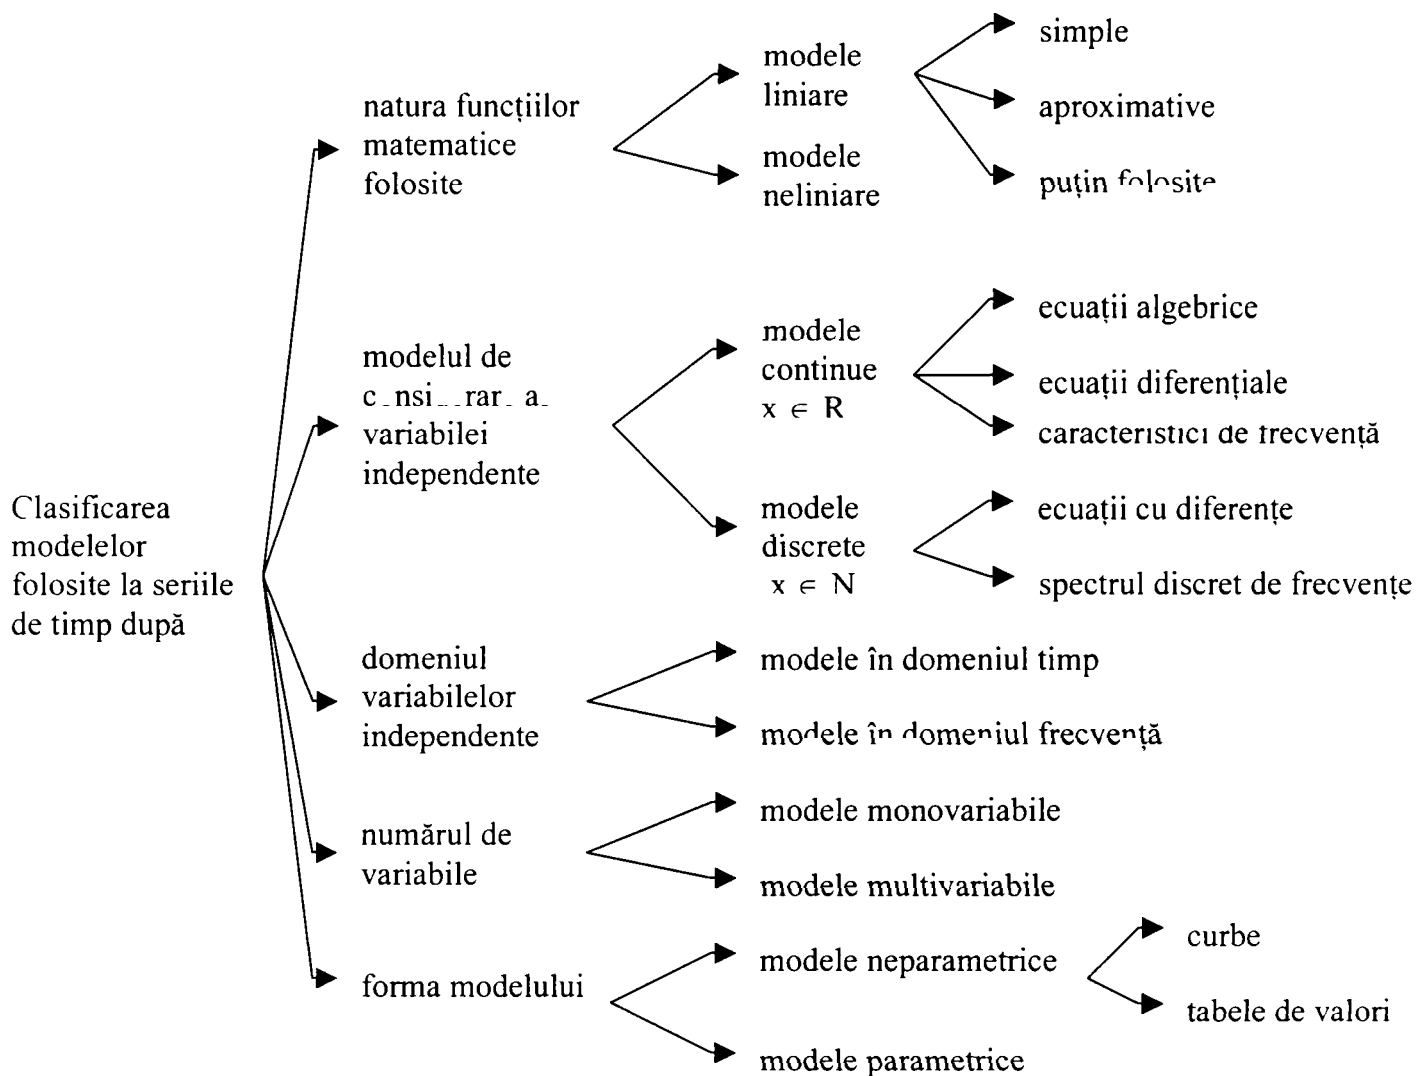


Figura 4.11. Clasificarea modelelor folosite în studiul seriilor de timp

$$A(q^{-1}) * y(t) = \varepsilon(t - k) \text{ unde } y(t) = -a_1 y(t-1) - \dots - a_{n_a} y(t - n_a) + \varepsilon(t - k) \quad (4.13)$$

Din analiza expresiei (4.13) se constată că valoarea ieșirii la un anumit moment depinde de valorile ei regresate, de la momentele anterioare, ceea ce justifică denumirea modelului.

b) $n_a = 0$, deci $A(q^{-1}) = 1$, rezultă astfel modelul cu medie alunecătoare n_b (moving average) de ordinul – MA(n_b), unde:

$$y(t) = B(q^{-1}) * \varepsilon(t - k) \text{ sau} \quad (4.14)$$

$$y(t) = b_0 * \varepsilon(t - k) + \dots + b_{n_b} * \varepsilon(t - k - n_b)$$

c) polinomul $A(q^{-1})$ nu conține factori de forma $(1 - q^{-1})$, se obține pentru seria de timp modelul cunoscut sub denumirea de autoregresiv cu medie alunecătoare – ARMA (n_a, n_b):

$$A(q^{-1}) * y(t) = B(q^{-1}) * \varepsilon(t - k) \text{ și} \quad (4.15)$$

$$y(t) = -a_1 * y(t-1) - \dots - a_{n_a} * y(t - n_a) + b_0 * \varepsilon(t - k) + b_1 * \varepsilon(t - k - 1) + \dots + b_{n_b} * \varepsilon(t - k - n_b)$$

Justificarea denumirii modelului se bazează pe faptul că el este o combinație a modelelor de la punctele 2 și 3. Acest model asigură oricum structura de bază pentru procesul stocastic staționar.

d) $A(q^{-1})$ conține factori de forma $(1-q^{-1})^d$, fapt ce semnifică existența unor componente integratoare – modelul numindu-se în aceste condiții autoregresiv integrat cu medie alunecătoare – ARIMA (n_a, d, n_b) .

Modele de tipul: $y(t) = y(t-1) + \varepsilon(t)$ crespund proceselor nestaționare cu creșteri aleatoare staționare. Dacă $\varepsilon(t)$ este un proces staționar cu media diferită de zero $E[\varepsilon(t)] = \mu \neq 0$ și dispersia $V[\varepsilon(t)] = E[\varepsilon(t) - \mu]^2 = \sigma^2$, atunci observând că $y(t) = \sum_{i=1}^t \varepsilon(i)$ rezultă:

$$E[y(t)] = \sum_{i=1}^t E[\varepsilon(i)] = \sum_{i=1}^t \mu = t * \mu \quad (4.17)$$

și similar:

$$V[y(t)] = \sum_{i=1}^t V[\varepsilon(i)] = \sum_{i=1}^t \sigma^2 = t * \sigma^2 \quad (4.18)$$

Prin urmare, atât media, cât și dispersia procesului, cresc continuu în timp. Faptul justifică de fapt numele tipului de proces în cauză. Diferențiind un astfel de proces, el poate fi adus la forma unui proces stocastic staționar. Majoritatea seriilor de timp reale sunt rezultatul suprapunerii unor factori determinați care exprimă tendința de evoluție a procesului $y_T(t)$ și a unor factori care reflectă tendințele ciclice (sezoniere) $-y_C(t)$, peste care se suprapune componenta aleatoare - $\varepsilon(t)$, deci $y(t) = y_T(t) + y_C(t) + \varepsilon(t)$.

Soluționarea ecuației de mai sus presupune o separare explicită a componentelor și apoi o tratare individuală a acestora. În acest sens, este ușor de observat că separarea implicită a componentei de tendință constă în trecerea de la modelul ARIMA la modelul ARMA. În mod similar se procedează cu componentele ciclice și sezoniere, observând că prin caracterul lor armonic, ele se repetă la intervale egale de timp, egale de fapt cu perioada T_c rezultând corelații de forma: $y(t) = y(t - T_c) = q^{-T_c} * y(t)$

Prin separarea corespunzătoare a componentelor vor exista trei serii de timp și anume:

- $y_T(t) = y(t) - y_1(t)$ - tendința;
- $y_2(t) = y_1(t)/(1 - q^{T_c})$ - seria de tip ARMA;
- $y_C(t) = y_1(t) - y_2(t)$ - componenta ciclică.

Problema identificării modelului seriei de timp constă în selectarea unei subclase din modelul general ARIMA (n_a, d, n_b) . Punctul de plecare în obținerea seriei de timp îl constituie existența unei realizări de forma: $y(1), y(2), \dots, y(n)$ care să conțină un număr n , semnificativ de observații ale unei variabile unidimensionale, de regulă $n \geq 50$.

Etapele identificării constau în [4.4.], [4.5.]:

1) Reprezentarea grafică a eșantionului de date, fapt ce permite evidențierea unor caracteristici esențiale ale procesului stocastic, cum ar fi:

- existența unei corelații statistice între observații;
- faptul că procesul este staționar sau nu;
- pentru un proces nestaționar se apreciază modul în care sunt afectate media, dispersia sau ambele;
- structura modelului matematic, ponderea componentei de trend, existența eventual a componentei ciclice;

- luarea deciziei de separare a componentelor;
- asigurarea caracterului staționar prin logaritmare, derivare etc.

Pentru ca metodologia de identificare elaborată de Box-Jenkins să poată fi aplicată, seria de timp trebuie adusă la forma caracteristică modelelor stocastice de tip ARMA (n_a, n_b), cu ajutorul unor transformări adecvat alese, efectuate asupra realizării inițiale.

- 2) Se apreciază FAC estimată. Pentru aceasta se calculează coeficienții de autocorelație estimați - \hat{r}_k ai observațiilor decalate prin k intervale de timp, aparținând aceleiași realizări. Coeficientul \hat{r}_k reprezintă o măsură a dependenței statistice dintre perechile ordonate de observații de forma $y(t), y(t+k)$. Așa cum este cunoscut, dacă $\hat{r}_k = 0$ variabilele în cauză nu sunt corelate; dacă $\hat{r}_k = \pm 1$ atunci corelația este perfectă. Oricum, valoarea estimată \hat{r}_k a coeficientului de autocorelație furnizează o apreciere, mai mult sau mai puțin exactă asupra coeficientului teoretic de autocorelație r_k . Formula standard pentru calculul coeficienților de autocorelație este:

$$\hat{r}_k = \frac{\sum_{t=1}^{n-k} [y(t) - \bar{y}] * [y(t+k) - \bar{y}]}{\sum_{t=1}^n [y(t) - \bar{y}]^2} \quad (4.19)$$

unde \bar{y} reprezintă valoarea medie a observațiilor eșantionului. Dacă procesul este staționar, într-o primă aproximație, ea poate constitui o estimație a valorii medii a populației statistice.

Oricum, în final se apreciază că $\hat{r}_k(k)$ reprezintă tocmai FAC estimată.

- 3) Se determină FACP estimată $\hat{\varphi}_{kk}$, care în principiu este similară cu FAC estimată - \hat{r}_k . Autocorelația parțială se referă la gradul de corelație dintre $y(t)$ și $y(t+k)$ luând în considerație și efectele valorilor seriei - $y(t)$, care intervin între cele două momente de timp t și $t+k$. În acest scop se calculează coeficienții de autocorelație parțială prin rezolvarea sistemului de ecuații recursive Yule-Walker [4.1.].
Va rezulta [4.4.]:

$$\hat{\varphi}_{1,1} = \hat{r}_1; \hat{\varphi}_{k,k} = \frac{\hat{r}_k - \sum_{j=1}^{k-1} \hat{\varphi}_{k-1,j} * \hat{r}_j}{1 - \sum_{j=1}^{k-1} \hat{\varphi}_{k-1,j} * \hat{r}_j}; k = 2,3,\dots \quad (4.20)$$

$$\hat{\varphi}_{k,j} = \hat{\varphi}_{k-1,j} - \hat{\varphi}_{k,k} * \hat{\varphi}_{k-1,k-j}; k = 3,4,\dots; j = 1,2,\dots, k-1$$

Se precizează prin definiție că FACP estimată este chiar $\hat{\varphi}_{kk}(k)$.

- 4) Se testează că coeficienții de autocorelație estimați \hat{r}_k sau cei de autocorelație parțială estimați $\hat{\varphi}_{kk}$ sunt zero sau nu. Pentru aceasta se folosește o statistică t și o aproximație a erorii standard a repartiției valorilor adecvată. Astfel :

$$t_{r_k} = \frac{\hat{r}_k - r_k}{S(\hat{r}_k)} \text{ iar } t_{\varphi_{kk}} = \frac{\hat{\varphi}_{kk} - \varphi_{kk}}{S(\hat{\varphi}_{kk})} \quad (4.21)$$

și respectiv:

$$S(\hat{r}_k) = \left[\frac{1}{n} (1 + 2 \sum_{j=1}^{k-1} \hat{r}_j^2) \right]^{1/2} \text{ și } S(\hat{\varphi}_{kk}) = \sqrt{1/n} \quad (4.22)$$

Coeficienții de autocorelație și autocorelație parțială estimați, pentru care valoarea absolută a statisticii testului t este mai mare ca 2, sunt diferiți statistic de valoarea 0, la un nivel de semnificație de aproximativ 5%.

- 5) Se determină structura modelului ARMA pentru problema considerată. Pentru aceasta se aplică următoarele etape [4.27.]:

- se caută stabilirea unor modele cât mai simple, printre următoarele tipuri clasice: AR(1), AR(2), MA(1), MA(2), ARMA (1,1), ARMA (2,2);
- se compară FAC și FACP estimate pentru realizarea studiată cu FAC și FACP teoretice, corespunzătoare modelelor de mai sus, reținându-se modelul cel mai adecvat;
- pentru un proces stocastic AR(n_a), FACP va avea elemente $\varphi_{kk} \neq 0$ pentru $k \leq n_a$ și $\varphi_{kk} = 0$ pentru $k > n_a$;
- pentru un proces stocastic MA(n_b), FAC va avea elemente $r_k \neq 0$ pentru $k \leq n_b$ și $r_k = 0$ pentru $k > n_b$;
- pentru un proces stocastic ARMA(n_a, n_b), FACP – φ_{kk} vor tinde către 0 după primele $n_b - n_a$ valori ale întârzierii, iar elementele FAC – r_k vor tinde către 0 după primele $n_b - n_a$ valori ale întârzierii.

- 6) Parametrii modelului a cărui structură a fost identificată la punctul anterior, trebuie estimați pe baza unei tehnici binecunoscute în literatură. Dacă modelul este liniar în parametrii se recomandă folosirea metodologiei specifice modelului stocastic liniar multivariabil. Dacă modelul este neliniar în parametrii și nu s-au aplicat tehnici de liniarizare, atunci se apelează la o metodă de gradient.

- 7) Evaluarea rezultatelor estimării parametrilor este în general considerată ca fiind o etapă premergătoare fazei de validare și diagnoză; totuși ea poate fi privită ca prima etapă a fazei de validare a modelului seriei de timp.

Evaluarea rezultatelor estimării parametrilor presupune abordarea următoarelor aspecte:

- verificarea stării staționare a modelului;
- verificarea inversabilității modelului;
- verificarea semnificației statistice a parametrilor modelului; se efectuează pe baza unui test t. Se calculează mărimea:

$t = \frac{\text{valoarea coeficientului estimat} - \text{valoarea coeficientului din ipoteză}}{\text{erori standard}}$

eroarea standard estimată pentru un coeficient.

- calculul matricei de corelație a modelului, care furnizează informații utile despre calitatea acestuia;
- aprecierea capacității modelului de a reprezenta datele seriei absolut necesară fiindcă nu există nici o garanție că un model construit corect va reprezenta suficient de precis datele realizării pe baza cărora a fost determinat.

8) Validarea – diagnoza modelului obținut în fazele anterioare, se analizează dacă acesta este reprezentativ pentru seria studiată. În cazul unui răspuns negativ, se revine la etapa de identificare pentru selectarea altor modele cu posibilități mai mari de reprezentare corectă a datelor seriei. Procesul de validare-diagnoză comportă mai multe etape și anume:

a) Reprezentarea grafică a reziduurilor, permite:

- detectarea unor erori grosolane a datelor;
- modificările valorilor dispersiei sugerează necesitatea aplicării unor transformări logaritmice a datelor seriei;

b) Verificarea independenței reziduurilor; este cel mai relevant test cu caracter statistic al unui model ARIMA. Dacă reziduurile modelului identificat sunt corelate, atunci înseamnă că trebuie găsit un alt model matematic. Se pot face precizările următoare:

- În faza de validare-diagnoză a modelului, instrumentul analitic de bază este funcția de autocorelație a reziduurilor FACP (k).

Coeficientul de autocorelație a reziduurilor se definește astfel:

$$\hat{r}_k(e) = \frac{\sum_{t=1}^{n-k} [e(t) - \bar{e}] * [e(t-k) - \bar{e}]}{\sum_{t=1}^n [e(t) - \bar{e}]^2} \quad (4.23)$$

Pentru un model ARIMA corect stabilit, în cazul ideal FACR (k) = $\hat{r}_k(e)$ are toate elementele nule. În situații reale, chiar la un model identificat corect, este de așteptat să apară valori ale FACR puțin diferite de zero, ca urmare a erorilor de eșantionare și a faptului că se folosesc realizări limitate în timp. Deci, practic este util a determina obiectiv dacă pentru FACR elementele sale sunt sau nu sunt semnificative. În acest scop se apelează la testul t.

- la aplicarea testului t pentru FACR este nevoie de cunoașterea dispersiei coeficienților de autocorelație a reziduurilor. Ea poate fi calculată aproximativ cu formula:

$$S[\hat{r}_k(e)] = \left[1 + \frac{2 \sum_{j=1}^{k-1} [\hat{r}_j(e)]^2}{n} \right]^{1/2} \quad (4.24)$$

iar apoi statistica

$$t_k = \frac{\hat{r}_k(e) - O}{S[\hat{r}_k(e)]} \quad (4.25)$$

- întrucât relația (4.24) poate introduce erori mari, se recomandă și folosirea testului Ljung-Box.
- c) Un alt procedeu de validare a modelului constă în supradimensionarea lui. În modelul care trebuie validat se introduce un nou parametru. Se urmărește apoi dacă modelul extins este mai adecvat procesului în cauză.
Evident, este posibilă și alternativa reducerii numărului de parametri ai modelului în același mod.
- d) O altă posibilitate de validare a modelului procesului constă în divizarea seriei de timp în submulțimi de date și identificarea a câte unui model pentru fiecare submulțime. Dacă modelele stabilite în acest mod nu diferă semnificativ între ele și față de modelul seriei complete, fapt verificat cu ajutorul unui test statistic adecvat, atunci pe de o parte procesul analizat nu-și modifică în timp caracteristicile sale, iar pe de altă parte modelele stabilite sunt relevante pentru procesul stocastic analizat. Dacă între modelele identificate pe submulțimi de date există diferențe sensibile, atunci există două posibilități ce trebuie analizate: fie procesul de identificare a eșuat și trebuie reluat pentru ca prin corecții potrivite să se ajungă la rezultatul dorit, fie modelele sunt corecte, dar procesul stocastic este variant în timp.
- e) Faza a treia de validare-diagnoză trebuie să se finalizeze fie printr-o concluzie clară de acceptare a modelului, fie prin recomandări de reformulare a modelului. Recomandările se referă de regulă la: modele extinse sau reduse, schimbarea structurii modelului prin reanalizarea FAC și FACP, substituirea modelului reziduurilor în modelul original, forma realizării $y_1(t)$ etc.

4.7.3. Prognoza seriilor de timp [4.1.], [4.4.], [4.27.]

Prognoza seriei de timp folosind modelul general ARMA de forma (4.15) presupune obținerea valorilor viitoare ale seriei de timp $y(t+l)$ cu $l \geq 1$.

Momentul t reprezintă originea predicției, l este orizontul de prognoză, iar $(t-k)$ este momentul anterior situat la k intervale de timp; totul exprimat în numere întregi, multipli ai perioadei de eșantionare T .

O observație oarecare, notată cu $y(t+l)$, generată de procesul ARMA, poate fi exprimată sub trei forme și anume:

- 1) Ecuație recursivă cu diferențe, obținută direct din relația (4.15) în care timpul curent t devine $(t+l)$, adică:

$$y(t+l) = - \sum_{i=1}^{n_a} a_i * y(t+l-i) + \sum_{i=0}^{n_b} b_i * \varepsilon(t+l-k-i) \quad (4.26)$$

- 2) Suma ponderată infinită a valorilor curente și anterioare ale zgomotului din intrare, adică:

$$y(t+l) = \sum_{i=0}^{\infty} \psi_i * \varepsilon(t+l-k-i) \quad (4.27)$$

unde ψ_i reprezintă ponderea zgomotului anterior cu i intervale față de orizontul prognozei, iar $\psi_0 = 1$. Coeficienții de pondere ψ_i se determină din rezolvarea sistemului de ecuații care rezultă din identitatea:

$$A(q^{-1}) * \sum_{i=0}^{\infty} \psi_i * q^{-i} = B(q^{-1}) \quad (4.28)$$

3) Suma ponderată infinită a observațiilor anterioare plus zgomotul de intrare din momentul prognozei, adică:

$$y(t+l) = \sum_{i=0}^{\infty} \psi_{l+i} * \varepsilon(t-k-i) = \sum_{j=l}^{\infty} \tilde{\psi}_j * \varepsilon(t+l-k-j) \quad (4.29)$$

unde ponderile $\tilde{\psi}$ urmează a fi determinate în continuare.

Eroarea medie pătratică a prognozei este:

$$E \left[y(t+l) - \hat{y}(t+l) \right]^2 = \left(1 + \sum_{i=1}^{l-1} \psi_i^2 \right) * \sigma_a^2 + \sum_{i=0}^{\infty} (\psi_{l+i} - \tilde{\psi}_{l+i})^2 * \sigma_a^2 \quad (4.30)$$

Eroarea este minimă atunci când $\tilde{\psi}_{l+i} = \psi_{l+i}$, ca urmare relația (4.27) devine:

$$\begin{aligned} y(t+l) &= \sum_{i=0}^{l-1} \psi_i * \varepsilon(t+l-k-i) + \sum_{i=l}^{\infty} \psi_i * \varepsilon(t+l-k-i) = \\ &= \sum_{i=0}^{l-1} \psi_i * \varepsilon(t+l-k-i) + \hat{y}(t+l) = e(t+l) + \hat{y}(t+l) \end{aligned} \quad (4.30)$$

unde $e(t+l)$ este eroarea predicției la momentul t .

Estimatorul prezentat mai sus are următoarele proprietăți:

- Valoarea medie a elementului $y(t+l)$, condiționată de valorile seriei până la momentul t este tocmai valoarea prezisă la momentul $(t+l)$:

$$E[y(t+l)] = E[y(t+l) | y(t), y(t+1), \dots] = \hat{y}(t+l) \quad (4.31)$$

- Valoarea prognozată nu este deplasată, deoarece media erorii de predicție condiționată de valorile seriei în cauză, până la momentul t , este nulă, adică:

$$E[e(t+l)] = 0 \quad (4.32)$$

- Dispersia valorii prescrise are expresia:

$$V[e(t+l)] = \left(\sum_{i=0}^{l-1} \psi_i^2 \right) * \sigma_a^2 \quad (4.33)$$

În concluzie, obținerea valorilor prognozate ale seriei se face, cel mai direct folosind ecuația cu diferențe a modelului și ținând cont că:

- termenii $y(t-i)$ ai seriei, corespunzători trecutului, care sunt cunoscuți la momentul t , se înlocuiesc cu valorile corespunzătoare, reale;
- termenii $y(t+i)$ ai seriei, pe perioada viitoare, care nu sunt cunoscuți la momentul t , se înlocuiesc cu valorile corespunzătoare, prescrise la momentul t , $\hat{y}(t+i)$:

- termenii $\varepsilon(t-i)$ ai seriei zgomotelor, pe perioada trecută se determină din relația:

$$\varepsilon(t-i) = y(t-i) - \hat{y}(t-i-1) \quad (4.34)$$

- termenii $\varepsilon(t+i)$ ai seriei zgomotelor, care nu se pot determina în viitor se consideră zero.

Ca urmare, rezultă estimatorul de forma:

$$\begin{aligned} y(t+l|t) = & - \sum_{i=1}^{l-1} a_i * \hat{y}(t+l-i) - \sum_{i=1}^{n_a} a_i * y(t+l-i) + \sum_{i=1}^{n_b} b_i * [y(t+l-k-i)] - \\ & - y(t+l-k-i) \end{aligned} \quad (4.35)$$

4.7.4. Metodă de prognoză a curbilor de sarcină bazată pe folosirea seriilor de timp [4.1.], [4.4.], [4.6.]

Metoda prezentată în cele ce urmează are în vedere următoarele ipoteze:

- Principalele componente ale variației unei curbe de sarcină sunt determinate de modificările factorilor climatici și de intensitatea activității social-economice depuse pe parcursul unei zile. Aceste cauze, firește, așa cum este de așteptat, nu afectează în aceeași măsură toate categoriile de consumatori ;
- Pentru curbele de sarcină ale aceleiași categorii de consumatori și corespunzătoare aceluiași tip de zi, variațiile ciclice cu perioadă de 7 zile nu sunt semnificative;
- Evenimentele aleatoare produc variații relativ mici ale consumului, însă considerarea lor îmbunătățește sensibil calitatea prognozei.

Modelul considerat pentru puterea cerută de sarcină, într-o anumită zi i și la o anumită oră t , cuprinde trei componente importante:

$$P(i,t) = P_{med}(i) + V(i,t) + \varepsilon(i,t) \quad (4.36)$$

- Puterea medie zilnică $P_{med}(i)$, care depinde numai de ziua la care se referă fiind constantă pe parcursul întregii zile. Această putere reprezintă tendințe de variație a curbilor de sarcină pe durata unui an de zile. Pentru prognoza ei se folosește un model condițional, de tip polinom de gradul 1 sau 2, cu o singură variabilă, notată cu x_i și numită factorul climatic. Pentru prognozele obișnuite factorul climatic poate fi considerat chiar temperatura medie a zilei;
- Variația orară a sarcinii $V(i,t)$ reprezintă principala componentă care se modifică pe durata unei zile. Ea depinde de ziua i și ora t la care se referă. Stabilirea ei pentru perioada de timp trecută se face cu relația:

$$V(i,t) = P(i,t) - P_{med}(i,t) \quad (4.37)$$

Valoarea prognozată a variației orare a sarcinii se calculează ca o medie a variabilei $V(i,t)$ pentru un număr de zile trecute, care prezintă aceleași caracteristici ce depind de tipul consumatorului analizat și de ziua în cauză, adică:

$$\hat{V}(i,t) = \frac{1}{M} \sum_{k=i-1-M}^{i-1} V(k,t) \quad (4.38)$$

unde M este numărul de zile anterioare, de același tip (lucrătoare, de sărbătoare, de vară, de iarnă etc):

- Componenta aleatoare sau reziduul curbei de sarcină $\varepsilon(i,t)$ reprezintă variația sarcinii orare cauzată de influența unor factori aleatori. Valoarea sa în trecut poate fi calculată pe baza relației :

$$\varepsilon(i,t) = V(i,t) - \hat{V}(i,t)$$

Componenta aleatoare poate fi prognozată după metodologia Box-Jenkins sau de multe ori, în situații practice, se poate adopta un model autoregresiv de forma:

$$\varepsilon(i,t) = - \sum_{k=i}^m a_k * \varepsilon(i,t-k) \quad (4.39)$$

Ordinul modelului se stabilește în conformitate cu caracteristicile FAC și FACP iar coeficienții modelului a_k se stabilesc cel mai simplu prin metoda celor mai mici pătrate.

4.7.5. Aplicație a metodei prognozei curbelor de sarcină folosind seriile de timp

În cele ce urmează se va prezenta algoritmul programului și rezultatele obținute în activitatea de prognoză a curbei de sarcină la nivelul sistemului energetic național, de către Operatorul Comercial [4.6.].

Așa cum este cunoscut, conform Regulamentului de programare și dispecerizare a sistemului energetic național, Operatorul Comercial stabilește ordinea de merit pentru fiecare interval orar al următoarelor două zile și prețul marginal de sistem corespunzător. Indiferent de reglementările ulterioare asupra prognozelor primite de la furnizori și independent de natura datelor disponibile, pentru stabilirea ordinii de merit și în urma acesteia a prețului marginal de sistem, Operatorul Comercial trebuie să dispună de o prognoză a consumului orar de energie electrică pe 48 ore și în consecință, de serviciul operativ al unui produs software destinat realizării prognozei. În acest scop s-au ales modelele parametrice (vezi figura 4.11.), în domeniul timp, cererile de energie și putere la nivel național încadrându-se din punct de vedere statistic în categoria seriilor de timp. S-au preferat aceste modele și corespunzător metoda amintită, întrucât aceste modele sunt operative și pentru faptul că pot fi dezvoltate atât în baza unui registru larg de date, cât și a unuiia restrâns de date.

Modelul folosit are trei componente: de trend $y(t)$, ciclică (sezonieră) $s(t)$ și aleatoare (reziduală) $\varepsilon(t)$.

Tendința este modelată printr-un polinom de gradul n cu coeficienți a_i și variabila t. adică: $\hat{y}(t) = \sum_{i=0}^n a_i * t^i$. Determinarea coeficienților a_i se efectuează prin metoda celor mai

mici pătrate, minimizând suma: $\sum_{t=1}^N [y(t) - \hat{y}(t)]^2$.

Componenta ciclică exprimă periodicitatea seriei de timp. De menționat că o serie de timp poate avea mai multe componente ciclice. Pentru o perioadă s determinată, $s = 2, 3, \dots, N/2$, se modelează $s(t)$ prin coeficienții sezonieri Y_k , reprezentând mediile termenilor omologi (de rang k, k+1, ..., s), în cadrul eșantionelor succesive de lungime egală cu perioada s, determinate pe eșantionul disponibil, de lungime N:

$$Y_k = \frac{1}{m} \sum_{i=1}^m y((t-1)s + k) \text{ unde } m = [N/s]$$

Componenta aleatoare este însăși abaterea realizării disponibile ca serie de valori reale de la modelul construit până în acest punct. Procesul de modelare al acestei componente aleatoare este un proces de autoregresie – medie alunecătoare – ARMA: $A(q^{-1}) * y(t) = B(q^{-1}) * \varepsilon(t)$, unde determinarea coeficienților se efectuează prin minimizarea unui criteriu pătratic, de forma:

$$\{ \hat{a}_i, \hat{b}_j \} = \arg \min_{(a_i, b_j)} \sum_{t=1}^N \left[\frac{A(q^{-1})}{B(q^{-1})} y(t) \right]^2$$

Etapile algoritmului de prognoză sunt prezentate sintetic în figura 4.12.

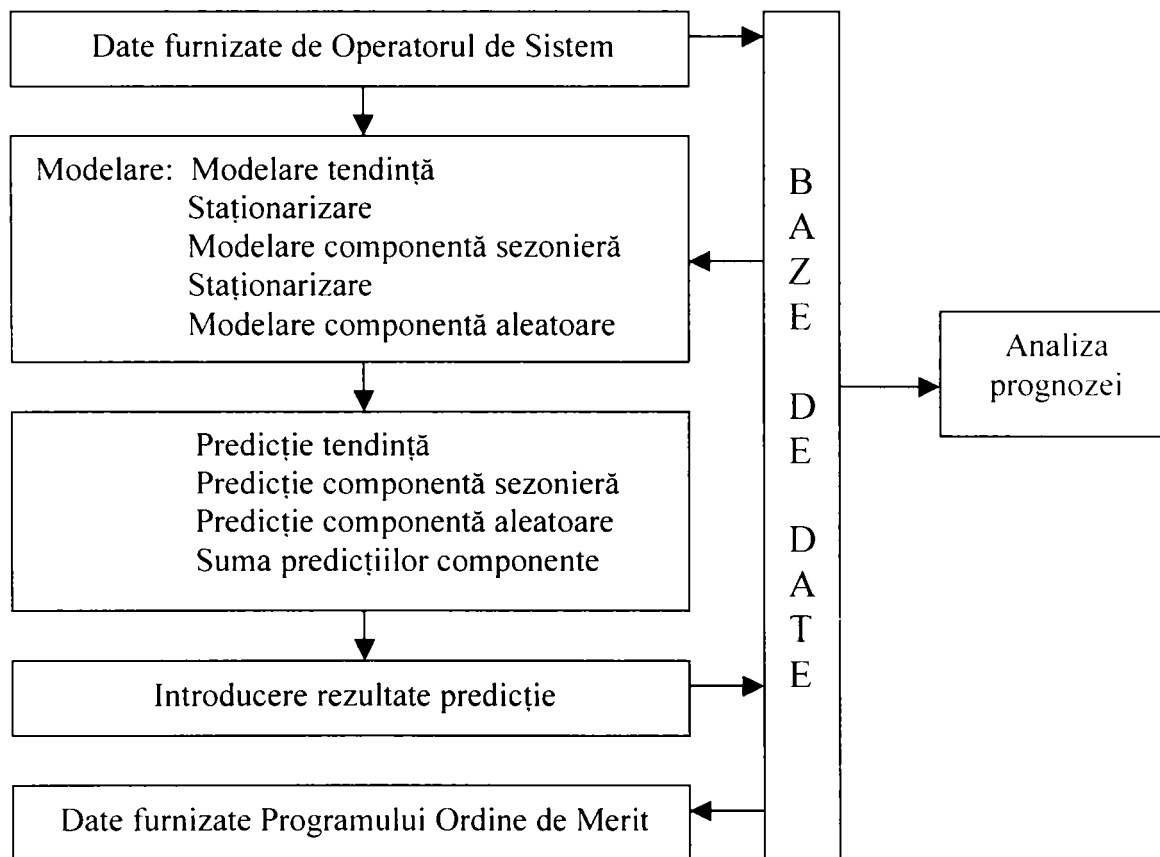


Figura 4.12. Algoritmul programului de prognoză

Criteriile utilizate pentru aprecierea calității prognozei au fost: eroarea relativă procentuală, deviația (abaterea) standard procentuală, deviația (abaterea) standard în unități absolute, deviația maximă/interval, procentuală, deviația maximă/interval în unități absolute.

Rezultatele obținute în luna februarie a anului 2000 sunt prezentate în tabelul 4.1.

Din analiza celor prezentate în tabelul 4.1. se constată că în proporție de 97 % valoarea deviației pe intervalul orar se situează sub 5 %, în timp ce eroarea relativă procentuală este de 1.684 %.

4.8. Concluzii

Prezentul capitol și-a propus să treacă în revistă problemele pe care le comportă prognoza curbelor de sarcină evidențiind pe de o parte utilitatea și importanța acestora, pe de altă parte complexitatea procesului de prognoză, în cadrul căruia rolul important îl deține modelarea matematică.

În acest sens au fost prezentate în prima parte problemele teoretice legate de curbele de sarcină: definiții, clasificări, terminologie, modul de obținere a curbelor de sarcină, mărimi caracteristice.

În cadrul clasificării s-a dorit a se sublinia diversificarea curbelor de sarcină, locul diferit în cadrul sistemului electroenergetic unde acestea pot fi studiate. Un element deloc de neglijat este modul de obținere a acestor curbe de sarcină, rolul deosebit revenind firește, măsurătorilor. În cadrul acestora, în ultima vreme, un rol important îl dețin contoarele de energie: electronice și digitale, precum și sistemele de achiziție și prelucrare. Introducerea sistemelor de achiziții și prelucrări de date conduc la o nouă filozofie de abordare a tuturor problemelor legate de concepția, proiectarea și exploatarea sistemului electroenergetic și aceasta ca urmare a multitudinii de informații, precum și a calității acestora.

Legat de mărimile caracteristice ale curbelor de sarcină, o atenție sporită s-a acordat timpului de pierdere. Cu această ocazie au fost trecute în revistă o serie întregă de relații utile la calculul acestuia.

Modelarea curbelor de sarcină este foarte importantă în procesul de prognoză iar abordarea ei trebuie efectuată din considerente statistice. Se arată că de fapt curba de sarcină este un ansamblu de două caracteristici distincte și complementare: una de formă, ce reflectă modularea relativă a puterilor consumate și alta de nivel, ce ține cont de cantitatea de energie electrică consumată într-un anumit interval de timp. Clasificarea curbelor de sarcină trebuie să se efectueze după coeficientul de variație ce reunește proprietățile a două mărimi importante: dispersia și valoarea medie, respectiv coeficientul de corelație.

Metodele de prognoză pot fi împărțite în două mari categorii și anume clasice și moderne. Din rândul celor clasice se detașează net metoda seriilor de timp, iar din categoria celor moderne cele care apelează la tehnicile inteligenței automate. Modelele folosite în cadrul metodelor seriilor de timp pot fi: liniare sau neliniare, continue sau discrete, monovariabile sau multivariabile, în domeniul timp sau transpuse în domeniul frecvență. În domeniul timp, foarte utilizat este modelul cunoscut sub denumirea de autoregresiv cu mediile alunecătoare – ARMA, acest model asigură de fapt structura de bază pentru procesul stocastic staționar.

Esențial însă în demararea procesului de prognoză (previziune) prin această tehnică este identificarea seriei de timp. De aceea în capitolul prezentat s-a trecut în revistă și sunt comentate etapele de identificare și validare. Dintre aceste etape se remarcă aceea de validare-diagnoză a modelului, care presupune independența reziduurilor. Modelul ARIMA nu poate fi realizat decât numai în condițiile independenței totale (toți coeficienții parțiali de corelație nuli). Pentru stabilirea acestor condiții este utilă aplicarea testului "t" care presupune cunoașterea dispersiei coeficienților de autocorelație a reziduurilor și statistica t_k .

În încheierea capitolului se descrie principal metoda efectivă de prognoză a curbelor de sarcină bazată pe folosirea seriilor de timp și se prezintă aplicația efectuată la nivelul curbei de sarcină a sistemului electroenergetic de către Operatorul Comercial.

Contribuția personală se referă la prelucrarea unui volum foarte mare de informații, sistematizarea și prezentarea într-o formă coerentă și etapizată.

Tabelul 4.1. Analiza rezultatelor prognozei puterilor orare absorbite la nivelul sistemului electroenergetic în luna februarie 2000

Interval prognoză 48 h	01.02	02.03	03.04	04.05	05.06	06.07	07.08	08.09	09.10	10.11	11.12	12.13	13.14	14.15
Eroare relativă procentuală (%)	1,42	1,76	1,25	1,56	1,66	2,11	2,21	1,43	1,28	1,79	1,46	1,18	1,33	1,59
Deviația standard (%)	1,91	2,3	1,52	1,84	1,97	2,66	2,86	1,81	1,72	2,34	2	1,58	1,57	2,05
Deviația standard (MW)	129	157	104	119	121	163	183	119	114	158	134	96	97	140
Deviația maximă pe interval 48 ore (%)	5,46	6,69	3,98	4,05	-4,7	7,13	8,43	5,18	6,24	6,63	6	5,09	4,23	7,6
Deviația maximă pe interval 48 ore (MW)	374	458	275	280	-293	471	558	349	416	442	396	323	252	506
Zi principală	M	M	J	V	S	D	L	M	M	J	V	S	D	L
Deviația maximă pe zi principală %	5,46	2,31	3,98	4,03	4,6	7,13	5,41	-3,3	6,24	5,85	4,28	5,01	-3,11	7,59
Nr. intervale orare în ziua principală cu deviație >5%	1	0	0	0	0	3	1	0	1	1	0	1	0	1

Tabelul 4.1. Analiza rezultatelor prognozei puterilor orare absorbite la nivelul sistemului electroenergetic în luna februarie 2000 (continuare)

Interval prognoză 48 h	15.16	16.17	17.18	18.19	19.20	20.21	21.22	22.23	23.24	24.25	25.26	26.27	27.28	28.29
Eroare relativă procentuală (%)	3,58	2,7	1,88	1,7	0,93	1,49	1,2	1,71	1,97	1,31	1,55	2,26	2,15	2,38
Deviația standard (%)	3,78	2,91	2,32	2,35	1,29	1,76	1,64	2,1	2,27	1,71	2,05	2,74	2,75	3,11
Deviația standard (MW)	252	193	155	163	81	107	118	151	159	114	129,6	164	166,7	204,7
Deviația maximă pe interval 48 ore (%)	-5,57	-4,45	5,1	-5,54	4,73	4,2	-4,67	-5,01	-3,9	-4,85	6,16	6,49	-6,9	8,25
Deviația maximă pe interval 48 ore (MW)	-376	-309	-304	-423	294	254	-348	-376	-289	-289	380	400	-449	205
Zi principală	M	M	J	V	S	D	L	M	M	J	V	S	D	L
Deviația maximă pe zi principală %	-5,55	-4,43	5,1	4,16	-3,2	2,61	-4,67	-3,11	-3,9	-4,85	6,16	5,84	-6,9	7,35
Nr. intervale orare în ziua principală cu deviație > 5%	3	0	1	0	0	0	0	0	0	0	1	1	2	4

BIBLIOGRAFIE

- 4.1. LUȘTREA.B - Prognoza consumului de energie. Editura AGIR. București 2001;
- 4.2. GEORGESCU.G.,RĂDĂȘANU.D. - Transprtul și distribuția energiei electrice. vol.1. Editura Gh. Asachi, Iași 2000;
- 4.3. BUTA. A. - Energetică generală și conversia energiei. Litografia I.P. Timișoara 1982;
- 4.4. STOICA P., TERTIȘCO M., POPESCU TH. - Modelarea și predicția seriilor de timp. Ed.Tehnică, București, 1984;
- 4.5. STOICA P, TERTIȘCO M. - Identificarea și estimarea parametrilor sistemelor. Ed. Tehnică, București, 1984;
- 4.6. IONESCU V., VASILEVSCHI C., DRUMEANU C., PALADE L. - Prognoza consumurilor energetice. Raport de studiu, Energetica, 48, 2000, nr.14. pp.489-493;
- 4.7. BUTA A, STOIAN A, PANA A, BUCATARIU IL. - Forecasting of hourly powers by load curve decomposition in Fourier series. Buletinul Științific al Univ."Politehnica" Timișoara. seria Energetica, tom 46(60) fasc 1-2, 2001. pp 51-56;
- 4.8. BUNN D.W - Forecasting loads and price in competitive power market, Proc.of IEEE, vol.88, no.2. Febr.2000. pp.163-169;
- 4.9. BOX G.E, JENKINS G.M. - Time series analysis forecasting and control. Holden- Day, 1976;
- 4.10. IONESCU T.G, POP OLGA - Ingineria sistemelor de distribuție a energiei electrice, Editura Tehnică, București 1998;
- 4.11. IONESCU T.G, NEAGOE M. - Evaluarea sarcinilor electrice de calcul în rețelele electrice de distribuție, Energetica, tom 33. 1985. nr.6, pp.252-262;
- 4.12. IONESCU T.G. - Stabilirea pe bază de măsurători a consumurilor de putere și energie electrică și a indicatorilor specifici graficelor de sarcină a consumatorilor casnici din mediul urban, Energetica, tom 31. 1983, nr.6, pp. 257-261;
- 4.13. CODIASSE A.M., GUILLEVICH M.GIRAUD D. - Connaissance des charges moyenne tension en vue de leur prise en compte dans les etudes de planification, RGE, nr.7-8, 1982, PP.518-527;
- 4.14. CANAL M, FIEUX H, LANDRY M - Le systeme informatique de gestion des ouvrages BT; calcul des charges appeleés par les reseaux basse tension, RGE, nr.2, 1984, pp.101-108;
- 4.15. MESEA N, BAZACLIU G, DUMBRAVA V. - Calculul pierderilor de energie pe baza curbelor de sarcină relative, SNRE 98, Pitești vol.1. pp.249-255;
- 4.16. ALBERT HERMINA, VATRA F, POIDA ANA - Gestiunea energiei electrice în FDEE. Concept-sistem informatic, SNRE 98, Pitești, vol I. pp.240-248;
- 4.17. SUFLEȚEL N, BRUMĂ N, DUMITROAIA C, LUCA D. - Contribuții la analiza pierderilor de putere și energie electrică în rețelele electrice de joasă tensiune din mediul rural utilizând grafice tip de sarcină, SNRE 98, Pitești, vol.1, pp.262-271;
- 4.18. GAVRILAȘ M, GEORGESCU G, - Clasificarea consumatorilor și identificarea

- RĂDĂȘAN D
- structurii de consum din nodurile rețelelor de distribuție folosind principiul autoorganizării, SNRE 1998, Pitești, vol.I, pp.282-289;
- 4.19. DUMBRAVĂ V, MESEA N, BAZACLIU G. - Metodă și program de calcul pentru analiza curbelor de sarcină la consumatori, SNRE 1998, Pitești, vol.I, pp. 383-390;
- 4.20. JARDINI J.A, TAHAN M.V., GOUVERA M.R.,SE.UN.AHN, FIGUEIRE- DO,F,M, - Daily Load profiles for residential, comercial and industrial low voltage consumers, IEEE Trans on Power Delivery vol.15, no.1, Jan.2000, pp.375-379;
- 4.21. JARDINI J.A., TAHAN C.M. V.S.U, AHN, FERRARI E.L - Distribution transformer loading. Evaluation based on load profiles measurement IEEE Power, paper PE-368-PWRD-0-11-1996;
- 4.22. GEORGESCU G. - Contribuții la modelarea matematică a dezvoltării rețelelor electrice urbane, teză de doctorat, Institutul Politehnic Iași 1983;
- 4.23. AMJADY N. - Short-term hourly load forecasting using time-series modeling with peak load estimation capability IEEE Transactions on Power Systems, vol. 16, no.3, August, pp.498-504;
- 4.24. VEMURI S, HUANG W.L., NELSON D.J. - On line algorithms for forecasting hourly loads of an electric utility, IEEE Trans.Power Append Systems, vol.PAS-100, aug.1981, pp.3775-3784;
- 4.25. MOGHARAM T., RAHMAN S - Analysis and evaluation of fire short term load forecasting techniques, IEEE Trans.Power Systems, vol.5, no.4, Nov.1989, pp. 1484-1491;
- 4.26. MESLIER F - New advances in short term load forecasting using Box and Jenkins approach. IEEE/PES Winter Meeting, 1978, paper AO 51-5;
- 4.27. HONG-TZER YANG, CHAO-MING, HUANG - A new short-term load forecasting approach using self-organizing fuzzy ARMAX models, IEEE Trans on power Systems, vol.13, no.1, February 1998, pp.217-225;
- 4.28. 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, no.1, February 1996, pp.403-408;
- 4.29. RAHMAN S, BHATNA GAR R - An expert system based algorithm for short term load forecast, IEEE Trans.Power Systems, vol. 3, no.2, May, 1988, pp 392-399;
- 4.30. STOIAN A., BUTA A, COLBAN S - Prognoza curbei săptămânale a puterilor medii zilnice folosind descompunerea spectrală; Simpozion internațional de Eficiență Energetică, Cluj Napoca, oct.2002;
- 4.31. STOIAN A, BUTA A, COLBAN S - Program pentru prognoza energiei și puterii pe termen scurt – PRENPS, Simpozionul internațional de Eficiență Energetică, Cluj Napoca, oct.2002;

TEHNICI DE PROGNOZĂ A CONSUMULUI DE ENERGIE
ELECTRICĂ ȘI A CURBELOR DE SARCINĂ

5.1. Serii Fourier. Probleme generale [5.1.], [5.2.]

Seriile de funcții $\sum_{k=0}^{\infty} f_k(x)$ în care termenul general este de forma

$f(x) = a_k \cos kx + b_k \sin kx$ cu coeficienți constanți a_k și b_k , se numesc serii trigonometrice. Dacă aceste serii converg într-un interval de lungime 2π , atunci funcțiile trigonometrice, fiind periodice, converg pentru orice x și reprezintă o funcție periodică $f(x)$. Dacă seria converge uniform atunci suma ei $f(x)$ este continuă, iar în acest caz, se poate stabili o legătură între coeficienții a_k , b_k și funcția $f(x)$. Înmulțind funcția :

$$f(x) = \sum_{k=0}^{\infty} f_k(x) = \sum_{k=0}^{\infty} (a_k \cos kx + b_k \sin kx)$$

cu factorii mărginiți $\cos px$ sau $\sin px$, unde p este un întreg nenegativ, convergența seriei nu se alterează, astfel încât este posibil să se calculeze integralele:

$$\int_0^{2\pi} f(x) \cos pxdx \quad \text{și} \quad \int_0^{2\pi} f(x) \sin pxdx$$

prin integrarea termen cu termen a seriilor $\sum f_k(x) \cos px$ și $\sum f_k(x) \sin px$. Aceste operații de integrare comportă integrarea în intervalul $(0, 2\pi)$ a funcțiilor $\cos kx \cos px$, $\sin kx \cos px$, $\cos kx \sin px$, $\sin kx \sin px$.

Integrând prin părți se constată ușor că aceste integrale au valoarea 0 pentru $k \neq p$ iar pentru $k = p$:

$$\int_0^{2\pi} \cos^2 kxdx = \int_0^{2\pi} \sin^2 kxdx = \pi \quad \text{pentru } k > 0$$

și

$$\int_0^{2\pi} \cos^2 kxdx = 2\pi, \quad \int_0^{2\pi} \sin^2 kxdx = 0 \quad \text{pentru } k = 0$$

Ca urmare, se justifică scrierea adaptată pentru seriile trigonometrice și anume:

$$f(x) = \frac{a_0}{2} + \sum_{k=1}^{\infty} (a_k \cos kx + b_k \sin kx) \tag{5.1}$$

unde coeficienții sunt calculați cu formulele lui Euler-Fourier:

$$a_0 = \frac{1}{2\pi} \int_0^{2\pi} f(x) dx; \quad a_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \cos kxdx; \quad b_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \sin kxdx \tag{5.2}$$

Desigur, pentru tehnică se impune întrebarea: ce fel de funcții pot fi reprezentate prin serii trigonometrice? S-ar părea că este necesar ca $f(x)$ să fie integrabilă, pentru a folosi formulele Euler-Fourier, iar apoi, pentru calculul coeficienților a_k și b_k , se poate scrie seria (5.1). **Aceasta este seria Fourier a funcției $f(x)$ iar a_k și b_k sunt coeficienții Fourier ai funcției $f(x)$.**

Se poate întâmpla ca seria Fourier a funcției $f(x)$ să nu fie convergentă, sau să convergă, dar suma ei să fie alta decât $f(x)$; acest lucru se poate întâmpla chiar dacă $f(x)$ este continuă. Cu toate acestea se poate afirma cu certitudine că, dacă seria Fourier a unei funcții continue $f(x)$ este uniform continuă, atunci suma ei trebuie să fie $f(x)$ iar $f(x)$ nu mai admite altă reprezentare printr-o serie trigonometrică uniform convergentă. Această condiție este numai suficientă, problema găsirii unor condiții necesare și suficiente pentru convergența seriei Fourier a funcției $f(x)$ nu este încă complet rezolvată.

Întrucât termenii $f_k(x)$ ai seriei Fourier sunt funcții periodice de perioadă 2π , funcția sumă este de asemenea o funcție periodică de perioadă 2π . Dacă $f(x)$ este suma seriei atunci se poate scrie:

$$f(x + 2\pi) = f(x) \quad (5.3)$$

Deci, dezvoltarea în serii Fourier are sens pentru funcții periodice cu perioada 2π . În cazul în care funcția este periodică de perioadă $2w$, atunci variabila x se înlocuiește prin variabila $\pi x/w$.

Totuși întrebarea care se pune este cum trebuie să fie o funcție pentru ca să admită o dezvoltare în serie Fourier? Condițiile pe care trebuie să le îndeplinească aceasta nu sunt încă complet cunoscute. Se cunosc spre exemplu funcții continue care nu pot fi reprezentate în serie Fourier. Dar, există o funcție continuă care nu este derivabilă în nici un punct și care admite totuși o reprezentare în serie Fourier uniform convergentă. Este vorba de funcția lui

Weierstrass $(\sum_{k=1}^{\infty} a^k \cos[b^k \pi x], a \in (0,1); b > 0, \text{întreg iar } ab > 1 + 3\pi/2)$.

Dirichlet a arătat că dacă intervalul $x \in (0, 2\pi)$ se poate descompune într-un număr finit de subintervale și $f(x)$ este în fiecare din aceste intervale continuă și monotonă, atunci $f(x)$ admite o reprezentare în serie Fourier, coeficienții Fourier se determină prin relațiile (5.2)

Condiția lui Dirichlet este îndeplinită de o clasă foarte largă de funcții $f(x)$ și este pe deplin satisfăcătoare în situațiile practice. Totuși în cazul unor funcții discontinue în punctul x_0 , adică în limite laterale diferite dar finite $(\lim_{t \rightarrow 0} f[x_0 + t] \neq \lim_{t \rightarrow 0} f[x_0 - t])$, este necesar ca în

acest punct să se considere:

$$f(x_0) = \frac{1}{2} (\lim_{t \rightarrow 0} f[x_0 + t] + \lim_{t \rightarrow 0} f[x_0 - t]) \quad (5.4)$$

Ca urmare, valoarea seriei Fourier coincide cu valoarea funcției în orice punct al intervalului de definiție.

În domeniul tehnic, pentru studiul proceselor periodice se folosește analiza armonică. Aceasta constă în determinarea coeficienților Fourier a_k și b_k , k având o valoare limitată, N .

Problema care se pune este aceea de a găsi cea mai bună aproximare a unei funcții periodice $f(x)$ printr-o sumă finită $\Phi_N(x)$ de funcții sinus și cosinus, adică:

$$\Phi_N(x) = \sum_{j=0}^N (a_j \cos jx + b_j \sin jx)$$

Soluționarea se poate efectua apelând la metoda celor mai mici pătrate punând condiția ca:

$$[f(x) - \Phi_N(x)]^2 = \min \quad (5.5)$$

Minimul expresiei (5.5.) se atinge atunci când coeficienții a_j și b_j sunt tocmai coeficienții Fourier ai funcției $f(x)$. Această constatare este foarte utilă pentru domeniul tehnic, stând la baza multor aplicații ale seriilor Fourier. Cu cât valoarea minimului expresiei (5.5) este mai redusă, cu atât și aproximarea este mai bună.

În ceea ce privește numărul armonicilor luate în considerare, adică N , s-ar părea la prima vedere că un N suficient de mare asigură o precizie suficient de bună a aproximării. În realitate coeficienții a_k și b_k se determină numeric, fiind necesară considerarea unui număr finit de puncte din graficul funcției $f(x)$. Schanann a aratat că este necesar ca $N \leq NI/2$, [5.3.], NI fiind numărul de puncte considerat din graficul funcției $f(x)$.

5.2. Descompunerea curbelor de sarcină în serii Fourier

Dacă curbele de sarcină ale puterilor într-un nod al unui sistem electroenergetic satisfac condițiile Dirichlet, atunci puterea activă (și reactivă) absorbită în acel nod poate fi exprimată sub forma [5.4.-5.7.]:

$$P(t) = P_m + \sum_{k=1}^N a_k \sin(k\omega t) + \sum_{k=1}^N b_k \cos(k\omega t) \quad (5.6)$$

unde:

N - numărul de armonici luate în considerare;

a_k, b_k - coeficienții Fourier ai armonicii de rang k , calculați cu relațiile (5.2), care în această situație primesc forma:

$$a_k = \frac{2}{T} \int_0^T P(t) \sin(k\omega t) dt ; \quad b_k = \frac{2}{T} \int_0^T P(t) \cos(k\omega t) dt ; \quad (5.7)$$

T - intervalul pe care se efectuează descompunerea, corespunde celor 24 ore, adică unei zile;

P_m - puterea medie (componenta continuă a curbei de putere), se calculează cu relația:

$$P_m = \frac{1}{T} \int_0^T P(t) dt \quad (5.8)$$

Dacă curba de sarcină se discreditează în NI intervale egale (de regula $NI = 24$) numărul acestora fiind pus în concordanță cu pretențiile operatorului de sistem pe de o parte [5.8], [5.9], dar și cu posibilitățile pe care le oferă sistemul de achiziție al datelor prelevate de contoarele digitale [5.10], atunci puterea activă P devine o funcție a numărului de intervale n , adică $P = P(n)$ și se poate scrie:

$$P(n) = P_m + \sum_{k=1}^N a_k \sin \frac{2k\pi n}{NI} + \sum_{k=1}^N b_k \cos \frac{2k\pi n}{NI} \quad (5.9)$$

iar

$$P_m = \frac{1}{NI} \sum_{n=1}^{NI} P(n)$$

Coeficienții Fourier se calculează cu relațiile (5.10):

$$a_k = \frac{2}{NI} \sum_{n=1}^{NI} P(n) \sin \left(\frac{2\pi k}{NI} n \right) \quad \text{și} \quad b_k = \frac{2}{NI} \sum_{n=1}^{NI} P(n) \cos \left(\frac{2\pi k}{NI} n \right) \quad (5.10)$$

În legătură cu descompunerea curbelor de sarcină, de fapt cu calculul coeficienților Fourier, se pun două probleme și anume:

- câte intervale trebuie considerate din curba de sarcină, 12; 24; 48; 96, știut fiind faptul că, contoarele electronice folosite în stațiile principale ale sistemului oferă valori medii la intervale de 15 minute;
- ce număr minim (de perechi) de coeficienți (armonici) trebuie luat în considerare pentru a asigura o precizie corespunzătoare la aproximarea curbei de sarcină.

5.2.1. Stabilirea numărului de intervale din curba de sarcină

Problema stabilirii numărului de intervale din curba de sarcină se rezumă, de fapt, la a stabili pasul (palierul) de discreditare al curbei de sarcină. Acesta depinde de forma curbei de sarcină și în primul rând de gradul ei de neuniformitate. Pentru aceasta s-au efectuat un număr mare de determinări, parte din acestea fiind prezentate în [5.11.], [5.12.].

Baza de date s-a constituit din înregistrările pe sfert de oră ale contoarelor electronice montate pe AT-urile din Stația Moșnița Timișoara. Datele au fost colectate pe o perioadă de trei ani consecutivi: 1999, 2000 și 2001. Corespunzător acestei perioade, s-au înregistrat și temperaturile zilnice: t_{\min} , t_{med} și t_{\max} . Spre exemplu pentru curba de sarcină aferentă autotransformatorului AT₁ din stația Moșnița - Timișoara, pentru zilele Luni, Marți și Duminică, perioada 4 - 11.01.1999, coeficienții seriei Fourier a_{1-10} , b_{1-10} , considerandu-se trepte de 1/4 h; 1/2 h; 1 h, 2 h, sunt prezentați în tabelul 5.1.

Tabelul 5.1. Valorile coeficienților seriei Fourier pentru diferite paliere ale curbelor de sarcină: a) Luni 4.01.1999; b) Marți 5.01.1999; c) Duminică 10.01.1999.

a)

k	T = 1/4 h		T = 1/2 h		T = 1h		T = 2h	
	A _k	B _k	A _k	B _k	A _k	B _k	A _k	B _k
1	-0,257	0,303	-0,257	0,302	-0,256	0,301	-0,252	0,296
2	-0,208	0,069	-0,207	0,065	-0,204	0,064	-0,190	0,060
3	$-4,4 \cdot 10^{-3}$	-0,015	$-4,64 \cdot 10^{-3}$	-0,015	$-4,589 \cdot 10^{-3}$	-0,014	$-9,209 \cdot 10^{-3}$	-0,011
4	0,052	$-9 \cdot 10^{-3}$	0,051	$-8,791 \cdot 10^{-3}$	0,048	$-7,704 \cdot 10^{-3}$	0,029	$-5,919 \cdot 10^{-3}$
5	-0,028	0,032	-0,028	0,032	-0,026	0,028	$-9,123 \cdot 10^{-3}$	0,017
6	-0,022	$-5,067 \cdot 10^{-3}$	-0,022	$-4,913 \cdot 10^{-3}$	-0,019	$-3,849 \cdot 10^{-3}$	-0,014	$5,985 \cdot 10^{-3}$
7	0,015	-0,012	0,014	-0,012	0,011	$-9,055 \cdot 10^{-3}$	-0,013	$-3,781 \cdot 10^{-3}$
8	$-8,48 \cdot 10^{-3}$	$9,99 \cdot 10^{-3}$	$-8,34 \cdot 10^{-3}$	$9,436 \cdot 10^{-3}$	$-8,794 \cdot 10^{-3}$	$9,19 \cdot 10^{-3}$	0,012	$-8,28 \cdot 10^{-3}$
9	-0,014	$8,38 \cdot 10^{-3}$	-0,014	$7,776 \cdot 10^{-3}$	-0,011	$5,75 \cdot 10^{-3}$	$3,372 \cdot 10^{-4}$	$4,678 \cdot 10^{-3}$
10	$3,79 \cdot 10^{-3}$	$1,766 \cdot 10^{-3}$	$3,649 \cdot 10^{-3}$	$1,275 \cdot 10^{-3}$	$1,259 \cdot 10^{-3}$	$-9,379 \cdot 10^{-4}$	-0,035	0,018

b)

1	-0,242	0,304	-0,242	0,303	-0,241	0,302	-0,236	0,297
2	-0,218	0,072	-0,217	0,072	-0,213	0,071	-0,199	0,067
3	0,010	$-5,522 \cdot 10^{-3}$	0,010	$-5,404 \cdot 10^{-3}$	$9,736 \cdot 10^{-3}$	$-5,839 \cdot 10^{-3}$	$2,388 \cdot 10^{-3}$	$-6,901 \cdot 10^{-3}$
4	0,057	$-2,793 \cdot 10^{-3}$	0,056	$-2,639 \cdot 10^{-3}$	0,051	$-2,737 \cdot 10^{-3}$	0,037	$-5,919 \cdot 10^{-3}$
5	-0,024	0,023	-0,023	0,023	-0,022	0,021	$-5,677 \cdot 10^{-3}$	0,016
6	$-6,96 \cdot 10^{-3}$	$-2,368 \cdot 10^{-4}$	$-6,711 \cdot 10^{-3}$	$-3,588 \cdot 10^{-4}$	$-6,209 \cdot 10^{-3}$	$-1,064 \cdot 10^{-4}$	$-5,262 \cdot 10^{-3}$	$2,18 \cdot 10^{-3}$
7	0,01	-0,022	$9,499 \cdot 10^{-3}$	-0,021	$6,924 \cdot 10^{-3}$	-0,015	-0,011	$-5,17 \cdot 10^{-3}$
8	$1,865 \cdot 10^{-3}$	$6,065 \cdot 10^{-3}$	$2,062 \cdot 10^{-3}$	$5,707 \cdot 10^{-3}$	$3,563 \cdot 10^{-3}$	$6,434 \cdot 10^{-3}$	0,015	-0,011
9	-0,011	0,017	-0,011	0,015	$-6,447 \cdot 10^{-3}$	0,013	$2,189 \cdot 10^{-3}$	$1,064 \cdot 10^{-3}$
10	$-2,561 \cdot 10^{-3}$	$-1,9 \cdot 10^{-3}$	$-2,156 \cdot 10^{-3}$	$-1,179 \cdot 10^{-3}$	$-7,748 \cdot 10^{-4}$	$-3,199 \cdot 10^{-3}$	-0,038	0,019

c)

1	-0,251	$4,896 \cdot 10^{-3}$	-0,251	$-4,922 \cdot 10^{-3}$	-0,25	$4,964 \cdot 10^{-3}$	-0,245	$4,888 \cdot 10^{-3}$
2	-0,149	0,045	-0,148	0,045	-0,145	0,044	-0,135	0,04
3	0,024	0,047	0,024	0,047	0,023	0,045	0,019	0,037
4	$8,553 \cdot 10^{-3}$	$-4,566 \cdot 10^{-3}$	$8,667 \cdot 10^{-3}$	$-4,558 \cdot 10^{-3}$	$8,551 \cdot 10^{-3}$	$-4,614 \cdot 10^{-3}$	$6,956 \cdot 10^{-3}$	$-1,942 \cdot 10^{-3}$
5	$-8,172 \cdot 10^{-3}$	$-4,459 \cdot 10^{-3}$	$-7,864 \cdot 10^{-3}$	$-4,343 \cdot 10^{-3}$	$-5,67 \cdot 10^{-3}$	$-3,729 \cdot 10^{-3}$	$1,05 \cdot 10^{-3}$	$-1,535 \cdot 10^{-3}$
6	$-5,929 \cdot 10^{-4}$	0,016	$-2,836 \cdot 10^{-4}$	0,016	$1,45 \cdot 10^{-4}$	0,0120	$-4,2 \cdot 10^{-3}$	$1,742 \cdot 10^{-3}$
7	$6,701 \cdot 10^{-3}$	$-9,675 \cdot 10^{-3}$	$6,295 \cdot 10^{-3}$	$-9,218 \cdot 10^{-3}$	$5,189 \cdot 10^{-3}$	$-7,405 \cdot 10^{-3}$	$1,305 \cdot 10^{-3}$	$2,449 \cdot 10^{-4}$
8	$-3,994 \cdot 10^{-3}$	$-3,234 \cdot 10^{-3}$	$-3,093 \cdot 10^{-3}$	$-3,396 \cdot 10^{-3}$	$-1,38 \cdot 10^{-3}$	$-2,915 \cdot 10^{-3}$	$3,146 \cdot 10^{-3}$	$-1,773 \cdot 10^{-3}$
9	$1,063 \cdot 10^{-3}$	$7,638 \cdot 10^{-3}$	$1,017 \cdot 10^{-3}$	$6,443 \cdot 10^{-3}$	$1,33 \cdot 10^{-3}$	$3,013 \cdot 10^{-3}$	$-4,077 \cdot 10^{-3}$	-0,013
10	$7,2 \cdot 10^{-3}$	$4,72 \cdot 10^{-3}$	$6,452 \cdot 10^{-3}$	$3,801 \cdot 10^{-3}$	$4,333 \cdot 10^{-4}$	$-9,336 \cdot 10^{-5}$	-0,025	0,013

La cele prezentate în tabelul 5.1. trebuie adăugate valorile puterilor medii din aceste zile:
 $P_{m\ 04.01} = 1,582$ u.r.; $P_{m\ 05.01} = 1,652$ u.r.; $P_{m\ 10.01} = 1,323$ u.r.

Corespunzător celor înscrise în tabelul 5.1, în tabelul 5.2 s-au calculat erorile în valoare absolută a coeficienților $a_{1\div 4}$, $b_{1\div 4}$, considerând ca referință palierul de lungime 1/4 h. În tabel s-a notat în dreptul fiecărui coeficient și ponderea pe care o deține în puterea medie zilnică.

Tabelul 5.2. Erorile în valoare absolută [%] comise la calculul coeficienților Fourier $a_{1\div 4}$, $b_{1\div 4}$ considerând paliere de 1/2 h, 1 h, și 2 h și zilele: a) Luni 04.01.1999; b) Marți 05.01.1999 și c) Duminică 10.01.1999.

a)

k	% din P_m		$\Delta T=1/2$ h		$\Delta T=1$ h		$\Delta T=2$ h	
	A_k	B_k	A_k	B_k	A_k	B_k	A_k	B_k
1	16,84	19,15	0	0,33	0,39	0,66	1,95	2,31
2	13,15	4,36	0,48	0,0	1,923	1,538	8,65	7,69
3	0,278	0,948	5,43	0,0	4,248	6,67	109,25	26,67
4	3,28	0,56	1,923	2,32	5,769	14,40	44,23	34,23

b)

k	% din P_m		$\Delta T=1/2$ h		$\Delta T=1$ h		$\Delta T=2$ h	
	A_k	B_k	A_k	B_k	A_k	B_k	A_k	B_k
1	14,65	18,40	0	0,329	0,413	0,658	2,48	2,303
2	13,19	4,36	0,458	0,0	2,29	1,388	4,128	6,94
3	0,605	0,334	0	2,137	2,64	5,740	76,12	24,95
4	3,45	0,169	1,754	5,514	10,526	2,0	35,087	100,04

c)

k	% din P_m		$\Delta T=1/2$ h		$\Delta T=1$ h		$\Delta T=2$ h	
	A_k	B_k	A_k	B_k	A_k	B_k	A_k	B_k
1	18,97	0,37	0	0,531	0,4	1,388	2,39	0,163
2	11,26	3,401	0,671	0	2,68	2,22	9,396	11,11
3	1,814	3,55	0	0	4,166	4,255	20,83	21,276
4	0,646	0,345	1,333	0,175	0,023	1,051	18,67	57,468

Din cele prezentate în tabelul 5.1, dar mai ales în 5.2 rezultă următoarele:

* valoarea coeficienților calculați variază în limite foarte largi, de la cca 0,1% până la 20% din puterea medie, deci participarea lor la sinteza curbei de putere este foarte

diferită: totuși, rolul hotărâtor, alături de puterea medie, îl au coeficienții de rang 1 și 2, adică $a_{1,2}$ și $b_{1,2}$; o analiză mai atentă arată că și participarea acestor coeficienți este diferită dependent de forma curbei de sarcină, de faptul că ziua este de lucru sau de repaus. Spre exemplu, pentru zilele de lucru ponderea importantă o au în ordine a_1 , b_1 , a_2 și mai puțin b_2 , pe când, pentru zilele de repaus, ordinea este a_1 , a_2 , b_2 și mai puțin b_1 :

* odată cu creșterea rangului armonicilor, ponderea (valoarea) coeficienților scade, dar situația nu este generală apărând și excepții de la această regulă, dar tendința de ansamblu este aceea de scădere. Spectrul coeficienților Fourier în procente din puterea medie se prezintă în figura 5.1.

Coeficienții c_k s-au calculat cu relația cunoscută: $c_k^2 = a_k^2 + b_k^2$:

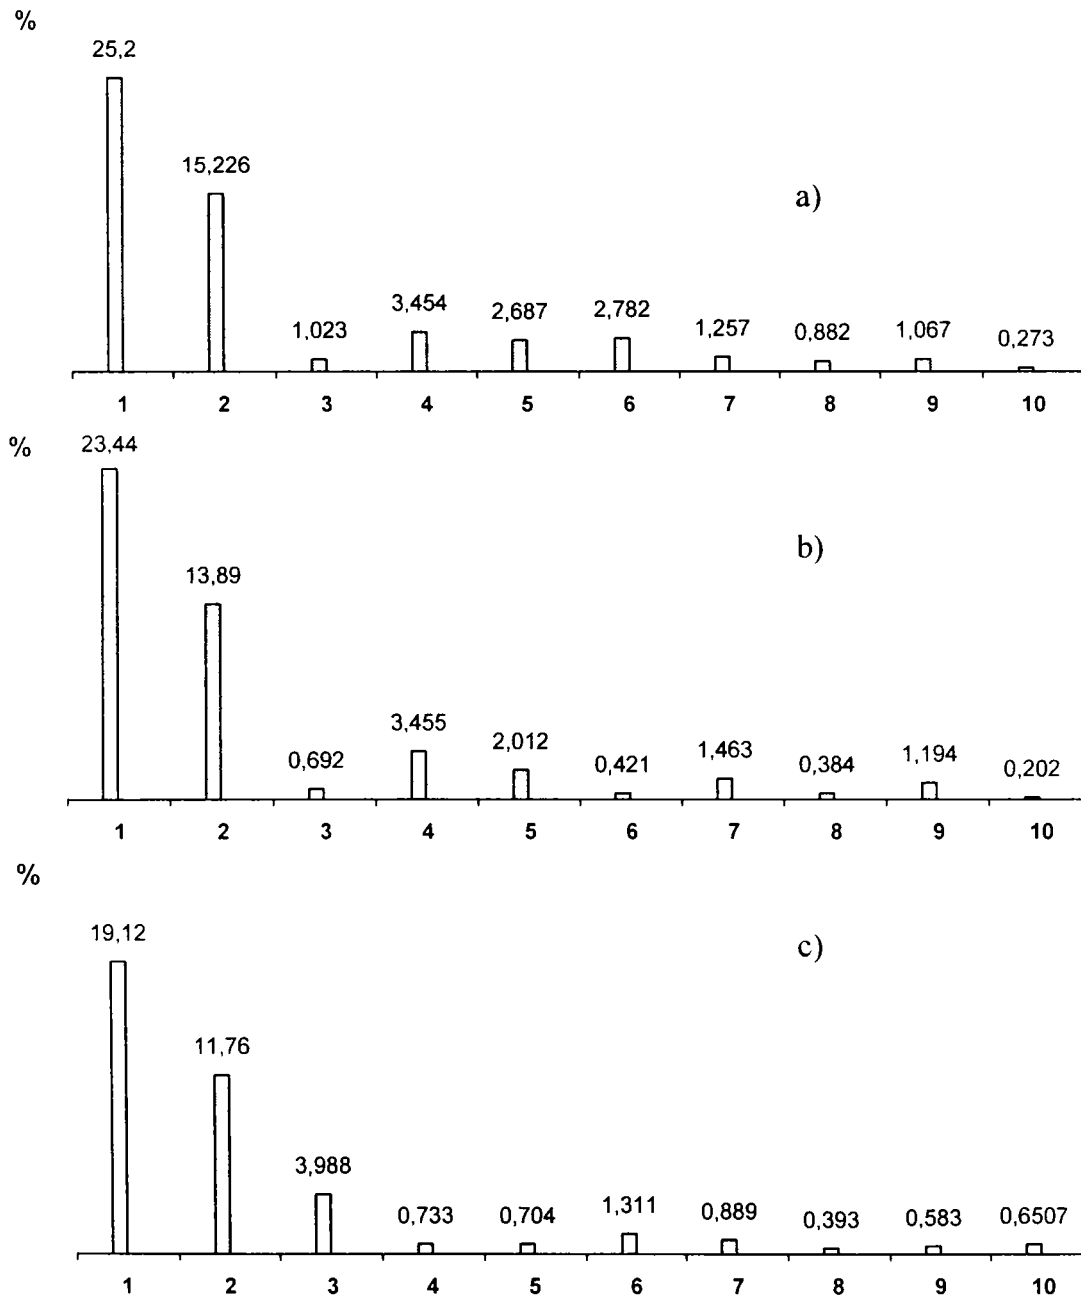


Figura 5.1. Histograma curbelor de putere activă : a) Luni 4.01.1999; b) Marți 5.01.1999; c) Duminică 10.01.1999, AT1 – stația Moșnița - Timișoara

- * se remarcă o sensibilitate accentuată a valorilor majorității coeficienților Fourier cu tipul zilei, de lucru sau de repaus ; De exemplu, dacă $a_5 = -0,028$ pentru ziua de Luni, $a_5 = -0,024$ pentru Marți, $a_5 = -8,172 \cdot 10^{-3}$ pentru Duminică. Mult mai stabil este însă coeficientul a_1 , care are valorile $a_1 = -0,257$ pentru Luni, $a_1 = -0,242$ pentru Marți și $a_1 = -0,251$ pentru Duminică; aceleași observații se pot face și în legătură cu coeficienții c_k . Sensibilitatea coeficienților se păstrează odată cu modificarea pasului de discreditare:
- * în ceea ce privește abaterile coeficienților față de valorile considerate exacte, se constată că acestea cresc odată cu creșterea pasului de discreditare, dacă pentru 1/2 h și 1 h nu depășesc 10-15% pentru a_{1-4} , b_{1-4} , pentru pasul de 2 h aceste abateri ating și valoarea de 100%; *deci pasul de 2 ore nu poate fi acceptat*; Trebuie menționat că problema pasului de discreditare trebuie pusă în concordanță cu forma curbei de sarcină, iar legat de aceasta, cu valoarea coeficientului de neuniformitate. Curbele de sarcină considerate în cadrul acestei lucrări se caracterizează printr-un coeficient de neuniformitate $\alpha = P_{\min}/P_{\max} \geq 0,5$;

Pentru a completa cele constatate mai sus, în figura 5.2 se prezintă dependența erorilor maxime în valoare absolută, efectuate la calculul lui a_1 și b_1 , în funcție de coeficientul α , pentru curbele de sarcină ale consumatorului considerat la nivelul anului 1999, admitându-se pasul de discreditare de 1 h, respectiv 2 h. Se constată că pentru un pas de 1 h, erorile nu depășesc 0,8÷0,9%, iar pentru un pas de 2 h, 27%. Desigur, $\alpha \in [0,5; 0,6]$.




Figura 5.2. Variația erorilor maxime în valoare absolută la determinarea coeficienților a_1 , b_1 cu α și $\Delta T = 1h; 2h$, pentru curbele de putere ale consumatorului AT1 Moșnița – Timișoara în anul 1999

5.2.2. Stabilirea numărului minim de coeficienți Fourier luați în considerare

Stabilirea numărului de coeficienți Fourier ce trebuie considerați în efectuarea prognozei este dependentă de precizia care se dorește a fi obținută și de comoditatea aplicării metodei. Cu cât numărul coeficienților este mai mic, cu atât și procedura de prognoză este mai ușor de aplicat și metoda propusă pare mai atractivă. Pe de altă parte, coeficienții corespunzători armonicilor superioare au o pondere foarte mică, de regulă sub 2÷3% din puterea medie ($k > 5$), iar palierele prognozate din curba de sarcină sunt supuse unui proces de corecție pe baza realizărilor trecute, cuprinse în baza de date.

Considerându-se numeroase curbe de sarcină pentru consumatorul considerat în perioada 1999, 2000, 2001, s-a constatat că pentru a obține o eroare medie de cca 5% în valoare absolută, sau chiar mai mică, sunt suficiente primele patru armonici. În unele situații particulare sunt suficiente chiar și primele două armonici, adică a_1 , a_2 , b_1 , b_2 . Este important

de menționat că alături de componenta constantă (continuă), armonicile 1 și 2 dau forma de ansamblu a curbei de sarcină, adică, într-o aproximare grosieră, armonicile superioare asigură finisarea acesteia.

Efectul considerării a 2, 3 sau 4 armonici pentru aproximarea curbelor de sarcină considerate în tabelul 5.1. se prezintă în tabelul 5.3.

Tabelul 5.3. Analiza considerării a 2; 3; 4 armonici la sinteza graficului de sarcină, asupra mărimii reziduurilor.

Arm. Treaptă	ZIUĂ								
	LUNI			MARȚI			DUMINICĂ		
	2	3	4	2	3	4	2	3	4
1	-10,02	-9,045	-4,36	-9,25	-8,27	-3,73	-5,785	-7,107	-6,36
2	-8,79	-9,075	-5,68	-10,14	-9,18	-4,58	-6,32	-4,163	-3,713
3	-2,84	-4,24	-5,83	-3,36	-3,08	-3,366	-6,037	-1,306	-1,686
4	6,87	5,404	0,656	5,012	4,45	-0,251	-4,79	-0,305	-1,26
5	13,59	12,75	9,97	13,15	12,18	8,01	1,32	2,874	2,38
6	13,36	13,76	14,91	21,28	20,50	20,75	4,99	2,735	3,205
7	6,32	7,24	10,54	10,17	9,97	13,34	7,136	2,65	3,55
8	-1,798	-0,77	1,33	-1,12	-0,795	1,813	7,536	3,525	3,95
9	0,405	0,953	0,21	2,329	2,917	2,757	6,426	5,11	4,429
10	2,940	2,77	-0,16	1,865	2,386	0,280	0,708	2,55	1,86
11	3,1707	2,33	0,288	2,33	2,54	0,0	-3,149	3,27	0,209
12	-0,399	-1,422	-0,456	0,347	0,0277	0,187	-4,016	-0,501	-0,202
13	-2,926	-3,52	-0,357	-3,109	-3,68	-1,0	-2,022	-0,797	-0,0306
14	-4,69	-4,46	-2,337	-4,005	-4,53	-1,96	-0,543	-2,377	-1,995
15	-0,163	0,71	-0,279	-0,949	-1,11	-1,27	3,056	-0,3055	-0,687
16	3,87	4,88	1,84	4,589	4,86	2,059	9,485	5,903	5,217
17	5,95	6,49	4,488	6,01	6,62	3,963	11,85	10,68	10,32
18	0,283	0,126	1,017	2,706	0,714	0,867	2,75	4,278	4,595
19	-1,017	-1,64	1,11	-1,329	-1,132	1,368	-0,733	2,22	2,76
20	-1,254	-2,204	-0,248	-2,814	-3,07	-0,659	-2,47	0,242	0,589
21	-3,964	-4,52	-5,47	-5,37	-5,95	-6,104	-4,15	-3,220	-3,453
22	-5,58	-5,403	-8,7	-5,46	-6,03	-8,93	-4,44	-5,92	-6,53
23	-7,46	-6,43	8,89	-7,22	-7,48	-10,46	-4,75	-8,11	-8,51
24	-10,98	-9,57	8,23	-9,249	-8,902	-8,03	-3,459	-7,022	-6,643

Variația erorilor în valoare absolută, treptele 1,3,5,6,7, în funcție de numărul armonicilor luate în considerare ($k \in [2; 12]$) pentru ziua de Luni 04.01.1999, curba de sarcină a AT1 stația Moșnita se prezintă ca în figura 5.3.

Din analiza celor prezentate în tabelul 5.3. și figura 5.3. rezultă următoarele:

- erorile maxime nu apar la vârfurile de sarcină (primul în jurul orei 10 și al doilea în jurul orei 20) și nici la golurile de sarcină, ci pe porțiuni de pantă maximă între goluri și vârful de seară, unde armonicile nu au elasticitatea de a realiza interpolarea necesară;

* considerarea unui număr mai mic sau mai mare de armonici consecutive afectează sensibil nivelul mediu al erorilor, fără a afecta sensibil valoarea erorii maxime și nici momentul (treapta) la care aceasta apare;




Figura 5.3. Variația erorilor în valoare absolută pentru treapta 1;3;5;6;7 din curba de sarcină a puterii active pentru AT1- Moșnița – Timișoara, ziua de 4.01.1999

- * nu întotdeauna considerarea unui număr mai mare de armonici conduce la reducerea valorii erorii maxime: pot apare și situații inverse; astfel, pentru ziua de Luni considerată, la 2 armonici eroarea maximă are valoarea de 13.59%. la 3 armonici 13,76%, iar la 4 armonici, 14.91%, adică exact invers de cum s-ar părea firesc. În continuare, considerându-se armonici de rang $k > 7$, eroarea maximă scade, dar nu sensibil, ajungând ca pentru $k=12$ să atingă valoarea apropiată de 10%;
- * pentru zilele de repaus, tendințele care se manifestă sunt de regulă inverse, cu cele din zilele de lucru. Astfel pentru ziua de Duminică, prima care urmează după aceea de Luni considerată, eroarea maximă ce apare în condițiile a două armonici este de 11.85%, pentru trei armonici 10,68%, iar pentru patru 10,32%. Erorile scad continuu cu creșterea numărului de armonici considerate, fără însă a ajunge la o valoare mai mică decât 8%, chiar și pentru $k=12$;
- * considerarea unui număr diferit de armonici poate conduce și la deplasarea orei la care apare eroarea maximă. De obicei pentru zilele lucrătoare aceasta poate fi maxim o oră și în situații cu totul deosebite (greve, demonstrații, schimbarea orei) două ore;
- * probleme deosebite apar la aproximarea golurilor de dimineață și noapte, când, chiar în condițiile considerării unui număr mare de armonici, erorile nu se reduc în valoare absolută sub 5÷7%; cauza o reprezintă firește dificultatea în a aproxima panta foarte abruptă a curbei de sarcină.

Oricum, indiferent de numărul armonicilor luate în considerare la aproximarea curbei de sarcină, erorile care apar pot fi controlate și reduse.

Pentru a întregi cunoștințele despre problema abordată, în figura 5.4. s-a considerat curba de sarcină pentru ziua de 04.01.1999 și, corespunzător, s-a analizat interpolarea acesteia cu un număr diferit de armonici, după cum urmează:

P_i - curba reală	P_{t7} - armonica 1, 3, 5, 6, 7	P_{t14} - armonica 1, 2, 4, 6, 7
P_{t1} - armonica 1, 2	P_{t8} - armonica 1, 3, 5, 6, 7, 8	P_{t15} - armonica 1, 2, 5, 6, 7, 9
P_{t2} - armonica 1, 2, 3	P_{t9} - armonica 1, 2, 4, 6, 8, 10	P_{t16} - armonica 1, 2, 5, 6, 8, 9, 10
P_{t3} - armonica 1, 3, 4, 5	P_{t10} - armonica 1, 2, 4	P_{t17} - armonica 1, 2, 3, 5, 6
P_{t4} - armonica 1, 3, 4, 5, 6	P_{t11} - armonica 1, 2, 4, 5	P_{t18} - armonica 1, 2, 3, 5, 7, 9
P_{t5} - armonica 1, 3, 4, 5, 6, 7, 8, 9, 10	P_{t12} - armonica 1, 2, 4, 5, 6	P_{t19} - armonica 1, 2, 3, 4, 7, 9, 10
P_{t6} - armonica 1, 3, 5, 7, 9	P_{t13} - armonica 1, 2, 4, 5, 7	P_{t20} - armonica 1, 3, 5, 6, 8, 10

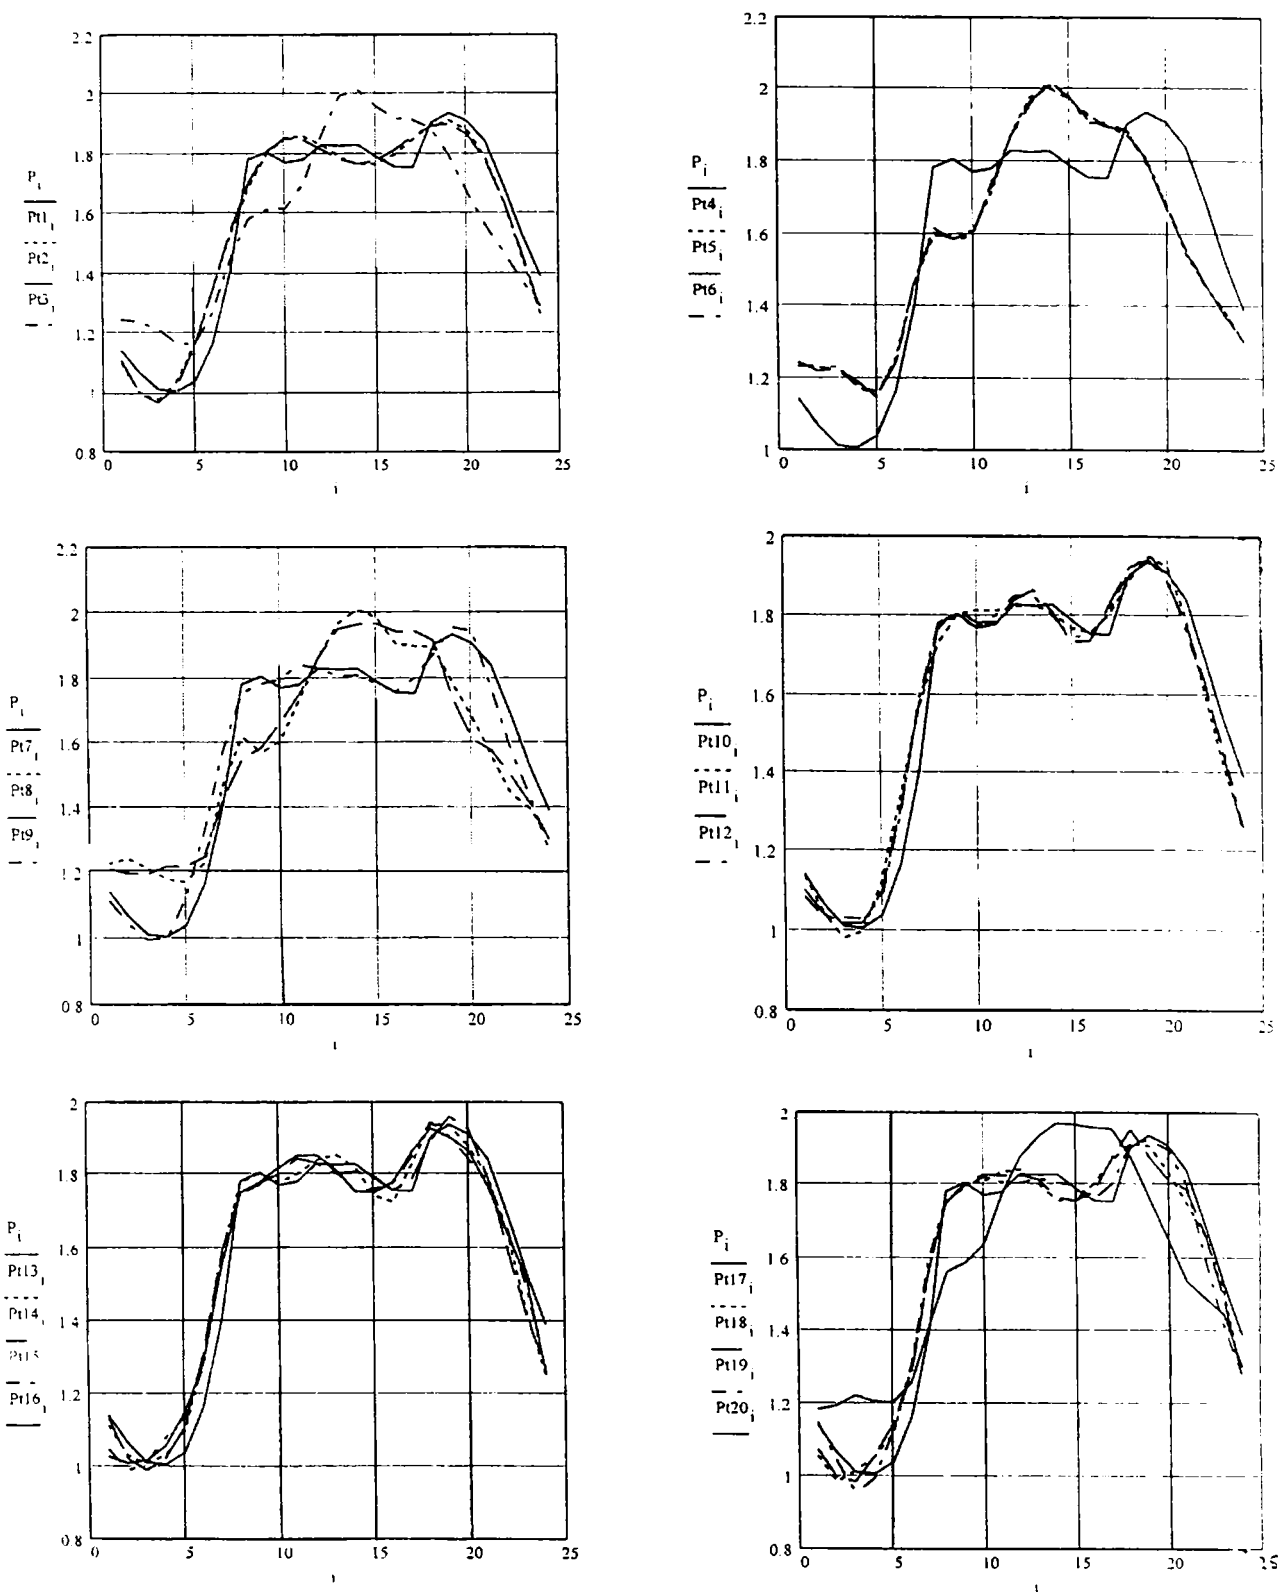


Figura 5.4. Sinteza curbei de sarcină din diverse armonici-aplicație pentru AT₁ Moșnița – Timișoara, 4.01.1999

Tabelul 5.4. Curbe de sarcină obținute prin interpolare cu un număr diferit de armonici

Nr. palier	P _i	P _{t1}	P _{t2}	P _{t3}	P _{t4}	P _{t5}	P _{t6}	P _{t7}	P _{t8}	P _{t9}	P _{t10}	P _{t11}	P _{t12}	P _{t13}	P _{t14}	P _{t15}	P _{t16}	P _{t17}	P _{t18}	P _{t19}	P _{t20}
1	1,143	1,099	1,109	1,248	1,232	1,245	1,236	1,227	1,212	1,115	1,138	1,101	1,086	1,114	1,136	1,049	1,029	1,096	1,074	1,151	1,189
2	1,066	0,998	0,996	1,239	1,229	1,219	1,231	1,243	1,198	1,042	1,042	1,04	1,03	1,03	1,021	0,988	1,009	0,984	0,997	1,042	1,197
3	1,012	0,976	0,964	1,216	1,232	1,224	1,220	1,214	1,196	0,994	0,981	1,017	1,033	1,01	0,989	1,012	1,018	1,016	0,985	0,955	1,223
4	1,006	1,038	1,023	1,168	1,179	1,192	1,184	1,181	1,219	0,999	0,999	1,019	1,03	1,033	1,023	1,081	1,057	1,094	1,099	0,995	1,209
5	1,039	1,169	1,160	1,164	1,148	1,149	1,161	1,172	1,218	1,123	1,125	1,10	1,084	1,1	1,11	1,139	1,151	1,119	1,145	1,127	1,204
6	1,167	1,344	1,346	1,27	1,259	1,246	1,242	1,229	1,248	1,325	1,339	1,305	1,295	1,291	1,314	1,273	1,283	1,301	1,285	1,314	1,261
7	1,406	1,527	1,539	1,449	1,465	1,471	1,463	1,470	1,425	1,572	1,566	1,575	1,590	1,581	1,588	1,566	1,549	1,563	1,562	1,592	1,417
8	1,782	1,687	1,702	1,583	1,593	1,604	1,616	1,619	1,551	1,755	1,731	1,769	1,779	1,779	1,752	1,747	1,75	1,750	1,752	1,759	1,562
9	1,806	1,799	1,808	1,614	1,598	1,586	1,583	1,571	1,571	1,587	1,783	1,804	1,819	1,80	1,803	1,776	1,773	1,78	1,804	1,798	1,790
10	1,771	1,894	1,853	1,617	1,607	1,602	1,594	1,608	1,669	1,797	1,815	1,783	1,773	1,779	1,801	1,82	1,817	1,81	1,829	1,823	1,637
11	1,781	1,858	1,846	1,701	1,716	1,731	1,743	1,735	1,751	1,842	1,814	1,786	1,802	1,801	1,844	1,852	1,85	1,834	1,825	1,808	1,773
12	1,830	1,829	1,814	1,863	1,874	1,871	1,867	1,866	1,864	1,831	1,824	1,842	1,852	1,838	1,831	1,852	1,852	1,842	1,827	1,804	1,875
13	1,826	1,790	1,780	1,994	1,978	1,966	1,957	1,968	1,952	1,806	1,829	1,866	1,851	1,854	1,801	1,809	1,814	1,802	1,815	1,818	1,931
14	1,829	1,764	1,766	2,013	2,002	2,012	2,024	2,01	1,966	1,809	1,808	1,810	1,799	1,82	1,807	1,752	1,751	1,757	1,769	1,806	1,97
15	1,790	1,766	1,778	1,958	1,973	1,981	1,977	1,986	1,968	1,785	1,771	1,735	1,750	1,743	1,794	1,761	1,751	1,757	1,757	1,80	1,965
16	1,756	1,798	1,813	2,013	1,928	1,915	1,906	1,906	1,945	1,759	1,759	1,738	1,749	1,725	1,756	1,776	1,78	1,803	1,78	1,761	1,959
17	1,754	1,848	1,857	1,958	1,897	1,896	1,909	1,899	1,916	1,801	1,804	1,829	1,814	1,829	1,787	1,847	1,861	1,867	1,872	1,803	1,953
18	1,903	1,894	1,892	1,918	1,873	1,887	1,884	1,896	1,916	1,875	1,889	1,923	1,912	1,937	1,892	1,944	1,926	1,915	1,952	1,914	1,875
19	1,936	1,911	1,90	1,912	1,808	1,802	1,793	1,784	1,739	1,957	1,951	1,942	1,958	1,936	1,959	1,904	1,901	1,907	1,877	1,923	1,761
20	1,909	1,879	1,864	1,884	1,680	1,669	1,682	1,681	1,613	1,947	1,923	1,885	1,896	1,875	1,923	1,84	1,864	1,837	1,814	1,897	1,648
21	1,841	1,787	1,777	1,793	1,544	1,556	1,553	1,561	1,577	1,771	1,792	1,780	1,765	1,792	1,788	1,782	1,765	1,75	1,788	1,803	1,536
22	1,692	1,638	1,64	1,669	1,458	1,462	1,453	1,442	1,499	1,581	1,599	1,631	1,620	1,635	1,592	1,651	1,639	1,661	1,663	1,593	1,488
23	1,531	1,452	1,464	1,375	1,390	1,376	1,389	1,396	1,413	1,436	1,408	1,436	1,452	1,422	1,41	1,49	1,516	1,508	1,486	1,413	1,447
24	1,391	1,261	1,276	1,291	1,301	1,304	1,301	1,302	1,3	1,263	1,256	1,239	1,249	1,242	1,27	1,259	1,252	1,269	1,263	1,276	1,303

Corespunzător celor din figura 5.4. în tabelul 5.4. sunt înscrise valorile celor 21 de curbe, pe paliere orare.

Din analiza celor prezentate în figura 5.4. și în tabelul 5.4. rezultă următoarele:

- * armonicile 1 și 2 asigură o modelare destul de bună a curbei de sarcină, mai precisă pentru vârfuri și goluri și relativ bună pentru porțiuni cu panta mare (a se vedea curbele P_i , P_{t1});
- * considerarea în plus a armonicii a 3-a (P_{t2}) nu schimbă cu nimic situația anterioară și aceasta datorită valorii foarte mici a coeficienților acestei armonici;
- * neconsiderarea armonicii a doua, indiferent în ce combinații sunt considerate celelalte armonici, conduce la erori destul de mari, vârfurile și golurile apar deplasate și deformate față de situația reală. Spre exemplu, panta de seară din curba de sarcină este deplasată spre dreapta cu cca. 1,5 h (curbele P_{t2} - P_{t8} ; P_{t20});
- * considerarea fundamentalei și a armonicilor pare în intervalul 2 - 10, asigură o interpolare destul de bună a curbei, finisând vârfurile, dar aproximarea rămâne la fel de deficitară pe porțiunile cu pantă mare, ascendente sau descendente (P_{t9});
- * considerarea armonicii a 5-a (P_{t11} , P_{t12} , P_{t13}) nu soluționează problema aproximării corecte a pantei, totuși atenuează puțin din valoarea reziduurilor; în aceeași direcție se înscrie și asocierea cu armonicile 9 și 10 (P_{t15} , P_{t16});
- * considerarea armonicilor impare, alături de armonicile 1 și 2, conduce la o modelare destul de bună (P_{t17} , P_{t18}), care, deși soluționează problema pantei descendente, nu o rezolvă pe aceea a pantei ascendente.


Concluzia care se desprinde din cele prezentate este aceea că practic sunt suficiente armonicile 1 și 2, iar în situația în care armonica a 3-a sau/și a 4-a prezintă coeficienți de valoare semnificativă (de exemplu mai mari de 2%) trebuie considerați și aceștia. Pentru porțiunile cu pantă în valoare absolută ridicată, erorile vor fi controlate pe baza realizărilor trecute.

5.3. Prognoza coeficienților Fourier


Metoda propusă în această lucrare are la bază păstrarea formei curbei de sarcină zilnică pentru o perioadă scurtă de timp (maximum 5-6 săptămâni) pentru fiecare din săptămână. În acest sens, în figura 5.5. sunt prezentate curbele de sarcină ale puterilor active orare pentru consumatorul AT1 din stația Moșnița-Timișoara pentru zilele de: a) Luni, b) Miercuri, c) Sâmbătă, d) Duminică.

Din analiza celor prezentate în figura 5.5. se pot face următoarele observații:


- * pentru unele zile de lucru, unde energiile zilnice consumate au fost foarte apropiate ca valoare, în intervalul redus (3-4 săptămâni), curbele de sarcină sunt foarte asemănătoare, aproape identice (a se vedea curbele b) din zilele de 20, 27.01 și 3.02, unde puterile medii zilnice au fost de $P_{m20.01}=1.735$ u.r., $P_{m27.01}=1.74$ u.r., $P_{m3.02}=1.75$ u.r). Identitatea formei se păstrează și la scăderea consumului, doar că, curba se deplasează corespunzător în jos (curba corespunzătoare lui $P_{m13.01}=1.625$ u.r.);
- * pentru ziua de Luni, ziua următoare celor de repaus, considerând și șase săptămâni succesive, cu consumuri zilnice relativ diferite, forma de ansamblu a curbelor se păstrează, deși la primul vârf apar abateri în amplitudine de cca. 5-7%; pentru ziua de Sâmbătă, deși s-au considerat șase săptămâni consecutive, cu consumuri relativ diferite, dar cu regim termic apropiat, se constată o bună asemănare a curbelor de sarcină, vârfurile și golurile corespund ca oră de apariție iar succesiunea vârfurilor corespunde în majoritatea cazurilor ordinei crescătoare a consumurilor




a)



b)



c)



d)

Figura 5.5. Curbele de sarcină ale puterii active pentru consumatorul AT₁ din stația Moșnița - Timișoara în zilele de: a) Luni(4;11;18;25.01.1999, 3.02.1999), b) Miercuri(13;20;27.01.1999, 5.02.1999), c) Sâmbătă(9;16;23;30.01.1999, 6; 13.02.1999), d) Duminică(10;17;24;31.01.1999, 7.02.1999)

zilnice (de exemplu curbele P_{m9} și P_{m16} prezintă vârful minim, având $P_{mzi}=1.472$ u.r. iar $P_{m30.01}$ și $P_{m13.02}$ având $P_{mzi}=1.558$ u.r. și respectiv 1.565 u.r. prezintă vârful maxim);

* ziua de Duminică deși prezintă aceeași alură pentru curbele de sarcină considerate, cunoaște unele diferențieri în ceea ce privește primul vârf, sub acest aspect curbele grupându-se în două categorii:

- a) primele trei corespunzătoare unor consumuri zilnice mai reduse și temperaturi medii mai ridicate;
- b) ultimele două corespunzătoare unor consumuri zilnice mai mari și temperaturi medii mai coborâte.

De fapt, procesul de prognoză al coeficienților Fourier se efectuează, ca tehnică, întocmai ca și prognoza puterilor medii (energiilor) săptămânale sau zilnice, cu observația că aici se pot accepta erori mai mari în estimare avându-se în vedere ponderea mai redusă pe care o au acești coeficienți în puterea medie zilnică.

Referitor la modelarea matematică a variației coeficienților cu diferite variabile, trebuie constatat că modelele matematice care au la bază regresia liniară simplă nu dau satisfacție întrucât coeficienții de corelație simplă au valori relativ reduse, nedepășind 0.7-0.85 în valoare absolută. Rezultate mult mai bune se obțin apelând la corelația liniară multiplă și la corelația neliniară. Drept variabile se pot considera: puterea medie zilnică, temperaturile zilnice: minimă, medie sau maximă și chiar timpul. În situații deosebite, dispersie mare, incertitudine asupra datelor de intrare, se poate apela la media aritmetică sau la o medie ponderată. Corelații utile se pot stabili și între coeficienții diferitelor zile.

În sensul celor afirmate mai sus, în tabelul 5.5. sunt prezentate expresiile analitice ale unor coeficienți în funcție de diverse variabile pentru intervalul 3.01-23.02.2002, pentru consumatorul AT1 din stația Moșnița-Timișoara. Alăturat se indică pătratul raportului de corelație ρ^2 .

Tabelul 5.5. Expresiile analitice ale coeficienților seriilor Fourier, consumatorul AT1 din stația Moșnița - Timișoara, perioada 03.01-23.02.2000

Nr. crt	X	Y	Expresia analitică a coeficientului	ρ^2
1.	A_1 luni	A_1 marți	$y = a + b \cdot x + c \cdot x^3$ $a = -0,6796; \quad b = 53,0815; \quad c = 198,9359$	0,857
2.	A_2 luni	A_2 marți	$y = a + \frac{b}{x^2}$ $a = -0,2324; \quad b = 0,0019$	0,354
3.	B_1 luni	B_1 marți	$y = a + b \cdot x \cdot \sqrt{x} + c \cdot x^2$ $a = 0,2242; \quad b = -2,9506; \quad c = 5,7789$	0,873
4.	A_1 luni	B_1 marți	$y = a + b \cdot e^x + \frac{c}{x^2}$ $a = 3,7052; \quad b = -4,5; \quad c = 0,0076$	0,655

5.	A ₂ luni	B ₁ marți	$y = a + b \cdot x + c \cdot x^3$ $a = -0,3031; \quad b = 42,662; \quad c = 141,4408$	0,379
6.	B ₁ luni	A ₂ marți	$y = a + b \cdot x \cdot \ln x + \frac{c}{x}$ $a = 16,364; \quad b = 37,8751; \quad c = -0,8625$	0,901
7.	P _{med zi}	A ₁ luni	$y = a + \frac{b}{\ln x}$ $a = -0,365; \quad b = 0,0662$	0,799
8.	P _{med zi}	B ₁ luni	$\frac{1}{y} = a + b \cdot x^2 \cdot \ln x$ $a = 6,844; \quad b = -3,21$	0,892
9.	B ₁ luni	t _{min}	$y = a + b \cdot x \cdot \ln x$ $a = 31,273; \quad b = 102,26$	0,725
10.	t _{max}	A ₂ dum	$y = a + b \cdot x + c \cdot x^3$ $a = -0,1345; \quad b = 0,003; \quad c = 0,0012$	0,886

Din cele prezentate în tabelul 5.5. se deduce faptul că, cu câteva excepții, corelațiile neliniare dintre mărimile considerate sunt suficient de strânse. Se remarcă $A_{2dum} = \varphi(t_{max})$ și $B_{1luni} = \varphi(P_{med})$.

Trebuie evidențată de asemenea și corelația neliniară dintre coeficienții de același nume a două zile consecutive (Luni, Marți).

Pentru zilele de Marți, în tabelul 5.6. sunt trecute datele aferente perioadei 04.01-01.02.2002, pentru același consumator, necesare modelării, iar în tabelul 5.7. valorile coeficienților de corelație corespunzători.

Tabelul 5.6. Baza de date necesară modelării coeficienților seriilor Fourier (A₁, A₂, B₁) pentru ziua de Marți, perioada 03.01-12.02.2000, AT1 Moșnița

ziua	A ₁ [u.r.]	A ₂ [u.r.]	B ₁ [u.r.]	P _{med M}	t _{min} [°C]	t _{med} [°C]	t _{max} [°C]	Obs.
04.01	-0,220	-0,142	0,185	2,514	-2,6	-1,2	0,1	date
11.01	-0,173	-0,209	0,233	2,573	-2,3	-1,3	-0,3	
18.01	-0,140	-0,166	0,275	2,702	-1,0	1,8	3,8	
25.01	-0,170	-0,225	0,216	2,633	-14,8	-12,7	-7,0	
01.02	-0,110	-0,191	0,195	2,438	0,6	6,3	12,6	
08.02	-0,163	-0,202	0,308	2,518	0,6	3,3	9,0	interval prognoză

Tabelul 5.7. Valorile coeficienților de corelație pentru corelația liniară dintre A_1 , A_2 , B_1 , și P_{medM} , t_{minM} , t_{medM} , t_{maxM}

Variabila Coeficient	P_{medM}	t_{minM}	t_{medM}	t_{maxM}	A_1	A_2	B_1
A_1	0,271	0,2715	0,4535	0,6153	-	-0,323	0,206
A_2	-0,0693	0,4769	0,413	0,197	-0,323	-	-0,217
B_1	0,372	0,289	0,233	0,254	0,206	-0,217	-

Evident, corelațiile liniare dintre mărimile considerate sunt slabe. Se remarcă corelația liniară multiplă:

$$\bar{A}_{1M} = a + b \cdot t_{minM} + c \cdot t_{medM} + d \cdot t_{maxM} \quad (5.9)$$

pentru care aplicând metoda celor mai mici pătrate se obțin:

$$a = -0,1325; b = -0,000718; c = 0,00536; \text{ și } d = -0,00653$$

iar coeficientul de corelație multiplă are valoarea de $r = 0,821$, o valoare relativ bună.

Pentru etapa de previziune rezultă: $A_1 = -0,1325 - 0,000718 \cdot 0,6 + 3,3 \cdot 0,00536 - 0,00653 \cdot 9,0 = -0,1739$ u.r., adică o eroare de 0,0109, deci 6.44%.

Considerând relația liniară $A_1 = a + b \cdot t_{max}$ se obțin:

$a = -0,156$ și $b = -0,002236$, care aplicați la etapa de prognoză conduc la $A_1 = -0,17612$, adică la o eroare comparabilă cu aceea de mai sus $\varepsilon = 8,049\%$.

Abordând o corelație neliniară de forma:

$$\bar{A}_1 = a + b t_{max} + c t_{max}^2 \quad (5.10)$$

se obțin coeficienții : $a = -0,398$; $b = -0,0032$; $c = 0,00354$,

pentru care $\bar{A}_1 = -0,398 - 0,0032 \cdot 9 + 0,00354 \cdot 81 = 0,1401$ u.r., adică o eroare de 14,05%.

Pentru A_2 se probează o relație neliniară de forma:

$$\bar{A}_2(k) = a + b \cdot A_2(k-1) + c \cdot A_2^2(k-1)$$

sau, calculând coeficienții:

$$\bar{A}_2(k) = -0,197 + 1,096 \cdot A_2(k-1) + 5,71 \cdot A_2^2(k-1)$$

Pentru etapa de prognoză, considerând $A_2(k-1) = -0,191$, se obține:

$$\bar{A}_2(6) = -0,210 \text{ u.r. față de } -0,202, \text{ adică o eroare de } 3,96\%.$$

O situație interesantă se constată și pentru zilele de repaus, de exemplu pentru ziua de Sâmbătă. În acest sens se consideră baza de date a zilelor de 8,15,22,29.01 și 2, 12.02 2000 pentru același consumator considerat, AT1 din stația Moșnița, în tabelul 5.8.

Tabelul 5.8. Baza de date necesară previziunii coeficienților A_1 și B_1 în ziua de 12.02.2000, AT1 stația Moșnița

Data	A_1 [u.r]	B_1 [u.r]	P_{mediu} [u.r]	t_{min} [°C]	t_{med} [°C]	t_{max} [°C]
8.01.2000	-0,2	0,038	2,281	-5	-1,8	3
15.01.2000	-0,167	0,07	2,302	-8,5	-4,9	1,2
22.01.2000	-0,167	0,032	2,546	-12	-3,4	5,2
29.01.2000	-0,194	0,08	2,198	-4	0,4	4,2
5.02.2000	-0,109	0,063	1,995	-3,5	2,6	10,4
12.02.2000	-0,134	0,052	2,121	-4,3	1,3	7

Corespunzător primelor cinci săptămâni s-au calculat coeficienții de corelație dintre variabilele considerate, în speranța identificării unor corelații liniare. Valorile corespunzătoare s-au figurat în tabelul 5.9.

Tabelul 5.9. Valorile coeficienților de corelație

Variabila Coeficient	$P_{medS}[u.r]$	$t_{min}[^{\circ}C]$	$t_{med}[^{\circ}C]$	$t_{max}[^{\circ}C]$	A_1	B_1
A_1	-0,651	0,34	0,685	0,825	-	0,472
B_1	-0,607	0,531	0,313	-0,009739	0,472	-

Dacă la estimarea lui A_1 se consideră t_{max} , se obține modelul liniar:

$$\bar{A}_1 = a + bt_{max} \text{ unde } a = -0,108, b = -0,01027, \text{ iar pentru prognoză rezultă :}$$

$\bar{A}_1(6) = -0,179$ adică o eroare de 33,58%. Deci corelațiile liniare simple nu pot fi luate în considerare.

Probând corelații neliniare de formă pătratică:

$$\bar{A}_1 = a + bt_{med} + ct_{med}^2 \quad (5.11)$$

sau

$$\bar{A}_1 = a + bt_{max} + ct_{max}^2 \quad (5.12)$$

se obțin următoarele matrici pentru reziduuri:

$$\varepsilon_{(5.11)}^{[\%]} = \begin{bmatrix} 7.898 \\ 2.519 \\ -8.387 \\ -4.917 \\ 1.52 \\ -6.864 \end{bmatrix} \quad \text{și} \quad \varepsilon_{(5.12)}^{[\%]} = \begin{bmatrix} 12.361 \\ -4.744 \\ 0.097 \\ -11.614 \\ 0.848 \\ -13.932 \end{bmatrix}$$

Considerând ultimele trei valori pentru A_1 și efectuând media lor aritmetică se obține $\bar{A}_1 = 0,143$, adică o eroare de 5,97%.

Reluând același raționament și pentru B_1 se obțin următoarele:

$\bar{B}_1 = a + b \cdot P_{med}$, unde $a = 0,034$; $b = 0,01236$ iar prognozat $\bar{B}_1 = 0,06$ adică, față de 0,052 realizat, o abatere de 15,38 %;

$$\bar{B}_1 = a + b \cdot t_{min} + c \cdot t_{min}^2 \quad (5.13)$$

sau

$$\bar{B}_1 = a + b \cdot P_{med} + c \cdot P_{med}^2 \quad (5.14)$$

iar matricele reziduurilor:

$$\varepsilon_{(5.13)}^{\circ} = \begin{bmatrix} -69,36 \\ 17,094 \\ -10,556 \\ 21,045 \\ 1,481 \\ \text{-----} \\ -22,427 \end{bmatrix}; \quad \varepsilon_{(5.14)}^{\circ} = \begin{bmatrix} -61,522 \\ 14,429 \\ 3,789 \\ 17,965 \\ -3,660 \\ \text{-----} \\ -29,417 \end{bmatrix}$$

Considerând media aritmetică a ultimelor trei realizări se obține: $\bar{B}_1 = 0,0583$, adică o abatere de 11,92%, care este mai bună decât în toate cele trei cazuri considerate mai sus.

Din cele prezentate, rezultă că determinarea cu mare precizie a coeficienților seriei Fourier pe baza numai a cinci realizări din trecut se efectuează cu mare dificultate, datorită împrăștierii acestora față de o tendință medie. Modele liniare simple nu dau satisfacția scontată, iar cele liniare, cu mai multe variabile, trebuie folosite cu atenție, întrucât unele variabile nu sunt independente. De exemplu puterea medie zilnică este de regulă corelată cu regimul termic al zilei. Deci, atunci când sunt folosite temperaturile zilnice este recomandat a nu folosi puterea medie (energia zilnică consumată). Simple medieri a unor valori realizate în trecutul apropiat (de exemplu trei săptămâni în urmă) pot conduce la rezultate mai bune, decât modelele matematice sofisticate.

5.3.1. Analiza influenței abaterilor coeficienților Fourier asupra reziduurilor

Așa cum s-a constatat anterior prognoza coeficienților Fourier este o problemă delicată dat fiind pe de o parte valorile lor reduse comparativ cu puterea medie, precum și sensibilitatea lor exagerată cu schimbarea datelor de intrare. Totuși considerarea lor cât mai apropiată de valorile corecte este benefică pentru rezultatele prognozei curbei de sarcină.

În acest sens, în cele ce urmează s-au efectuat două categorii de determinări și anume:

- s-a considerat curba de sarcină pentru o zi lucrătoare (Luni 4.01.1999, consumatorul AT1 Moșnița-Timișoara) sintetizată cu coeficienții Fourier A_1 , B_1 , A_2 , B_2 și s-a urmărit mărimea erorilor (reziduurilor) pentru abateri cu $\pm 5\%$ a coeficienților, considerate succesiv;
- s-au considerat curbele de sarcină pentru zilele de Luni, săptămânile 1-5, anul 2000, consumatorul AT1 Moșnița-Timișoara și s-au sintetizat curbele de sarcină din săptămâna $i+1$ ($i=1..6$) luând coeficienții Fourier (A_1 , B_1 , A_2 , B_2 , A_3 , B_3 , A_4 , B_4) din săptămâna i .

5.3.1.1. Determinarea a)

Variantele analizate corespund următoarelor valori pentru coeficienții Fourier:

- $A_1 = -0,275$; $A_2 = -0,211$; $B_1 = 0,284$; $B_2 = 0,037$; $P_m = 1,582$;
- $A_1 = -0,2475$; $A_2 = -0,211$; $B_1 = 0,284$; $B_2 = 0,037$; $P_m = 1,582$;
- $A_1 = -0,3025$; $A_2 = -0,211$; $B_1 = 0,284$; $B_2 = 0,037$; $P_m = 1,582$;
- $A_1 = -0,275$; $A_2 = -0,1899$; $B_1 = 0,284$; $B_2 = 0,037$; $P_m = 1,582$;
- $A_1 = -0,275$; $A_2 = -0,2321$; $B_1 = 0,284$; $B_2 = 0,037$; $P_m = 1,582$;
- $A_1 = -0,275$; $A_2 = -0,211$; $B_1 = 0,2556$; $B_2 = 0,037$; $P_m = 1,582$;
- $A_1 = -0,275$; $A_2 = -0,211$; $B_1 = 0,3124$; $B_2 = 0,037$; $P_m = 1,582$;

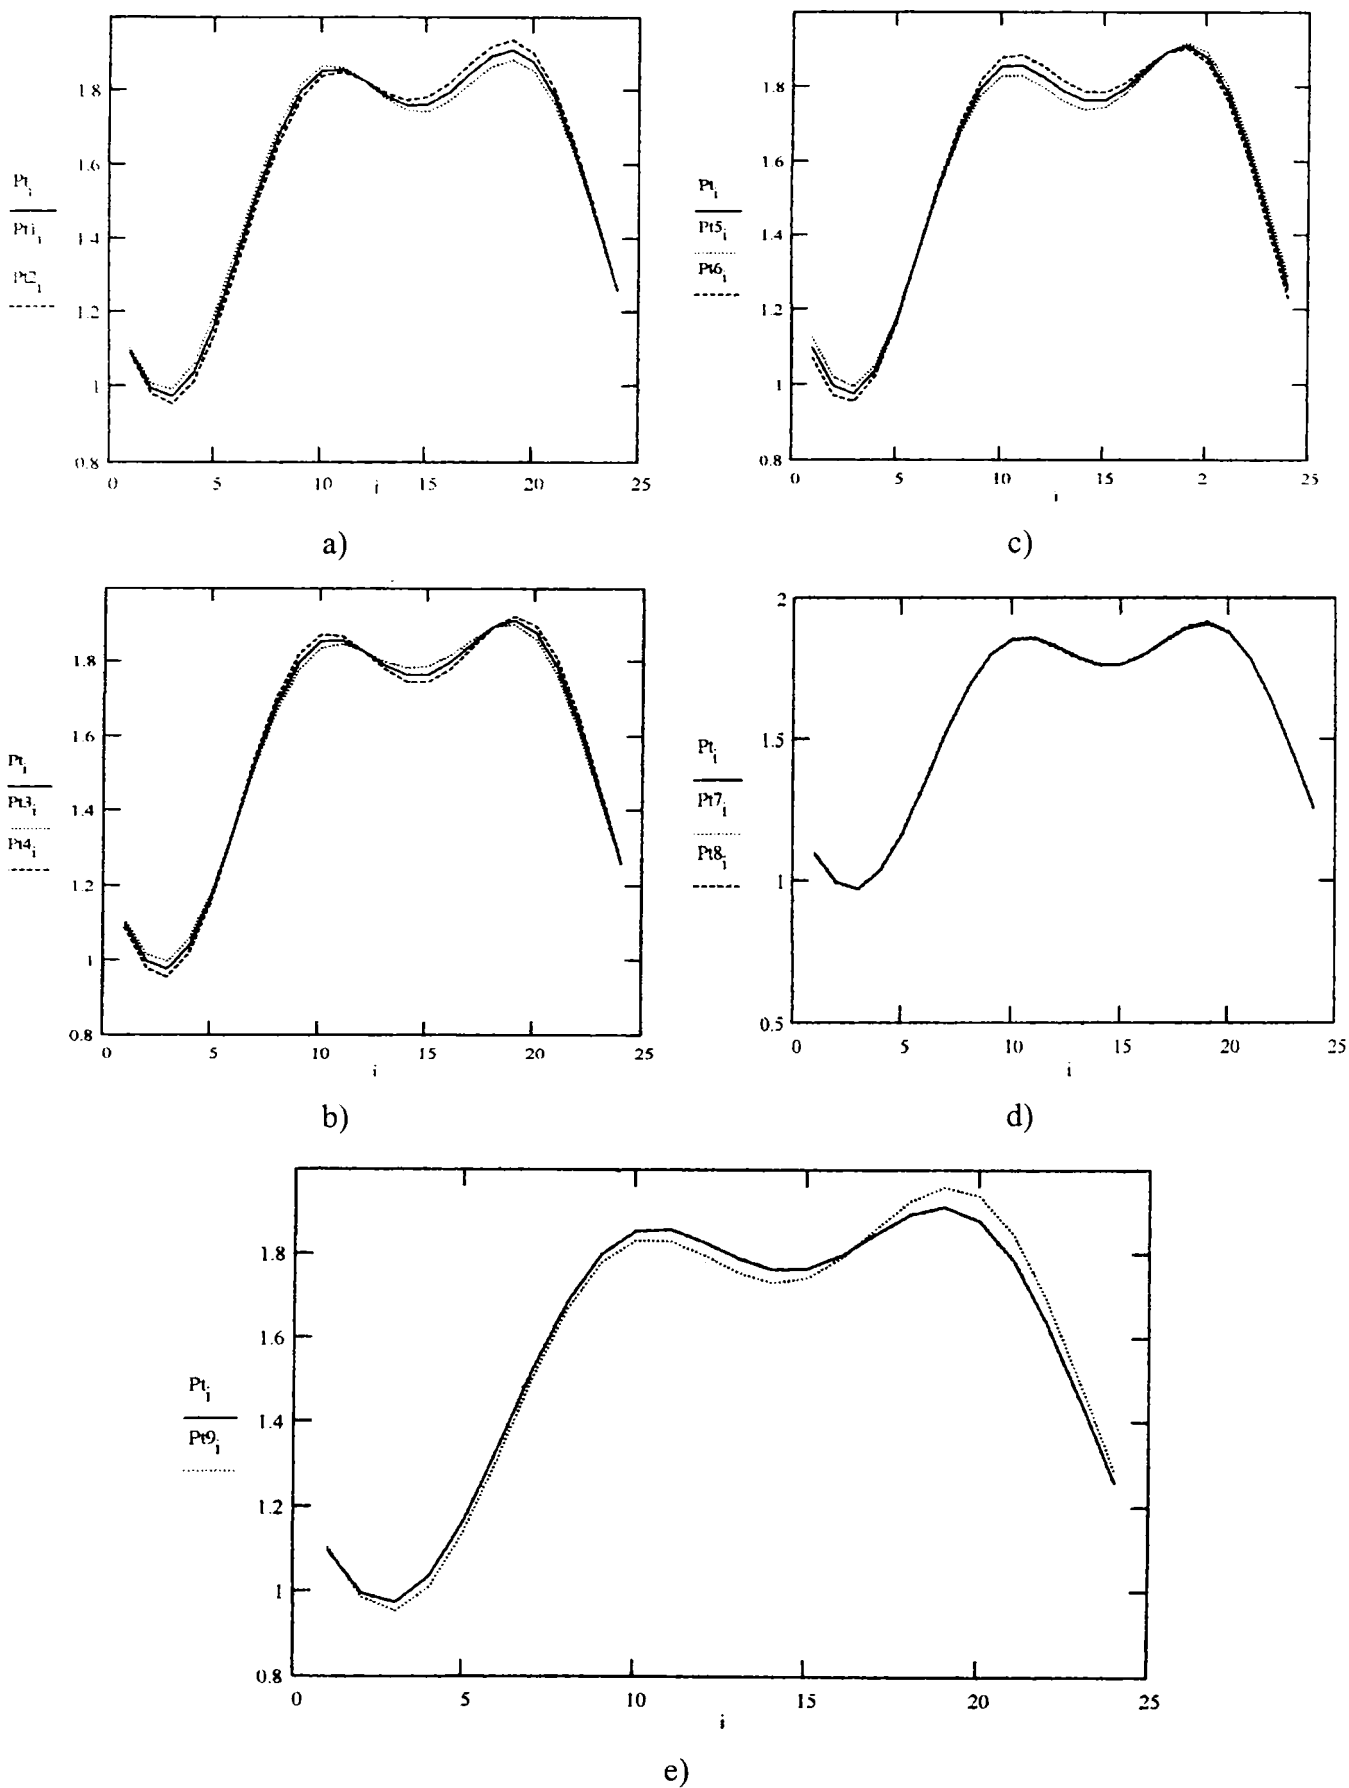


Figura 5.6. Variația puterilor active orare pentru ziua de Luni 4.01.1999, considerând variantele: a) 1;2;3, b) 1;4;5, c) 1;6;7, d)1;8;9,e) 1;10

8. $A_1 = -0,275$; $A_2 = -0,211$; $B_1 = 0,284$; $B_2 = 0,0333$; $P_m = 1,582$;

9. $A_1 = -0,275$; $A_2 = -0,211$; $B_1 = 0,284$; $B_2 = 0,0407$; $P_m = 1,582$;

10. $A_1 = -0,3025$; $A_2 = -0,2321$; $B_1 = 0,3124$; $B_2 = 0,0407$; $P_m = 1,582$;

iar graficele de sarcină aferente sunt prezentate în figura 5.6.

Din analiza curbelor calculate și prezentate în figura 5.6. se desprind următoarele observații:


- * coeficienții A_1 , A_2 , B_1 , B_2 , dau forma de ansamblu a curbei de sarcină, modificarea unuia dintre ei cu cca. 10% sau a tuturor cu 10 % și în același sens, modifică neesențial valorile puterilor orare; în golul de noapte (valoarea minimă de raportare) abaterea nu depășește 2%;
- * creșterea valorii lui A_1 mărește amplitudinea primului vârf și o diminuează pe cea de-a doua și invers;
- * creșterea valorii lui A_2 micșorează amplitudinea primului vârf și la fel a celui de-al doilea; în schimb nivelul golurilor crește; la scăderea valorii lui A_2 , lucrurile stau tocmai invers;
- * creșterea valorii lui B_1 micșorează amplitudinea primului vârf și o mărește ușor pe a celui de-al doilea; nivelul primului gol crește iar al celui de-al doilea scade; la scăderea valorii lui B_1 situația se prezintă invers;
- * modificarea lui B_2 chiar cu $\pm 10\%$ nu se resimte practic și aceasta datorită valorii foarte mici a acestuia (cca. 2% din puterea medie zilnică);
- * datorită acțiunilor diferite pe care le are modificarea în același sens a coeficienților seriilor Fourier, este posibil ca pe ansamblu să apară compensări ale erorilor.

5.3.1.2. Determinarea b)


Variantele analizate corespund următoarelor valori pentru coeficienții Fourier și valori medii ale puterii zilnice:

- $P_m = 2.529$ u.r.
 - 1.1. $A_1 = -0.214$, $B_1 = 0.159$, $A_2 = -0.151$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.026$, $B_4 = 0$
 - 1.2. $A_1 = -0.202$, $B_1 = 0.275$, $A_2 = -0.188$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.031$, $B_4 = 0$
- $P_m = 2.623$ u.r.
 - 2.1. $A_1 = -0.202$, $B_1 = 0.275$, $A_2 = -0.188$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.031$, $B_4 = 0$
 - 2.2. $A_1 = -0.211$, $B_1 = 0.314$, $A_2 = -0.221$, $B_2 = 0$,
 $A_3 = -0.221$, $B_3 = 0$, $A_4 = 0.035$, $B_4 = 0$
- $P_m = 2.563$ u.r.
 - 3.1. $A_1 = -0.211$, $B_1 = 0.314$, $A_2 = -0.221$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.046$, $B_4 = 0$
 - 3.2. $A_1 = -0.201$, $B_1 = 0.25$, $A_2 = -0.231$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.046$, $B_4 = 0$
- $P_m = 2.434$ u.r.
 - 4.1. $A_1 = -0.201$, $B_1 = 0.25$, $A_2 = -0.231$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.046$, $B_4 = 0$
 - 4.2. $A_1 = -0.173$, $B_1 = 0.232$, $A_2 = -0.241$, $B_2 = 0$,
 $A_3 = 0$, $B_3 = 0$, $A_4 = 0.05$, $B_4 = 0$


Curbele de sarcină corespunzătoare sunt prezentate în figura 5.7.




a)



b)



c)



d)

Figura. 5.7. Curbele de sarcină aferente zilelor de Luni:10, 17, 24, 31.01.2000 și 7.02.2000 în variantele: a)1.1, 1.2, b) 2.1., 2.2., c) 3.1., 3.2., d) 4.1., 4.2. (curba P_{ti} este aproximată, P_{t1i} este corectă).

Erorile corespunzătoare sunt înscrise în tabelul 5.10.

Tabelul 5.10. Valorile reziduurilor ridicate pentru curbele de sarcină previzionate în condițiile determinărilor b)

Variante Palier	1)	2)	3)	4)
1	-5.74	-2.427	3.142	1.106
2	-5.948	-3.041	2.939	1.231
3	-5.517	-3.296	2.103	1.182
4	-4.143	-2.878	1.11	1.102
5	-1.926	-1.764	0.544	1.138
6	0.516	-0.373	0.423	1.238
7	2.551	0.809	0.294	1.239
8	3.907	1.552	-0.187	1.032
9	4.606	1.859	-0.996	0.628
10	4.788	1.843	-1.807	0.133
11	4.603	1.639	-2.294	-0.32
12	4.137	1.328	-2.275	-0.675
13	3.409	0.93	-2.153	-0.997
14	2.443	0.463	-2.190	-1.361
15	1.364	0.034	-2.351	-1.715
16	0.424	-0.173	-2.244	-1.854
17	-0.164	-0.043	-1.528	-1.608
18	-0.439	0.318	-0.362	-1.074
19	-0.677	0.643	0.753	-0.515
20	-1.162	0.709	1.456	-0.115
21	-2.0	0.425	1.746	0.111
22	-3.115	-0.159	1.901	0.273
23	-4.238	-0.909	2.234	0.501
24	-5.146	-1.689	2.767	0.817

Din analiza celor înscrise în tabelul 5.10. rezultă următoarele:

- * majoritatea valorilor reziduurilor sunt mai mici de 2%;
- * reziduurile mai mari de 5% în valoare absolută sunt foarte puține;
- * repartiția reziduurilor depinde foarte mult de asemănarea curbelor de sarcină din săptămânile consecutive, de faptul că într-o perioadă sau alta au avut loc incidente, sărbători religioase, etc. Astfel în cazul 1) reziduurile de valoare relativ mare se justifică prin existența unei sărbători religioase mai deosebite în perioade apropiate.

Histograma reziduurilor (abaterilor) în valoare absolută este reprezentată în figura 5.8.




Figura 5.8. Histograma reziduurilor în valoare absolută (în unități relative $f_i=N_i/N$)

Din cele prezentate se deduc trei observații importante și anume:

- * coeficienții a căror valoare absolută este mai mică decât 2-3% din puterea medie pot fi neglijați în procesul de aproximare a curbelor de sarcină;
- * la estimarea coeficienților seriilor pot fi acceptate precizii mai scăzute, de exemplu o eroare de cca. 10% poate fi acceptată fără probleme;
- * este util ca erorile coeficienților Fourier să fie efectuate în același sens, desigur acest lucru nu poate fi urmărit decât în faza de întocmire a modelului.

5.4. Compensarea erorilor

Datorită considerării unui număr finit de armonici, curba de sarcină nu poate fi aproximată întotdeauna cu exactitate. Ca urmare, pe anumite porțiuni (așa cum s-a afirmat anterior) de pantă (în modul) de valoare ridicată pot apare erori sensibile care trebuiesc compensate, întrucât adăugarea acestora la erorile survenite prin estimare, poate conduce la erori inadmisibile.

În tabelul 5.11. sunt prezentate variațiile orare a reziduurilor sistematice pentru curbele de sarcină din zilele de 06.02 și 13.02. 1999.

Tabelul 5.11. Variația orară a reziduurilor sistematice pentru curbele de sarcină din ziua de Sâmbătă (6.02 și 13.02.1999) pe AT1 Moșnița – Timișoara

Ora	P _{6.02} calc.	P _{6.02} realiz.	ε[%]	P _{13.02} calc.	P _{13.02} comp.	P _{13.02} realiz.	ε[%]
1	1,204	1,303	7,610	1,348	1,451	1,444	-0,484
2	1,100	1,199	8,256	1,235	1,337	1,319	-1,360
3	1,052	1,111	5,345	1,178	1,241	1,247	0,484
4	1,066	1,095	2,697	1,183	1,214	1,207	-0,616
5	1,134	1,095	-3,505	1,247	1,203	1,218	1,202
6	1,238	1,121	-10,387	1,349	1,209	1,260	4,057
7	1,351	1,238	-9,118	1,465	1,330	1,349	1,303
8	1,447	1,372	-5,443	1,568	1,483	1,487	0,292
9	1,509	1,478	-2,104	1,637	1,603	1,567	-2,269
10	1,529	1,505	-1,554	1,663	1,637	1,644	0,416
11	1,514	1,523	0,578	1,650	1,651	1,650	-0,058
12	1,478	1,494	1,057	1,613	1,630	1,654	1,448
13	1,443	1,491	3,230	1,572	1,623	1,640	1,050
14	1,430	1,497	4,640	1,551	1,623	1,604	1,183
15	1,450	1,470	1,387	1,562	1,584	1,566	-1,128
16	1,506	1,460	-3,157	1,611	1,560	1,526	-2,237
17	1,586	1,439	-10,230	1,689	1,516	1,554	2,430
18	1,670	1,500	-11,303	1,775	1,574	1,654	4,810
19	1,734	1,754	1,180	1,846	1,867	1,861	0,042
20	1,755	1,847	5,012	1,878	1,887	1,945	2,960
21	1,721	1,789	3,823	1,855	1,926	1,904	-1,150
22	1,631	1,703	4,239	1,774	1,849	1,820	-1,644
23	1,498	1,536	2,499	1,646	1,687	1,695	0,464
24	1,346	1,385	2,787	1,495	1,537	1,572	2,248

Un singur reziduu depășește cu puțin 4%, iar 14 reziduuri sunt sub 1%.

5.5. Algoritmi pentru efectuarea prognozei

În cadrul acestui paragraf se prezintă algoritmi originali care au stat la baza metodologiei de calcul a energiilor și puterilor prognozate .

5.5.1. Energia consumată săptămânal

Pentru calculul energiei consumate săptămânal, adică a puterii medii zilnice, s-a conceput un algoritm original [5.13],[5.14] care urmărește variația puterilor medii săptămânale, de la o săptămână la alta pentru perioada anterioară (5 săptămâni), reține variația maximă și o pune în concordanță cu variația temperaturii medii săptămânale: minime, medii sau maxime. Corespunzător, rezultă o sensibilitate a energiei consumate cu temperatura medie săptămânală. Stabilirea temperaturii medii care urmează să fie folosită se efectuează pe baza unui test al temperaturii medii săptămânale. Astfel, pentru :

$$\begin{aligned} \bar{t}_{med}(6) < 9^{\circ} C, \text{ rezultă } \bar{t}_{min} \\ \bar{t}_{med}(6) \in (9^{\circ}, 17^{\circ} C], \text{ dar } t_{max} < 29^{\circ} C, \text{ rezultă } \bar{t}_{med} \\ \bar{t}_{med}(6) > 17^{\circ} C, \text{ dar } t_{max} < 29^{\circ} C, \text{ rezultă } \bar{t}_{med} \\ \bar{t}_{med}(6) > 17^{\circ} C, \text{ dar } t_{max} \geq 29^{\circ} C, \text{ rezultă } \bar{t}_{max} \end{aligned}$$

Desigur, aceste temperaturi corespund unor praguri de sensibilitate (confort, respectiv disconfort) pentru zonele urbane.

În acest sens, în figura 5.9. este prezentată ordinograma principială a procedurii de calcul. În cadrul acesteia se disting următoarele etape de calcul :

- * calculul variațiilor de putere medie săptămânală;
- * stabilirea temperaturii medii săptămânale \bar{t}^* , care influențează în măsura cea mai mare variația consumului de energie;
- * calculul sensibilității puterii medii săptămânale cu temperatura \bar{t}^* ;
- * calculul variației de temperatură Δt^* pentru perioada de prognoză și, corespunzător, al variației de putere medie săptămânală.

Trebuie remarcat că sensibilitatea calculată pe baza datelor din urmă nu este o sensibilitate medie, ci este una limită, care are în vedere variațiile maxime de putere medie și de temperatură medie \bar{t}^* , care apar. Este posibil ca acestea, în cazul general, să nu corespundă, situație cel mai des întâlnită în anotimpul friguros sau să corespundă, situație întâlnită în anotimpul călduros. Așa cum ne așteptam, mediul ambiental se comportă diferit la variația temperaturii în condițiile anotimpului friguros sau călduros. În prima situație apare o inerție termică mai mare decât în a doua. Aceasta se poate manifesta printr-o întârziere a răspunsului consumatorului cu mai multe zile și chiar una sau două săptămâni.

Algoritmul de calcul al puterii medii săptămânale poate fi descris și pe baza enumerării următoarelor etape:

- * Calculează $k(i) = \frac{\text{Max}[P(i), P(i+1)]}{\text{Min}[P(i), P(i+1)]}$; $i = 1; 4$
- * Calculează $\text{Max}[k(i)-1]$; $i = 1; 4$
- * Intreabă $\bar{t}_{med}(6) \leq 9^\circ C$ NU. Du – te la 1
DA. Urmează sec vența
- * Calculează $\Delta \bar{t}_{min}(i) = \text{ABS}(\bar{t}_{min}(i) - \bar{t}_{min}(i+1))$, când $i = 1, 4$
- * Reține $\text{MAX}[\Delta \bar{t}_{min}(i)]$; $i = 1; 4$
- * Calculează $k_p = \text{MAX}[k(i)-1] / \text{MAX}[\Delta \bar{t}_{min}(i)]$
- * Calculează $\text{Med}\{\bar{t}_{min}(i)\} = \sum_{i=1}^5 \bar{t}_{min}(i) / 5$
- * Du – te la 4
- 1* Intreabă $\bar{t}_{med}(6) \leq 17^\circ C$? NU. Du – te la 2
DA. Urmează sec vența
- 3* Calculează $\Delta \bar{t}_{med}(i) = \text{ABS}(\bar{t}_{med}(i) - \bar{t}_{med}(i+1))$, când $i = 1; 4$
- * Reține $\text{MAX}[\Delta \bar{t}_{med}(i)]$; $i = 1; 4$
- * Calculează $k_p = \text{MAX}[k(i)-1] / \text{MAX}[\Delta \bar{t}_{med}(i)]$
- * Calculează $\text{Med}\{\bar{t}_{med}(i)\} = \sum_{i=1}^5 \bar{t}_{med}(i) / 5$
- * Du – te la 7
- 2* Intreabă $\bar{t}_{med}(6) \geq 29^\circ C$? NU. Du – te la 3
DA. Urmează sec vența
- * Calculează $\Delta \bar{t}_{max}(i) = \text{ABS}(\bar{t}_{max}(i) - \bar{t}_{max}(i+1))$, când $i = 1; 4$
- * Reține $\text{MAX}[\Delta \bar{t}_{max}(i)]$; $i = 1; 4$
- * Calculează $k_p = \text{MAX}[k(i)-1] / \text{MAX}[\Delta \bar{t}_{max}(i)]$
- * Calculează $\text{Med}[\bar{t}_{max}(i)] = \sum_{i=1}^5 \bar{t}_{max}(i) / 5$
- * Du – te la 11
- 4* Intreabă $\bar{t}_{min}(6) < \text{Med}\{\bar{t}_{min}(i)\}$. NU. Urmează încălzire.
Du – te la 5
- * Intreabă dacă racirea este bruscă?, adică $\bar{t}_{min}(5) - \bar{t}_{min}(6) \geq 4^\circ C$
NU. Du – te la 6
DA. $k_p = k_p / 2$
- * Calculează $P(6) = P(5) * [1 + k_p * (\bar{t}_{min}(6) - \bar{t}_{min}(5))]$ Du – te la 10
- 5* Calculează $P(6) = P(5) / [1 + k_p * (\bar{t}_{min}(6) - \bar{t}_{min}(5))]$ Du – te la 10
- 7* Intreabă $\bar{t}_{med}(6) > \text{Med}\{\bar{t}_{med}(i)\}$. DA. Temperatura crește. Du – te la 8
- * Calculează $P(6) = P(5) * [1 + k_p * (\bar{t}_{med}(6) - \bar{t}_{med}(5))]$ Du – te la 10

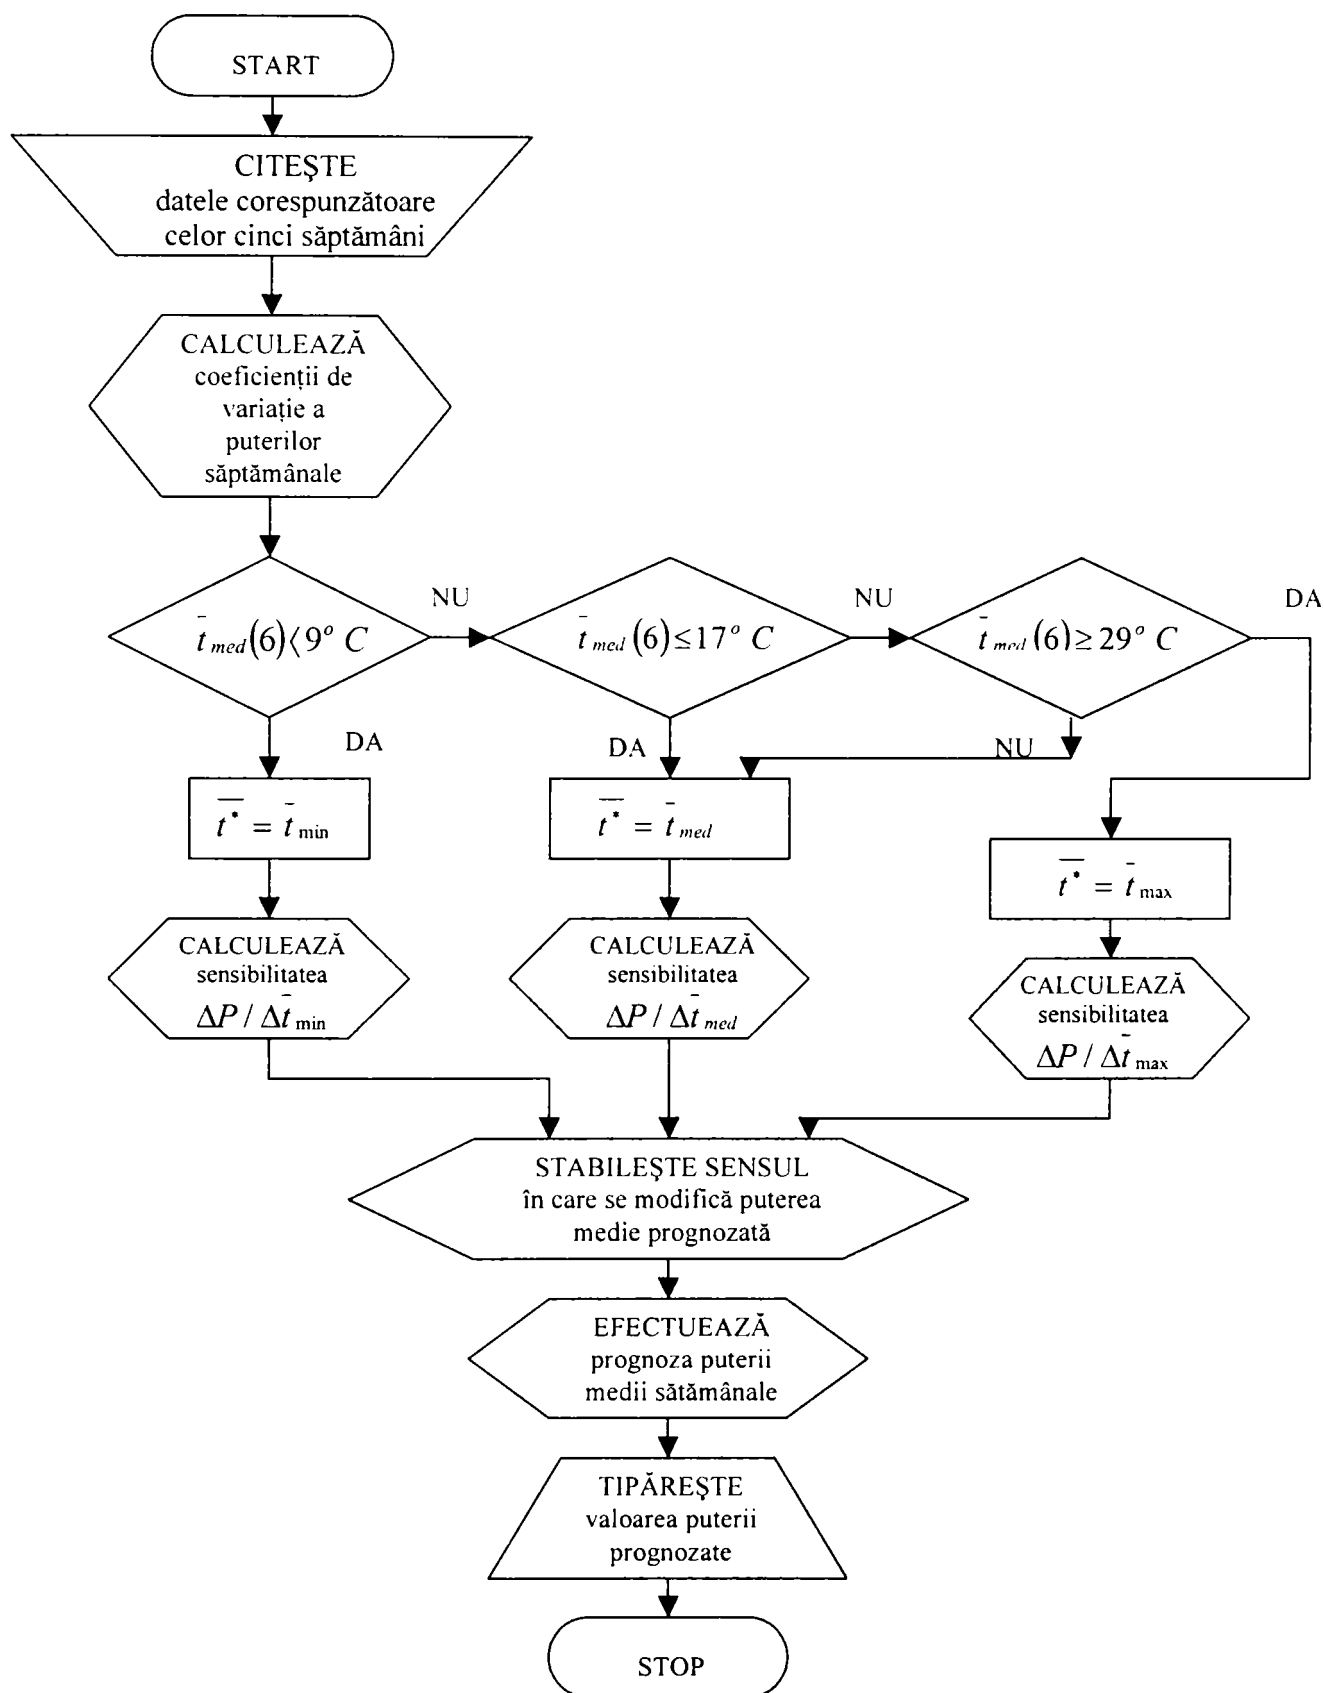


Figura 5.9. Ordinograma principală a algoritmului de calcul a puterii active medii săptămânale

8* *Intreabă dacă încălzirea este bruscă?, adică $\bar{t}_{med}(6) - \bar{t}_{med}(5) \geq 3,5^\circ C$*

DA. $k_p = 2k_p$. Du – tela 9

NU. Urmează sec ventă

9* *Calculează $P(6) = P(5) / [1 + k_p * (\bar{t}_{med}(6) - \bar{t}_{med}(5))]$ Du – tela 10*

11* *Intreabă $\bar{t}_{max}(6) \geq Med\{\bar{t}_{max}(i)\}$. DA. Temperatura crește. Du – tela 12*

NU. Temperatura se racește

** Calculează $P(6) = P(5) / [1 + k_p * (\bar{t}_{max}(6) - \bar{t}_{max}(5))]$ Du – tela 10*

12* *Intreabă dacă încălzirea este excesivă? adică $t_{max}(6) \geq 35^\circ C$.*

DA. $k_p = 2k_p$. Du – tela 13

NU.

13* *Calculează $P(6) = P(5) * [1 + k_p * (\bar{t}_{max}(6) - \bar{t}_{max}(5))]$*

10* *Tiparește $P(6) = \dots\dots\dots$*

Corespunzător acestui algoritm s-a conceput un program de calcul în Delphi. Rezultatele aplicării lui pentru primele 12 săptămâni din anul 2000 sunt prezentate în tabelul 5.12.

Din analiza celor prezentate în tabelul 5.12 se constată realizarea unor erori suficient de mici.

5.5.2. Prognoza energiilor zilnice

Pentru prognoza energiilor zilnice s-au utilizat doi algoritmi diferiți, primul are în vedere raportarea puterilor medii zilnice la puterea medie săptămânală și gruparea valorilor raportate dependent de distanța temperaturii zilnice față de temperatura medie săptămânală.

Al doilea algoritm descompune curba săptămânală a puterilor medii zilnice în trei armonici și efectuează prognoza coeficienților armonici dependent de temperaturile săptămânii.

5.5.2.1. Gruparea puterilor zilnice raportate

În cadrul acestui algoritm original, prezentat și în [5.13.], [5.14] ideea principală este aceea că raportul dintre puterea medie zilnică și puterea medie săptămânală depinde de “distanța” dintre temperatura medie a zilei \bar{t}^* și temperatura medie săptămânală $med(\bar{t}^*)$, aceasta (adică \bar{t}^*) putând fi temperatura minimă, medie sau maximă. Coeficienții calculați, adică puterile medii zilnice raportate sunt grupate în trei grupe, dependent de distanța dintre temperatura zilei și cea medie a săptămânii. Formarea a trei grupe de valori este obligatorie și dacă acest lucru nu se poate realiza în mod firesc pe baza datelor din cele 5 săptămâni, atunci algoritmul forțează crearea lor, considerând niște coeficienți de ajustare și anume 0.95, 1.0, respectiv 1.05.

Ordinograma principală a programului se prezintă în figura 5.10.

Algoritmul de efectuare a prognozei poate fi descris și prin prezentarea structurii etapelor de calcul.

Tabelul nr. 5.12 Prognoza puterilor medii săptămânale, săptămânile 1÷12, anul 2000, pentru consumatorul AT1 din stația Moșnița-Tișișoara

Săpt.	\bar{t}_{med} [°C]	Max {k(i)}	Max { $\Delta t_{min}(i)$ } [°C]	k_p [%/°C]	med($\bar{t}_{min}(i)$) [°C]	$\bar{t}_{min}(6)$ [°C]	$\bar{P}_{prog}(ur)$	$\bar{P}_{real}(ur)$	ϵ [%]
1	-2.286	1.1315	7.040	1.867	-2.578	-3.430	2.392	2.415	-0.941
2	-2.080	1.0745	7.040	1.058	-2.482	-4.100	2.432	2.467	-1.413
3	-2.170	1.0546	7.040	0.775	-3.242	-5.030	2.485	2.525	-1.590
4	-5.580	1.0546	6.300	<u>0.866</u> 0.433	-4.188	-10.430	2.584	2.542	1.655
5	3.829	1.0546	5.400	1.011	-4.806	-0.400	2.308	2.305	0.126
6	4.100	1.1028	10.030	0.998	-4.678	-0.770	2.297	2.285	0.504
7	2.586	1.1028	10.030	0.998	-4.146	-1.157	2.276	2.273	0.154
8	1.014	1.1028	10.030	0.998	-3.557	-3.300	2.224	2.186	1.738
9	4.300	1.1028	10.030	0.998	-1.371	-3.210	2.140	2.158	-0.805
10	5.300	1.0398	2.143	1.857	-1.371	1.416	2.103	2.089	0.655
11	2.130	1.0398	2.143	1.857	-1.254	-2.186	2.200	2.153	2.180
12	6.140	1.0398	2.143	1.857	-1.500	-0.270	2.086	2.089	-0.132

* Calculează $k(i)=P_{zi}(i) / P_m(i)$, $i = 1 ; 5$

* Întreabă cât este $\bar{t}_{med}(6)$, adică $\bar{t}_{med}(6) \leq 9^\circ$. **DA**, Du-te la 1
NU, Urmărește secvența

* Întreabă $\bar{t}_{med}(6) \geq 17^\circ C$. **DA**, Întreabă $t_{max}(6) \geq 29^\circ$. **DA**, Du-te la 2
NU, Du-te la 3

NU, Urmărește secvența

3 * Calculează $\Delta t_{med}(i)=ABS(t_{med zi}(i) - \bar{t}_{med}(i))$; $i = 1, 5$

* Grupează $\Delta t_{med}(i)$ în două grupe, prima : $\Delta t_{med}(i) \geq 2^\circ C$, adică
 $t_{med zi}(i) > \bar{t}_{med}(i)$. **DA**, $k(i)$ aparține subgrupeii 1
NU, $k(i)$ aparține subgrupeii 2

* Grupa a doua se caracterizează prin : $\Delta t_{med}(i) < 2^\circ C$

$$k^1 = \sum_{n_1} k(i) / n_1 \quad \text{pentru prima subgrupă}$$

* Calculează $k^2 = \sum_{n_2} k(i) / n_2$ *pentru a doua subgrupă*

$$k^3 = \sum_m k(i) / m \quad \text{pentru a doua grupă}$$

* Întreabă dacă k^1, k^2, k^3 există ? **Dacă DA**, du-te la 4

* Dacă **NU**, întreabă: există numai k^1 , *atunci* $k^2 = 1,03 k^1$
 $k^3 = (k^1 + k^2) / 2$

există numai k^2 , *atunci* $k^1 = 0,97 k^2$
 $k^3 = (k^1 + k^2) / 2$

există k^1, k^2 , *atunci* $k^3 = (k^1 + k^2) / 2$

există k^1, k^3 , *atunci* $k^2 = 2 k^3 - k^1$

există k^2, k^3 *atunci* $k^1 = 2 k^3 - k^2$

4 * Efectuează prognoza: unde se situează $\Delta t_{med}(6)=ABS [t_{med zi}(6) - \bar{t}_{med}(6)]$?

* Dacă se situează în prima grupă, cum este $t_{med zi}(6) > \bar{t}_{med}(6)$

DA, face parte din prima subgrupă $P_{zi}(6) = P_m(6) k^1$

NU, face parte din a doua grupă $P_{zi}(6) = P_m(6) k^2$

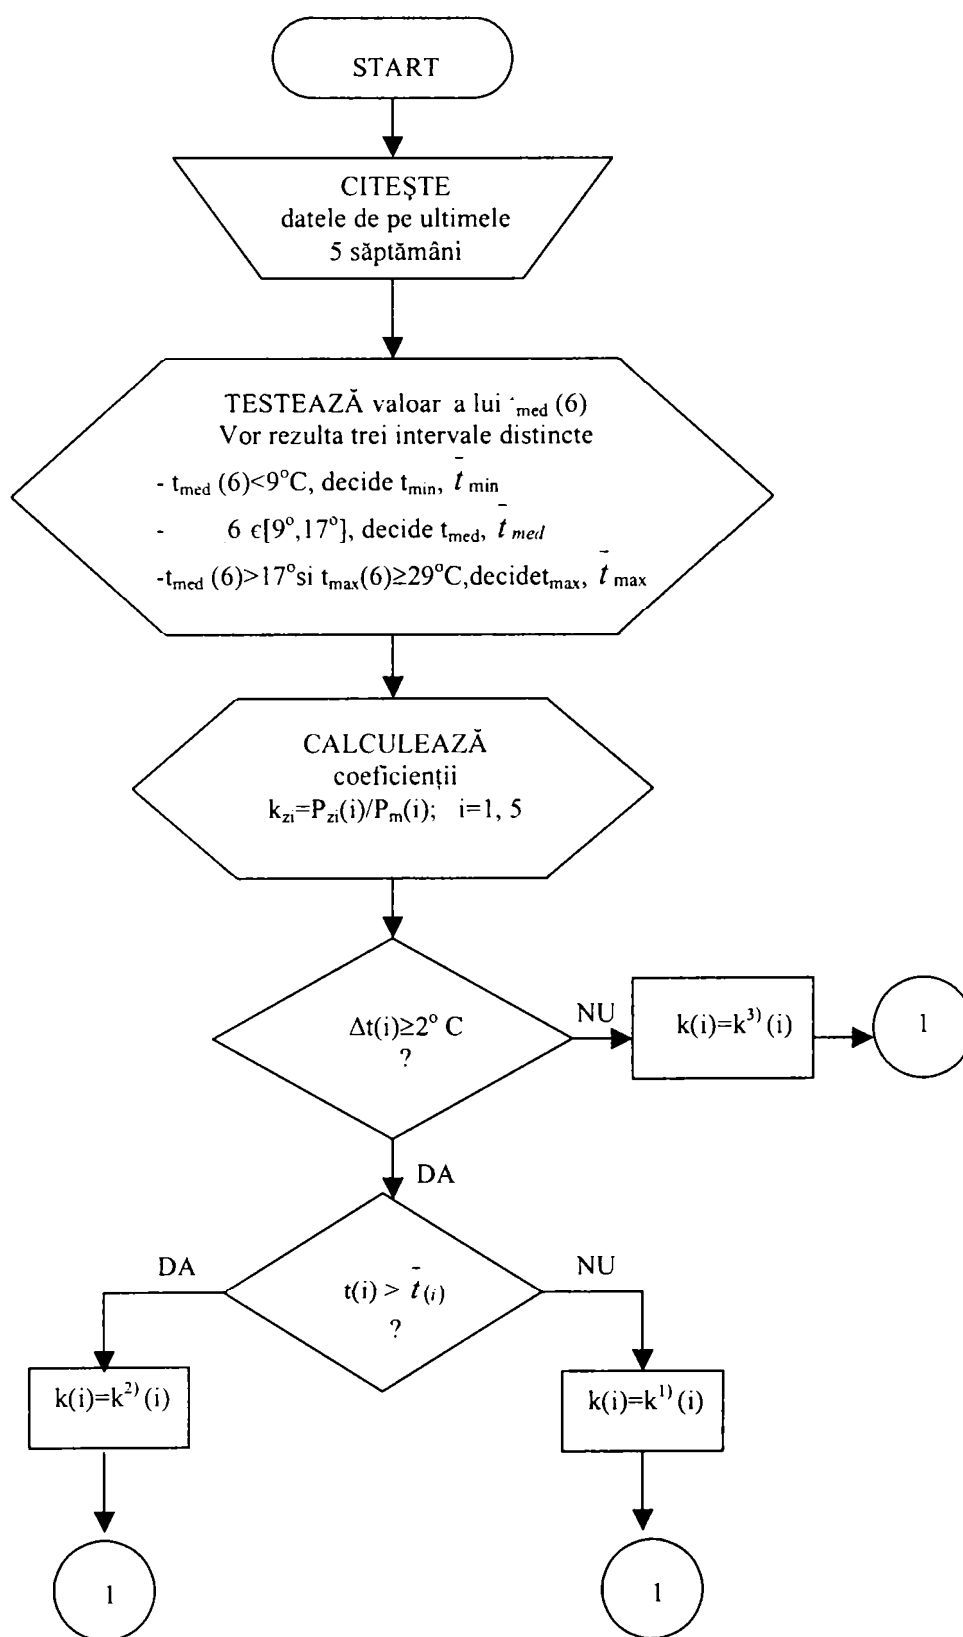
* Dacă se situează în a doua grupă $P_{zi}(6) = P_m(6) k^3$. Du-te la 10

1 * Calculează $\Delta t_{min}(i)=ABS(t_{min}(i) - \bar{t}_{min}(i))$

* Grupează $\Delta t_{min}(i)$ în două grupe; prima $\Delta t_{min}(i) \geq 2^\circ C$

$t_{min zi}(i) > \bar{t}_{min}(i)$. **DA**, $k(i)$ aparține subgrupeii 1

NU, $k(i)$ aparține subgrupeii 2



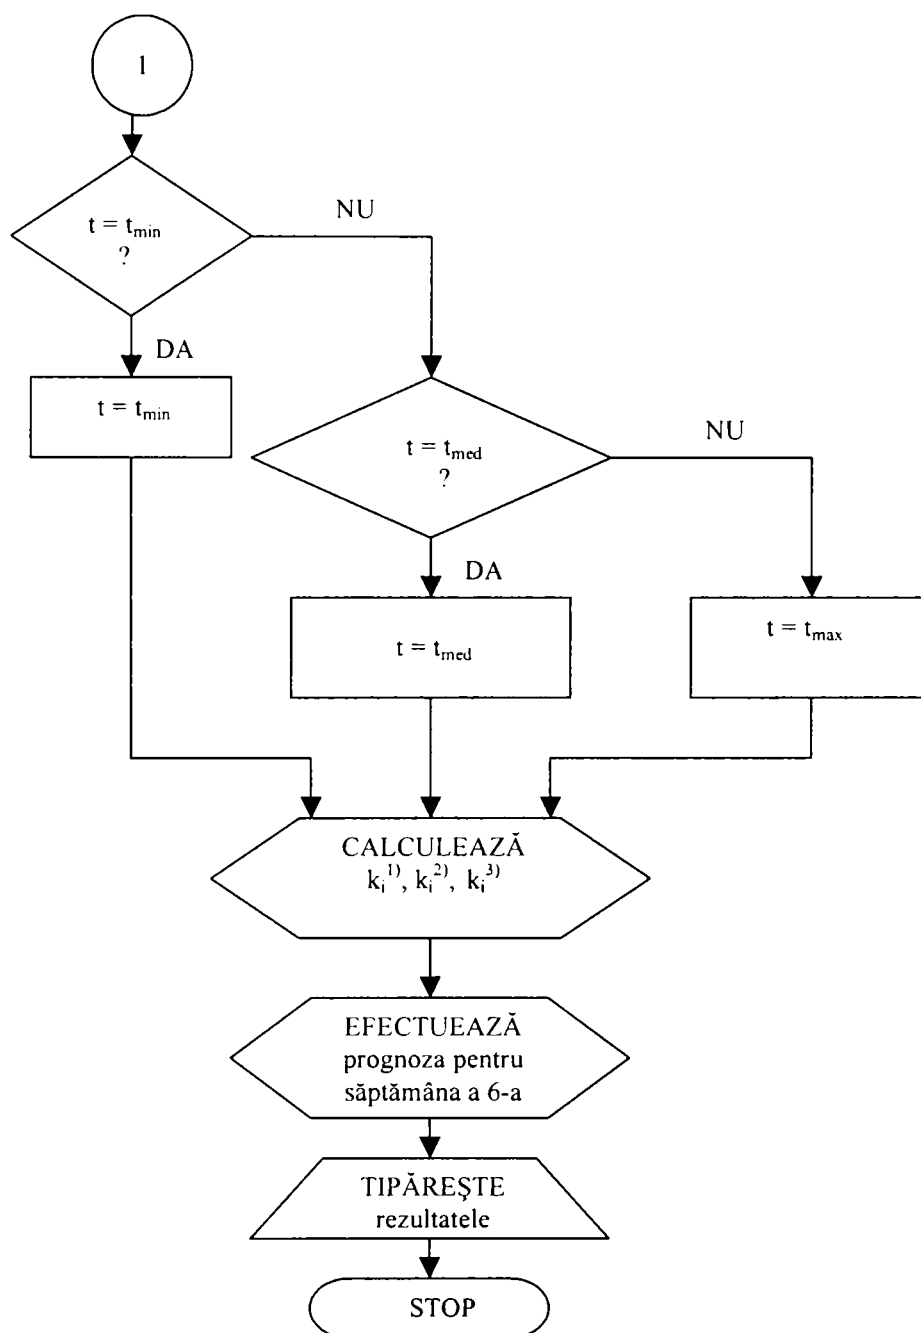


Figura 5.10. Ordinograma principală a algoritmului de calcul (prognoză) a puterilor medii zilnice folosind gruparea puterilor medii raportate

- * Grupa a doua se caracterizează prin $\Delta t_{\min}(i) < 2^\circ\text{C}$

$$k^{(1)} = \sum k(i) / n_1 \quad \text{pentru prima subgrupă}$$

- * Calculează $k^{(2)} = \sum k(i) / n_2$ pentru a doua subgrupă

$$k^{(3)} = \sum k(i) / m \quad \text{pentru a doua grupă}$$

- * Întreabă dacă $k^{(1)}, k^{(2)}, k^{(3)}$ există? Dacă **DA**, du-te la **5**

- * Dacă **NU**, întreabă: există numai $k^{(1)}$, atunci $k^{(2)} = 1,03 k^{(1)}$
 $k^{(3)} = (k^{(1)} + k^{(2)}) / 2$

$$\text{există numai } k^{(2)}, \quad \text{atunci } k^{(1)} = 0,97 k^{(2)}$$

$$k^{(3)} = (k^{(1)} + k^{(2)}) / 2$$

$$\text{există } k^{(1)}, k^{(2)}, \quad \text{atunci } k^{(3)} = (k^{(1)} + k^{(2)}) / 2$$

$$\text{există } k^{(1)}, k^{(3)}, \quad \text{atunci } k^{(2)} = 2 k^{(3)} - k^{(1)}$$

$$\text{există } k^{(2)}, k^{(3)} \quad \text{atunci } k^{(1)} = 2 k^{(3)} - k^{(2)}$$

- 5** * Efectuează prognoza; unde se situează $\Delta t_{\min}(6) = \text{ABS} [t_{\min zi}(6) - \bar{t}_{\min}(6)]$?

- * Dacă se situează în prima grupă, cum este $t_{\min zi}(6) > \bar{t}_{\min}(6)$?

$$\text{DA, face parte din prima subgrupă: } P_{zi}(6) = P_m(6) k^{(1)}$$

$$\text{NU, face parte din a doua subgrupă: } P_{zi}(6) = P_m(6) k^{(2)}$$

- * Dacă se situează în a doua grupă: $P_{zi}(6) = P_m(6) k^{(3)}$. Du-te la **10**

- 2** * Calculează $\Delta t_{\max}(i) = \text{ABS}(t_{\max zi}(i) - \bar{t}_{\max}(i))$

- * Grupează $\Delta t_{\min}(i)$ în două grupe; prima $\Delta t_{\max}(i) < 2^\circ\text{C}$

$$k^{(1)} = \sum_{n_1} k(i) / n_1 \quad \text{pentru prima subgrupă}$$

- * Calculează $k^{(2)} = \sum_{n_2} k(i) / n_2$ pentru a doua subgrupă

$$k^{(3)} = \sum_m k(i) / m \quad \text{pentru a doua grupă}$$

- * Întreabă dacă $k^{(1)}, k^{(2)}, k^{(3)}$ există? Dacă **DA**, du-te la **6**

- * Dacă **NU**, întreabă: există numai $k^{(1)}$, atunci $k^{(2)} = 0,97 k^{(1)}$
 $k^{(3)} = (k^{(1)} + k^{(2)}) / 2$

$$\text{există numai } k^{(2)}, \quad \text{atunci } k^{(1)} = 1,03 k^{(2)}$$

$$k^{(3)} = (k^{(1)} + k^{(2)}) / 2$$

$$\text{există } k^{(1)}, k^{(2)}, \quad \text{atunci } k^{(3)} = (k^{(1)} + k^{(2)}) / 2$$

$$\text{există } k^{(1)}, k^{(3)}, \quad \text{atunci } k^{(2)} = 2 k^{(3)} - k^{(1)}$$

există $k^{(2)}, k^{(3)}$ atunci $k^{(1)} = 2k^{(3)} - k^{(2)}$

- 6 * Efectuează prognoza; unde se situează $\Delta t_{\max}(6) = \text{ABS} [t_{\max \text{ zi}}(6) - \bar{t}_{\max}(6)]$?
- * Dacă se situează în prima grupă, cum este $t_{\max \text{ zi}}(6) > \bar{t}_{\max}(6)$?
 DA, face parte din prima subgrupă: $P_{zi}(6) = P_m(6) k^{(1)}$
 NU, face parte din a doua subgrupă: $P_{zi}(6) = P_m(6) k^{(2)}$
- * Dacă se situează în a doua grupă: $P_{zi}(6) = P_m(6) k^{(3)}$.
- 10 * Tipărește rezultatul obținut: **Puterea medie zilnică pentru ziua i din săptămâna a 6-a este: $P_{zi}(6) = \dots$**

5.5.2.2. Exemplu de aplicare

Săptămânile 1- 5, an 2000, prognoză săptămână 6 (7,8,9,10)

Ziua de Luni

- * $k_L(1) = 0,989$;
- * $k_L(2) = 1,025$;
- * $k_L(3) = 1,039$;
- * $k_L(4) = 1,008$;
- * $k_L(5) = 1,056$;
- * $t_{\text{med}}(6) < 9^\circ \text{C}$. DA este $4,1^\circ \text{C}$, deci t_{\min} și \bar{t}_{\min} decide
- * grupează pe k_L în trei categorii, funcție de distanța $\Delta t_{\min L}(i) = t_{\min L}(i) - \bar{t}_{\min}(i)$
- * $k_L(1) \Rightarrow$ corespunde la $\Delta t_{\min L}(1) = -3,43 + 4,3 = 0,87$, adică $k_L(1) = k_L^{(3)}$
- * $k_L(2) \Rightarrow$ corespunde la $\Delta t_{\min L}(2) = -4,10 + 5,4 = 1,03$, adică $k_L(2) = k_L^{(3)}$
- * $k_L(3) \Rightarrow$ corespunde la $\Delta t_{\min L}(3) = -5,03 + 6,4 = 1,37$, adică $k_L(3) = k_L^{(3)}$
- * $k_L(4) \Rightarrow$ corespunde la $\Delta t_{\min L}(4) = -10,43 + 8,8 = -1,63$, adică $k_L(4) = k_L^{(3)}$
- * $k_L(5) \Rightarrow$ corespunde la $\bar{t}_{\min} < t_{\min}(5)$, $k_L(5) = k_L^{(2)}$
- * calculează $k_L^{(1)}, k_L^{(2)}, k_L^{(3)}$. Astfel: $k_L^{(3)} = 1,01525$
 $k_L^{(2)} = 1,056$ se deduce $k_L^{(1)} = 0,9745$
- * stabilește $k_L(6)$; știind că $t_{\min L}(6) = -0,3$, iar $\bar{t}_{\min}(6) = -0,77$, adică $k_L(6)$ este de tipul $k_L^{(3)}$, adică 1,01525. Valoarea realizată efectiv a fost de 1,034, adică o abatere de 1,813%.
- * pentru $k_L(7)$; știind că $t_{\min L}(7) = -1,5$, iar $\bar{t}_{\min}(7) = -1,157$, adică $k_L(7)$ este de tipul $k_L^{(3)}$, adică 1,019. Valoarea realizată efectiv a fost de 1,007, adică o abatere de 1,177%.
- * pentru $k_L(9)$; știind că $t_{\min L}(9) = -4,1$, iar $\bar{t}_{\min}(9) = -1,23$, adică $k_L(9) = k_L^{(2)}$
- * se calculează întâi $k_L^{(2)}(9)$ ca fiind 1,056
- * rezultă $k_L(9) = 1,056$, adică o eroare de 1,53%
- * pentru $k_L(10)$, știind că $t_{\min L}(10) = -4,7^\circ \text{C}$, iar $\bar{t}_{\min}(10) = 0,186$, rezultă $k_L(10) = k_L^{(2)} = 1,048$, adică o eroare de -0,287%.

Raționamentul poate fi aplicat pentru orice zi din săptămână, inclusiv pentru zilele de odihnă. Astfel, pentru Duminică rezultă:

- * calculul lui k_D pentru primele cinci săptămâni.

$k_D(1) = 0,88$;

$k_D(2) = 0,887$;

$k_D(3) = 0,864$;

$$k_D(4) = 0,832;$$

$$k_D(5) = 0,851;$$

* $t_{\min}(6) < 9^\circ\text{C}$, deci decide t_{\min} și \bar{t}_{\min}

$$k_D(1) = k_D^{(2)}, \text{ întrucât } t_{\min}(1) < \bar{t}_{\min}$$

$$k_D(2) = k_D^{(3)}, \text{ întrucât } t_{\min}(2) \cong \bar{t}_{\min}$$

$$k_D(3) = k_D^{(2)}, \text{ întrucât } t_{\min}(3) < \bar{t}_{\min}$$

$$k_D(4) = k_D^{(1)}, \text{ întrucât } t_{\min}(4) > \bar{t}_{\min}$$

* Ca urmare, au rezultat $k_D^{(1)} = 0,832$; $k_D^{(2)} = 0,872$; $k_D^{(3)} = 0,887$

* $k_D(6) = k_D^{(2)} = 0,872$ față de 0,824, adică o eroare de 5,80%

* $k_D(7) = k_D^{(3)} = 0,887$ față de 0,845, adică o eroare de 4,97%

* $k_D(8) = k_D^{(3)} = 0,845$ față de 0,833, adică o eroare de 1,44%

* $k_D(9) = k_D^{(1)}$, întrucât $t_{\min}(9) > \bar{t}_{\min}(9)$, $k_D(1) = 0,832$

* $k_D(9) = 0,832$ față de 0,852 o eroare de 2,34%

* $k_D(10) = k_D^{(3)} = (0,845 + 0,833)/2 = 0,839$ față de 0,846, adică o eroare de -0,827%.

Înainte de a încheia această problemă este desigur util a urmări și evoluția coeficienților $k_{zi}(i)$ în funcție de mărimea și sensul lui $\Delta t_{\min} = t_{\min zi}(i) - \bar{t}_{\min}(i)$, de exemplu primele zece săptămâni din anul 2000 și zilele de Sâmbătă și Duminică.

Tabelul 5.13. Evoluția coeficienților $k_D(i)$ și $k_S(i)$ pentru $i=1, 10$ a anului 2000 în funcție de mărimea lui $\Delta t_{\min D, S}(i)$

i	$\Delta t_{\min S}(i)$	$k_S(i)$	$\Delta t_{\min D}(i)$	$k_D(i)$	Care din k decide	
					S	D
1	zero	0,948	mare și negativ	0,880	$k^{(3)}$	$k^{(2)}$
2	zero	0,925	zero	0,887	$k^{(3)}$	$k^{(3)}$
3	mare și negativ	0,912	mare și negativ	0,864	$k^{(2)}$	$k^{(2)}$
4	zero	1,002	mare și pozitiv	0,832	$k^{(3)}$	$k^{(1)}$
5	mare și negativ	0,954	mare și pozitiv	0,851	$k^{(2)}$	$k^{(1)}$
6	mare și negativ	0,873	mare și pozitiv	0,824	$k^{(2)}$	$k^{(1)}$
7	mare și negativ	0,933	zero	0,845	$k^{(2)}$	$k^{(3)}$
8	mare și pozitiv	0,864	zero	0,833	$k^{(1)}$	$k^{(3)}$
9	zero	0,919	mare și pozitiv	0,852	$k^{(3)}$	$k^{(1)}$
10	mare și negativ	0,904	zero	0,846	$k^{(2)}$	$k^{(3)}$

Cele prezentate în tabelul 5.13. sunt foarte utile atât pentru a urmări modul în care evoluează puterile în zilele de odihnă în unități raportate precum și modul în care acestea se grupează dependent de “distanța” dintre temperatura medie minimă săptămânală și cea minimă zilnică. Deși insuficiente pentru a stabili o concluzie mai generală, extinzând analiza la întreaga bază de date existentă pentru această perioadă, mai precis primul trimestru al anului, rezultă niște reguli foarte clare, mare parte din ele putând fi extinse pe întreaga durată a anului, mai puțin în zilele cu probleme (situații) deosebite.

Astfel:

- * puterea medie săptămânală este cu ceva mai mică sau egală cu puterea medie a zilei de Luni; adică $P_L \cong (1-1,03)P_{m\text{ sapt}}$;
- * puterea medie a zilei de Vineri este foarte apropiată de aceea a zilei de Luni; diferența poate fi cauzată de diferența de temperatură, dar cu o eroare de 3-4 % se poate aprecia $P_L \approx P_V$;
- * puterea medie a zilei de Sâmbătă este cuprinsă întotdeauna între cele ale zilelor de Vineri și Duminică ce o mărginesc; de multe ori (50-60 % din cazuri) se poate scrie o relație de forma: $P_S = (P_D + P_V)/2$;
- * consumul de energie cel mai mare se înregistrează de regulă în una din zilele de lucru: Marți, Miercuri, Joi;
- * în anotimpul friguros, ziua cu temperatura minimă nu corespunde cu ziua cu cel mai mare consum de energie electrică, diferența poate fi de câteva zile, poate chiar săptămâni;
- * în anotimpul călduros, ziua cu temperatura maximă poate corespunde cu ziua cu cel mai mare consum de energie electrică.

5.5.2.3. Analiza spectrală și prognoza coeficienților Fourier

O a doua posibilitate de prognoză a puterilor medii zilnice este aceea de a apela la descompunerea spectrală a curbelor săptămânale de puteri medii zilnice în armonici și de a prognoza în continuare coeficienții seriei Fourier.

O problemă deosebită care apare aici se referă la faptul că numărul de puncte (date) este șapte (numărul zilelor din săptămână) ca urmare nu se pot considera mai mult de 3 armonici și deci este discutabilă finetea interpolării curbei reale.

O propunere de ameliorare a acestei situații este de a forța alte puncte, între cele date, ca medie aritmetică a valorilor de la capete. În acest sens, în tabelul 5.14 se prezintă erorile de interpolare a curbelor săptămânale ale puterilor medii zilnice considerând 7 puncte și respectiv 13.

Primul set de erori, coeficienții ($A_k, B_k, k=1, 3$) au fost calculați considerându-se 7 puncte, corespunzătoare puterilor medii zilnice. Relațiile de calcul sunt cele cunoscute.

În al doilea caz s-au considerat 13 puncte, câte un punct suplimentar între două zile cunoscute. De exemplu între Luni și Marți, un punct de putere medie $(P_L + P_M)/2$, între Marți și Miercuri, un punct de putere medie $(P_M + P_{Mi})/2$, ș.a.m.d.

Din analiza erorilor realizate în cele două situații se pot trage următoarele concluzii:

- * în primele patru zile ale săptămânii erorile de interpolare sunt în general mici, în medie nedepășind 2-2,5 %; erori mai mari apar în prima zi, adică Luni;
- * în a doua parte a săptămânii, adică Vineri, Sâmbătă, Duminică, erorile cresc sensibil, atingând valori record de 10-13% Duminică; este cert că ziua de Duminică este ziua cel mai prost modelată;
- * prin creșterea numărului de puncte de interpolare, erorile se micșorează simțitor; spre exemplu, pentru zilele de lucru, erorile nu vor depăși decât izolat eroarea de 2 %;
- * pentru ziua de Sâmbătă erorile se reduc la aproape jumătate, erorile maxime nedepășind în această situație (în mod excepțional) 7 %;
- * pentru ziua de Duminică, reducerea erorilor este foarte puțin semnificativă, totuși în al doilea caz, eroarea de interpolare poate fi mai ușor controlată.

Cunoscând coeficienții seriilor Fourier se poate efectua prognoza acestora.

Referitor la prognoza coeficienților s-au încercat două tehnici și anume:

a) corelația liniară multiplă, considerând un model de forma:

$$c_k = a_0 + \sum_{i=1}^9 t_i \cdot a_i \quad (5.15)$$

unde:

t_i – sunt succesiv temperaturile săptămânii: min, med, și max din $\min(t_z)$, $\text{med}(t_z)$, $\max(t_z)$, t_z fiind temperatura zilei;

a_i – coeficienții corelației liniare; se determină apelând la analiza de regresie.

Astfel, spre exemplu, pentru primele 5 săptămâni ale anului 2000, considerând matricea temperaturilor de forma prezentată în tabelul 5.15.

Tabelul 5.14. Erorile de interpolare a curbelor săptămânale ale puterilor medii zilnice: săptămânile 1-10, anul 2000

Săptămăna	1	2	3	4	5	6	7	8	9	10
ε_L	-3,148	-1,515	-3,274	-3,846	-2,82	-5,287	-4,369	1,426	-2,162	-2,051
ε_M	-2,384	-0,703	2,319	1,214	3,604	2,124	0,555	-1,542	1,528	1,031
ε_{Mi}	1,493	1,184	-0,762	-1,504	-2,475	-0,276	-2,847	1,234	-4,777	-0,974
ε_J	1,66	-0,142	0,171	1,568	1,507	0,609	4,822	-0,517	4,932	0,661
ε_V	2,163	4,039	5,099	-0,565	2,014	7,134	2,72	8,29	3,632	5,25
ε_S	5,338	4,648	5,118	10,215	7,324	5,89	6,081	5,683	5,441	6,457
ε_D	-5,836	-8,129	-9,65	-8,58	-10,883	-12,133	-7,97	-13,464	-10,058	-11,796
A_1	0,128	0,132	0,160	0,079	0,121	0,210	0,152	0,16	0,138	0,139
A_2	0,035	0,084	0,130	0,095	0,122	0,138	0,061	0,121	0,081	0,112
A_3	0,032	0,027	0,024	0,077	0,054	0,017	0,045	0,032	0,050	0,036
B_1	0,15	0,117	0,128	0,160	0,097	0,167	0,173	0,143	0,147	0,131
B_2	0,034	0,01	$6,1 \cdot 10^{-3}$	0,067	0,015	0,010	$-2,2 \cdot 10^{-3}$	-0,037	-0,039	$-4,99 \cdot 10^{-3}$
B_3	-0,016	-0,028	$-2,49 \cdot 10^{-4}$	0,018	0,020	$-1,29 \cdot 10^{-3}$	0,029	-0,056	0,028	-0,011
ε_L	-0,102	1,892	0,088	1,118	1,076	-0,653	0,281	1,71	1,453	0,956
ε_M	-0,904	0,195	1,496	0,505	1,691	1,618	0,349	-0,25	1,624	0,751
ε_{Mi}	1,435	-0,60	-0,210	0,126	-0,961	0,136	0,737	0,993	-4,126	-0,222
ε_J	1,312	1,173	0,691	1,347	1,292	1,108	3,237	0,663	3,032	1,00
ε_V	1,477	3,693	2,837	0,148	1,107	3,993	1,602	4,635	2,43	2,887
ε_S	3,711	1,219	3,577	6,729	4,93	4,241	4,394	4,218	4,307	4,43
ε_D	-5,827	-7,842	-9,657	-9,357	-11,304	-12,152	-8,374	-12,201	-9,654	-11,511
A_1	0,123	0,123	0,145	0,065	0,105	0,195	0,143	0,148	0,135	0,125

A ₂	0,036	0,036	0,126	0,076	0,108	0,138	0,059	0,119	0,058	0,105
A ₃	0,03	0,03	0,037	0,062	0,053	0,037	0,042	0,044	0,063	0,041
B ₁	0,135	0,107	0,119	0,138	0,087	0,154	0,161	0,140	0,159	0,124
B ₂	0,039	0,018	0,018	0,064	0,014	0,017	$2,14 \cdot 10^{-3}$	-0,018	-0,041	$3,23 \cdot 10^{-3}$
B ₃	$-6,7 \cdot 10^{-3}$	-0,018	-0,018	0,028	0,021	$3,96 \cdot 10^{-3}$	0,029	-0,048	0,025	$-6,94 \cdot 10^{-3}$

Tabelul 5.15. Matricea temperaturilor pentru primele 5 săptămâni ale anului 2000

Săptămâna	min(t _{min})	med(t _{min})	max(t _{min})	min(t _{med})	med(t _{med})	ma(t _{med})	min(t _{max})	med(t _{max})	max(t _{max})
1	-5,4	-3,43	-0,9	-4,6	-2,286	-0,2	-3,0	-0,94	0,7
2	-5,5	-4,10	-2,3	-3,8	3,400	-1,3	-1,8	-0,53	-1,3
3	-10,1	-5,03	-1,0	-7,2	-2,170	1,8	-4,2	1,30	5,0
4	-20,1	-10,43	2,6	-12,7	-5,580	3,9	-4,0	0,06	3,9
5	-4,0	-0,40	2,2	0,4	3,830	6,3	4,2	9,83	13,5

s-a obținut următoarea matrice a coeficienților prezentată în tabelul 5.16.

Tabelul 5.16. Matricea coeficienților

	A ₁	A ₂	A ₃	B ₁	B ₂	B ₃
a ₀	-0,08430	-0,08300	0,17350	-0,423415	-0,4404	0,1410
a ₁	-0,00705	0,06040	0,00870	-0,07095	-0,0209	-0,0048
a ₂	-0,07200	0,04979	-0,00230	-0,79053	-0,0489	-0,0170
a ₃	0,06520	-0,14580	0,00980	0,240697	0,1015	0,0100
a ₄	0,01006	-0,02457	0,002144	0,04112	0,01397	0,00479
a ₅	-0,05890	0,07670	-0,003714	-0,13950	-0,0487	-0,0028
a ₆	-0,34800	0,54020	-0,033069	-0,93629	-0,3290	-0,0247
a ₇	0,01097	-0,02150	0,000377	0,01543	0,00946	-0,0053
a ₈	0,17630	-0,24330	0,015934	0,44693	0,15208	0,01370
a ₁₀	0,04480	-0,06060	0,003990	0,11275	0,03810	0,00365

Efectuând prognoza pentru săptămâna 6, au rezultat valorile pentru coeficienții din tabelul 5.17. Alăturat au fost înscrise și valorile efectiv realizate.

Tabelul 5.17. Valorile prognozate și realizate ale coeficienților

	A ₁	A ₂	A ₃	B ₁	B ₂	B ₃
Prognozată	0,0678	-0,036	-0,198	-0,627	-0,526	0,116
Realizat	0,195	0,138	0,037	0,154	0,017	$3,96 \cdot 10^{-3}$

Din analiza celor prezentate mai sus se constată o diferență sensibilă între valorile prognozate și cele efectiv realizate. Mai mult, calculându-se coeficientul de corelație multiplă, a rezultat o valoare mai mică decât 0,1. Deci această cale trebuie abandonată;

b) corelația liniară sau pătratică simplă; s-au calculat coeficienții de corelație dintre fiecare coeficient și cele nouă temperaturi. S-a reținut corelația cu coeficientul de

corelație, în modul, de valoarea cea mai mare. Au rezultat, pentru aceeași aplicație, următoarele valori:

$$r(A_1, \max(t_{\min})) = -0.0027$$

$$r(A_2, \max(t_{\max})) = 0,747$$

$$r(A_3, \max(t_{\min})) = 0,958$$

$$r(B_1, \text{med}(t_{\text{med}})) = -0,912$$

$$r(B_2, \text{med}(t_{\min})) = -0,775$$

$$r(B_3, \max(t_{\min})) = 0,9709$$

Se poate constata că pentru trei coeficienți (A_3, B_1, B_3) pot fi folosite corelații liniare în funcție de $\max(t_{\min})$; $\text{med}(t_{\text{med}})$; $\max(t_{\min})$. Pentru ceilalți coeficienți A_2, B_2 , se pot adopta corelații pătratice iar pentru A_1 se poate accepta ultima valoare realizată.

Soluția din urmă rămâne oricum la dispoziție în condițiile în care sistemul de calcul nu găsește altă variantă.

În acest sens, considerând pentru A_k și B_k valorile din săptămâna 5 și puterea medie corespunzătoare s-au calculat puterile medii zilnice din săptămâna 6, obținându-se valorile din tabelul 5.18.

Tabelul 5.18. Puterile medii zilnice pentru săptămâna 6

P_m \ zi	Luni	Martți	Miercuri	Joi	Vineri	Sâmbata	Duminica
Efectiv realizate	2,364	2,518	2,423	2,444	2,371	1,995	1,882
Simulate cu coef. Fourier exact	2,390	2,376	2,345	2,363	2,307	2,062	2,163
Simulate cu coef. Fourier din sapt. 5	2,389	2,377	2,344	2,364	2,307	2,062	2,164
Eroare (%)	-1,210	5,655	3,230	2,314	-1,602	-3,360	-14,950

Din cele prezentate în tabelul 5.18 rezultă faptul că nici aici nu se justifică considerarea prognozei coeficienților seriei Fourier, eventual a tuturor coeficienților în raport cu anumiți parametri. Fără îndoială că anumiți coeficienți Fourier, care prezintă o stabilitate foarte bună de la o săptămână la alta, nu mai trebuie să fie prognozați.

Poate fi considerată eroarea relativ mare pentru ziua de Duminică și compensată cu ajutorul erorii realizată în cursul săptămânii anterioare.

5.5.3. Prognoza curbelor de sarcină zilnice

Așa cum s-a mai prezentat, pentru prognoza curbelor de sarcină zilnice s-a folosit descompunerea spectrală a curbelor de sarcină. S-a apreciat, pe baza celor relatate la paragraful 5.2.2. că, considerarea a două armonici este suficientă, eroarea de metodă introdusă putând fi compensată printr-o corecție corespunzătoare. Pentru aprecierea corelației liniare a coeficienților Fourier cu temperaturile zilei sau în general cu alți factori (indicatori) s-a considerat ca fiind util a analiza și alți coeficienți Fourier, de exemplu:

$C_k = \sqrt{A_k^2 + B_k^2}$ și $\alpha_k = a \tan(B_k / A_k)$, unde $k = 1, 2$. S-a constatat că, coeficienții C_k prezintă o stabilitate mult mai bună cu factorii meteorologici. Ca urmare, au fost analizate următoarele corelații:

- | | |
|------------------------------|---------------------------------|
| 1) $t_{\min} - k_u$ | 14) $t_{\text{med}} - \alpha_1$ |
| 2) $t_{\text{med}} - k_u$ | 15) $t_{\max} - \alpha_1$ |
| 3) $t_{\max} - k_u$ | 16) $t_{\min} - \alpha_2$ |
| 4) $t_{\min} - \alpha$ | 17) $t_{\text{med}} - \alpha_2$ |
| 5) $t_{\text{med}} - \alpha$ | 18) $t_{\max} - \alpha_2$ |
| 6) $t_{\max} - \alpha$ | 19) $k_u - C_1$ |
| 7) $t_{\min} - C_1$ | 20) $k_u - C_2$ |
| 8) $t_{\text{med}} - C_1$ | 21) $k_u - \alpha_1$ |
| 9) $t_{\max} - C_1$ | 22) $k_u - \alpha_2$ |
| 10) $t_{\min} - C_2$ | 23) $\alpha - C_1$ |
| 11) $t_{\text{med}} - C_2$ | 24) $\alpha - C_2$ |
| 12) $t_{\max} - C_2$ | 25) $\alpha - \alpha_1$ |
| 13) $t_{\min} - \alpha_1$ | 26) $\alpha - \alpha_1$ |
| | 27) $\alpha - k_u$ |

unde:

k_u - coeficientul de utilizare a curbei de sarcină $k_u = \frac{P_{\text{med}}}{P_{\text{max}}}$

α - coeficientul de uniformizare a curbei de sarcină $\alpha = \frac{P_{\min}}{P_{\max}}$

$$C_1 = \sqrt{A_1^2 + B_1^2}, \quad \alpha_1 = a \tan(B_1 / A_1)$$

$$C_2 = \sqrt{A_2^2 + B_2^2}, \quad \alpha_2 = a \tan(B_2 / A_2)$$

Pentru cele 27 de corelații de mai sus s-au calculat coeficienții de corelație în funcție de numărul de săptămâni luate în considerare. Acest număr de săptămâni s-a modificat în limitele 5 – 12, apreciindu-se că peste 12 săptămâni nu se mai poate vorbi de o prognoză pe termen scurt.

Variația coeficienților de corelație se prezintă în figura 5.11.

De remarcat că, pentru 5 săptămâni, cele mai intense corelații liniare sunt în ordine:

$t_{\text{med}} - \alpha_2, t_{\min} - \alpha_2, t_{\max} - \alpha_2, k_u - C_1, t_{\min} - \alpha_1, t_{\min} - C_2, k_u - \alpha_2, t_{\text{med}} - C_1, \alpha - k_u, k_u - C_2,$
 $t_{\max} - C_1, t_{\max} - \alpha, t_{\text{med}} - \alpha;$

Pentru procesul de prognoză al coeficienților $C_{1,2}$ și $\alpha_{1,2}$ sunt utile corelațiile 7-12 și 13-18. În acest sens, se constată o bună stabilitate a corelațiilor liniare $(t_{\text{med}}, C_1), (t_{\min}, C_2); (t_{\min}, \alpha_2); (t_{\text{med}}, \alpha_2); (t_{\max}, \alpha_2)$ pentru maximum 7-8 săptămâni și (t_{\min}, α_1) pentru 5 săptămâni, respectiv $(t_{\text{med}}, \alpha_1)$ pentru 8-12 săptămâni.

S-a propus o modelare de forma:

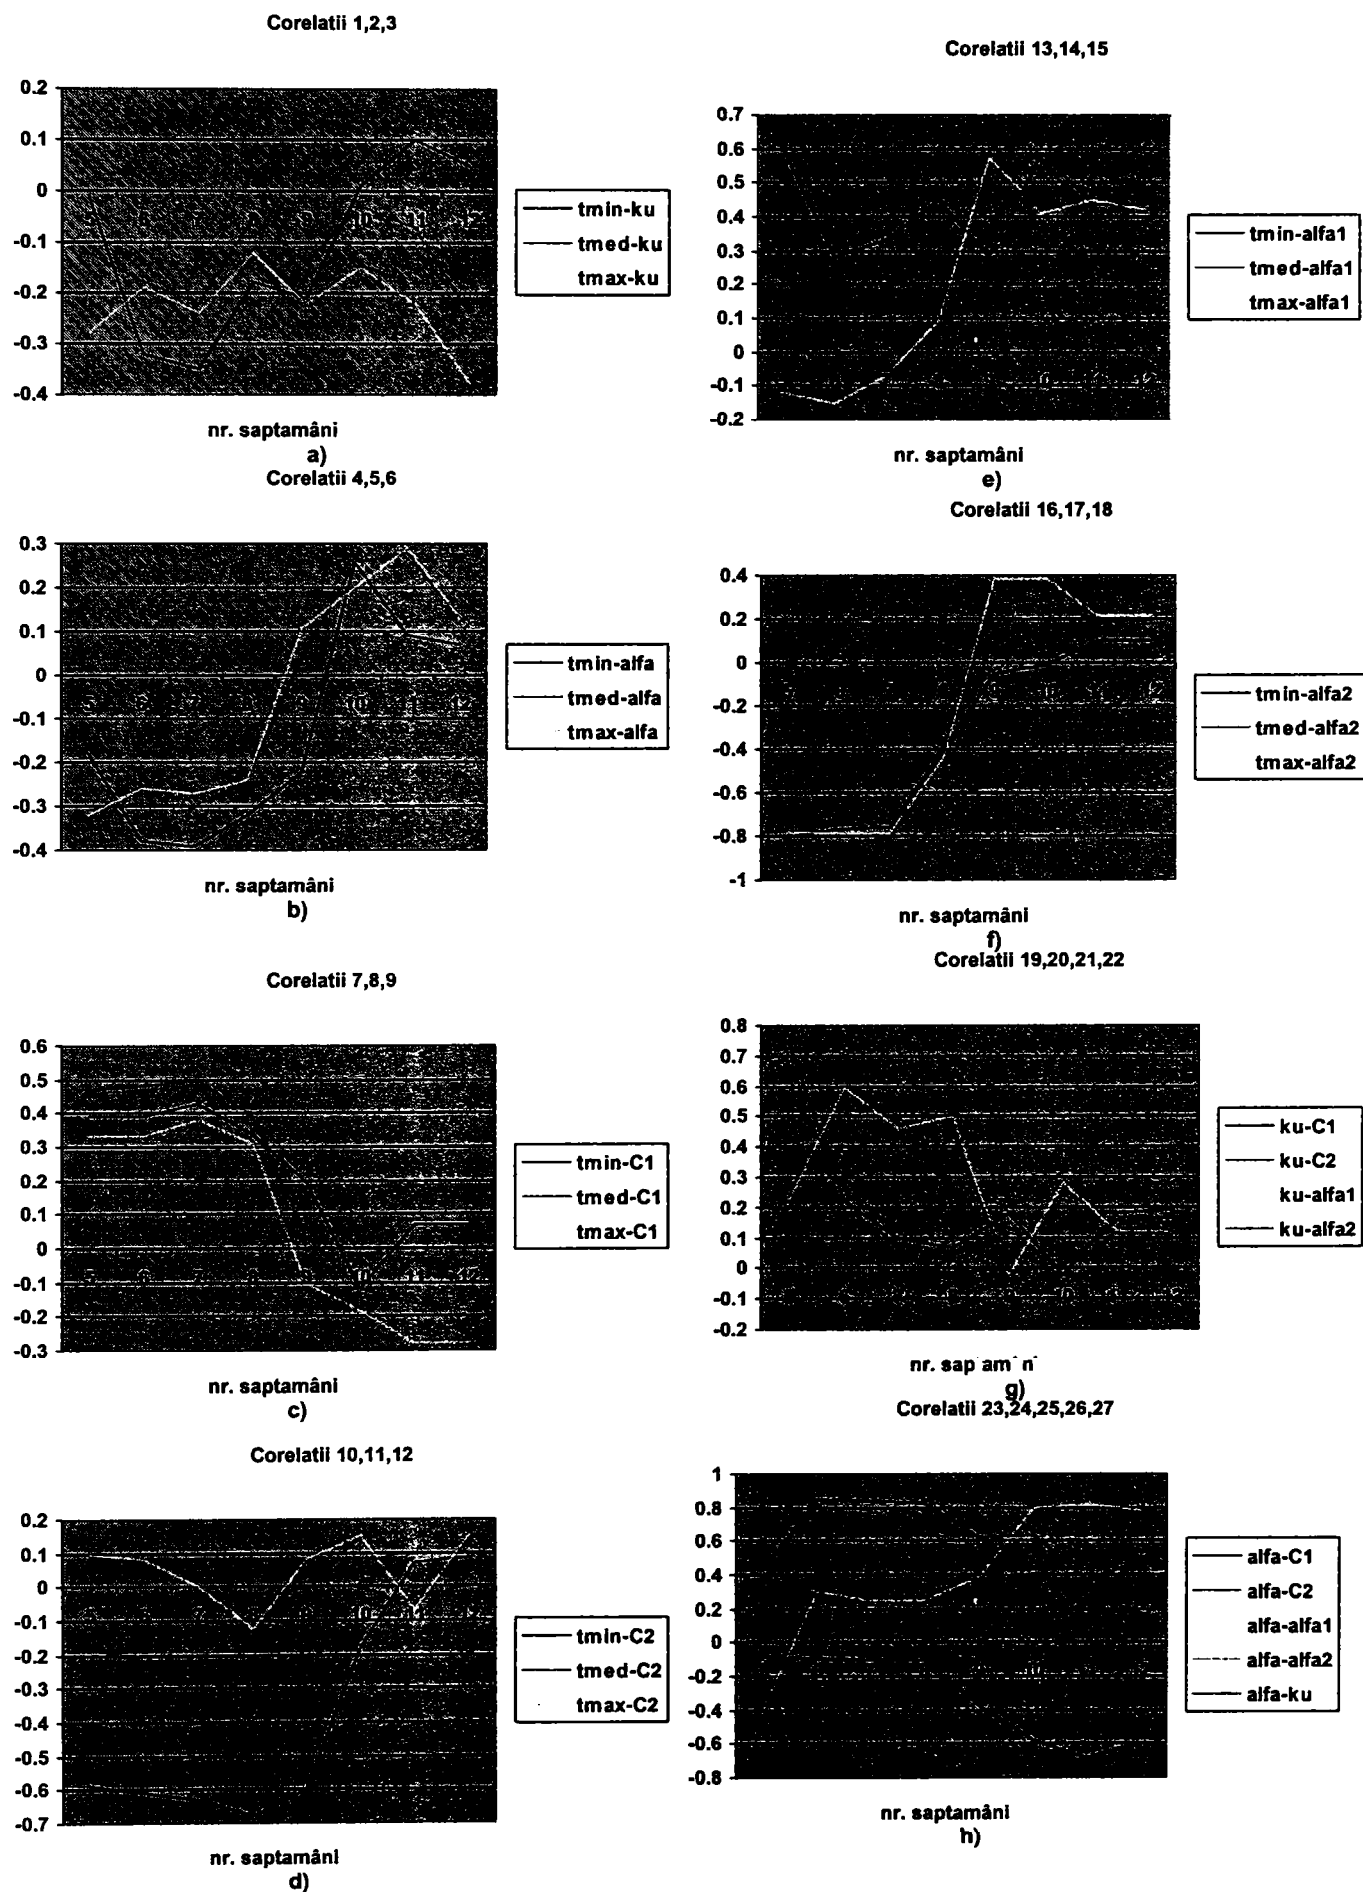


Figura 5.11. Variația coeficienților de corelație cu numărul de săptămâni pentru cele 27 de corelații menționate: a) 1,2,3; b) 4,5,6; c) 7,8,9; d) 10,11,12; e) 13,14,15; f) 16,17,18; g) 19,20,21,22; h) 23,24,25,26,27.

$$C_{1,2} = a + b \cdot t_{\min} + c \cdot t_{\text{med}} + d \cdot t_{\max},$$

respectiv

$$\alpha_{1,2} = a' + b' \cdot t_{\min} + c' \cdot t_{\text{med}} + d' \cdot t_{\max}$$
(5.16)

Pentru primele 10 săptămâni ale anului 2000, considerându-se baza de date corespunzătoare tabelului 5.19 s-au obținut valorile înscrise în tabelul 5.20.

Tabelul 5.19. Baza de date aferentă calculului coeficienților $C_{1,2}$, $\alpha_{1,2}$ și valorile acestora pentru primele 10 săptămâni ale anului 2000

săptămâna	$t_{\min}[^{\circ}\text{C}]$	$t_{\text{med}}[^{\circ}\text{C}]$	$t_{\max}[^{\circ}\text{C}]$	C_1	C_2	α_1 (2000)	α_2 (2000)
1	0,6	1,4	2,4	0,397	0,218	2,267	2,836
2	0	4,6	9,8	0,368	0,277	2,215	2,922
3	-3	1,7	9,6	0,344	0,270	2,106	2,857
4	-3,4	-3,1	-2,7	0,454	0,262	2,170	3,053
5	-7,2	-5,7	-3,8	0,414	0,279	2,170	3,099
6	-0,2	1,1	4,5	0,476	0,248	2,095	2,93
7	-3,7	-1,9	-0,1	0,362	0,274	2,12	3,09
8	1,2	4,9	9,0	0,416	0,242	2,23	3,12
9	-0,9	5,6	14,5	0,248	0,277	2,63	3,67
10	3,4	4,9	8,0	0,229	0,295	3,14	3,104

Tabelul 5.20. Valori prognozate pentru coeficienții $C_{1,2}$, $\alpha_{1,2}$ și erori corespunzătoare [%]

săptămâna	C_1	ϵ_{C1} [%]	C_2	ϵ_{C2} [%]	α_1	$\epsilon_{\alpha1}$ [%]	α_2	$\epsilon_{\alpha2}$ [%]
6	0,388	-18,500	0,259	4,435	2,190	4,530	2,74	-6,48
7	0,434	19,890	0,263	-4,015	2,160	1,880	3,15	1,94
8	0,388	6,730	0,256	5,780	2,079	-0,151	3,07	-1,60
9	0,251	1,195	0,283	2,166	2,310	-12,170	3,51	-4,36
10	0,238	3,782	0,299	-1,338	2,870	-8,590	3,22	3,74

În ceea ce privește calculul (prognoza) curbelor de sarcină zilnice, acesta se efectuează conform algoritmului de mai jos și anume :

- * Se consideră în ordine curbele de sarcină pentru fiecare zi din săptămână (Luni, Marți, Miercuri etc);
- * Se descompune fiecare curbă de sarcină în armonici cu relațiile cunoscute :

$$A_k = \frac{1}{k \pi} \sum_{i=1}^{24} P(i) \left[\cos\left(\frac{k \pi (i-1)}{12}\right) - \cos\left(\frac{k \pi i}{12}\right) \right] \quad \text{și}$$

$$B_k = \frac{1}{k \pi} \sum_{i=1}^{24} P(i) \left[\sin\left(\frac{k \pi (i-1)}{12}\right) - \sin\left(\frac{k \pi i}{12}\right) \right]$$

unde: $k = 1, 2$ iar $i = 1, 24$ și se referă la cele 24 de intervale orare ale zilei.

- * Se calculează coeficienții C_k și φ_k

Cazuri $A_k > 0 ; B_k > 0$, *cadran 1* , $\varphi_k \leq \pi / 2$

$A_k < 0 ; B_k > 0$, *cadran 2* , $\varphi_k = \pi - \tan^{-1} (B_k / |A_k|)$

$A_k < 0 ; B_k < 0$, *cadran 3* , $\varphi_k = \pi + \tan^{-1} (|B_k| / |A_k|)$

$A_k > 0 ; B_k < 0$, *cadran 4* , $\varphi_k = 2\pi - \tan^{-1} (|B_k| / A_k)$

- * Pentru coeficienții C_i, φ_i se probează un model de simulare de forma:

$$C_k = a + b t_{\min} + c t_{\text{med}} + d t_{\max},$$

pentru care sistemul normal de unde se determină coeficienții are forma:

$$\begin{cases} \sum_1^5 C_k = a \cdot 5 + b \sum_1^5 t_{\min} + c \sum_1^5 t_{\text{med}} + d \sum_1^5 t_{\max} \\ \sum C_k \cdot t_{\min} = a \sum t_{\min} + b \sum t_{\min}^2 + c \sum t_{\text{med}} t_{\min} + d \sum t_{\min} t_{\max} \\ \sum C_k \cdot t_{\text{med}} = a \sum t_{\text{med}} + b \sum t_{\min} t_{\text{med}} + c \sum t_{\text{med}}^2 + d \sum t_{\text{med}} t_{\max} \\ \sum C_k \cdot t_{\max} = a \sum t_{\max} + b \sum t_{\min} t_{\max} + c \sum t_{\text{med}} t_{\max} + d \sum t_{\max}^2 \end{cases} \quad (5.17)$$

Rezultă a, b, c, d

- * Apreciază calitatea modelării calculând coeficientul de corelație multiplă, astfel:

$$R_{c_k}^2 = 1 - \frac{\sum_1^5 [c_k(i) - \hat{c}_k(i)]^2}{\sum_1^5 [c_k(i) - \bar{c}_k(i)]^2} \quad \text{unde } \hat{c}_k \text{ este valoarea calculată cu modelul admis}$$

$$\bar{c}_k = \sum c_k(i) / 5, \text{ valoarea medie a lui } c_k$$

- * Dacă $R_{c_k}^2 \leq 0,6$, calitatea este necorespunzătoare și se trece la analiza corelațiilor liniare simple:

$(C_k, t_{\min}); (C_k, t_{\text{med}}); (C_k, t_{\max})$.

- * Se reține corelația cea mai intensă și, corespunzător, i se atașează modelul corespunzător. Cu acesta, odată determinat, se efectuează și operația de prognoză.
- * Din valorile lui C_k, φ_k se deduc valorile lui A_k, B_k .
- * Calculează puterile active approximate pentru săptămâna 5 și ora i, $i = 1, 24$.

$$* \bar{P}(5, i) = P_m(5) + \sum_{k=1,2} \left[A_k \sin\left(\frac{k \pi i}{12}\right) - B_k \cos\left(\frac{k \pi i}{12}\right) \right] \quad i = 1, 24$$

* Calculează erorile orare :

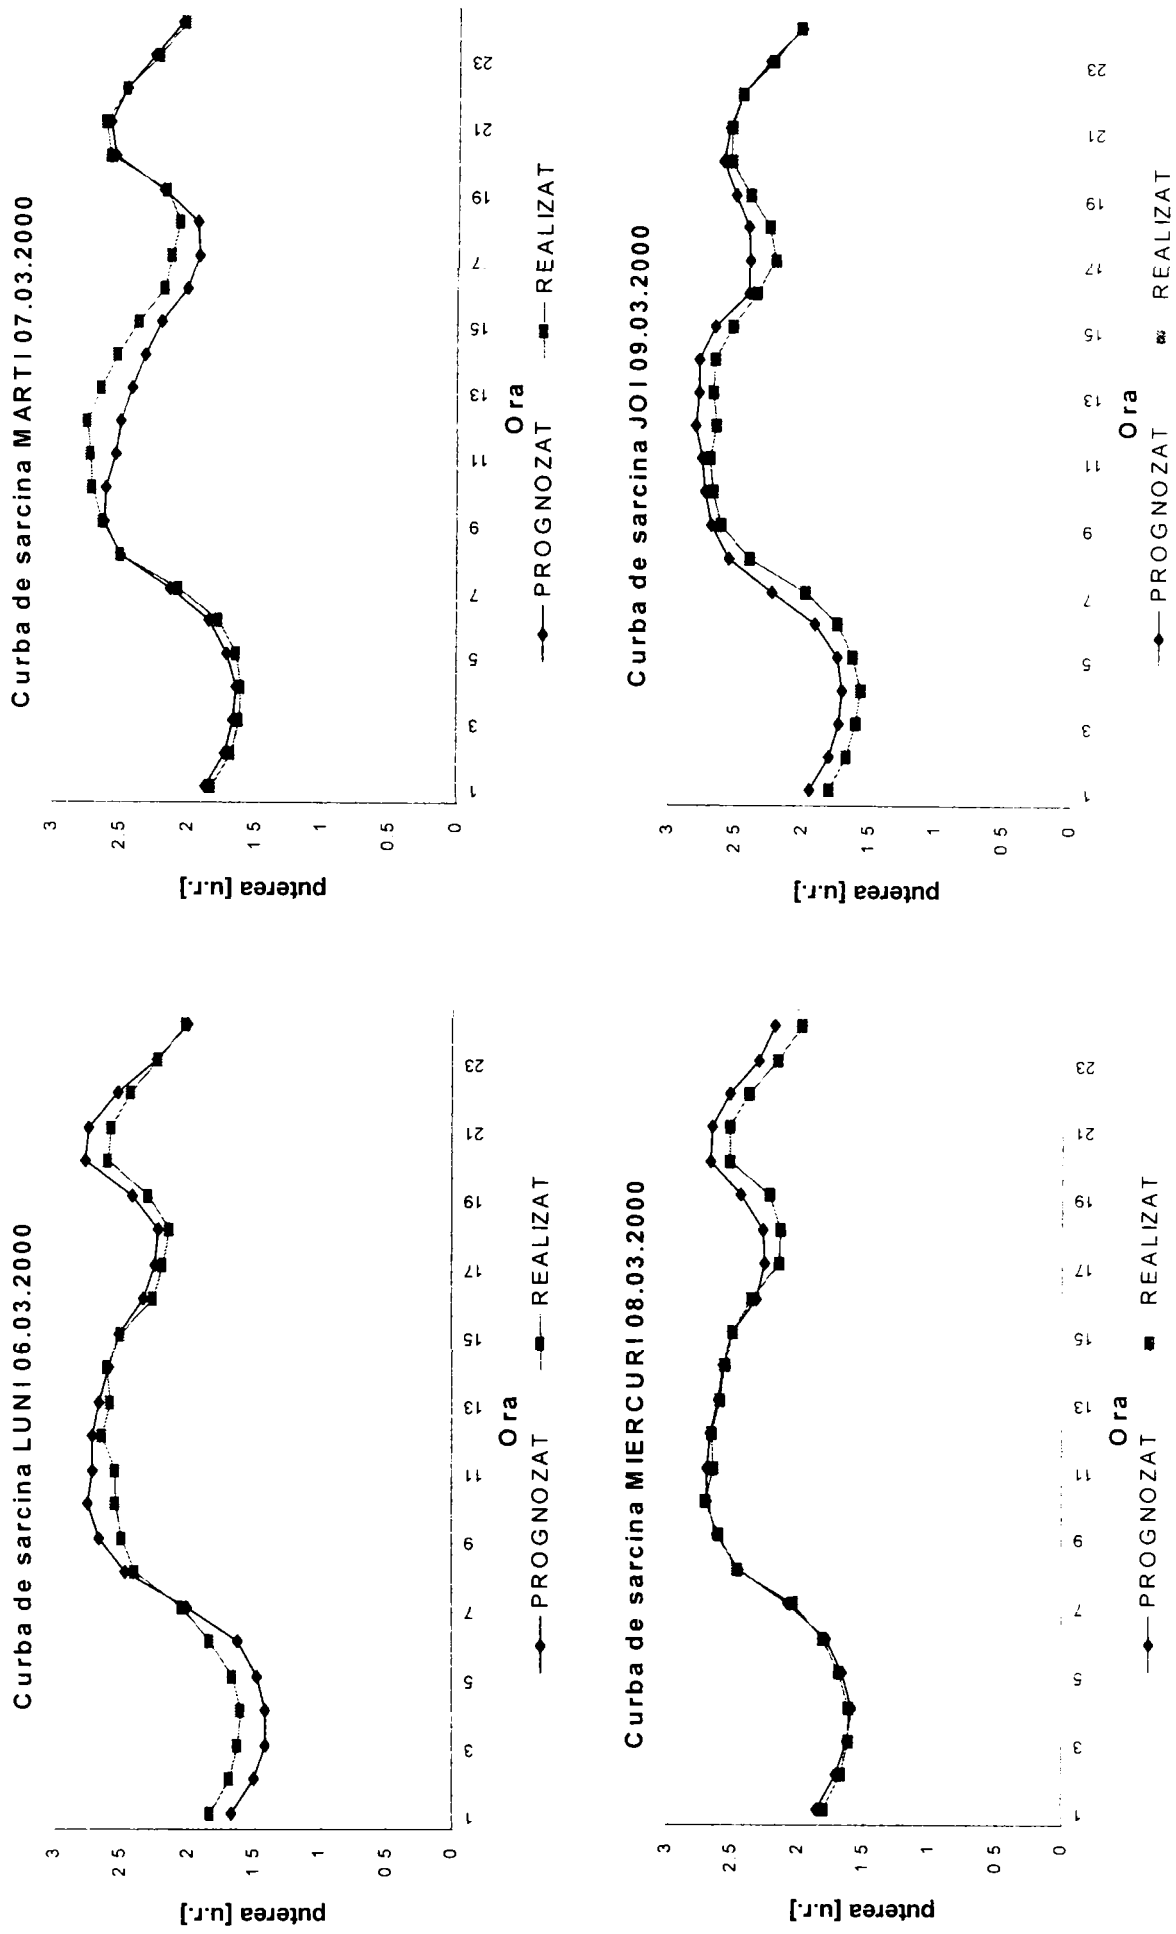
$$* \varepsilon(5, i) = [P(5, i) - \bar{P}(5, i)] / P(5, i) \quad i = 1, 24$$

* Corectează valorile puterilor orare, corespunzător erorile realizate în săptămâna 5.

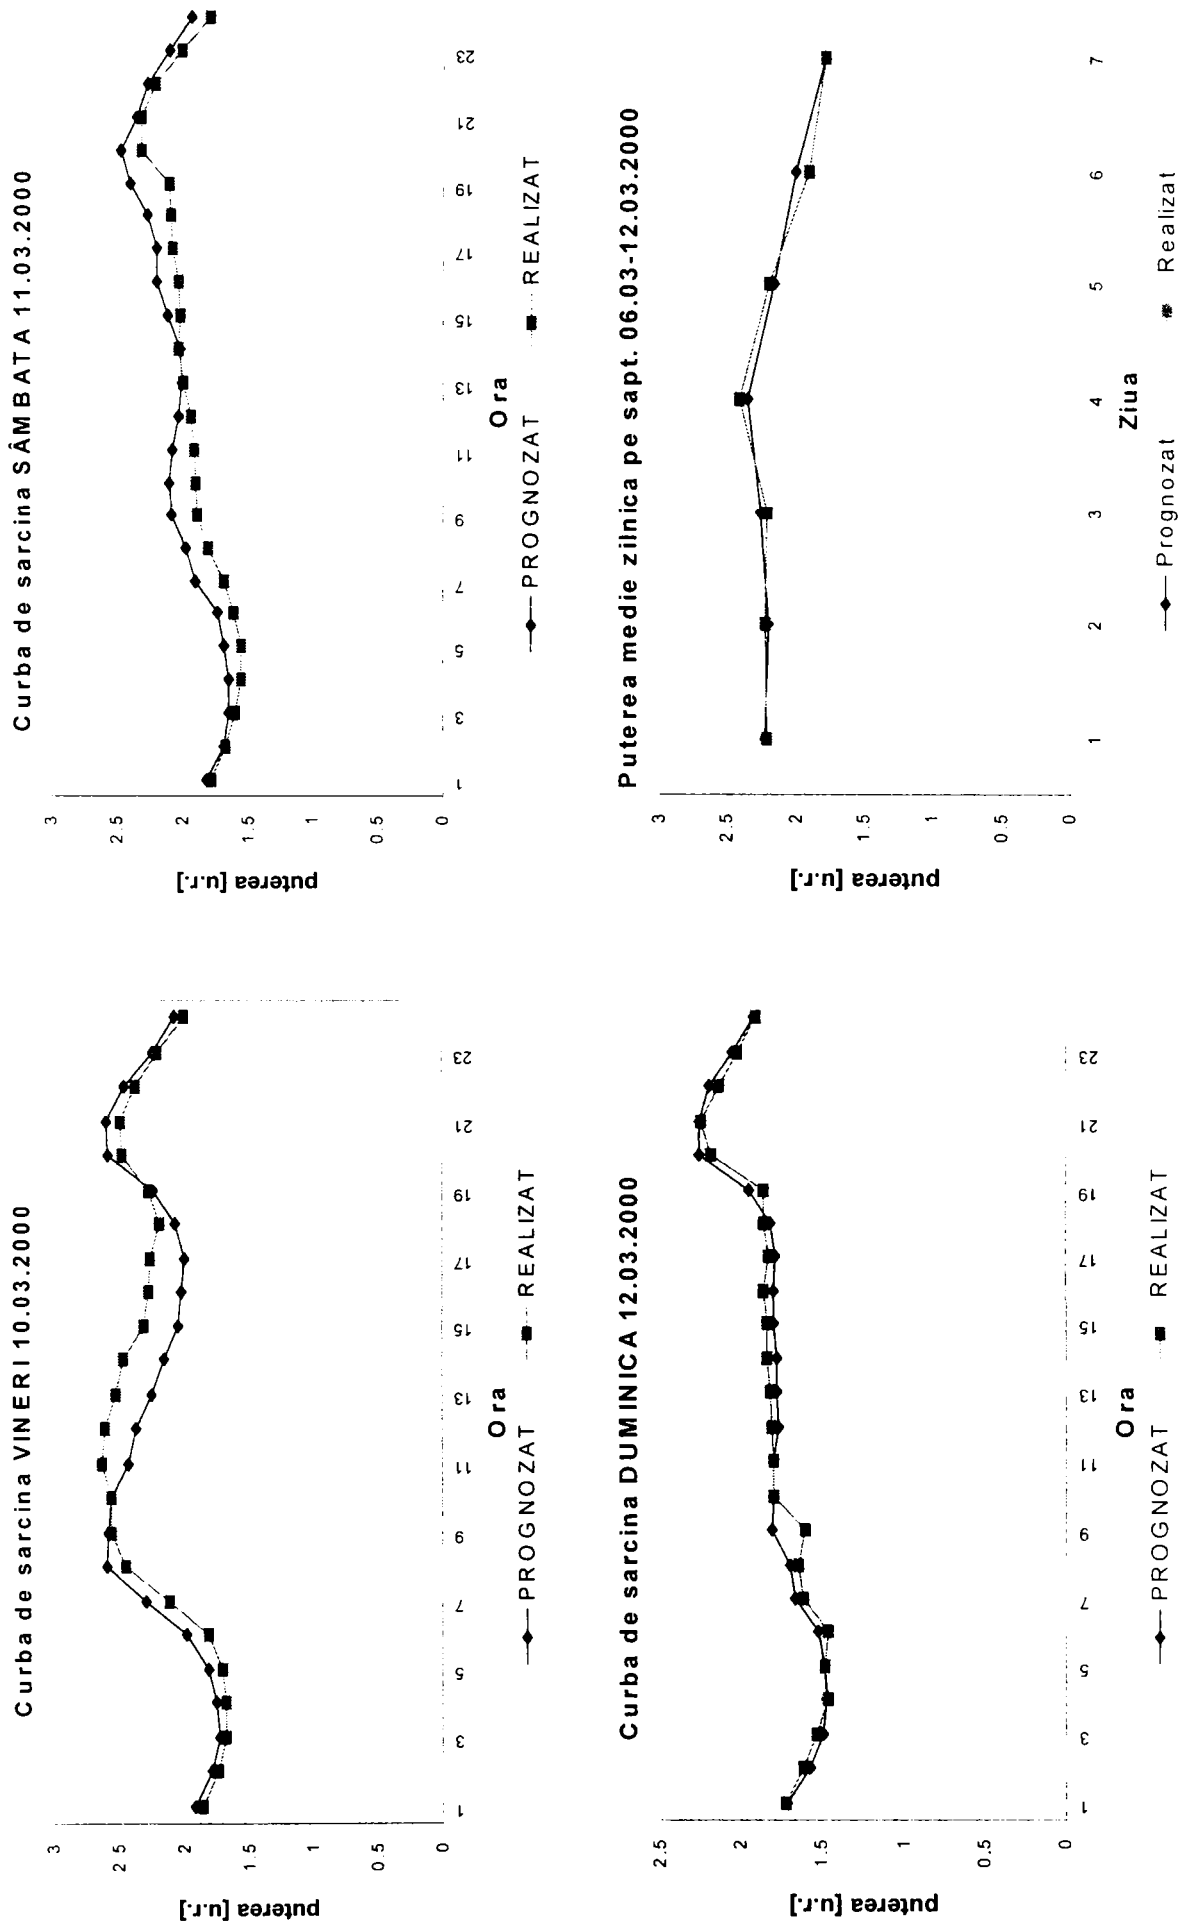
$$P(6, i) = \left\{ \bar{P}_m(6) + \sum \left[A_k(6) \sin\left(\frac{k \pi i}{12}\right) - B_k(6) \cos\left(\frac{k \pi i}{12}\right) \right] \right\} * \frac{1}{1 - \varepsilon(5, i)}$$

În continuare, pentru săptămânile 06.03. –12.03.2000 și 14.02.- 20.02.2000 și pentru consumatorul considerat în cazul lucrării de față (AT1 stația Moșnița – Timișoara) se prezintă curbele de sarcină zilnică prognozate și realizate (figura 5.12.) și alăturat, în tabelul 5.21., sunt înscrise și erorile corespunzătoare .

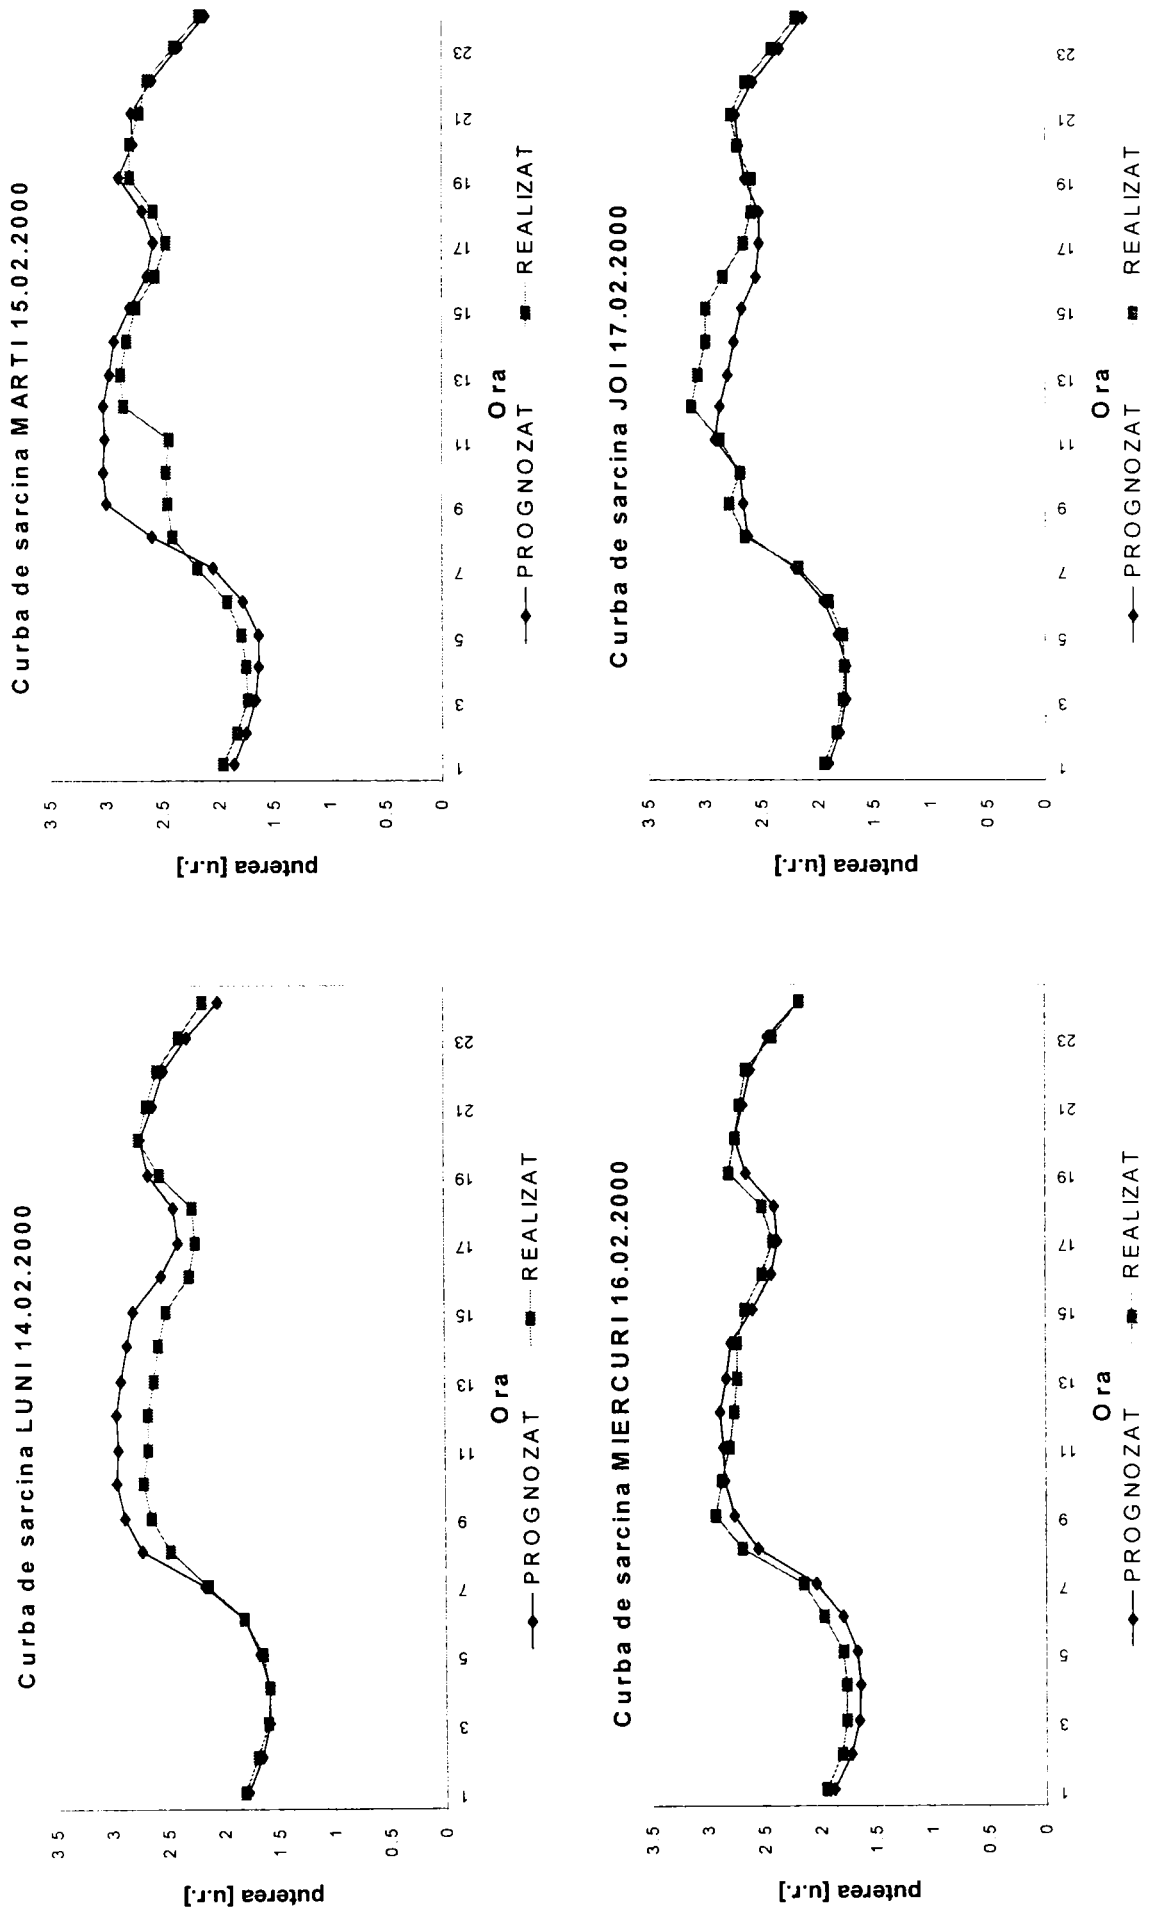
Cap. 5 Tehnici de prognoză a consumului de energie electrică și a curbelor de sarcină.



Cap. 5 Tehnici de prognoză a consumului de energie electrică și a curbelor de sarcină.



Cap. 5 Tehnici de prognoză a consumului de energie electrică și a curbelor de sarcină.



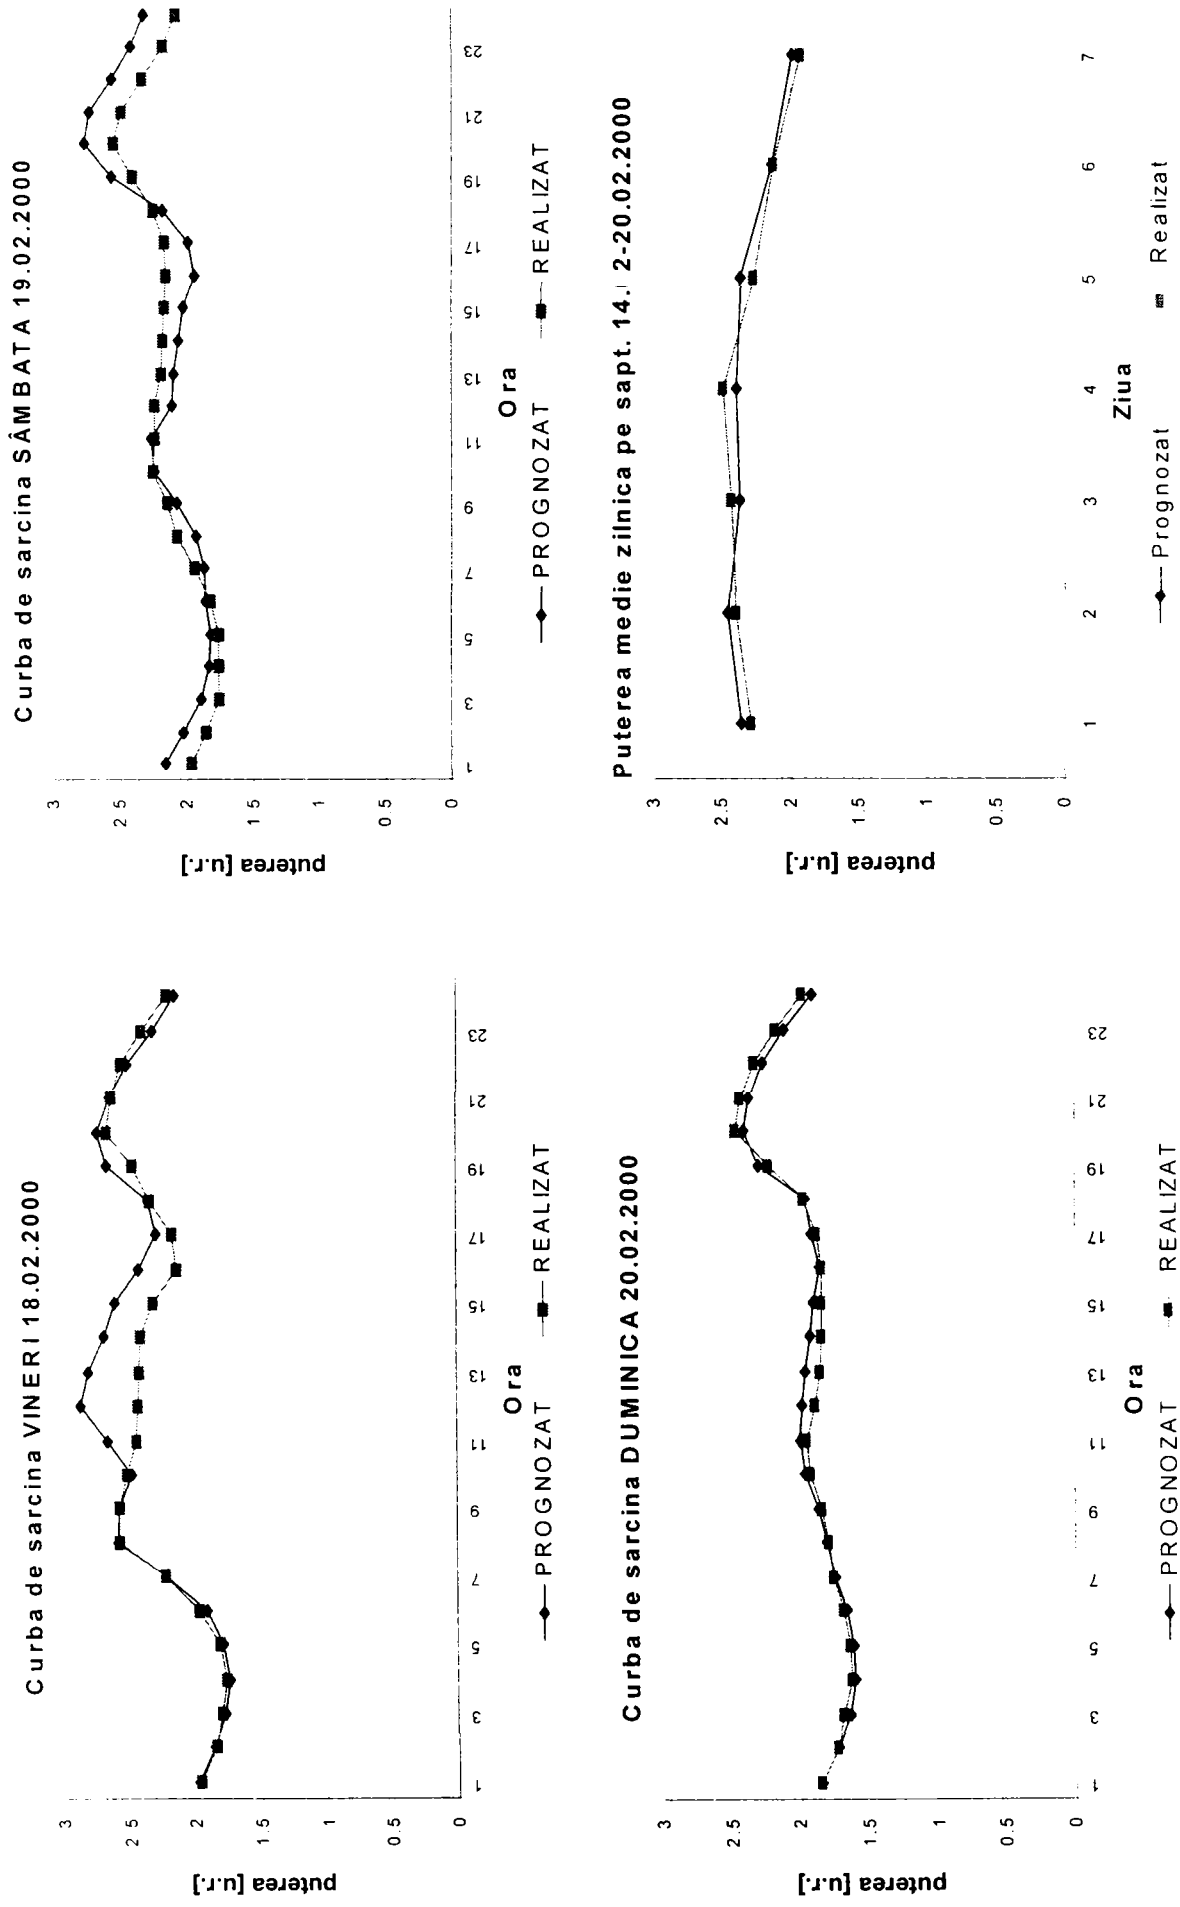


Figura 5.12. Curbele de sarcină zilnice și puterea medie zilnică pentru săptămânile 06.03.20 0 și 14.02.2000

TABELUL 5.21. Puterile medii zilnice din săptămânile 06.03.-12.03.2000 și 14.02.-20.02.2000 prognozate și realizate și erorile obținute

SĂPTĂMÎNA	LUNI	MARȚI	MIERCURI	JOI	VINERI	SĂMBĂȚĂ	DUMINICĂ
06.03.-12.03.2000	PROGNOZAT	2.230	2.200	2.268	2.362	2.161	2.005
	REALIZAT	2.211	2.228	2.219	2.418	2.204	1.913
	EROARE	-0.85934	1.256732	-2.2082	2.315964	1.950998	-4.8092
14.02.-20.02.2000	PROGNOZAT	2.363	2.453	2.375	2.400	2.359	2.123
	REALIZAT	2.289	2.391	2.430	2.495	2.267	2.121
	EROARE	-3.22834	-2.59306	2.263374	3.807615	-4.05823	-0.0943

5.6. Concluzii

Prezentul capitol și-a propus să prezinte alături de metode clasice și tehnici noi originale de prognoză a necesarului de energie și a curbelor de sarcină, iar pe baza acestora să elaboreze algoritmi care să stea la baza întocmirii unui program de calcul complex care va constitui obiectul capitolului următor. Scopul final al prognozei pe termen scurt este de fapt estimarea necesarului de energie orară, adică curba de sarcină orară, ca urmare capitolul de față a început cu prezentarea unor elemente strict necesare descrierii tehnicilor de prognoză a acestor curbe. Astfel, admitând o anumită stabilitate a formei curbelor de sarcină pe durata celor șase săptămâni considerate (cinci corespunzătoare datelor și una corespunzătoare prognozei), curbele de sarcină au fost descompuse în serii Fourier, s-au reținut coeficienții de valoare semnificativă, s-a urmărit dependența lor de anumiți indicatori, reținând corelațiile cele mai semnificative și apoi extrapolându-le pentru zilele săptămânii de prognoză.

În acest sens, pentru început, s-au prezentat câteva elemente generale privind descompunerea funcțiilor în serii Fourier: condiții necesare a fi îndeplinite, relații de calcul pentru coeficienți, număr de armonici luate în considerare. Apoi s-a trecut la analiza problemelor pe care le ridică descompunerea curbelor de sarcină în serii Fourier. Cu această ocazie s-au evidențiat cele două mari probleme care trebuie luate în considerare și anume :

- numărul minim de intervale în care trebuie discreditată curba de sarcină, avându-se în vedere pe de o parte modul în care se efectuează citirile de contor, pe de altă parte faptul că prognoza trebuie prezentată sub formă de paliere orare;
- numărul minim de coeficienți Fourier care trebuie luat în considerare pentru a se asigura o precizie corespunzătoare la aproximarea curbei de sarcină .

Referitor la numărul de intervale, respectiv mărimea pasului de discreditare, s-a constatat următoarele :

- precizia de determinare a coeficienților seriei Fourier pentru o anumită durată a pasului de discreditare (1/4h,1/2h,1h,2h) depinde de forma curbei de sarcină și mai ales de gradul ei de neuniformitate, cu cât acesta este mai accentuat, cu atât este necesar a adopta un pas de discreditare mai mic;
- valoarea coeficienților Fourier calculați variază în limite foarte largi, de la cca 0,1% până la cca 20% din puterea medie zilnică, rolul determinant deținându-l, alături de puterea medie, coeficienții de rang 1 și 2, adică $a_{1,2}$ și $b_{1,2}$;
- participarea coeficienți $a_{1,2}$ și $b_{1,2}$ la sinteza curbei de sarcină depinde de tipul zilei luată în considerare, de lucru sau de odihnă, astfel pentru zilele de lucru ordinea de participare a coeficienților este a_1, b_1, a_2, b_2 pe când pentru zilele de repaus a_1, a_2, b_2, b_1 ;
- odată cu creșterea rangului armonicilor, ponderea coeficienților scade, dar situația nu este generală, apărând și excepții de la această regulă, tendința de ansamblu însă fiind aceea de scădere;
- sensibilitatea coeficienților Fourier pentru un anumit consumator depinde de tipul coeficientului (a, b, c), rangul lor (k), de faptul că ziua este de lucru sau de repaus; o sensibilitate redusă, adică o stabilitate bună prezintă coeficientul a_1 , care are valori foarte apropiate pentru zilele de lucru și pentru cele de odihnă;
- abaterile coeficienților față de valorile considerate exacte (corespunzătoare pasului de 1/4h), cresc odată cu creșterea pasului de discreditare; dacă pentru pași de 1/2h și 1h acestea nu depășesc 10-15%, pentru a_{1-4}, b_{1-4} , pentru pasul de 2h acestea ating și valoarea de 100%, deci pasul de 2h nu poate fi acceptat.

Referitor la numărul minim de coeficienți Fourier ce trebuie luați în considerare pentru asigurarea unei precizii corespunzătoare de aproximare, s-au constatat următoarele:

- erorile maxime nu apar la vârful de sarcină și nici la goluri, ci pe porțiunile de pantă maximă, datorită faptului că armonicile nu au suficientă elasticitate pentru a asigura interpolarea necesară;
- considerarea unui număr mai mic sau mai mare de armonici consecutive afectează sensibil nivelul mediu al erorilor, fără însă a afecta sensibil nivelul erorii maxime și nici treapta la care aceasta apare;
- nu întotdeauna considerarea unui număr sporit de armonici conduce la reducerea nivelului erorii maxime, pot apare și situații inverse, aceasta depinzând de forma curbei de sarcină; pentru zilele de odihnă situația este inversă ca pentru cele de lucru;
- considerarea unui număr diferit de armonici poate conduce și la deplasarea palierului la care apare eroarea maximă. De obicei pentru zilele lucrătoare această deplasare poate fi de maxim un palier (una oră) iar în situații deosebite două paliere (două ore);
- indiferent de numărul de armonici superioare ($k > 1$) luate în considerare la aproximarea curbelor de sarcină, erorile care apar pot fi controlate și reduse;
- considerarea armonicelor pare ($k=2\div 10$) alături de fundamentală asigură o interpolare relativ bună a curbei, finisând vârfurile, dar nu rezolvă problema aproximării precise a porțiunilor cu pantă mare;
- considerarea armonicelor impare ($k=3\div 9$) alături de armonicile 1 și 2 asigură o interpolare relativ bună a curbei de sarcină, rezolvă problema porțiunilor cu pantă mare descendentă, dar nu și pe aceea a porțiunilor cu pantă mare ascendentă.

Referitor la prognoza coeficienților seriilor Fourier se pot deduce următoarele concluzii:

- forma curbei de sarcină, deci și valorile și semnul coeficienților Fourier luați în considerare depind esențial de natura zilei (de lucru sau de repaus), de poziționarea ei față de zilele de repaus (după sau înainte zilele de repaus), iar în cadrul acestora de regimul termic al zilei;
- la efectuarea prognozei coeficienților seriilor Fourier trebuie avută în vedere distinct fiecare zi din săptămână, consumul de energie al zilei respective și regimul termic al săptămânii din care face parte și al zilei respective;
- procesul de prognoză comportă de fapt două etape distincte și anume previziunea efectivă a coeficienților și tratarea reziduurilor datorită aproximării imperfecte a curbei de sarcină;
- în procesul de estimare efectivă a coeficienților Fourier modelele matematice care au la bază regresia liniară simplă nu dau satisfacție, rezultate mult mai utile oferind corelația liniară multiplă sau aceea neliniară. Drept variabile se pot considera puterea medie zilnică, temperaturile zilnice minimă, medie, maximă și chiar timpul. Corelații utile se pot stabili și între coeficienții aparținând diferitelor zile, îndeosebi zile consecutive;
- o stabilitate relativ bună la variația temperaturii prezintă coeficienții de tip c_k , respectiv argumentele acestora φ_k , față de cea a coeficienților a_k, b_k , motiv pentru care în prezenta lucrare s-au preferat aceștia;
- reziduurile (abaterile) coeficienților seriilor Fourier pot fi admiși de valoare mai mare decât a puterilor medii și aceasta datorită ponderii mult mai reduse a coeficienților Fourier față de puterea medie zilnică, de regulă chiar și abateri de 10% pot fi acceptate fără probleme;
- pentru controlul reziduurilor se pot considera, cu rezultate destul de bune, corecțiile efectuate pe baza realizărilor din săptămâna a 5-a;
- prognoza curbelor de sarcină zilnică a evidențiat o altă situație a erorilor față de aceea a interpolării, anume probleme ridică porțiunile de minim și maxim, mai ales pentru zilele de Luni și de Vineri, aici pot apare erori de cca 10% și aceasta datorită neuniformității regimului de funcționare a marilor consumatori. Același lucru se poate întâmpla și cu prima parte a zilei de Sâmbătă. În schimb ziua de Duminică nu ridică probleme, regimul termic având un rol hotărâtor asupra consumurilor de energie. Deci,

metoda de prognoză este utilă atunci când se elimină marii consumatori ,aceștia fiind studiați separat.

În legătură cu prognoza energiei (puterii medii) săptămânale, în cadrul lucrării au rezultat următoarele:

- este cea mai importantă etapă a întregii activități de prognoză pe termen scurt ,ea putând constitui un indicator (variabilă) fundamental în stabilirea corelațiilor necesare prognozelor energiilor (puterilor medii) zilnice și a curbelor de sarcină;
- pentru modelarea evoluției energiei săptămânale se adoptă mai multe modele, criteriul de alegere fiind calitatea modelării;
- alături de tehnicile de prognoză clasice, un rol deosebit pot să-l dețină și metodele euristice, bazate pe anumite raționamente logice ,una dintre acestea fiind și aceea a sensibilității necesarului de energie electrică săptămânală cu variația temperaturii medii săptămânale :minimă, medie și maximă ,dezvoltată în acest capitol și denumită metoda sensibilității termice;
- aplicarea corectă a metodei sensibilității termice presupune eliminarea componentei datorate marilor consumatori, stabilirea limitelor de confort termic pentru mediul ambiental, identificarea temperaturii medii săptămânale care influențează în măsura cea mai mare variația consumului de energie de la o săptămână la alta;
- la aplicarea metodei sensibilității termice a necesarului de energie trebuie avută în vedere inerția termică diferită a mediului ambiental în condițiile anotimpului calduros, respectiv friguros. Acest lucru se manifestă printr-o întârziere a răspunsului consumatorului la variații bruște de temperatură. Prin urmare variațiile de temperatură în cadrul acestei metode trebuie tratate diferit, bruște sau lente. Pentru studiul de caz analizat limita temperaturii minime a fost găsită de 4°C ;
- dacă baza de date este corectă , prin aplicarea metodei rezultă erori mai mici de 3%.

Prognoza consumurilor de energie electrică zilnică a fost efectuată prin metode clasice de regresie, printr-o metodă euristică dezvoltată în lucrare și numită a distanțelor termice sau a distanțelor limită, precum și prin descompunerea curbei de sarcină săptămânale a puterilor medii zilnice în serii Fourier. Metoda a treia deși utilă nu a dat rezultate corespunzătoare pentru zilele de repaus, motiv pentru care nu a fost reținută în final pentru a fi cuprinsă în tehnica de prognoză.

Referitor la aplicarea metodelor de analiză de regresie trebuie menționat următoarele :

- modelele care au la bază corelații liniare simple sunt cele mai utile;
- corelația liniară a puterii medii zilnice cu puterea medie săptămânală conduce la reziduuri de valoare redusă pentru toate zilele săptămânii mai puțin ziua de Sâmbătă;
- corelațiile liniare cu temperaturile zilnice și chiar cu temperatura medie săptămânală, deși prezintă coeficienți de corelație de valoare absolută relativ ridicată , nu conduc la reziduuri de valoare mică;
- corelațiile liniare multiple, care folosesc drept variabile puterile medii zilnice, săptămânale și temperaturile zilnice sau săptămânale nu dau satisfacție în etapa de modelare și nici în aceea de prognoză;
- nu întotdeauna consumul unei zile se corelează liniar cu acela al zilei anterioare, dar, de regulă, se corelează neliniar după o funcție pătratică;
- consumul zilei de Vineri se corelează liniar cu acela al zilei de Luni ;
- consumul zilei de Sâmbătă se corelează foarte bine cu acela al zilelor de Vineri și de Duminică ce o mărginesc ;
- consumul zilei de Duminică se corelează foarte bine cu acela al zilei de Sâmbătă după o funcție de tipul $y=a+b/x$;

- variațiile mari de temperatură care pot apare de la o zi la alta, combinate cu inerția termică a mediului ambiental fac ca temperaturile medii zilnice să nu ofere întotdeauna modele atractive pentru prognoza consumului de energie zilnică ;
- sunt de preferat modelele matematice care cuprind energia săptămânală față de energia zilnică.

În cea ce privește aplicarea unor metode noi la prognoza consumurilor zilnice de energie, se pot deduce următoarele concluzii:

- metoda distanței termice limită nu folosește modelări analitice ,ci gruparea puterilor medii zilnice raportate la puterea medie săptămânală în trei grupe, dependent de distanța temperaturii zilnice față de temperatura medie săptămânală. Astfel, pentru fiecare grupă se poate calcula un coeficient mediu care înmulțit cu puterea medie săptămânală (prognozată) permite obținerea puterilor medii zilnice;
- metoda distanței termice are la bază idea că în condițiile aceluiași interval de temperatură (distanță termică) puterea medie zilnică raportată la puterea medie săptămânală rămâne aceeași;
- distanța termică limită se apreciază concret în funcție de baza de date existentă; pentru studiul de caz analizat ea a fost stabilită la 2°C;
- prin aplicarea metodei distanței termice rezultatele obținute în procesul de prognoză a energiilor consumate zilnic sunt comparabile sau chiar mai bune decât cele obținute cu metodele clasice;

Cu ocazia analizei bazei de date raportate la puterea medie săptămânală au mai rezultat următoarele:

- puterea medie săptămânală este de regulă ceva mai mică (1-3 %) sau egală cu puterea medie a zilei de Luni, adică $P_L = (1-1,03) P_{Sapt}$;
- puterea medie a zilei de Vineri este foarte apropiată de aceea a zilei de Luni, diferența ce eventual ar putea apare se datorează depășirii distanței termice limită dintre cele două zile;
- puterea medie a zilei de Sâmbătă este cuprinsă întotdeauna între cele ale zilelor de Vineri și Duminică ce o mărginesc, de multe ori (peste 50% din cazurile analizate) se poate scrie o relație de forma $P_S = (P_V + P_D) / 2$;
- consumul cel mai mare de energie zilnică se consemnează în zilele de Marți, Miercuri sau Joi ;
- în anotimpul friguros, ziua cu temperatura minimă nu corespunde cu ziua cu cel mai mare consum de energie electrică ;
- în anotimpul cald ziua cu cel mai mare consum de energie corespunde de regulă cu ziua cea mai călduroasă .

La aplicarea metodei de prognoză a puterilor medii zilnice prin descompunerea curbei de sarcină săptămânale a puterilor medii zilnice au rezultat următoarele:

- prin considerarea a șapte puncte (corespunzătoare zilelor săptămânii) erorile de interpolare sunt în general mici pentru primele patru zile ale săptămânii (nedepășind în medie 2-2,5 %). Erorile cele mai mari apar în prima zi (Luni); în a doua parte a săptămânii erorile cresc sensibil, atingând valori de 10-13 % Duminică; aceasta este de fapt ziua cel mai prost modelată;
- prin creșterea numărului de zile, prin introducerea unor zile intermediare fictive, erorile se micșorează simțitor, pentru zilele de lucru ele nedepășind 2%;
- pentru ziua de Sâmbătă eroarea se reduce la jumătate ,în schimb pentru ziua de Duminică reducerea este nesemnificativă;
- pentru prognoza coeficienților seriei Fourier corelația liniară multiplă, având drept variabile cele nouă temperaturi săptămânale, nu conduce la rezultate utile, în schimb

corelațiile liniare simple se pretează mai bine, mai ales atunci când folosesc temperatura: $\max(t_{\min})$ sau $\text{med}(t_{\text{med}})$;

- pentru un regim termic relativ constant, aplicarea metodei distanței termice poate conduce la reziduuri mai mici de 3%.

CONTRIBUȚIILE ADUSE ÎN CADRUL CAPITOLULUI

- aplicarea descompunerii curbei de sarcină în serie Fourier și prognoza coeficienților Fourier la estimarea curbei de sarcină pe categorii de zile;
- evidențierea problemelor care se pun în legătură cu aproximarea curbei de sarcină zilnice prin serii trigonometrice;
- stabilirea concluziilor referitoare la influența pe care o are lungimea pasului de discretizare a curbei de sarcină asupra preciziei de determinare a coeficienților Fourier;
- stabilirea concluziilor referitoare la influența pe care o au numărul de coeficienți Fourier considerați și rangul acestora asupra preciziei de aproximare a curbei de sarcină;
- evidențierea dependenței valorilor coeficienților Fourier de forma curbei de sarcină;
- analiza sensibilității valorilor coeficienților Fourier cu forma curbei de sarcină și stabilirea de concluzii utile pentru procesul de prognoză al acestora;
- stabilirea unor concluzii utile în legătură cu modelarea variației coeficienților Fourier pentru studiul de caz analizat;
- evidențierea unei stabilități mai bune a coeficienților c_k, φ_k decât a_k, b_k ;
- abordarea procedurii de prognoză a curbelor de sarcină orară parcurgând etapele: prognoză energie-săptămânală; prognoză energie-zilnică, prognoză curbe de sarcină;
- evidențierea rolului hotărâtor al săptămânii calendaristice ca unitate de bază-perioadă, în activitatea de prognoză a necesarului de energie și putere pe termen scurt;
- elaborarea unei metode euristice de prognoză a necesarului de energie săptămânală, numită a „sensibilității termice”, fundamentarea și aplicarea ei în condițiile studiului de caz analizat;
- evidențierea inerției termice cu valori diferite pentru mediul ambiental în condițiile anotimpului friguros și a celui călduros;
- stabilirea limitelor de confort, respectiv disconfort termic în condițiile studiului de caz analizat;
- stabilirea unor concluzii utile la aplicarea metodelor clasice de prognoză a necesarului de energie zilnică pentru studiul de caz considerat;
- stabilirea unor concluzii utile referitor la intensitatea corelațiilor (liniare și neliniare) dintre consumurile de energie electrică a zilelor din săptămână;
- elaborarea și aplicarea metodei „distanței termice limită” în condițiilor studiului de caz, la prognoza consumului de energie zilnică;
- evidențierea unor observații utile referitoare la coincidența unor consumuri de energie zilnică extreme (minimă și maximă) și temperaturile limită înregistrate de regimul termic;
- aplicarea metodei descompunerii în serie Fourier la prognoza curbei săptămânale a puterilor medii zilnice;
- introducerea zilelor fictive ale săptămânii în procesul de creștere a calității aproximării curbei de sarcină săptămânale a puterilor medii zilnice;
- aplicarea metodei descompunerii în serii Fourier la prognoza curbei săptămânale a puterilor medii zilnice pentru studiul de caz analizat și stabilirea de concluzii utile.

BIBLIOGRAFIE

- 5.1. PISKUNOV,N, - Calculul diferentiel et integral et integral , tome 2, Edition MIR , Moscow, 1974,
- 5.2. POSTELNICU,V, COATU S, - Mică enciclopedie matematică ,Editura tehnică ,București, 1980,
- 5.3. HORE, R,A, - Metode moderne de calcul și proiectare a sistemelor electice ,Editura tehnică ,București, 1970,
- 5.4. RADULEȚ,R, - Bazele Electrotehnicii, Probleme, vol. 2, Editura Didactică și Pedagogică, București, 1975,
- 5.5. ANTONIUH,I,S, A,ALBERT, H - Culegere de probleme de Electrotehnică, Chestiuni speciale, Ediția a doua, Editura Energetică de Stat, București, 1955,
- 5.6. LUȘTREA,B, - Prognoza consumului de energie electrică, Editura AGIR, București, 2001,
- 5.7. CÂRTÎNĂ,GH,GAVRILAȘ,M, GEORGESCU,GH,BONCIU,C, - Rețele neuronale artificiale și sisteme expert în energetică,
- 5.8. GOLOVANOV,C, și alții, - Probleme moderne de măsurare în electroenergetică, Editura Didactică și Pedagogică, București, 2001,
- 5.9. ALBU,M, - Prelucrarea numerică a semnalelor din sistemele de măsurare, Editura Printech, București 2000,
- 5.10. GHINEA,M, - Procesarea digitală a semnalelor, Editura Tritonic, București, 1997,
- 5.11. BUTA,A,COLBAN,S ,STOIAN,A, - Sistem expert pentru prognoza pe termen scurt a consumului de energie și putere, Contract de cercetare nr. 751/2001, Universitatea Politehnica Timișoara,
- 5.12. STOIAN,A,BUTA,A, BUCĂTARIU,I, - Prognoza curbelor de sarcină prin descompunerea în armonici, Simpozionul Internațional de Eficiență Energetică , Cluj-Napoca, 2000.
- 5.13. STOIAN,A.,BUTA,A,COMAN, V - Algoritmi pentru prognoza consumului de energie electrică pe termen scurt, Conferința de Inginerie Energetică, CIE 2002, Oradea
- 5.14. STOIAN A.,BUTA ,A.,PANĂ, A., - Algorithms for electricity consumption and power demand forecast on short term, 17th International conference on Electricity Distribution, Barcelona, 12-15 May, 2003
- 5.15. GEORGESCU, GH., POEATĂ, A., GAVRILAȘ,M., - Calculul pierderilor de energie în rețelele de distribuție folosind descompunerea graficelor de sarcină în serii Fourier, Energetica, nr. 5, seria B, 1995, pp 49-62
- 5.16. GEORGESCU,GH, RĂDĂȘANU,D. - Transportul și distribuția energiei electrice., vol 1, Editura Gh. ASACHI, Iași, 2000,
- 5.17. COSTIN,E., - Metode pentru prognoza consumului de

- 5.18. COSTIN,E., energie electrică, teză de doctorat, Institutul Politehnic București,1973;
- Considerații asupra prognozei consumului de energie electrică pe baze statistico-probabilistice, Energetica, an 13, Nr.6, 1965, pp 15-22;
- 5.19. COSTIN,E., - Prognoza de dimensionare și prognoza de planificare în industria energiei electrice, Energetica, Nr 1, 1969, pp 7-11;
- 5.20 BUTA, A., - Energetică generală și conversia energiei, Litografia Institutului Politehnic Timișoara, 1982;
- 5.21. LUȘTREA, B., - Prognoza consumului de energie , Editura AGIR, București, 2001;
- 5.22. SARGUNARAJ S., SEN GUPTA D.P., - Short term load forecasting for demand side management, IEE Proc.-Gener. Transm. Distrib., Vol.144, No.1, January1997, pp. 68-74.
- 5.23. JANTSCH, E., - Prognoza tehnologică, Editura Științifică, București, 1972;
- 5.24. NIȚU,V., - Economia energiei, vol I, II, Editura Tehnică, București, 1981;
- 5.25. CÂRȚINĂ, GH.,GRIGORAȘ, GH., - Inteligența artificială, optimizări în energetică, Casa de editură Venus, Iași, 2001;
- 5.26. CÂRȚINĂ, GH., GAVRILAȘ, M., GEORGESCU, GH., BONCIU C., - Rețele neuronale artificiale și sisteme expert în energetică, Editura “Gh. Asachi” Iași, 1994;
- 5.27. CRIȘAN, O., BUTA, A., LUȘTREA, B., KILYENI, ȘT., - Prognoza consumului de energie electrică, Energetica, vol 22, nr 10-11-12, 1974, pp 405-414;
- 5.28. CRIȘAN, O., - Optimizări decizionale în sistemele electroenergetice, Editura FACLA, Timișoara, 1976;
- 5.29. KILYENI, ȘT., LUȘTREA, B.,CRIȘAN, O., BUTA, A., - Prognoza consumului de energie electrică și putere de vârf efectuată în zona unui IRE utilizând calculatorul FELIX C256. Datele, modelul matematic și programele utilizate, Energetica, vol 25, nr 6, 1977, pp 201-206;
- 5.30. TETRIȘCO, M., STOICA, P., POPESCU, TH., - Modelarea și predicția seriilor de timp Editura Academiei, București, 1985;
- 5.31. GROSS, G., GALIANA F.D., - Short-term Load Forecasting, Proceedings of the IEEE, vol 75, No. 12, dec 1987, pp 1558-1572;
- 5.32. PAPALEXOPOULOS, A.D., HESTEBORG, T.C., - A Regression Based Approach to Short term Szsstem Load Forecasting, IEEE Transaction on Power Systems, vol 5, No 4, 1990, pp 1535-1547;
- 5.33. GEORGESCU, GH, GAVRILAȘ, M., RĂDĂȘANU,D., - Prognoza pe termen mediu și scurt a energiei electrice folosind rețele neuronale, Energetica, vol 47., No 8-9, 1999, pp 351-

- 5.34. VEMURI,S., HUANG, W.L., NELSON,D.J., 356;
- On-line Algorithms for Forecasting Hourly Loads of an Electric Utility , IEEE Transaction on Power App. And Systems, vol PAS-100, No 8, 1990, pp 3775-3785;
- 5.35. BOLYERN, P., FRONZA, G., - Role of Weather Inputs in Short-term Forecasting of Electric Load, Electric Power and Energy Systems, vol 8, No.1, 1986, pp 42-46;
- 5.36. RANMAN,S., BHATNAGAR, R., - An expert System Based Alghorithm for Short-term Load Forecasting Assistant, IEEE Transactions PWRS, vol 3, 1988, pp 392-399;
- 5.37. JABBOUR, K., RIVEROS, J.F.V., LANDSBERGEN, D., MEYER, W., - “ALFA: Automated Load Forecasting Assistant“, IEEE Transactions PWRS, vol 3, 1988, pp 908-914;
- 5.38. BAKIRTZIS, A.G., PETRIDIS, V., KLARTZIS, S.J., ALEXIADIS, M.E., MAISSIS, A.M., - A Neutral Network Short Term Load Forecasting Model for the Greek Power System, IEEE Transaction on Power Systems, vol 11, No.2, 1996, pp 898-863;
- 5.39. BUTA, A., STOIAN, A, - Forecastings of transient powers by load curve decomposition into Fourier series, IASTED Conference, Innsbruck,2000
- 5.40. PAPALEXOPOULOS, A.D., HUTERBERG, T.C., - A Regression Based Approach to Short Term System Load Forecasting, IEEE Transactions on Power Systems, vol 5, No 4, 1990, pp 1535-1547,
- 5.41. GEORGESCU ,G., GAVRILAȘ, M., RĂDĂȘANU, D., - Previziunea pe termen scurt și mediu folosind rețele neuronale și artificiale, Energetica, vol 47, 1999, Nr. 8-9, pp 351-356,
- 5.42. BOLZERN, P., FRANZA, G., - Role of Weather Inputs in Short-term Forecasting of Electric Load, Electric Power and Energy Systems, vol 8, No 1, 1986, pp 42-46,
- 5.43. AMJADY, N., - Short-term hourly load forecasting using time-series modeling with peak load estimation capability, IEEE Transaction power systems, vol.16, nr. 3, august 2001, pp 498-503
- 5.44. BUNN, D.W., - Forecasting loads and price in competitive power markets, Proc. of the IEEE, vol 88, No. 2, Feb. 2000, pp. 163-169,
- 5.45. GEORGESCU, G., GAVRILAȘ, M., RĂDĂȘANU, D. - “Medium and Short-term Electric Load Forecasting Use the Artificial Neural Network”, (in Romanian), Energetica, Vol. 47, No. 8-9, 1999, pp.351-356.

CAPITOLUL 6

PROGRAM PENTRU PROGNOZA ENERGIEI ȘI PUTERII PE TERMEN SCURT - PRENPS

6.1. Introducere

Prognoza sarcinii electrice reprezintă estimarea formei și valorilor curbelor de sarcină. Ea presupune un studiu aprofundat privind necesarul de energie pentru diferite utilizări finale.

În cadrul funcționării sistemului electroenergetic un rol important revine prognozei consumului de energie și a cererii de putere pe termen scurt (de la o oră până la câteva ore), aceasta furnizând informații referitor la planificarea rezervei de putere, a gradului de încărcare a elementelor de rețea și la eventualele contingente care pot surveni [6.1.], [6.2.], [6.3.].

Prognoza energiei electrice este influențată de diferiți factori: economici, de timp, meteorologici, politici, etc., cei meteorologici având un rol important în cadrul prognozei pe termen scurt. Această influență este cu atât mai pronunțată cu cât ponderea marilor consumatori în consumul final este mai redusă.

O altă categorie de factori foarte importanți în activitatea de prognoză a necesarului de energie pe termen scurt sunt aceia de timp (temporali): ciclurile zilnice, săptămânale, sezoniere. Ciclul săptămânal de lucru, necesitatea zilelor de lucru, odihnă, a celor dinainte sau după zilele de odihnă, asigură o anumită formă a curbelor de sarcină, nuanțându-le în funcție de anotimp. Aceste influențe au fost considerate ca fiind determinante în cadrul metodei de prognoză și a algoritmilor de calcul elaborați, algoritmi ce au stat la baza programului PRENPS (Prognoza Energiei și Puterii Săptămânale). Factorii cauzali: evenimentele aleatorii care pot surveni: greve, demonstrații, sărbători naționale, etc., nu au fost considerate explicit, acestea putând fi operate în rezultatele prognozei.

Principalele componente ale unui sistem de prognoză pe termen scurt sunt: modelul de prognoză, baza de date și interfața dintre operator și mașină. În ceea ce privește prelucrarea bazei de date aceasta se realizează actualmente cu programe software specializate scrise în limbaje de programare: MATLAB, Borland C++, etc. [6.4.].

6.2. Modele matematice

Sistemul de prognoză a fost conceput să lucreze în trei etape, determinând: energia săptămânală, zilnică și curbele de sarcină orare pentru fiecare zi. Elementul de bază este săptămâna și poziția fiecărei zile în săptămână. În plus, la prognoza energiilor zilnice, acestea s-au raportat la energia săptămânală (puterea media săptămânală). De fapt sistemul funcționează pe baza unor corelații dintre energia săptămânală, zilnică, palierele curbei de sarcină și diferiți indicatori. Această funcționare se efectuează etapizat: săptămână – zi – oră. Fiecare etapă sprijinindu-se pe aceea anterioară, dar este posibilă și funcționarea distinctă în cadrul fiecărei etape.

Sistemul reclamă cunoașterea unor date despre consum (puterile orare zilnice pentru fiecare zi din săptămână), pe parcursul a 5 săptămâni. Definierea acestui interval s-a efectuat

pe baza a numeroase determinări, ținându-se seama și de asigurarea continuității trecerii de la un anotimp la altul. Datele zilnice sunt organizate pe săptămâni, aceasta așa cum s-a mai menționat constituind elementul de bază al sistemului. Indicatorul principal s-a considerat temperatura zilnică prin valorile ei: t_{\min} , t_{med} , t_{\max} . Determinările care au stat la baza corelațiilor identificate au avut în vedere afirmațiile făcute în literatura din țară, precum și în alte țări.

6.2.1. Algoritm pentru prognoza energiei săptămânale

Pentru prognoza energiei săptămânale s-au folosit doi algoritmi: unul clasic și altul euristic al sensibilității termice. Rezultatele obținute pe cele două căi se ponderează dependent de încrederea în baza de date, obținându-se rezultatul final. Metoda euristică este prezentată în [6.5.], motiv pentru care în continuare se prezintă numai algoritmul clasic. Acesta pleacă de la cunoașterea temperaturilor zilnice: t_{\min} , t_{med} , t_{\max} . Pe baza lor se analizează corelațiile simple și multiple ale consumului de energie și aceste temperaturi. În condițiile în care corelația sau calitatea modelului stabilit nu dau satisfacție se apelează la alte două proceduri: prima vizează corelarea consumurilor din săptămâni succesive, iar a doua apelează la extrapolarea în timp a consumului.

6.2.2. Algoritm pentru prognoza energiei zilnice

Pentru prognoza energiei zilnice (puterilor medii zilnice) s-a apelat și aici la două proceduri distincte: prima corespunde unei tehnici clasice, cealaltă unei tehnici euristice numită a „distanței termice”, prezentată în [6.5.].

În cadrul tehnicii clasice s-a folosit analiza de regresie, modele liniare și neliniare cu diferiți indicatori, extrapolarea în timp iar în situații extreme relații empirice.

6.2.3. Prognoza curbelor de sarcină zilnică

Pentru prognoza curbelor de sarcină zilnică s-a folosit descompunerea spectrală a curbelor de sarcină. S-a apreciat pe baza celor prezentate în capitolul 5 că, considerarea a două armonici este suficientă, eroarea de metodă introdusă putând fi compensată printr-o corecție corespunzătoare realizărilor din săptămâna a 5-a.

6.3. Prezentarea programului

Programul PRENPS este scris într-un limbaj de nivel înalt DELPHI și are interfața om-mașină prietenoasă. Determinările referitoare la prognoza necesarului de energie a curbelor de sarcină se efectuează în trei etape:

- determinarea puterii medii săptămânale, adică energia activă absorbită în cursul săptămânii;
- determinarea puterii medii zilnice ale fiecărei zi din săptămână;
- ridicarea curbei de sarcină zilnică prin trepte de puteri medii orare.

Pentru a putea parcurge etapele de mai sus, este necesar de a dispune de o bază de date alcătuită din puteri medii orare pentru fiecare zi pe o perioadă de cinci săptămâni în urmă și temperaturile zilnice: minime, medii și maxime aferente. Baza de date depinde de configurația calculatorului în ceea ce privește semnele de punctuație și succesiunea zilelor din calendar.

Meniurile existente în program sunt: File, Calcul Date, Vizualizare Rezultate și Help. Fiecare dintre acestea având submeniuri. Apelarea meniurilor și submeniurilor se efectuează într-o anumită ordine prestabilită.

La pornirea aplicației se introduc anumite limite corespunzătoare bazei de date pentru a evita introducerea unor erori grosolane.

În anexa 6.1 este prezentat manualul de operare pentru programul PRENPS

6.4. Concluzii

Programul PRENPS este un program complex care permite efectuarea prognozei pe termen scurt a necesarului de energie și a curbelor de sarcină prin mai multe metode: clasice și euristice, care reclamă o bază de redusă de date. Elementul fundamental pe care-l consideră este sensibilitatea consumurilor finale, din care s-a exclus acela al consumatorilor industriali de energie. cu temperatura. El poate fi extins considerând și alți indicatori.

Programul estimează necesarul de energie săptămânal și zilnic (puteri medii) precum și curba de sarcină (paliere orare).

Determinările se fac în trei etape:

- în cadrul primei etape se determină puterea medie săptămânală adică energia activă absorbită în cursul săptămânii;
- în cadrul celei de-a doua etape se determină puterile medii zilnice ale fiecărei zi din săptămână;
- în cadrul etapei a 3-a se ridică curba de sarcină zilnică prin trepte de puteri medii orare.

BIBLIGRAFIE

- 6.1. BUTA ,A.,
- Energetică generală și conversia energiei. Litografia IP Timișoara, 1982,
- 6.2. LUȘTREA, B.,
- Prognoza consumului de energie, Editura AGIR, București, 2001
- 6.3. GEORGESCU, G.,
RĂDĂȘANU, D.
- Transportul și distribuția energiei electrice., vol 1, Editura Gh. ASACHI, Iași, 2000,
- 6.4. AMJADY,N.
- Short-term hourly load forecasting using time-series modeling with peak load estimation capability, IEEE Transaction power systems, vol.16, nr. 3, august 2001, pp 498-503
- 6.5. **STOLAN ,A., BUTA, A., PANĂ, A.,**
- Algorithms for electricity consumption and power demand forecast on short term, 17th International conference on Electricity Distribution, Barcelona, 12-15 May,2003
- 6.6. **STOLAN ,A., BUTA, A., PANĂ, A.,**
- Algorithm for electricity demand estimation on short term, Proceedings of the Energy Engeneering Conference, CIE 2002, Oradea
- 6.7. **STOLAN, A., BUTA ,A., PANĂ ,A.,**
- A software for the short term energy and power forecast, Proceedings of the International Symposium „Energy Efficiency”, Cluj

ANEXA 6.1

PRENPS

Prognoza Energiei și Puterii Săptămânale

Prezentare

P R E N P S


PRognoza ENergiei și Puterii Săptămânale.

Manual de Operare

Introducere în utilizarea programului de prognoză pe termen scurt a energiei și necesarului de putere.

PRENPS - PRognoza ENergie și Puterii Săptămânale.

Prezentare.

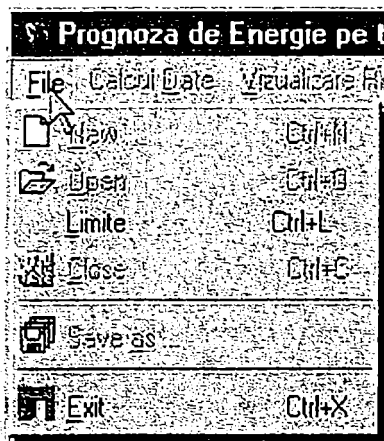


Programul estimează necesarul de energie săptămânală și zilnică (puteri medii) precum și curba de sarcină zilnică (paliere orare).

Determinările se fac în trei etape:

1. în cadrul primei etape se determină puterea medie săptămânală adică energia activă absorbită în cursul săptămânii.
2. în cadrul celei de-a doua etape se determină puterile medii zilnice ale fiecărei zi din săptămână.
3. în cadrul etapei a 3-a se ridică curba de sarcină zilnică prin trepte de puteri medii orare.

Meniul File



Apelarea meniului File se poate face fie cu combinație de taste ALT+F fie cu mouse-ul.

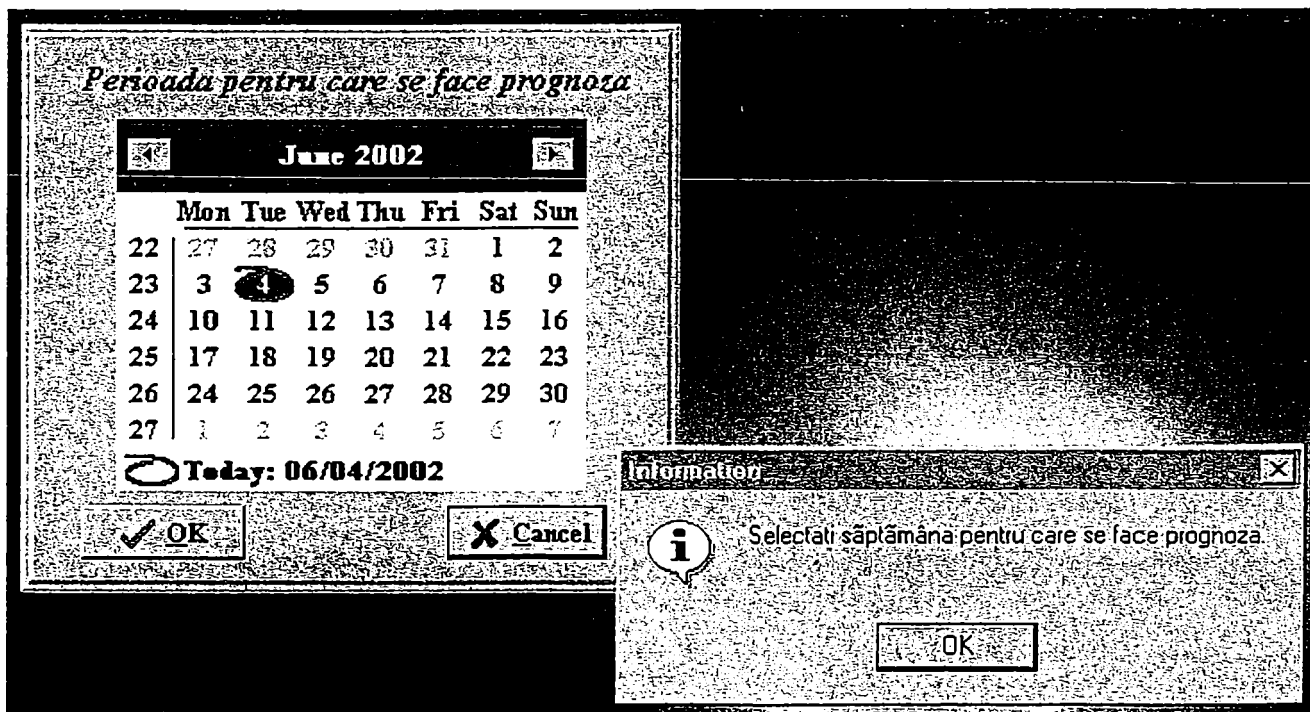
Calculul prognozei de energie prin intermediul acestui program de calcul se face doar în pași de calcul prestabiliți, meniurile și submeniurile se apelează în ordinea în care ele devin active.

După pornirea aplicației se introduce prima dată limitele între care trebuie să se încadreze datele existente din baza de date sau la introducerea unei baze de date noi.

Submeniul New

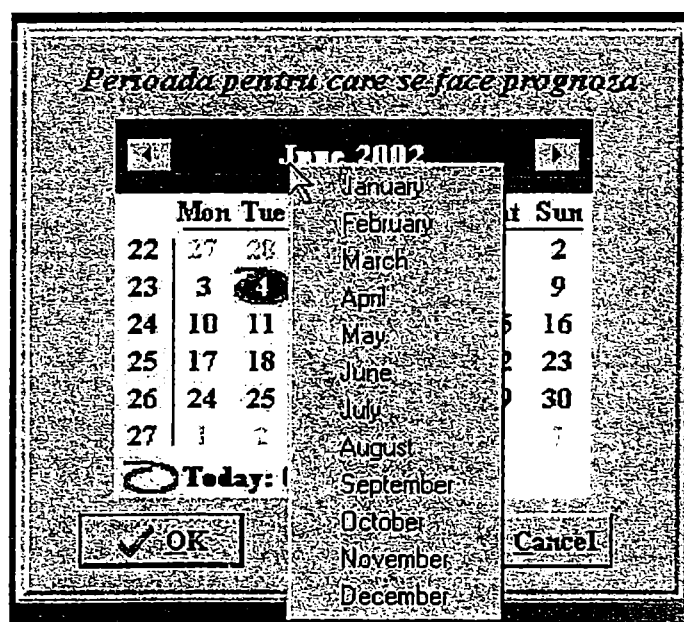
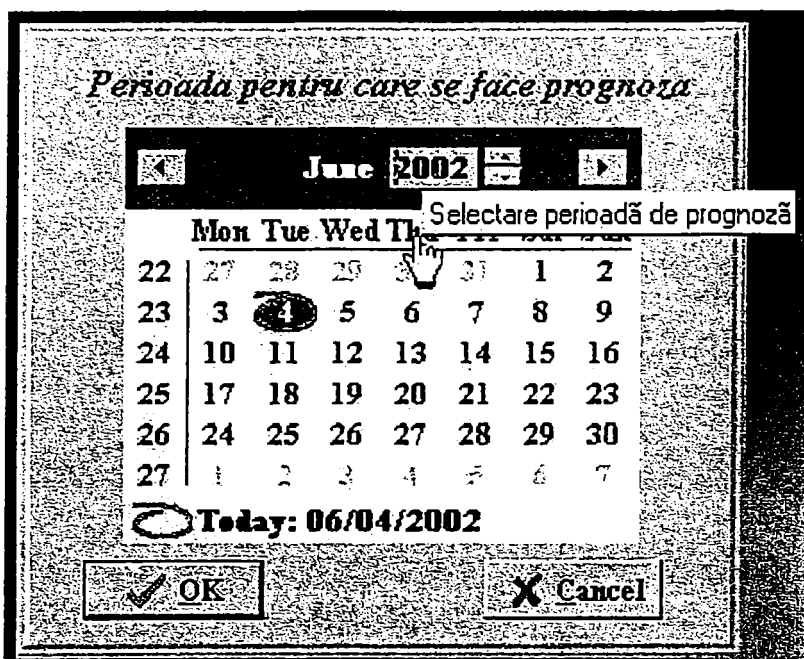
La introducerea datelor în program se accesează submeniul NEW cu combinația de taste CTRL+N sau cu mouse-ul.

În acest caz submeniul **Open** va fi dezactivat și va apărea un mesaj în care se solicită selectarea săptămânii pentru care se face prognoza.



După ce se apasă pe butonul de OK de la mesaj va rămâne doar fereastra în care este un calendar prin care se face selecția săptămânii de prognoză.


Aceasta se realizează prin modificarea anului și lunii din partea de sus a ferestrei.




Selectarea se face ducând cursorul din prima zi (Luni) până în ultima zi (Duminică) a săptămânii de prognoză.



Dacă se selectează mai puține zile din săptămână sau săptămâna luată în considerare începe din altă zi decât cea de **Luni**, vor apărea următoarele mesaje:



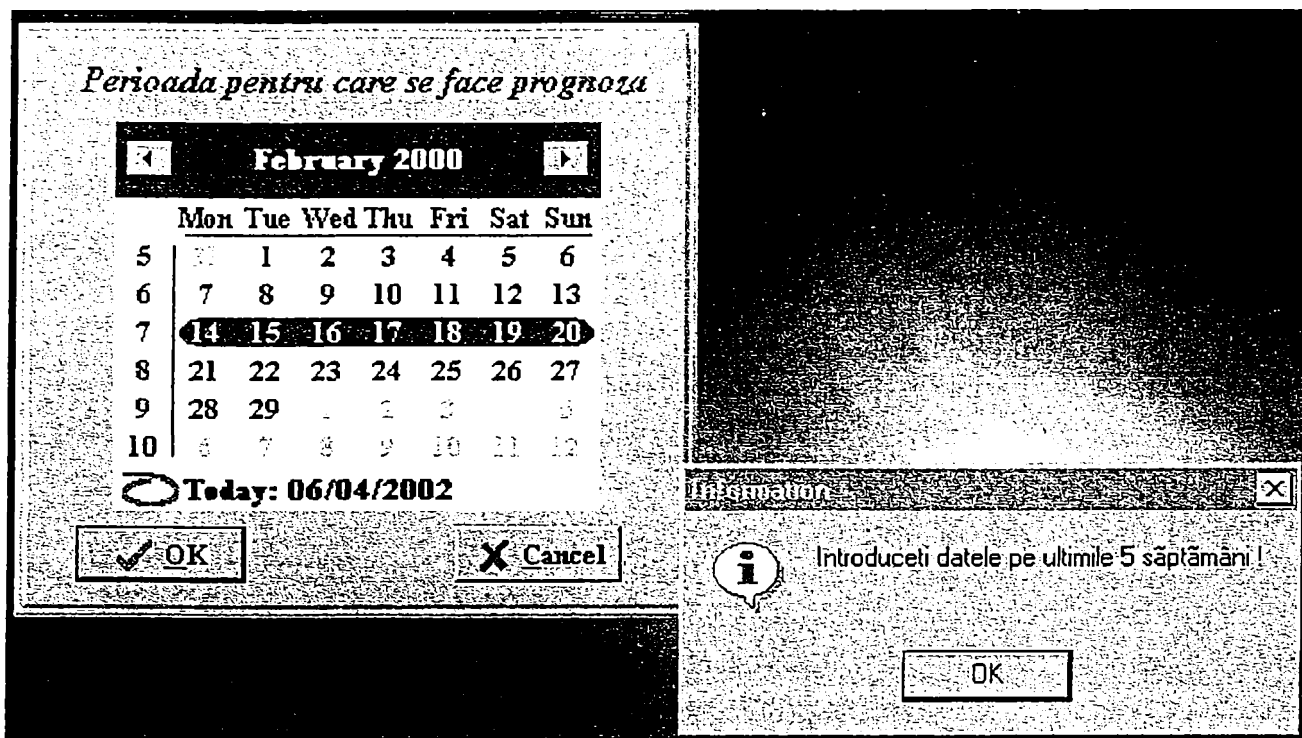
Dacă se selectează mai multe zile din săptămână sau săptămâna luată în considerare se extinde pe mai mult de 7 zile va apărea următorul mesaj:



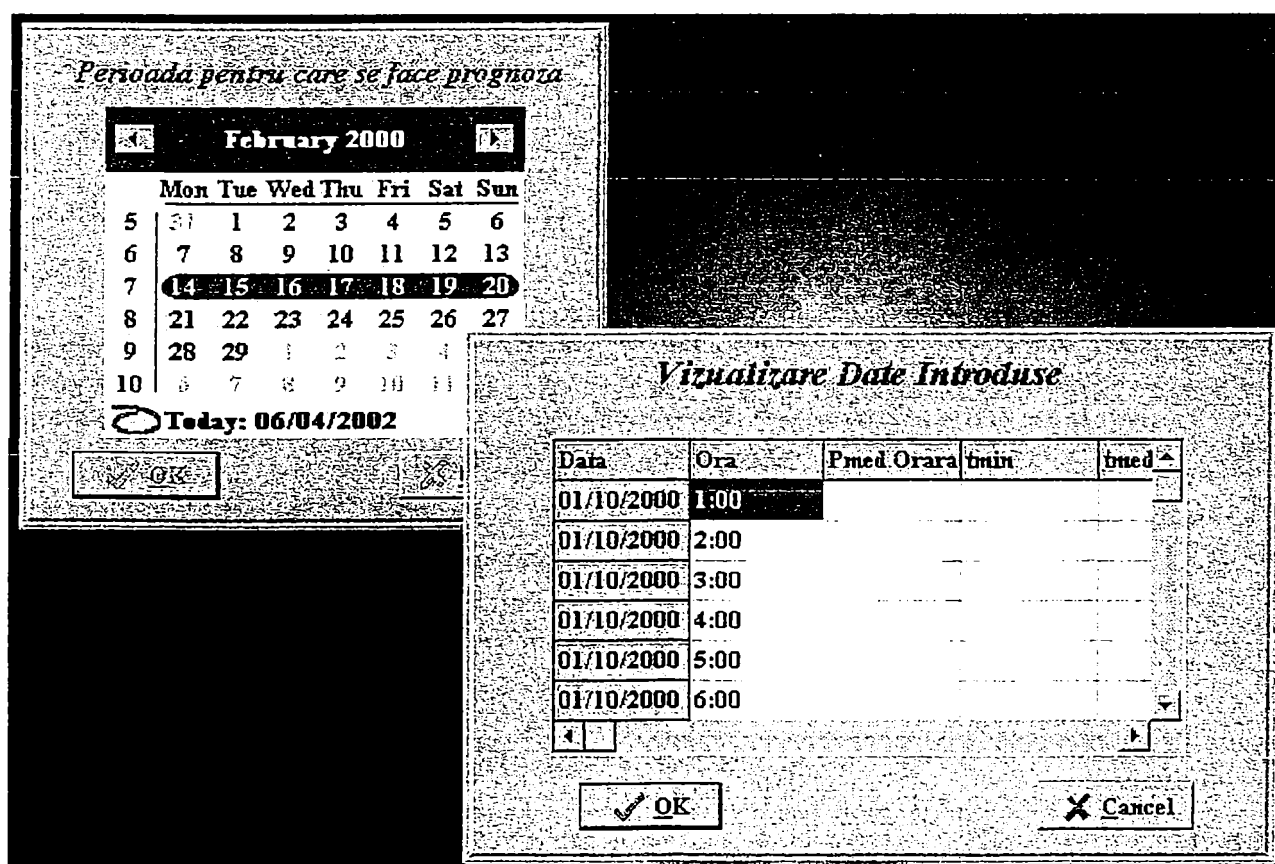
După selectarea săptămânii de prognoză se cere introducerea datelor din cele 5 săptămâni anterioare celei de prognoză.

Acestea trebuie să conțină: puteri medii orare; temperaturile minime, medii și maxime ale zilelor din săptămânile respective pe cele 24 de ore.

Data	Ora	Pmed orara	tmin	tmed	tmax
01/03/2000	01:00	1.936	-4.3	-3.3	-2.3
01/03/2000	02:00	1.80136	-4.3	-3.3	-2.3
01/03/2000	03:00	1.74988	-4.3	-3.3	-2.3
01/03/2000	04:00	1.749	-4.3	-3.3	-2.3
01/03/2000	05:00	1.77892	-4.3	-3.3	-2.3
01/03/2000	06:00	1.91356	-4.3	-3.3	-2.3
01/03/2000	07:00	2.13928	-4.3	-3.3	-2.3
01/03/2000	08:00	2.37952	-4.3	-3.3	-2.3
01/03/2000	09:00	2.48424	-4.3	-3.3	-2.3
01/03/2000	10:00	2.53748	-4.3	-3.3	-2.3
01/03/2000	11:00	2.58412	-4.3	-3.3	-2.3
01/03/2000	12:00	2.6686	-4.3	-3.3	-2.3
01/03/2000	13:00	2.71656	-4.3	-3.3	-2.3
01/03/2000	14:00	2.7258	-4.3	-3.3	-2.3
01/03/2000	15:00	2.61712	-4.3	-3.3	-2.3
01/03/2000	16:00	2.50976	-4.3	-3.3	-2.3
01/03/2000	17:00	2.52296	-4.3	-3.3	-2.3
01/03/2000	18:00	2.695	-4.3	-3.3	-2.3
01/03/2000	19:00	2.77772	-4.3	-3.3	-2.3
01/03/2000	20:00	2.86088	-4.3	-3.3	-2.3
01/03/2000	21:00	2.84504	-4.3	-3.3	-2.3
01/03/2000	22:00	2.7104	-4.3	-3.3	-2.3
01/03/2000	23:00	2.47148	-4.3	-3.3	-2.3
01/03/2000	24:00	2.22728	-4.3	-3.3	-2.3



În final va apărea fereastra în care se vor introduce valorile cerute care stau la baza calculului de prognoză.



!!! **Atenție:** La introducerea datelor trebuie să se aibă în vedere că introducerea unei valori greșite conduce la erori de calcul care vor afecta rezultatele finale.

Datele vor avea de exemplu următoarea formă:

Data	Ora	Pmed Orară	tmin	tmed	tmax
01/10/2002	01:00	1.256	-12	18	24

Nu sunt acceptate lipsa de date și introducerea de caractere speciale (de ex. =/!*"%'&/*?, etc.) și alfabetice (a, b, c, etc.).

După introducerea datelor, la apăsarea butonului **OK** corespunzător ferestrei de **Vizualizare date introduse**, se va dezactiva submeniul **New** din meniul **File** și se va activa meniul **Calcul Date** cu 2 submeniuri de **Vizualizare/Actualizare Date** și **Date săptămână prognozată**.

Dacă nu se dorește introducerea datelor în acest program și dar se dorește ieșirea din submeniu există 2 posibilități:

- se acționează cu combinația de taste **CTRL+C**
- din meniul **File** se selectează submeniul **Close**

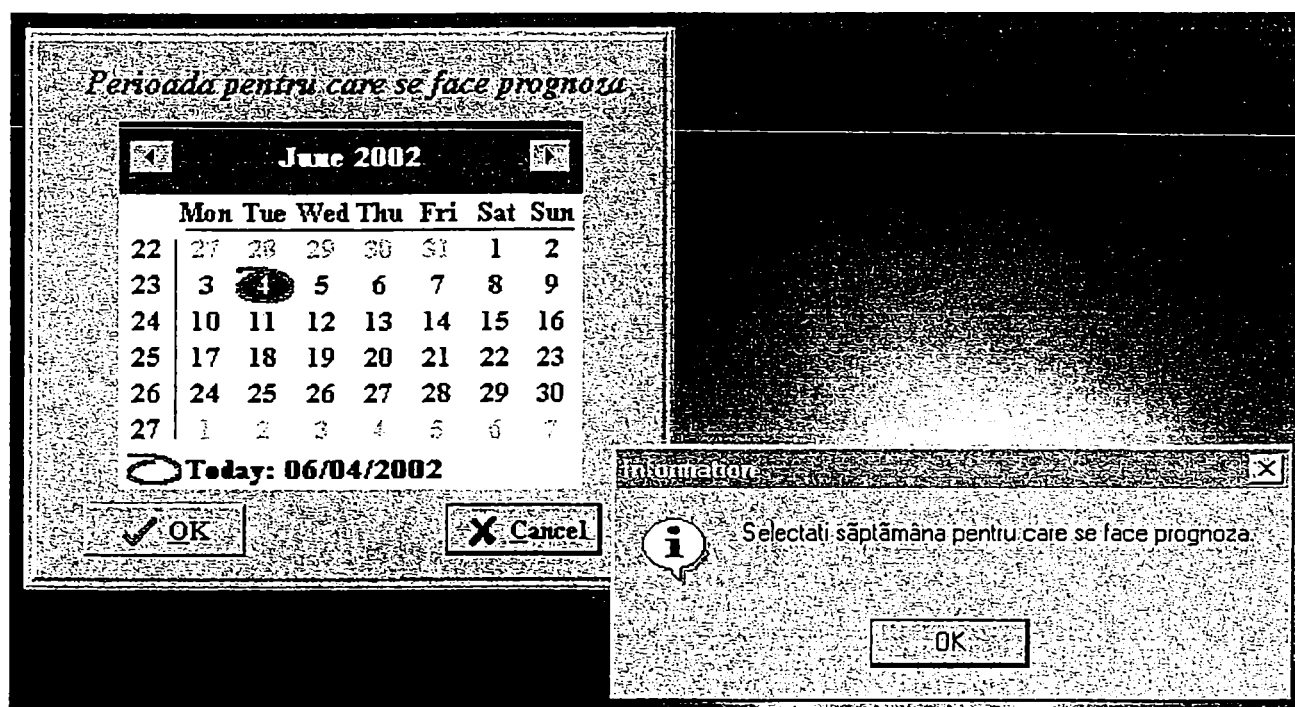
Aplicarea uneia din cele 2 variante oferă posibilitatea începerii unei noi **APLICAȚII**.

Submeniul Open

Dacă datele sunt stocate într-un fișier de tip text (*.txt) cu delimitare **TAB** între câmpuri, acestea pot fi citite de către program.

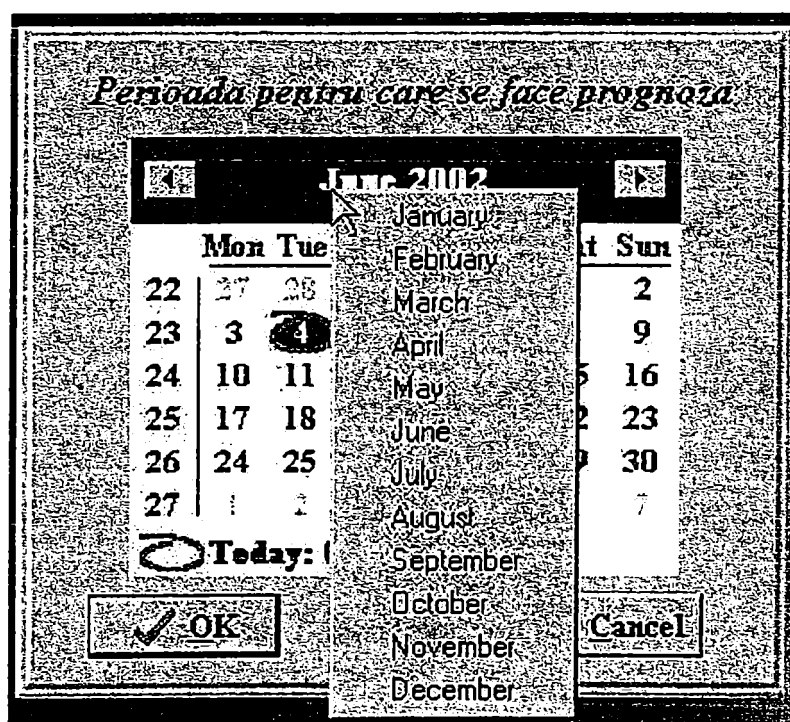
Structura datelor va fi conform fișierelor *.TXT atașate documentației.

În acest caz submeniul **New** va fi dezactivat și va apărea un mesaj în care se solicită selectarea săptămânii pentru care se face prognoza.

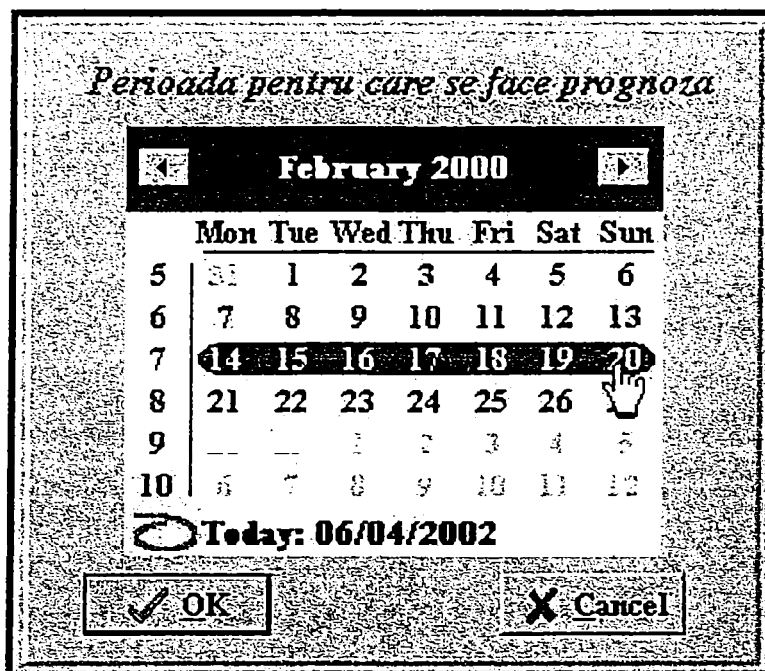


După ce se apasă pe butonul de OK de la mesaj va rămâne doar fereastra în care este un calendar prin care se face selecția săptămânii de prognoză.



Aceasta se realizează prin modificarea anului și lunii din partea de sus a ferestrei.



Selectarea se face ducând cursorul din prima zi (Luni) până în ultima zi (Duminică) a săptămânii de prognoză.



Dacă se selectează mai puține zile din săptămână sau săptămâna luată în considerare începe din altă zi decât cea de **Luni**, vor apărea următoarele mesaje:



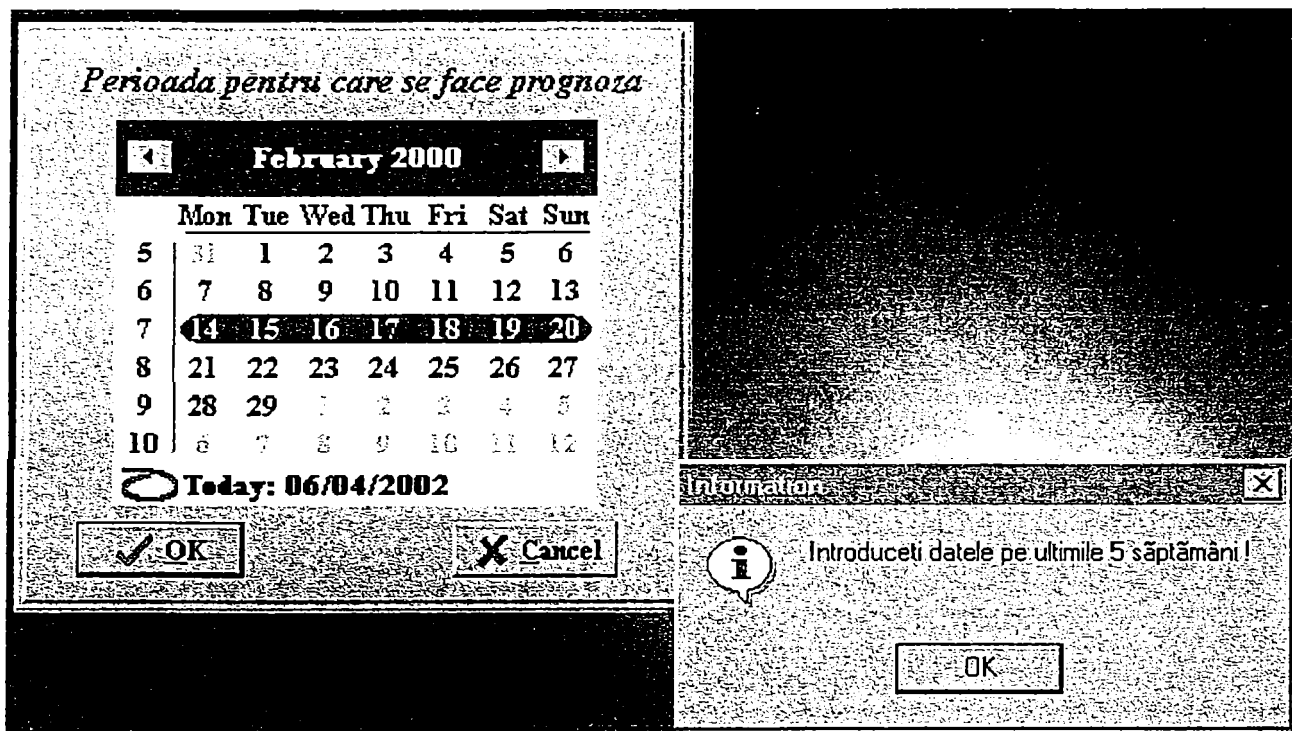
Dacă se selectează mai multe zile din săptămână sau săptămâna luată în considerare se extinde pe mai mult de 7 zile va apărea următorul mesaj:



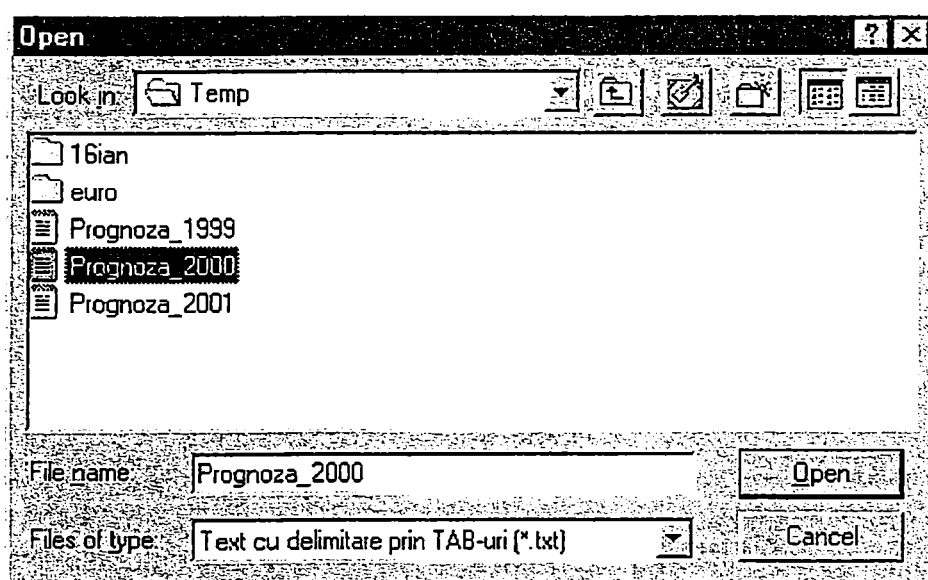
După selectarea săptămânii de prognoză se cere introducerea datelor din cele 5 săptămâni anterioare celei de prognoză.

Acestea trebuie să conțină: puteri medii orare; temperaturile minime, medii și maxime ale zilelor din săptămânile respective pe cele 24 de ore.

Data	Ora	Pmed orara	tmin	tmed	tmax
01/03/2000	01:00	1.936	-4.3	-3.3	-2.3
01/03/2000	02:00	1.80136	-4.3	-3.3	-2.3
01/03/2000	03:00	1.74988	-4.3	-3.3	-2.3
01/03/2000	04:00	1.749	-4.3	-3.3	-2.3
01/03/2000	05:00	1.77892	-4.3	-3.3	-2.3
01/03/2000	06:00	1.91356	-4.3	-3.3	-2.3
01/03/2000	07:00	2.13928	-4.3	-3.3	-2.3
01/03/2000	08:00	2.37952	-4.3	-3.3	-2.3
01/03/2000	09:00	2.48424	-4.3	-3.3	-2.3
01/03/2000	10:00	2.53748	-4.3	-3.3	-2.3
01/03/2000	11:00	2.58412	-4.3	-3.3	-2.3
01/03/2000	12:00	2.6686	-4.3	-3.3	-2.3
01/03/2000	13:00	2.71656	-4.3	-3.3	-2.3
01/03/2000	14:00	2.7258	-4.3	-3.3	-2.3
01/03/2000	15:00	2.61712	-4.3	-3.3	-2.3
01/03/2000	16:00	2.50976	-4.3	-3.3	-2.3
01/03/2000	17:00	2.52296	-4.3	-3.3	-2.3
01/03/2000	18:00	2.695	-4.3	-3.3	-2.3
01/03/2000	19:00	2.77772	-4.3	-3.3	-2.3
01/03/2000	20:00	2.86088	-4.3	-3.3	-2.3
01/03/2000	21:00	2.84504	-4.3	-3.3	-2.3
01/03/2000	22:00	2.7104	-4.3	-3.3	-2.3
01/03/2000	23:00	2.47148	-4.3	-3.3	-2.3
01/03/2000	24:00	2.22728	-4.3	-3.3	-2.3



La apăsarea butonului OK va apărea o fereastră de dialog prin intermediul căruia se selectează fișierul care conține datele corespunzătoare.



În final va apărea fereastra cu datele existente din baza de date având valorile cerute, valori care stau la baza calculului de prognoză.

!!! Important. Numărul maxim de date care pot fi introduse este cel corespunzător unui an de zile! (maxim 8760 care este corespunzător numărului de ore dintr-un an de zile).

Perioada pentru care se face prognoza

February 2000

	Mon	Tue	Wed	Thu	Fri	Sat	Sun
5	31	1	2	3	4	5	6
6	7	8	9	10	11	12	13
7	14	15	16	17	18	19	20
8	21	22	23	24	25	26	27
9	28	29					
10							

Today: 06/04/2002

OK

Vizualizare Date Introduse

Data	Ora	Pmed orara	tmin	tmed ▲
01/03/2000	01:00	1.936	-4.3	-3.3
01/03/2000	02:00	1.80136	-4.3	-3.3
01/03/2000	03:00	1.74988	-4.3	-3.3
01/03/2000	04:00	1.749	-4.3	-3.3
01/03/2000	05:00	1.77892	-4.3	-3.3
01/03/2000	06:00	1.91356	-4.3	-3.3

OK Cancel

Dacă în baza de date corespunzătoare celor 5 săptămâni anterioare celei de prognoză s-au introdus alte caractere decât cele numerice, vor apărea mesaje corespunzătoare, inclusiv pentru depășirile de limite prestabilite înainte.

Vizualizare Date Introduse

Data	Ora	Pmed orara	tmin	tmed ▲
02/01/2000	19:00	2.783	0.6	6.3
02/01/2000	20:00		0.6	6.3
02/01/2000	21:00	2.7896	0.6	6.3

Warning

Nu există date introduse la puterile medii orare!!!
corespunzător zilei din data de: 02/01/2000

OK

Vizualizare Date Introduse

Data	Ora	Pmed orara	trun	tmed
02/01/2000	19:00	2.783	0.6	6.3
02/01/2000	20:00	0	0.6	6.3
02/01/2000	21:00	2.7896	0.6	6.3

Warning

S-au introdus puteri egale cu zero in baza de date !!!
corespunzator zilei din data de: 02/01/2000

OK

Vizualizare Date Introduse

Data	Ora	Pmed orara	trun	tmed
02/01/2000	19:00	2.783	0.6	6.3
02/01/2000	20:00	-2.6674	0.6	6.3
02/01/2000	21:00	2.7896	0.6	6.3

Warning

S-au introdus puteri negative in baza de date !!!
corespunzator zilei din data de: 02/01/2000

OK

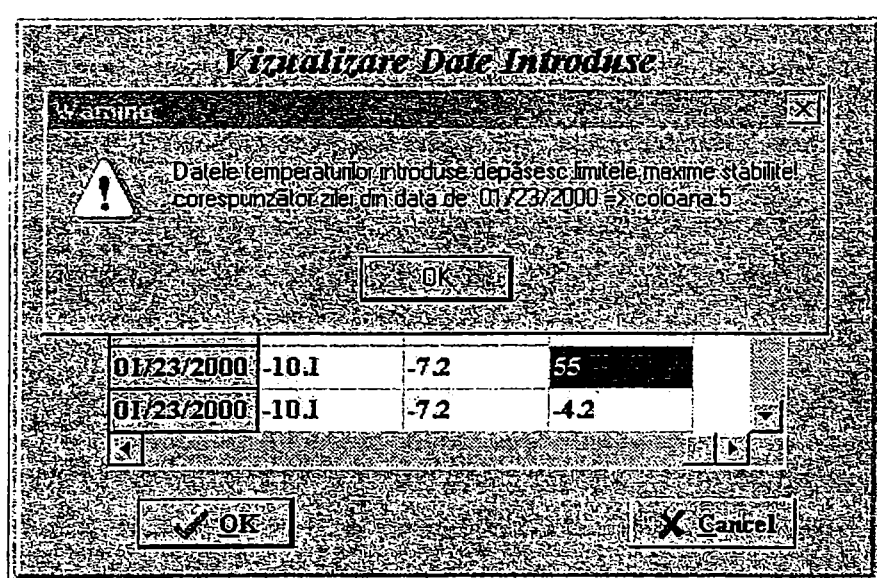
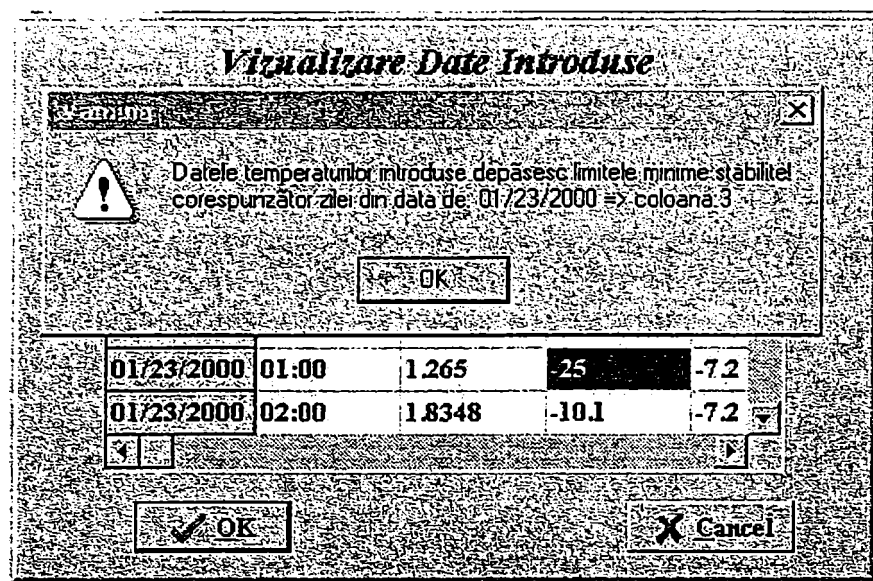
Vizualizare Date Introduse

Data	Ora	Pmed orara	trun	tmed
02/01/2000	19:00	2.783	0.6	6.3
02/01/2000	20:00	2.7374	//0.6	6.3
02/01/2000	21:00	2.7896	0.6	6.3

Warning

NU sunt admise caractere alfabetice si cele speciale de tipul
!@#\$%^&*()_

OK



După introducerea datelor, la apăsarea butonului **OK** corespunzător ferestrei de **Vizualizare date introduse**, se va dezactiva submeniul **Open** din meniul **File** și se va activa meniul **Calcul Date** cu 2 submeniuri: **Vizualizare/Actualizare Date** și **Date săptămână prognozată**.

Submeniul Limite

Apelarea meniului Limite se face fie cu combinație de taste CTRL+L fie cu mouse-ul.

Stabilire limite de verificare a bazei de date

	Minim	Maxim
Puterea medie	-10	20
Temperatura	-23	40

*Introducere mărime de bază pentru
puterea medie orară :*

Se introduc limitele minime și maxime ale mărimilor ce urmează să fie introduse în program.

Se va introduce o mărime de bază la care se raportează la puterile medii orare zilnice din baza de date (de ex. 10 000,, 30 000, kW) în funcție de ordinul de mărime al puterii orare zilnice.

În cazul în care aceste puteri orare sunt raportate la o valoare de bază, atunci se introduce în căsuța corespunzătoare valoarea 1.

În cazul în care se dorește introducerea mai multor tipuri de parametri de apasă pe butonul INSERT.

Introduce Denumirea Parametrului


(maxim 13 caractere)

La apăsarea butonului OK va rezulta în fereastră de Stabilire Limite un rând nou cu parametrul respectiv, la care se vor introduce limitele de funcționare.

Numărul de caractere este limitat la 13.

Atenționare: Nu este permisă introducerea mai multor parametri cu același nume.

În caz că acest lucru are loc va apărea următorul mesaj:



Stabilire limite de verificare a bazei de date

	Minim	Maxim
Puterea medie	-10	20
Temperatura	-23	40
Viteza Vint		

Introducere limite de funcționare

Introducere mărime de bază pentru puterea medie orară :

OK Insert Delete Cancel

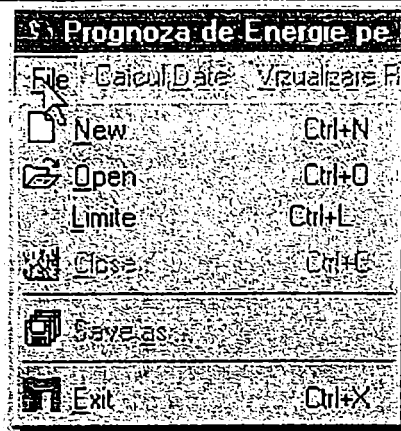
La apăsarea butonului **Delete** ultima linie se va șterge în ordine decrescătoare, adică ultima linie introdusă – prima linie ștearsă.

Primii doi parametri se consideră indici de bază pentru calculul prognozei de energie electrică, și nu pot fi anulați.

Dacă acest lucru se efectuează apare mesajul următor:



După introducerea limitelor, în meniul File se activează două submeniuri și anume: **NEW** și **OPEN**.



Comanda Close

Submeniul Close dă posibilitatea de închidere a aplicației în derulare fără închiderea programului. Apelarea acestuia se poate face fie cu combinația de taste **CTRL+C** fie cu mouse-ul se apasă submeniul Close din Meniul File.

Comanda Save As


După introducerea datelor sau după modificări în baza de date, aceasta se poate salva într-un fișier de tip text cu delimitatoare **TAB**.

Comanda Exit

Este opțiunea de închidere a programului.


Vizualizare/Actualizare Date

La activarea submeniului de Vizualizare / Actualizare date va apărea o fereastră în care se pot actualiza datele.



ATENȚIE!!! Datele introduse și semnele de punctuație țin cont de setările calculatorului.

În cazul în care se dorește introducerea mai multor tipuri de parametri se apasă pe butonul **INSERARE Linie** sau **INSERARE Coloană**.




La apăsarea butonului **OK** va rezulta în fereastra de **Vizualizare / Actualizare Date** apariția unui rând sau a unei coloane cu noul parametru la care se vor introduce datele.

Numărul de caractere este limitat la 13.

Atenționare: Nu este permisă introducerea de parametri cu același nume.

În cazul că se introduc mai mult de un parametru cu același nume, apare mesajul:



Date săptămână prognozată

La selectarea submeniului de **Date săptămână prognozată** se dezactivează submeniul anterior de **Vizualizare/Actualizare Date**, va apărea o fereastră corespunzătoare în care se vor introduce valorile temperaturilor din săptămâna de prognoză.

*Introducere parametrii pentru
săptămâna de prognoză*

Data	tmin	tmed	tmax
02/14/2000	-1.5	2.2	
02/15/2000	-2.1	1.2	
02/16/2000	-0.5		
02/17/2000	2.3		

OK Open Save Cancel

Se pot introduce și salva aceste date de temperaturi în fișiere de tip text cu delimitatori **TAB** între câmpuri.

De exemplu:


Temperaturile corespunzătoare din perioada de prognoză: 03/06/2000 - 03/12/2000

Data	tmin	tmed	tmax
03/06/2000	-4.7	0.6	6.5
03/07/2000	-2.8	4.4	13.6
03/08/2000	-2.7	4.6	14.2
03/09/2000	8.3	11.7	18
03/10/2000	5	8.4	13.3
03/11/2000	-3.8	1.4	6.8
03/12/2000	2	6	11.3

După introducerea corect a datelor la apăsarea butonului **OK** se va activa submeniul de **Calcul Prognoză putere săptămânală**.

Calcul Prognoză putere săptămânală

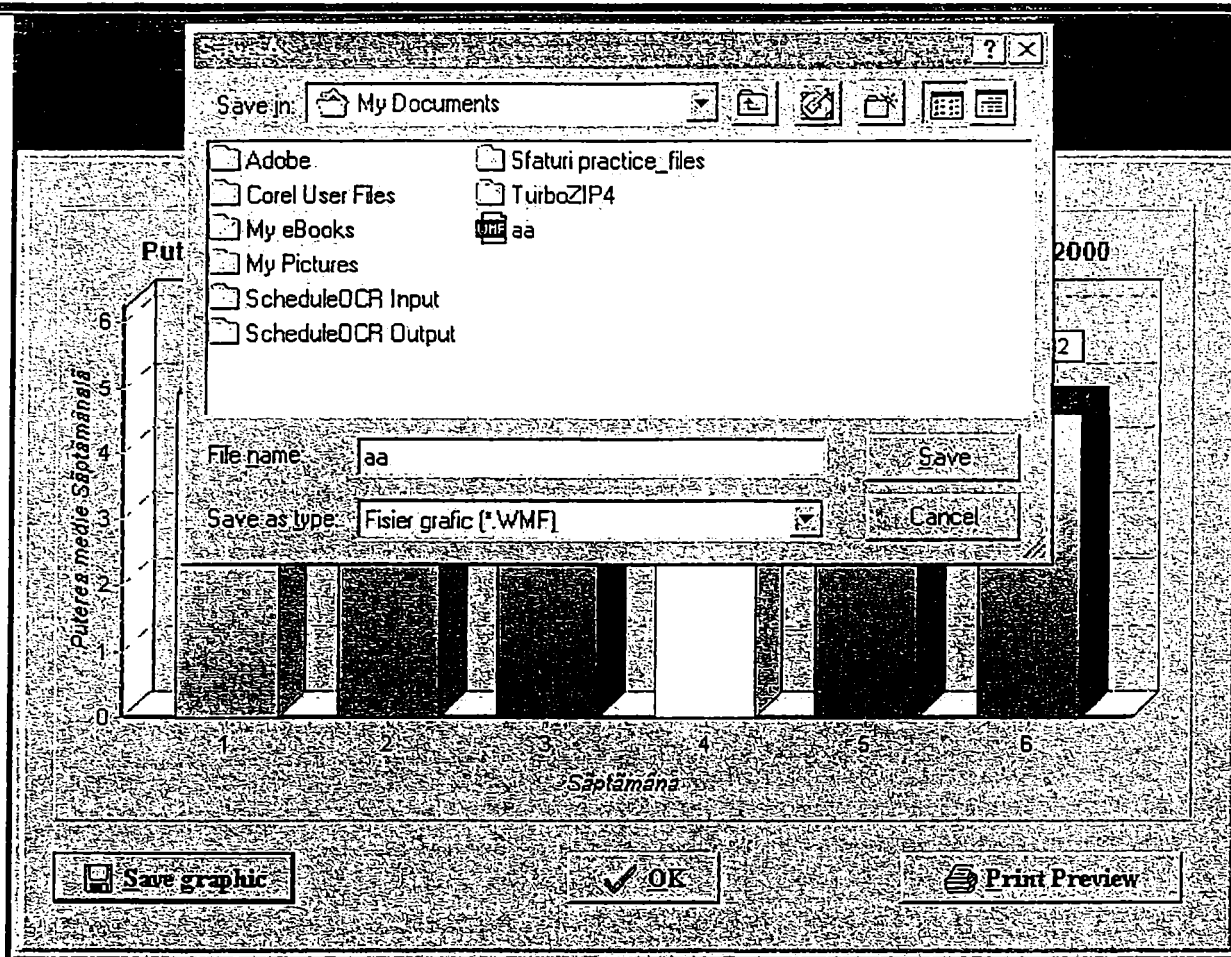
Afișează rezultatul calculului de prognoză a puterii medii săptămânale.



În acest grafic sunt afișate puterile medii săptămânale pe cele 5 săptămâni anterioare și cea din săptămâna de prognoză notată cu 6.

Atenționare!!! Rezultate calculului sunt exprimate în *unități relative* și trebuie înmulțite cu mărimea de bază introdusă în submeniul de *Limite* pentru a le obține în *unități absolute*.


Acest grafic poate fi exportat într-un fișier grafic de tip Windows MetaFile (*.wmf).



Graficul poate fi scos la imprimantă apăsând pe butonul **Print Preview**.

Va apărea o fereastră nouă în care este arătat modul cum aceasta va fi scos la imprimantă.

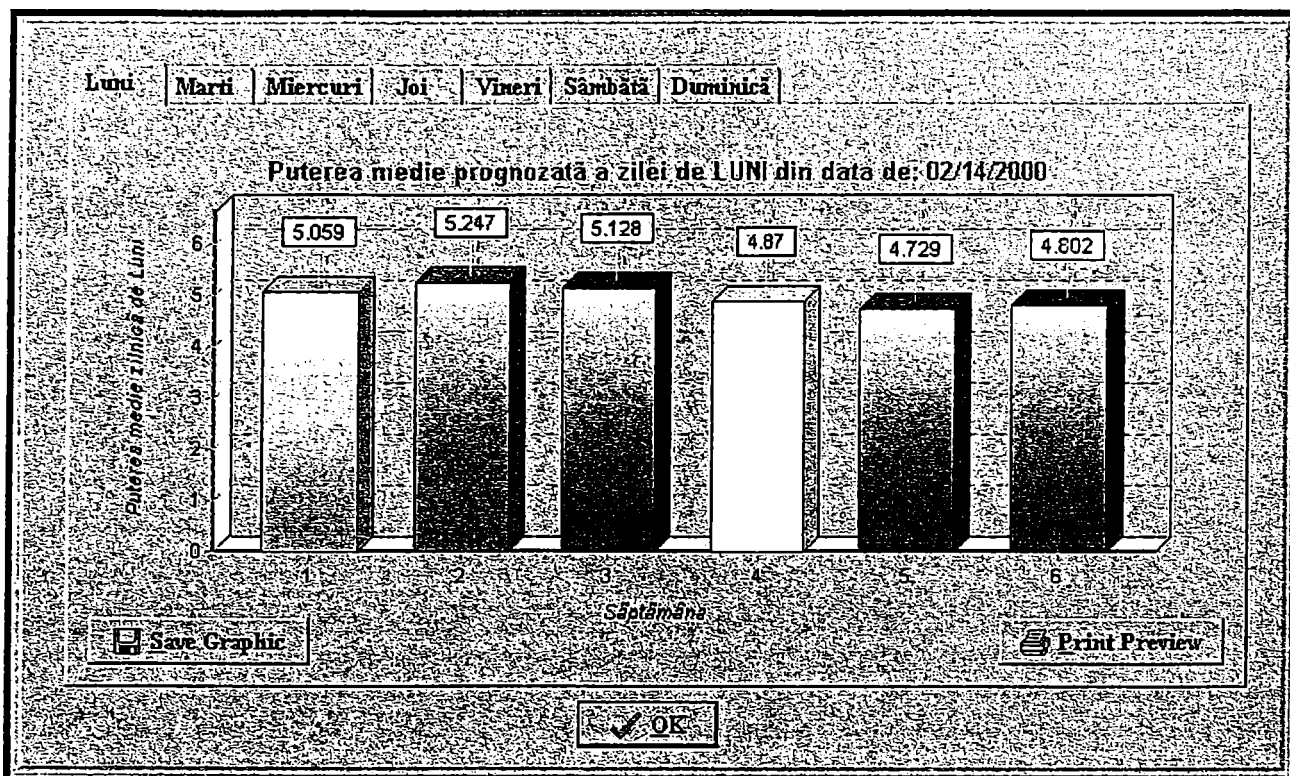
În partea de sus există o bară de unelte cu care se poate configura așezarea pe hârtie a graficului, tipul de imprimantă și butonul de comandă pentru scoaterea la imprimantă.



La apăsarea butonului **OK** fereastra corespunzătoare **Puterii medii săptămânale** se închide și submeniul corespunzător de calcul a **puterii medii săptămânale** din meniul **Calcul Date** se dezactivează și se activează submeniul **Calcul prognoză putere zilnică** și meniul de **Vizualizare rezultate** având submeniul de **Calcul Prognoză putere săptămânală**.

Calcul prognoză Putere zilnică

Afișează rezultatul calculului de prognoză a puterii medii zilnice din săptămâna de prognoză.



În acest grafic sunt afișate puterile medii zilnice pe cele 5 săptămâni anterioare celei de prognoză și cea din săptămâna de prognoză notată cu 6.


În partea de sus cu ajutorul mouse-ului sau de la tastatură se trece de la o zi la alta.

Și aici rămân valabile facilitățile în ceea ce privește posibilitatea de salvare și de scoatere la imprimantă a graficelor.

La apăsarea butonului **OK** fereastra corespunzătoare se închide și submeniul corespunzător de calcul a puterii medii zilnice din meniul **Calcul Date** se dezactivează și se activează submeniul **Prognoza curbelor de sarcină** și submeniul de **Calcul Prognoză putere zilnică** din meniul de **Vizualizare rezultate**.

Prognoza curbelor de sarcină

Afișează rezultatul calculului de prognoză a puterii medii zilnice din săptămâna de prognoză.



În acest grafic este afișat curba de sarcină a puterilor medii zilnice pe săptămâna 5 (reprezentată cu culoarea verde) anterioară celei prognozate și cea din săptămâna de prognoză (reprezentată cu culoarea roșie).

În partea de sus cu ajutorul mouse-ului sau de la tastatură se trece de la o zi la alta.

Și aici rămân valabile facilitățile în ceea ce privește posibilitatea de salvare și de scoatere la imprimantă a graficelor.

Există posibilitatea de salvare a datelor palierelor curbelor de sarcină într-un fișier de tip text cu delimitatori TAB.

La apăsarea butonului OK fereastra se închide și submeniul corespunzător de calcul a curbelor de sarcină din meniul **Calcul Date** se dezactivează și se activează submeniul de **Prognoza curbelor de sarcină** din meniul de **Vizualizare rezultate**.

CAPITOLUL 7

CONCLUZII GENERALE ȘI CONTRIBUȚII

Scopul acestei lucrări a fost acela de a elabora o procedură simplă și eficientă pentru prognoza pe termen scurt a consumurilor de energie electrică și a curbelor de sarcină zilnică, aferente consumatorilor finali. S-a considerat util a face acest lucru dat fiind condițiile actuale, social – economice pe care le traversează România . Spiritul tranziției a implicat modificări structurale în dezvoltarea societății românești, conducând la apariția unor tendințe, de multe ori contradictorii, în care rolul hazardului a devenit prioritar; la fel, multe din procedurile clasice, care apelează la baze de date riguros cunoscute, nu-și găsesc aplicația cuvenită în condițiile sistemului energetic românesc.

Modul în care sunt colectate și procesate datele, lipsa unor sisteme de achiziție electronice, suficient de dezvoltate, cu terminale fiabile și cu personal de exploatare corespunzător, a pus de multe ori, sub semnul întrebării, **calitatea bazelor de date** .

În aceste condiții, folosirea unor modele matematice sofisticate, în care fiecare element este esențial pentru rezultatul procesului de prognoză, devine greoaie și găsirea unor mijloace simple (dar nu simpliste), verificate statistic, care să combine experiența specialiștilor cu particularitățile sistemului socio – economic, sunt bine venite. Chiar dacă tendința actuală în domeniul prognozei pe termen scurt este folosirea rețelelor neuronale, antrenarea lor în condițiile unei baze de date incerte sau incomplete conduce la rezultate eronate.

În acest context, lucrarea și-a propus să prezinte o nouă metodă simplă dar cu un substrat matematic suficient de solid, care, de fapt, încearcă să aducă realitatea consumului de energie la pretențiile pe care le-ar avea evoluția logică într-un sistem social – economic valabil. Aceasta ar corespunde tocmai exigențelor pe care le impune descompunerea în serie Fourier a curbelor de sarcină zilnice, săptămânale, lunare etc.

Pentru soluționarea problemei mai sus menționate s-au analizat aspecte legate de importanța activității de prognoză și rolul ei în desfășurarea activităților specifice sistemului energetic național, metode clasice de prognoză ale consumului de energie și putere, metode moderne de prognoză a energiei electrice, folosirea inteligenței artificiale, prognoza curbelor de sarcină, tehnici efective de prognoză a consumului de energie electrică și a curbelor de sarcină, elaborarea unui program performant pentru prognoza energiei electrice și puterii pe termen scurt (PRENPS).

În cadrul prezentării problemelor legate de **importanța activității de prognoză** s-a evidențiat faptul că activitatea de prognoză nu este altceva decât o aproximare a unor evenimente viitoare, necunoscute, pe baza modului în care s-au desfășurat aceste evenimente în trecut și se desfășoară în prezent.

Astăzi, în condițiile economiei de piață, și mai ales a formării pieței libere de energie, prognoza necesarului de energie și putere pe termen scurt câștigă o nouă dimensiune în relația dintre furnizorul de energie și consumator, având un rol important în gestionarea consumurilor de energie și a desfășurării eficiente a activității distribuitorilor de energie. În funcție de consumul de energie prognozat producătorii de energie electrică trebuie să oferteze zilnic capacitățile disponibile pentru a acoperi acest consum. La ordonarea ofertelor producătorilor de către Operatorul Comercial se ține seama de următoarele restricții:

- asigurarea debitelor de servitute și a altor restricții de utilizare a apei din amenajările hidroenergetice;
- preluarea integrală a energiei furnizate de CNE Cernavodă;
- asigurarea încărcării electrice a grupurilor în cogenerare la nivelul impus de sarcina termică;
- arderea unor cantități prestabilite de cărbune;
- respectarea contractelor tip PPA ale unor producători;
- respectarea contractelor bilaterale ale unor producători încheiate cu consumatori eligibili;
- respectarea contractelor de import/export de energie electrică.

Operatorul comercial va ordona crescător, funcție de preț, toate ofertele de producere primite, nu numai cele corespunzătoare acoperirii prognozei de consum.

Prețul marginal de sistem (PMS) reprezintă prețul ultimului MWh stabilit de ordinea de merit pentru acoperirea cererii de energie electrică într-un interval bază de programare.

Elementele care stau la baza stabilirii Ordinii de Merit și a Prețului Marginal de Sistem sunt:

- Prognoza consumului net de energie electrică activă, în valori medii orare, realizată de către furnizori pentru următoarele două zile energetice și prelucrată de către Operatorul Comercial pe baza:
- Valorilor medii orare ale consumului înregistrate în aceeași zi calendaristică a anului anterior;
- Valorilor medii orare ale consumului înregistrate în zilele precedente;
- Prognozei meteorologice.

Pe lângă cele menționate în cadrul acestui capitol, se subliniază rolul caracteristicilor consumului de energie din zona analizată asupra modelului de prognoză pe termen scurt. Aceste caracteristici au în vedere caracterul nestaționar al consumului de energie electrică, forma de principiu a curbelor de sarcină, particularitățile evoluției sarcinii, în zilele speciale și, nu în ultimul rând, principalii factori care caracterizează nivelul consumului de energie electrică.

Demne de remarcat sunt, fără îndoială, particularitățile pe care le prezintă curbele de sarcină din zilele săptămânii și anume gruparea lor în trei categorii pentru zilele lucrătoare: luni, marți - joi și vineri, iar pentru zilele de odihnă (repaus) firește, sâmbăta și duminica. Condiționările care apar între zile, precum și anumite relații stabilite între consumurile zilelor de lucru, de lucru și de repaus, vor fi determinante în logica algoritmilor de prognoză.

În finalul acestui capitol, în scopul de a arăta locul pe care îl are prognoza pe termen scurt în cadrul întregii activități de prognoză, s-au făcut referiri și la prognoza pe termen mediu, în particular la stabilirea cantităților și prețurilor contractuale precum și la principiile care se au în vedere la elaborarea unui model de prognoză pe termen mediu.

Legat de **metodele clasice de prognoză a consumului de energie și putere** s-au prezentat aspectele generale pe care le comportă abordarea problemelor aferente activităților de prognoză investigate cu metodele clasice – deterministe. Acestea stau, de fapt, la baza rezultatelor și experienței uriașe acumulate de companiile de electricitate, pe de-o parte, iar pe de altă parte, stau la baza apariției și dezvoltării metodelor moderne, larg folosite astăzi:

De la bun început, s-a dorit a se evidenția faptul că activitatea de prognoză nu este una singulară, care nu poate fi concepută și desfășurată separat în cadrul SEN, ci în strânsă dependență cu întreaga viață social-economică a societății, eventual politica energetică promovată de guvernul țării respective.

În cadrul acestui capitol sunt evidențiate criteriile de clasificare a metodelor de prognoză, etapele unui studiu de prognoză, insistându-se asupra modelelor matematice adoptate. Dintre

aceste modele, un rol determinant îl are regresia liniară simplă. În finalul capitolului se evidențiază necesitatea reconsiderării unor metode de prognoză care apelează la comparații cu alte țări, respectiv cu alte sisteme energetice, care au trecut prin etapele pe care le parcurge astăzi România.

Anumite corelații, dependențe și legități economice, caracteristice economiilor acestor țări și regăsite într-o formă sau alta în evoluția consumului de energie, vor marca fără îndoială și evoluția consumului de energie electrică din țara noastră.

În capitolul al treilea sunt prezentate **metodele moderne de prognoză** a energiei electrice folosind rețele neuronale. Sunt trecute în revistă principalele componente ale tehnicilor de inteligență artificială, centrul de greutate fiind concentrat pe rețele neuronale artificiale (RNA).

Legat de acestea, se prezintă arhitectura tipică a unei rețele, caracteristici principale, clasificarea unei RNA, antrenarea acestora, precum și rețele neuronale de tip Perceptron multistrat.

Sunt prezentate câțiva algoritmi specifici pentru antrenarea rețelelor Standard Back, Back Propagation, Resilient Propagation.

S-a pus în evidență analogia dintre metodele statistice și rețelele neuronale artificiale, demonstrând în același timp cum o rețea neuronală cu propagare înapoi conduce la aceleași rezultate ca și un proces autoregresiv cu medie mobilă.

Sunt prezentate avantajele și dezavantajele utilizării rețelelor neuronale în raport cu modelele statistice. De reținut este faptul că RNA pot modela serii foarte complexe, care nu pot fi descrise de un simplu model liniar.

Cu datele existente pentru consumatorul Stația electrică Moșnița Timișoara s-a realizat prognoza orară a puterilor utilizând o RNA de tip Perceptron Multistrat cu un strat ascuns. Erorile care apar sunt foarte mari (18,9% - 28,2%) pentru zilele de sâmbătă și duminică și în general mai mari decât cele care apar în cazul descompunerii Fourier.

Legat de **prognoza curbilor de sarcină**, lucrarea trece în revistă aspectele pe care le comportă prognoza acestora, evidențiind, pe de-o parte utilitatea și importanța acestora, iar pe de altă parte, complexitatea procesului de prognoză.

Sunt subliniate problemele teoretice pe care le comportă analiza curbilor de sarcină: definiții de mărimi caracteristice, clasificări, terminologie, mod de obținere. Nu în ultimul rând, se subliniază rolul modelării în procesul de prognoză, faptul că abordarea ei trebuie făcută din considerente statistice.

Se arată că, de fapt, curba de sarcină este un ansamblu de 2 caracteristici distincte și complementare: una de formă, ce reflectă modularea relativă a puterilor consumate și alta de nivel, ce ține cont de cantitatea de energie electrică consumată.

Prognoza curbilor de sarcină poate fi efectuată în domeniul frecvență sau în domeniul timp. În domeniul timp, foarte utilizat este modelul cunoscut sub denumirea autoregresiv cu medie alunecătoare ARMA. Acest model asigură structura de bază pentru modelul stocastic staționar.

Important, însă, în demararea procesului de prognoză în această tehnică, este identificarea seriei de timp, identificare care trebuie completată și de o validare corespunzătoare.

În încheiere se descrie principal metoda efectivă de prognoză a curbilor de sarcină, bazată pe folosirea seriilor de timp și aplicația efectuată la nivelul curbilor de sarcină la nivelul sistemului, efectuată de Operatorul Comercial.

În ceea ce privește tehnicile propuse pentru **prognoza pe termen scurt a necesarului de energie și a curbilor de sarcină**, acestea reprezintă de fapt contribuțiile originale ale tezei și toate observațiile desprinse în cadrul capitolului se constituie în premise utile și evident necesare pentru elaborarea algoritmului care a stat la baza tehnicii de prognoză prezentată.

Astfel, admitând o anumită stabilitate a formei curbei de sarcină pe durata a 6 săptămâni considerate (cinci corespunzătoare datelor și una corespunzătoare prognozei), curbele de sarcină au fost descompuse în serie Fourier, s-au reținut coeficienții de valoare semnificativă, s-a urmărit dependența lor de anumiți indicatori, reținând corelațiile semnificative și apoi extrapolându-le pentru zilele săptămânii de prognoză.

O etapă importantă a constituit-o identificarea problemelor pe care le comportă descompunerea curbelor de sarcină în serie Fourier și anume: stabilirea numărului minim de intervale în care trebuie discreditată curba de sarcină, avându-se în vedere, pe de-o parte modul în care se efectuează citirile de contor (contoarele electronice sau digitale) și pe de altă parte, faptul că prognoza trebuie prezentată sub formă de paliere orare. O altă problemă este stabilirea numărului minim de coeficienți Fourier care trebuie luat în considerare pentru a asigura o precizie corespunzătoare în aprecierea curbei de sarcină.

Referitor la numărul de intervale, respectiv mărimea pasului de discreditare s-au stabilit următoarele:

- precizia de determinare a coeficienților seriei Fourier pentru o anumită durată a pasului de discreditare (1/4h, 1/2h, 1h, 2h) depinde de forma curbei de sarcină și mai ales de gradul ei de neuniformitate, cu cât acesta este mai accentuat, cu atât este necesar a adopta un pas de discreditare mai mic;
- valoarea coeficienților Fourier calculați variază în limite foarte largi, de la cca 0,1% până la cca 20% din puterea medie zilnică, rolul determinant deținându-l alături de puterea medie coeficienții de rang 1 și 2, adică $a_{1,2}$ și $b_{1,2}$;
- participarea coeficienți $a_{1,2}$ și $b_{1,2}$ la sinteza curbei de sarcină depinde de faptul că ziua luată în considerare este de lucru sau de odihnă, astfel pentru zilele de lucru ordinea de participare a coeficienților este a_1, b_1, a_2, b_2 pe când pentru zilele de repaus a_1, a_2, b_2, b_1 ;
- odată cu creșterea rangului armonicilor, ponderea coeficienților scade, dar situația nu este generală, apărând și excepții de la această regulă, tendința de ansamblu însă fiind aceea de scădere;
- sensibilitatea coeficienților Fourier pentru un anumit consumator depinde de tipul coeficientului (a, b, c), rangul lor (k), de faptul că ziua este de lucru sau de repaus; o sensibilitate redusă, adică o stabilitate bună prezintă coeficientul a_1 , care are valori foarte apropiate pentru zilele de lucru și cele de odihnă;
- abaterile coeficienților față de valorile considerate exacte (corespunzătoare pasului de 1/4h), cresc odată cu creșterea pasului de discreditare, dacă pentru pași de 1/2h și 1h acestea nu depășesc 10-15%, pentru a_{1-4} , b_{1-4} , pentru pasul de 2h acestea ating și valoarea de 100%, deci pasul de 2h nu poate fi acceptat.

Referitor la numărul minim de coeficienți Fourier, s-au constatat următoarele:

- erorile maxime nu apar la vârful de sarcină și nici la goluri, ci pe porțiunile de pantă maximă, datorită faptului că armonicile nu au suficientă elasticitate pentru a asigura interpolarea necesară;
- considerarea unui număr mai mic sau mai mare de armonici consecutive afectează sensibil nivelul mediu al erorilor, fără însă a afecta sensibil nivelul erorii maxime și nici treapta la care aceasta apare;
- nu întotdeauna considerarea unui număr sporit de armonici conduce la reducerea nivelului erorii maxime, pot apare și situații inverse, aceasta depinzând de forma curbei de sarcină, pentru zilele de odihnă situația este inversă ca pentru cele de lucru;
- considerarea unui număr diferit de armonici poate conduce și la deplasarea palierului la care apare eroarea maximă. De obicei pentru zilele lucrătoare această

deplasare poate fi de maxim un palier (una oră) iar în situații deosebite două paliere (două ore);

- indiferent de numărul de armonici superioare ($k > 1$) luate în considerare la aproximarea curbelor de sarcină, erorile care apar pot fi controlate și reduse;
- considerarea armonicelor pare ($k=2\div 10$) alături de fundamentală asigură o interpolare relativ bună a curbei, finisând vârfurile, dar nu rezolvă problema aproximării precise a porțiunilor cu pantă mare;
- considerarea armonicelor impare ($k=3\div 9$) alături de armonicile 1 și 2 asigură o interpolare relativ bună a curbei de sarcină, rezolvă problema porțiunilor cu pantă mare descendentă, dar nu și pe aceea a porțiunilor cu pantă mare ascendentă.

Concluzii utile au rezultat și în legătură cu prognoza consumului de energie săptămânal și respectiv zilnic. Astfel, referitor la prognoza energiilor săptămânale, au rezultat următoarele:

- este cea mai importantă etapă a întregii activități de prognoză pe termen scurt, ea putând constitui un indicator (variabilă) fundamental în stabilirea corelațiilor necesare prognozelor energiilor (puterilor medii) zilnice și a curbelor de sarcină;
- pentru modelarea evoluției energiei săptămânale se adoptă mai multe modele, criteriul de alegere fiind calitatea modelării;
- alături de tehnicile de prognoză clasice, un rol deosebit pot să-l dețină și metodele euristice, bazate pe anumite raționamente logice, una dintre acestea fiind și aceea a sensibilității necesarului de energie electrică săptămânală cu variația temperaturii medii săptămânale: minimă, medie și maximă, dezvoltată în acest capitol și denumită metoda sensibilității termice;
- aplicarea corectă a metodei sensibilității termice presupune eliminarea componentei datorate marilor consumatori, stabilirea limitelor de confort termic pentru mediul ambiental, identificarea temperaturii medii săptămânale care influențează în măsura cea mai mare variația consumului de energie de la o săptămână la alta;
- la aplicarea metodei sensibilității termice a necesarului de energie trebuie avută în vedere inerția termică diferită a mediului ambiental în condițiile anotimpului călduros, respectiv friguros. Acest lucru se manifestă printr-o întârziere a răspunsului consumatorului la variații bruște de temperatură. Prin urmare variațiile de temperatură în cadrul acestei metode trebuie tratate diferit, bruște sau lente. Pentru studiul de caz analizat limita temperaturii minime a fost găsită de 4°C ;
- dacă baza de date este corectă, prin aplicarea metodei rezultă erori mai mici de 3%.

Referitor la prognoza consumului de energie electrică zilnică, aceasta s-a efectuat prin metode clasice de regresie și metode euristice, folosind așa-numita metodă a “distanței termice” sau “termice limită”, precum și prin descompunerea curbei de sarcină săptămânale a puterilor medii zilnice în serie Fourier. Deși aceasta din urmă este complet originală și foarte utilă pentru zilele de lucru, s-a dovedit inefficientă pentru zilele de repaus, motiv pentru care nu a fost reținută în final pentru a fi cuprinsă în tehnica de prognoză.

Referitor la aplicarea metodelor de analiză de regresie, trebuie menționate următoarele:

- modelele care au la bază corelații liniare simple sunt cele mai utile;
- corelația liniară a puterii medii zilnice cu puterea medie săptămânală conduce la reziduuri de valoare redusă pentru toate zilele săptămânii mai puțin ziua de Sâmbătă;

- corelațiile liniare cu temperaturile zilnice și chiar cu temperatura medie săptămânală, deși prezintă coeficienți de corelație de valoare absolută relativ ridicată, nu conduc la reziduuri de valoare mică;
- corelațiile liniare multiple, care folosesc drept variabile puterile medii zilnice, săptămânale și temperaturile zilnice sau săptămânale nu dau satisfacție în etapa de modelare și nici în aceea de prognoză;
- nu întotdeauna consumul unei zile se corelează liniar cu acela al zilei anterioare, dar de regulă se corelează neliniar, după o funcție pătratică;
- consumul zilei de Vineri se corelează liniar cu acela al zilei de Luni ;
- consumul zilei de Sâmbătă se corelează foarte bine cu acela al zilelor de Vineri și de Duminică ce o mărginesc ;
- consumul zilei de Duminică se corelează foarte bine cu acela al zilei de Sâmbătă după o funcție de tipul $y=a+b/x$;
- variațiile mari de temperatură care pot apare de la o zi la alta, combinate cu inerția termică a mediului ambiental, fac ca temperaturile medii zilnice să nu ofere întotdeauna modele atractive pentru prognoza consumului de energie zilnică ;
- sunt de preferat modelele matematice care cuprind energia săptămânală față de energia zilnică.

Referitor la aplicarea metodei “distanței termice” (metoda distanței termice limită) sau stabilirea următoarelor:

- metoda distanței limită nu folosește modelări analitice, ci gruparea puterilor medii zilnice raportate la puterea medie săptămânală în trei grupe, dependent de distanța temperaturii zilnice față de temperatura medie săptămânală. Astfel pentru fiecare grupă se poate calcula un coeficient mediu care înmulțit cu puterea medie săptămânală (prognozată) permite obținerea puterilor medii zilnice;
- metoda distanței termice are la bază ideea că în condițiile aceluiași interval de temperatură (distanță termică) puterea medie zilnică raportată la puterea medie săptămânală rămâne aceeași;
- distanța termică limită se apreciază concret în funcție de baza de date existentă; pentru studiul de caz analizat ea a fost stabilită la 2^oC;
- prin aplicarea metodei distanței termice rezultatele obținute în procesul de prognoză a energiilor consumate zilnic sunt comparabile sau chiar mai bune decât cele obținute cu metodele clasice.

Față de cele mai sus menționate se cuvine a evidenția anumite particularități referitoare la baza de date folosită, bază specifică consumatorilor finali de felul celui analizat (oraș Timișoara – stația Moșnița, AT1):

- puterea medie săptămânală este de regulă cu ceva mai mică (1-3 %) sau egală cu puterea medie a zilei de Luni, adică $P_L=(1-1,03) P_{Sapt}$;
- puterea medie a zilei de Vineri este foarte apropiată de aceea a zilei de Luni, diferența ce eventual ar putea apare se datorează depășirii distanței termice limită dintre cele două zile;
- puterea medie a zilei de Sâmbătă este cuprinsă întotdeauna între cele ale zilei de Vineri și Duminică ce o mărginesc, de multe ori (peste 50% din cazurile analizate) se poate scrie o relație de forma $P_S=(P_V+P_D)/2$;
- consumul de energie zilnică cel mai mare se consemnează în zilele de Marți, Miercuri, sau Joi ;
- în anotimpul friguros ziua cu temperatura minimă nu corespunde cu ziua cu cel mai mare consum de energie electrică ;

- în anotimpul cald ziua cu cel mai mare consum de energie corespunde de regulă cu ziua cea mai călduroasă .

Referitor la aplicarea metodei de programare a puterii medii zilnice au rezultat următoarele:

- prin considerarea a șapte puncte (corespunzătoare zilelor săptămânii) erorile de interpolare sunt în general mici pentru primele patru zile ale săptămânii (nedepășind în medie 2-2,5 %).Erorile cele mai mari apar în prima zi (Luni); în a doua parte a săptămânii erorile cresc sensibil atingând valori de 10-13 % Duminică; aceasta este de fapt ziua cel mai prost modelată;
- prin creșterea numărului de zile prin introducerea unor zile intermediare fictive ,erorile se micșorează simțitor pentru zilele de lucru ele nedepășind 2%;
- pentru ziua de Sâmbătă eroarea se reduce la jumătate ,în schimb pentru ziua de Duminică reducerea este ne semnificativă;
- pentru prognoza coeficienților seriei Fourier corelația liniară multiplă având drept variabile cele nouă temperaturi săptămânale nu conduce la rezultate utile, în schimb corelațiile liniare simple se pretează mai bine ,mai ales atunci când folosesc temperatura; max (t_{min}) sau med (t_{med}) ;
- pentru un regim termic relativ constant ,aplicarea metodei distanței termice poate conduce la reziduuri mai mici de 3%.

În ultima parte a lucrării a fost prezentat programul PRENPS (PRognoza ENergie și Puterii Săptămânale). El a fost conceput să lucreze în 3 etape, determinând energia săptămânală, zilnică și curbele de sarcină orare pentru fiecare zi. Elementul de bază este săptămâna și poziția fiecărei zile în săptămână. În plus, la prognoza energiilor zilnice, acestea s-au raportat la energia săptămânală, iar cea orară, la energia zilnică. Tehnica funcționează pe baza unor corelații dintre energia săptămânală, zilnică, palierele curbei de sarcină și diferiți indicatori dintre care, rolul fundamental îl au temperaturile zilnice prin valorile t_{min} , t_{med} , t_{max} .

Rezultatele obținute prin rularea acestui program, pe datele de consum achiziționate din stația Moșnița din Timișoara, au scot în evidență faptul că erorile apărute în prognozarea puterilor medii zilnice pentru săptămânile 06.03.-12.03.2000 și 14.02.-20.02.2000 se încadrează în limite rezonabile, sub 5%.

O dezvoltare ulterioară a programului ar presupune apelarea la rețele neuronale, având în vedere avantajele utilizării acestora în rezolvarea problemelor neliniare, cum este și prognoza sarcinii electrice.

Aceasta abordare va recurge la descompunerea în armonici a curbelor de consum, urmând ca prognoza acestora să se efectueze folosind rețele neuronale.