

**UNIVERSITATEA POLITEHNICA TIMIȘOARA**  
**FACULTATEA DE ELECTROTEHNICĂ ȘI**  
**ELECTROENERGETICĂ**  
**DEPARTAMENTUL DE ELECTROENERGETICĂ**

**Ing. Antheia Deacu**

**REZUMAT**  
**TEZĂ DE DOCTORAT**

**PROGNOZA CONSUMULUI**  
**DE ENERGIE ELECTRICĂ UTILIZÂND**  
**REȚELE NEURONALE ARTIFICIALE**

**Conducător științific:**  
**Prof.univ.dr.ing. Ștefan Kilyeni**

## CUPRINS

|                                                                                               |    |
|-----------------------------------------------------------------------------------------------|----|
| 1. INTRODUCERE.....                                                                           | 3  |
| 2. STADIUL ACTUAL AL EVOLUȚIEI SECTORULUI ENERGETIC ȘI ELECTROENERGETIC                       | 3  |
| 2.1. Contextul global. Politica energetică a Uniunii Europene.....                            | 4  |
| 2.2. Politica energetică a României.....                                                      | 4  |
| 2.3. Concluzii.....                                                                           | 4  |
| 3. MODALITĂȚI DE SOLUȚIONAREA PROGNOZEI CONSUMULUI DE ENERGIE<br>ELECTRICĂ.....               | 4  |
| 3.1. Clasificarea metodelor de prognoză .....                                                 | 4  |
| 3.2. Metode în funcție de natura variabilei independente .....                                | 4  |
| 3.3. Metode în funcție de orizontul de timp al prognozei.....                                 | 5  |
| 3.3.1. Metode pentru prognoze pe termen mediu și lung .....                                   | 5  |
| 3.3.2. Metode pentru prognoze pe termen scurt .....                                           | 5  |
| 3.4. Factorii care influențează consumul de energie electrică .....                           | 6  |
| 3.5. Concluzii .....                                                                          | 6  |
| 4. REȚELE NEURONALE ARTIFICIALE (RNA).....                                                    | 6  |
| 4.1. Aspecte generale ale RNA .....                                                           | 6  |
| 4.2. Modelul RNA.....                                                                         | 7  |
| 4.3. Rețele neuronale de tip perceptron.....                                                  | 7  |
| 4.4. Concluzii.....                                                                           | 8  |
| 5. METODE NUMERICE ȘI TEHNICI DE OPTIMIZARE.....                                              | 8  |
| 6. MODEL MATEMATIC ȘI INSTRUMENT SOFT PENTRU PROGNOZA CONSUMULUI DE<br>ENERGIE ELECTRICĂ..... | 8  |
| 7. STUDII DE CAZ ȘI REZULTATE.....                                                            | 9  |
| 8. CONCLUZII GENERALE. CONTRIBUȚII PERSONALE.....                                             | 10 |
| Bibliografie.....                                                                             | 10 |

## **1. INTRODUCERE**

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

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

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

În România, piața de energie s-a liberalizat complet relativ recent, lucru care a determinat apariția unei competiții în domeniu. Conectarea la sistemul național a producătorilor de energie din surse regenerabile și dezvoltarea industriei prin achiziția de echipamente noi, precum și dotarea populației cu echipamente electrice pentru confortul rezidențial, ridică probleme care necesită rezolvare urgentă, prin prisma acestor noi provocări. Tendința de a oferi consumatorului final posibilitate de alegere a furnizorului de energie electrică, tinde să devină o realitate. Astfel, furnizorii și distribuitorii de energie electrică devin tot mai mult interesați de dezvoltarea de noi strategii orientate către implementarea de soluții de control și asistență a deciziilor.

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

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

Proгноza consumului de putere și de energie electrică, în condițiile unei piețe deschise, are un rol foarte important în funcționarea eficientă și sigură a sistemului electroenergetic. Acest fapt este valabil și pentru sistemele clasice de producere centralizată a energiei electrice, dar mai ales pentru sistemele moderne, caracterizate de utilizarea și integrarea pe scară largă a surselor regenerabile de energie.

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

## **2. STADIUL ACTUAL AL EVOLUȚIEI SECTORULUI ENERGETIC ȘI ELECTROENERGETIC**

În capitolul 2 este prezentată situația actuală a evoluției sectorului energetic și a sistemului electroenergetic, atât la modul general, cât și cel particular al României. O atenție specială se acordă consumului și producerii de energie electrică.

În prima parte este prezentat contextul global, politica energetică a Uniunii Europene, și obiectivele generale ale strategiei sectorului energetic.

A doua parte a capitolului este consacrată politicii energetice a României, pieței de energie electrică din România, cu un accent special asupra situației și evoluției producerii și consumului de energie electrică. În contextul discutat, se prezintă și o serie de elemente legate de conceptul de Smart Metering, de factorii motivați pentru implementarea contorizării inteligente a consumului de energie electrică.

## **2.1. Contextul global. Politica energetică a Uniunii Europene**

Uniunea Europeană (UE) elaborează o politică energetică ambițioasă care acoperă toate sursele de energie, de la combustibili fosili (țitei, gaz și cărbune) până la energia nucleară și cea regenerabilă (solară, eoliană, geotermală, hidro etc.), în încercarea de a declanșa o nouă revoluție industrială, care să ducă la o economie cu consum redus de energie și la limitarea schimbărilor climatice.

Politica Uniunii Europene pentru perioada următoare se bazează pe trei obiective fundamentale [SE2007] [ESE2011]:

- durabilitate – are ca obiectiv schimbările climatice prin reducerea emisiilor de gaze cu efect de seră, promovarea producerii energiei pe bază de resurse regenerabile, reducerea impactului negativ al sectorului energetic asupra mediului;
- competitivitatea – vizează asigurarea implementării efective a pieței interne de energie, dezvoltarea piețelor concurențiale de energie electrică, gaze naturale și servicii energetice, liberalizarea tranzitului de energie și asigurarea accesului nediscriminatoriu al participațiilor la piață la rețelele de transport internaționale;
- siguranța în alimentarea cu energie – reducerea vulnerabilității UE în privința importurilor de energie, a întreruperilor în alimentare, a posibilelor crize energetice și a nesiguranței privind alimentarea cu energie în viitor, în special prin încurajarea investițiilor în resurse proprii și prin diversificarea surselor de aprovizionare.

## **2.2. Politica energetică a României**

Obiectivul general al strategiei sectorului energetic îl constituie satisfacerea necesarului de energie atât în prezent, cât și pe termen mediu și lung, la prețul cel mai mic, suportabili pentru consumatori, adecvat unei economii moderne de piață și un standard de viață civilizat, în condiții de calitate, siguranță în alimentare, cu respectarea principiilor dezvoltării durabile [SEN2014].

## **2.3. Concluzii**

voluția sectorului energetic, în general, și a sistemelor electroenergetice, în particular, prezintă o serie de particularități complexe. Sectorul energetic are o influență puternică asupra altor sectoare de activitate, ceea ce conduce la necesitatea unei dezvoltări durabile, ținând cont și de mediu. Problemele au fost abordate în cadrul acestui capitol atât la modul general, cât și cel particular al României. O atenție specială s-a acordat evoluției consumului și producerii de energie electrică.

# **3. MODALITĂȚI DE SOLUȚIONAREA PROGNOZEI CONSUMULUI DE ENERGIE ELECTRICĂ**

## **3.1. Clasificarea metodelor de prognoză**

Prognoza consumului de energie poate fi clasificată după mai multe criterii [Luștea2001], cu observația că părerile nu sunt întotdeauna unitare (mai ales în ceea ce privește orizontul de timp, în sensul pornirii de la un anumit număr de ore sau zile):

- după perioada pe care se referă:
- după extinderea spațială:
- după scop:
- după natura metodei matematice:
- după tipul metodei:
- după natura variabilei independente:
- după numărul de componente ale consumului:

## **3.2. Metode în funcție de natura variabilei independente**

### **Metode directe**

Metodele directe de prognoză au la bază ipoteza conform căreia cauzele, factorii și tendințele care au determinat evoluția consumului de energie sau de putere în perioada trecută se păstrează și cea viitoare, pe toată durata prognozei neintervenind schimbări dramatice, bruste care să influențeze evoluția consumului [Luștea2001]

### **Metode indirecte**

Metodele indirecte de prognoză a consumului de energie folosesc corelația existentă între consumul de energie sau de putere și factorii demografici, climatici, economici etc. [Luștea2001].

### **Metode analitice**

Folosirea unei metode analitice pentru estimarea consumului de energie este foarte laborioasă și pare să introducă complicații inutile, pentru că ea presupune înlocuirea rezolvării problemei inițiale de prognoză a evoluției unui consumator prin mai multe probleme de prognoză referitoare la comportarea în timp a componentelor sale [Luștea2001].

### **Metoda Delphi**

Metoda Delphi s-a aplicat cu mult succes în prognoza consumului de energie, în situațiile când rezultatele obținute pe termen lung nu au fost satisfăcătoare din diverse motive: date inițiale insuficiente, ipotezele adoptate nu corespund realității, apariția unor modificări tehnologice, sociale.

### **3.3. Metode în funcție de orizontul de timp al prognozei**

#### **3.3.1. Metode pentru prognoze pe termen mediu și lung**

##### **Modelele de tip „end-use”**

Abordarea "end-use" estimează direct consumul de energie folosind o gamă largă de informații existente despre consumul final și utilizatorului final. Datele statistice de consum și dinamica schimbărilor stau la baza prognozei [Chow2004].

##### **Metodele econometrice**

Abordarea econometrică combină informațiile de natură economică și tehnicile statistice pentru prognoza consumului de energie electrică [Chow2004]. Această abordare estimează relația dintre consumul de energie și factorii ce influențează consumul. Estimarea se bazează pe metoda celor mai mici pătrate [Kilyeni2011] sau pe metoda seriilor temporale [Luștea2001].

##### **Metodele mixte**

Este posibilă și utilizarea combinată a celor două categorii de metode de mai sus, rezultând o serie de metode "mixte" din acest punct de vedere. O asemenea abordare este avantajoasă atunci când consumul de energie electrică din diverse sectoare (rezidențial, comercial, industrial etc.) se determină în funcție de date de natură economică, climatică, socială etc., în final prognozele fiind comparate cu cele obținute pe baza istoriei recente (câțiva ani anteriori) [Chow2004].

##### **Abordări moderne**

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

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

##### **Metoda zilei similare**

Această abordare are la bază cercetarea datelor istorice pentru a găsi zile (în ultimii câțiva ani) cu caracteristici similare zilei pentru care se face prognoza. Caracteristici similare includ vremea, ziua în cadrul săptămânii și data. În locul prognozei pe baza unei singure zile similare, se poate utiliza o combinație liniară sau o procedură de regresie care include mai multe zile similare.

##### **Metoda regresiei**

Metoda regresiei este una dintre cele mai des folosite tehnici statistice. Pentru prognoza consumului de energie (putere) electrică asemenea abordări sunt utilizate pentru a modela legătura dintre consum și alți factori cum ar fi vremea, tipul zilei, natura consumului etc. De regulă se utilizează regresia liniară, totuși influența temperaturii se modelează neliniar. Avantajele acestei metode sunt legate de implementarea relativ simplă, de înțelegerea facilă a legăturii dintre variabilele de intrare și cele de ieșire și de aprecierea ușoară a performanțelor metodei de prognoză [Hahn2009]. Totuși, datorită dependenței complexe neliniare între consumul de energie electrică și factorii de influență, apar probleme inerente legate de identificarea modelului corect [Kyriakides2007]. Se remarcă și utilizarea altor tipuri de funcții de regresie: regresie polinomială [Zivanovic2001], regresie neparametrică [Charytoniuk1998], regresie robustă [Jin2004].

##### **Metoda seriilor de timp**

Această metodă este bazată pe ipoteza că datele au o structură internă clară, cum ar fi autocorelarea, trendul sau variațiile sezonale. Metodele de prognoză bazate pe serii de timp detectează și explorează asemenea structuri. Seriile de timp au fost folosite în domeniul economic și cel al procesării semnalelor digitale, dar și la prognoza consumului de electrică (cele mai vechi metode). Cele mai utilizate metode legate de seriile de timp sunt următoarele: ARMA (autoregressive moving average), ARIMA (autoregressive integrated moving average), ARMAX (autoregressive moving average with exogenous variables) și ARIMAX (autoregressive integrated moving average with exogenous variables).

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

RNA sunt în esență circuite neliniare care au capacitatea demonstrată de a realiza aproximarea numerică a unor funcții neliniare. Mărimile de ieșire ale RNA sunt funcții liniare sau neliniare de mărimile de intrare. Mărimile de intrare pot fi și mărimile de ieșire ale altor rețele. Practic elementele RNA sunt dispuse într-un număr relativ redus de straturi, între mărimile de intrare și cele de ieșire. Uneori se utilizează și căi de reacție inversă [Chow2004].

##### **Metode care încorporează și logica fuzzy**

Spre deosebire de logica clasică, în care se lucrează cu două valori de adevăr exacte (notate de exemplu cu 0 pentru fals și 1 pentru adevărat), logica fuzzy folosește o plajă continuă de valori

logice cuprinse în intervalul  $[0, 1]$ , unde 0 indică falsitatea completă, iar 1 indică adevărul complet. Astfel, dacă în logica clasică un obiect poate aparține (1) sau nu (0) unei mulțimi date, logica fuzzy lucrează cu gradul de apartenență al obiectului la mulțime, acesta putând lua valori între 0 și 1.

#### **Metode bazate pe sisteme expert**

Un sistem expert poate codifica sute sau mii de reguli, fiind eficient atunci când există o colaborare bună între expertul uman și specialiștii soft, în sensul de a exista capacitatea operatorului uman de a explica în mod corespunzător deciziile și logica sa programatorilor.

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

SVM sunt modele cu învățare supervizată. Considerând un set de date de antrenare, fiecare dintre ele marcată ca aparținând uneia din două categorii posibile, algoritmul de învățare SVM construiește un model care asignează noile date ca aparținând uneia sau celeilalte categorii, rezultând de fapt un clasificator non-probabilistic liniar binar.

#### **Metode hibride, care utilizează și tehnici de calcul evolutiv**

Există o serie de metode hibride (mixte), care combină una dintre metodele discutate în paragrafele anterioare cu o serie de tehnici de calcul evolutiv. Scopul urmărit este de a ameliora calitatea prognozelor obținute sau de a soluționa situații pe care modelele anterioare nu sunt capabile să le trateze.

Dintre tehnicile de calcul evolutiv utilizate se remarcă: algoritmi de calcul evolutiv diferențial, tehnici căutare de tip "tabu", algoritmi de tip "Simulated Annealing", algoritmi de tip PSO, algoritmi genetici și memetici, tehnici de tip "data mining", tehnici de tip "pattern recognition" etc.

### **3.4. Factorii care influențează consumul de energie electrică**

Înainte de a începe efectuarea unui studiu de prognoză de consumului de energie electrică (putere) este necesară identificarea factori de care depinde acest consum.

Conform [Mielezarski1998] există patru categorii de factori:

- a) Factorii legați de climă
- b) Factorii legați de tiparul (pattern-ul) consumului
- c) Factorii legați de trend
- d) Factorii economici

### **3.5. Concluzii**

În acest capitol s-a realizat o prezentare sistematizată a aspectelor generale legate de prognoza consumului de energie electrică (putere de vârf sau orară, energie consumată, curbe de sarcină etc.) și a metodelor utilizate. Prima parte cuprinde o abordare mai generală a metodelor de prognoză, însoțită deja de referiri concrete la literatura recentă de specialitate (în partea care vizează metodele de tip Delphi). Apoi se trece la prezentarea propriu-zisă a metodelor, în funcție de orizontul de timp care se referă, prin prisma realizării unui studiu bibliografic referitor la lucrările de dată recentă publicate în acest domeniu. Sunt urmărite atât metodele "clasice", bazate pe modelarea matematică, cât și cele "moderne", utilizând tehnici de inteligență artificială, logică fuzzy, sisteme expert, "support vector machine" (SVM) etc. Ultima parte a capitolului abordează și o serie de aspecte legate de factorii care influențează consumul de energie electrică, prin prisma influenței lor asupra activității de prognoză.

## **4. REȚELE NEURONALE ARTIFICIALE (RNA)**

Capitolul 4 are ca obiect prezentarea rețelelor neuronale artificiale (RNA). Împreună cu capitolul următor, constituie baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică.

În prima parte a capitolului se trec în revistă o serie de aspecte generale legate de RNA: prezentarea terminologiei de bază și a structurii RNA, clasificarea RNA, domeniile de aplicație, avantajele și dezavantajele utilizării RNA. Un paragraf aparte este consacrat prezentării tipurilor de învățare specifice RNA – supravegheată, respectiv nesupravegheată.

În continuare atenția se focalizează asupra modelului neuronului și asupra structurii RNA. Un subcapitol aparte este consacrat rețelelor neuronale de tip per-ceptron, cu un singur strat și cu mai multe straturi, cu accent special pe cele de tip backpropagation.

### **4.1. Aspecte generale ale RNA**

Rețelele neuronale artificiale (RNA), reprezintă un sistem de procesare a semnalelor, compus dintr-un număr mare de procesoare elementare interconectate, denumite neuroni artificiali sau noduri, care cooperează pentru rezolvarea unor sarcini specifice. Astfel de modele conexiuniste oferă anumite avantaje, caracteristice doar sistemelor neuronale reale (biologice), neîntâlnite în cazul sistemelor de calcul tradiționale, secvențiale [Tiponut2002]:

- proprietatea de a învăța și de a se adapta;
- posibilitatea de a opera cu date imprecise;
- capacitatea de generalizare, în sensul în care RNA va opera corect și cu date de intrare care nu au fost prezentate în timpul procesului de antrenament;
- datorită gradului ridicat de paralelism, funcționarea defectuoasă sau chiar pierderea unui număr de neuroni nu afectează semnificativ performanța sistemului global – RNA reprezintă deci sisteme tolerante la erori;
- capacitatea de a aproxima orice funcție continuă neliniară cu gradul de acuratețe dorit – deci RNA pot fi folosite cu succes în modelarea sistemelor neliniare;
- datorită numărului mare de intrări și ieșiri, RNA modelează cu ușurință sistemele multivariabile;
- implementările hardware ale RNA, de exemplu prin intermediul circuitelor integrate VLSI, fac posibilă utilizarea RNA pentru aplicațiile în timp real.

Clasificarea RNA poate fi făcută după mai multe criterii [Luștea2004]:

- După numărul de straturi;
- După existența reacției;
- După tipul de învățare;
- După modul de propagare.

## 4.2. Modelul RNA

### Modelul neuronului artificial

Fiecare unitate de procesare primește intrări de la unitățile vecine și cu acestea calculează semnalul de ieșire pe care-l trimite altor unități (microprocesoare care modelează neuroni). Simultan se ajustează ponderile sinaptice. Sistemul aplică procesarea paralelă (mai multe unități fac calcule în același timp) [Popper2010].

### Structura unei RNA

Din punctul de vedere al structurii rețelelor neuronale artificiale se pot distinge două mari categorii [Tiponut2002]:

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

Aceste RNA sunt caracterizate de prezența unui strat de neuroni de intrare, 0, 1, 2, ... straturi ascunse și un strat de ieșire. Structura unui RNA constă în: un neuron care primește semnale doar de la neuroni aflați în stratul (straturile) precedent (precedente). RNA este total conectată dacă fiecare neuron dintr-un anumit strat este conectat la fiecare neuron din stratul precedent.

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

Abordarea lui Hopfield se referă la rețelele recurente care pot fi folosite la simularea memoriilor asociative și la rezolvarea problemelor de optimizare combinatorie. Memoriile asociative sunt sisteme dinamice ce permit stocarea și extragerea informațiilor prin intermediul parametrilor, pe baza unor exemple incomplete sau deteriorate. Stabilirea ponderilor conexiunilor dintre neuroni se realizează astfel încât informațiile de memorat să devină puncte fixe (stări staționare) ale dinamicii rețelei [Tudor2012].

### Învățarea RNA

Învățarea RNA se face prin modificarea continuă a ponderilor sinaptice, urmând o anumită regulă specifică fiecărui tip de RNA și metodă de învățare. Se poate face distincție între antrenamentul *supervizat* și cel *nesupervizat* [Luștea2004].

#### Învățarea supervizată

Învățarea *supervizată* presupune existența perechilor exemplu intrări - ieșiri. Se adaptează ponderile sinaptice astfel ca la aplicarea intrărilor RNA să calculeze tocmai ieșirile pereche. Din punct de vedere matematic, problema constă în minimizarea unei funcții a erorilor definită pe baza diferențelor între ieșirile furnizate de RNA și cele "așteptate", funcție care depinde de ponderile sinapselor.

#### Învățarea nesupervizată

Învățarea *nesupervizată* este caracterizată de absența unui semnal sau supervisor care să aprecieze corectitudinea asociațiilor intrare-ieșire. RNA va descoperi singură legăturile conținute în datele de intrare printr-o reprezentare internă adecvată a trăsăturilor vectorului de intrare [Tiponut2002].

## 4.3. Rețele neuronale de tip perceptron

### RNA de tip perceptron cu un singur strat

Perceptronul simplu reprezintă în esență o particularizare a modelului McCulloch-Pitts al neuronului artificial pentru cazul în care funcția de activare este de tip treaptă unitate bipolară [Tiponut2002].

### **RNA de tip perceptron cu mai multe straturi**

Structura de principiu a unei Rețele Neuronale Artificiale de tip perceptron multistrat (Multilayer Perceptron – MLP). Ea cuprinde un strat de intrare, un strat de ieșire și mai multe straturi ascunse formate din NA (perceptroni) complex interconectați între ei. Fiecare strat folosește un anumit număr de NA, care se alege în funcție de natura problemei abordate, acest fapt constituind unul din aspectele importante ce trebuie rezolvate la proiectarea unei RNA.

### **Rețele neuronale Backpropagation**

Perceptronii multistrat cu mai multe ieșiri și funcții de transfer sigmoidale se mai numesc și rețele backpropagation, denumire care provine de la algoritmul de învățare utilizat de aceste structuri și algoritmul propagare înapoi a erorii [Eremia2006].

Algoritmul de învățare al rețelelor backpropagation cuprinde două etape principale:

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

### **4.4. Concluzii**

În acest capitol s-au prezentat rețelele neuronale artificiale (RNA). Împreună cu capitolul următor, constituie baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică.

În prima parte s-au trecut în revistă o serie de aspecte generale legate de RNA: prezentarea terminologiei de bază și a structurii RNA, clasificarea RNA, domeniile de aplicație, avantajele și dezavantajele utilizării RNA. Un paragraf aparte a fost consacrat prezentării tipurilor de învățare specifice RNA – supravegheată, respectiv nesupravegheată.

În continuare atenția s-a focalizat asupra modelului neuronului și asupra structurii RNA. Un subcapitol aparte a fost consacrat rețelelor neuronale de tip perceptron, cu un singur strat și cu mai multe straturi, cu accent special pe cele de tip backpropagation.

## **5. METODE NUMERICE ȘI TEHNICI DE OPTIMIZARE**

Capitolul 5 are ca obiectiv prezentarea sintetică a metodelor numerice și a tehnicilor de optimizare utilizate în capitolul următor, la elaborarea modelului matematic și a metodei de soluționare a prognozei consumului de energie electrică (a curbelor de sarcină) folosind tehnici de inteligență artificială: procedee de optimizare neliniară utilizate la ameliorarea performanțelor rețelelor neuronale (cu un accent special asupra metodei gradientilor conjugați); metode de interpolare polinomială a funcțiilor (polinoame de tip Newton de speța 1), utilizate la metoda gradientilor conjugați; diferențe finite, utilizate la prognosticarea calității prognozei curbelor de sarcină în funcție de datele existente; procedee de aproximare polinomială bazate pe metoda celor mai mici pătrate, utilizate la prognoza clasică prin extrapolare liniară și parabolică.

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

Capitolul 6 are ca obiectiv prezentarea modelului matematic al metodelor utilizate efectiv în lucrare pentru prognoza consumului de energie electrică (putere) și a curbelor de sarcină. Ele au fost elaborate pe baza elementelor teoretice prezentate în capitolele anterioare, atât în ceea ce privește RNA cât și metodele de calcul numeric și tehnicile de optimizare.

În prima parte a capitolului se detaliază metoda care utilizează RNA de tip perceptron cu mai multe straturi, cu algoritmul de tip backpropagation. Se trec în revistă principalele etape ale algoritmului de calcul, care se poate utiliza atât pentru prognoza curbelor de sarcină, cât și pentru prognoza consumului de energie electrică, a puterii de vârf sau a puterii medii orare pentru un consumator individual sau o zonă de consum. Se evidențiază și elementele de noutate, legate de implementarea unor tehnici de optimizare neliniară, de evitare a blocării soluției într-un minim local, de tratare a altor situații speciale care pot să apară în derularea calculelor. Se prezintă pe scurt și instrumentul soft corespunzător algoritmului prezentat, cu observația că sunt incluse și metodele prezentate anterior. Se prezintă pe scurt metodele clasice de prognoză, bazate pe aproximarea valorii funcțiilor cunoscute prin puncte cu metoda celor mai mici pătrate, implementate la rândul lor în instrumentul soft elaborat.

Ultima parte, în întregime originală, prezintă un instrument de analiză (estimare) a calității prognozelor pentru curbele de sarcină în funcție de calitatea datelor cunoscute (gradul de corelare) pentru o anumită perioadă trecută (un anumit număr de ani). Acest instrument are la bază diferențele finite, cu ajutorul cărora se determină o serie de indici globali caracteristici. El va fi verificat (validat) în cadrul studiilor de caz, pentru date test și date reale de consum.

Estimarea calității se referă atât la prognoza curbelor de sarcină orare pentru o anumită zi a anului cât și la cele lunare aferente unei anumite ore a unei zile anume.

## 7. STUDII DE CAZ ȘI REZULTATE

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

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

De asemenea, o bună parte din rezultatele obținute și pentru alte sisteme de distribuție a energiei electrice sunt prezente și au fost utilizate în cadrul unor contracte derulate în ultimii 3 ani prin Centrul de Cercetare pentru Analiza și Optimizarea regi-murilor SEE din cadrul Universității Politehnica din Timișoara (director prof.dr.ing. Ștefan Kilyeni), beneficiarii fiind operatori de distribuție de România (Enel Distribuție Banat, Electrica Muntenia Nord, Enel Distribuție Dobrogea) și o serie de agenți economici cu preocupări domeniul implementării resurselor regenerabile de energie.

Prima parte a capitolului se referă atât la ansamblul Enel Distribuție Banat cât și la principalele unități teritoriale rețea (UTR) componente: UTR Timișoara, UTR Arad, UTR Deva și UTR Reșița.

A doua parte a capitolului este dedicată stațiilor de transformare de 110 kV / m.t. din cadrul UTR Timișoara: Cetate, Dumbrăvița, Bucovina, Pădurea Verde, Victoria, IMT, Muzicescu, Fratelia, Freidorf, Azur, Venus, Giulvăz, Gătaia, Deta, Orțișoara, Călacea, Satchinez, Cărpiniș, Jimbolia, Lovrin, Sănnicolau Mare, Buziaș, Lugoj, IURT, Făget, Nădrag.

Dintre acestea au fost selectate pentru prezentare în detaliu în cadrul acestui capitol cinci stații semnificative de 110 / 20 kV: Victoria, Cetate, Pădurea Verde, Sănnicolau Mare și Lugoj.

Analizele efectuate vizează prognoza unor curbe de sarcină definite de valorile puterii consumate la o anumită oră a unei anumite zile pentru fiecare dintre cele 12 luni ale anului. Rezultatele prezentate în cadrul acestui subcapitol se referă la ora 9 și la ora 21 a ultimei zile de joi a fiecărei luni, la aceleași ore ale primei zile de marți, respectiv a celei de a doua zile de miercuri.

Primii 6 ani (dintre cei 8 pentru care se cunosc datele de consum), 2006-2011, s-au utilizat pentru realizare efectivă a prognozei, iar ultimii 2 ani, 2012 și 2013, pentru verificare prognozelor obținute. Se menționează că toate datele referitoare la consumuri au fost obținute de la Enel Distribuție Banat.

Pentru prognoza acestor curbe de sarcină s-au utilizat atât metode numerice clasice cât și tehnici bazate pe RNA:

a) metode numerice clasice:

- regresie liniară (aplicată pentru fiecare lună în parte);
- regresie parabolică (aplicată pentru fiecare lună în parte);

b) tehnici bazate pe RNA:

- RNA pentru toată curba de sarcină (12 luni);
- RNA pentru fiecare lună în parte.

La finele subcapitolului cât și la sfârșitul capitolului se prezintă o serie de comentarii și concluzii, cu caracter particular sau mai general, atât legat de rezultatele concrete ale prognozelor cât și de RNA utilizate. O atenție specială se acordă comparării rezultatelor obținute cu diverse metode, evidențierii calității metodelor utilizate, apre-cierii gradului de corelare a curbelor de sarcină cunoscute și a influenței gradului de corelare asupra calității prognozelor realizate.

Au fost definite două seturi de curbe de sarcină etalon, cu un grad bun de corelare între curbele pentru anii luați în considerare:

- "etalon 1", pentru care evoluția consumului se face în progresie aritmetică (rație constantă pozitivă pentru toate orele), cu alte cuvinte se acceptă o variație crescătoare liniară a consumului;
- "etalon 2", pentru care evoluția consumului se face în progresie geometrică (rație constantă pozitivă pentru toate orele), cu alte cuvinte se acceptă o variație crescătoare neliniară a consumului.

Primii 10 ani (dintre cei 13 pentru care se s-au definit curbele de sarcină etalon) (2001-2010) s-au utilizat pentru realizare efectivă a prognozei, iar ultimii 3 ani (2011-2013) pentru verificare prognozelor obținute.

Pronosticul apriori asupra calității rezultatelor prognozelor va fi realizat pe baza diferențelor finite, în maniera prezentată în capitolul 6. Vor fi utilizate atât dife-rențele finite orare (lunare) cât și cele anuale, calculate pentru fiecare UTR (stație) în parte. În cazul stațiilor analizele vor viza toate zilele discutate (marți, joi și miercuri) și cele două ore considerate pentru fiecare zi (9 și 21).

Se vor întocmi clasamente comparative, în scopul stabilirii unei legături între calitatea prognozelor obținute și valorile cumulate ale diferențelor finite. Calitatea prognozelor obținute se referă, evident, la rezultatele obținute prin utilizarea RNA (pentru ansamblul curbei de sarcină, respectiv orar sau lunar).

## 8. CONCLUZII GENERALE. CONTRIBUȚII PERSONALE

Acest ultim capitol sintetizează o serie de concluzii generale rezultate în urma elaborării tezei de doctorat, contribuțiile originale aduse în cadrul tezei, modul de valorificare a rezultatelor obținute și direcțiile posibile de continuare și aprofundare a cercetărilor în domeniul abordat.

### Bibliografie selectivă

- 1.[SE2007] Strategia Energetică a Românie în perioada 2007-2020,Ministerul Economie, Comerțului și Turismului, varianta 16, Mai 2007 <http://www.minind.ro>
- 2.[ESE2011] Elemente de strategie energetică pentru perioada 2011-2035, Direcții și obiective strategice în sectorul energie electrice, Ministerul Economiei Comerțului și Mediului de Afaceri
- 3.[SEN2014] Strategia Energiei Naționale, Servicii de consultanță specializate necesare pentru elaborarea Strategiei Energetice Naționale pentru perioada 2014-2035 și perspective pentru 2050, <http://energie.gov.ro>
- 4.[Luștrea2001] Luștrea B., Prognoza consumului de energie, Ed.Agir, 2001
- 5.[Luștrea2004] Luștrea B., Elemente de inteligență artificială cu aplicații în energetică, Universitatea Politehnica Timișoara, 2004
- 6.[Helmer1967] Helmer-Hirschberg, Olaf, Analysis of the Future. The Delphi Method, Santa Monica, CA, USA, RAND Corporation, 1967, pp.1-11
- 7.[Gellings1996] Gellings C.W., Demand Forecasting for Electric Utilities, The Fairmont Press, Lilbrun, GA, 1996
- 8.[Chow2004] Chow J. H., Wu F. F., Momoh J. A., Applied mathematics for restructured electric power systems, Optimiyation, Control, and Computational Intelligence, Springer's Power Electronics and Power Systems Series, Series Editors: M.A. Pai and Alex M. Stankovic, 2004
- 9.[Kilyeni2011] Kilyeni St., Metode numerice. Algoritme, programe de calcul, aplicații în energetică, Ed. a 4-a, Editura Orizonturi Universitare, Timișoara, 2011
- 10.[Hahn2009] Hahn H., Meyer-Nieberg S., Pickl S., Electric Load Forecasting methods: Tools for decision making Elsevier ScienceDirect European Journal of Operational Research, 2009, pp.902-907
- 11.[Kyriakides2007] Kyriakides E., Polycarpou M., 2007. Short Term Electric Load Forecasting: A tutorial, in Chen, K., Wang, L. (Eds.), Trends in Neural Computation, Studies in Computational Intelligence, vol. 35. Springer, Chapter 16
- 12.[Zivanovic2001] Zivanovic R., Local Regression-Based Short-Term Load Forecasting, Journal of Intelligent and Robotic Systems, nr. 1, 2001; pp. 115-127
- 13.[Charytoniuk1998] Charytoniuk W., Chen M.S., Van Olinda P., Nonparametric Regression Based Short-Team Load Forecasting, IEEE Transaction on Power Systems, vol.13, no.3, August 1998, pp.735-730
- 14.[Jin2004] Jin L., Lai Y.J., Long T.X., Peak Load Forecasting Based on Robust Regression, Proceedings of the 8th International Conference on Probabilistic Methods Applied to Power Systems, Ames, USA, 2004, pp. 123-128
- 15.[Peng1992] Peng T.M., Hubele N.F., Karady G.G., Advancement in the Application of Neural Networks for Short-Term Load Forecasting, IEEE Transactions on Power Systems, vol.7, no.1, February 1992, pp.250-257
- 16.[Mielezarski1998] Wladyslaw Mielezarski, Fuzzy Logic Techniques in Power Systems, Editura Springer, 1998
- 17.[Tiponuț2002] Tiponuț V., Căleanu C.D., Rețele neuronale Arhitecturi și Algoritmi, Ed.Politehnica, Timișoara, 2002
- 18.[Popper2010] Popper M., Sisteme Neuro-Geno-Expert aplicabile echipamentelor energetice de mare putere, Rezumatul tezei de doctorat, Universitatea „Transilvania” din Brașov, Facultatea de Inginerie Electrică și Știința calculatoarelor, Catedra de automatică, Brașov, 2010
- 19.[Tudor2012] Tudor N. L., Rețele neuronale artificial, Aplicații Matlab, Ed. MATRIX ROM București, 2012
- 20.[Eremia2006] Eremia M., Cârțină G., Petrică D., Bulac A.I.,Bulac C., Triștiu I., Grigoraș G., Tehnici de inteligență artificială în conducerea sistemelor electroenergetice, Academia de științe tehnice din România, Ed. Agir, 2006