

## Utilizarea rețelelor neuronale bayesiene la prognoza consumului de energie electrică

### Teză de doctorat – Rezumat

pentru obținerea titlului științific de doctor la  
Universitatea Politehnică Timișoara  
în domeniul de doctorat Inginerie Energetică  
**autor Mihaela Daciana Mic (Crăciun)**  
conducător științific Prof.univ.dr.ing. Ștefan Kilyeni  
luna 10 anul 2021

Acronime.....	9
Lista de figuri, tabele și anexe.....	11
1. Introducere .....	27
2. Teoria rețelelor neuronale bayesiene .....	33
2.1. Elemente de probabilități și statistică .....	33
2.2. Modelare probabilistică și învățare automată .....	39
2.3. Rețele neuronale bayesiene .....	46
2.4. Concluzii .....	56
3. Aplicații ale rețelelor bayesiene în domeniul ingineriei sistemelor electroenergetice .....	57
3.1. Considerații preliminare .....	57
3.2. Aplicații în domeniul fiabilității rețelelor și sistemelor electroenergetice .....	58
3.3. Aplicații în domeniul estimării stării sistemelor electroenergetice .....	60
3.4. Aplicații în domeniul analizei stabilității sistemelor electroenergetice.....	62
3.5. Aplicații în domeniul diagnozei și localizării defectelor .....	62
3.6. Alte aplicații ale rețelelor bayesiene .....	64
3.7. Concluzii .....	66
4. Prognoza consumului de energie electrică .....	67
4.1. Clasificarea metodelor de prognoză .....	67
4.2. Metode pentru prognoze pe termen mediu și lung .....	69
4.3. Metode pentru prognoze pe termen scurt .....	70
4.4. Utilizare rețelelor neuronale bayesiene în studiile de prognoză .....	76
4.5. Concluzii .....	81
5. Rețele neuronale artificiale (RNA) .....	83
5.1. Prezentarea generală a RNA .....	83
5.2. Modelul RNA .....	85
5.3. Rețele neuronale de tip perceptron .....	92
5.4. Concluzii .....	97
6. Model matematic și instrument soft pentru prognoza consumului de energie electrică și de putere.....	99
6.1. Tehnica bayesiană.....	99
6.2. Metoda de optimizare – Gradient Conjugat Scalat .....	107
6.3. Instrumentul software RNA bayesiană .....	110
6.4. Concluzii .....	118
7. Studii de caz și rezultate.....	119
7.1. Validarea prin comparații a metodelor elaborate .....	119
7.2. Enel Distribuție Banat și UTR componente .....	151
7.3. Stații din cadrul Enel Distribuție Banat .....	171
7.4. Concluzii .....	215
8. Concluzii generale, contribuții personale.....	217
Bibliografie (selectivă).....	221
Sinteza privind lucrările proprii .....	233
Anexe electronice (CD) .....	235
Anexa 7.1. Comparații prognoze.....	235
Anexa 7.2. Prognoze unități teritoriale rețea .....	247
Anexa 7.3. Prognoze stații.....	259

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

Indiferent de orizontul timp pentru care se efectuează prognoza, abordarea problemei se poate face atât prin metode "clasice", bazate pe modelarea matematică și tehnicile de optimizare liniară sau neliniară cunoscute [Kilyeni2015], cât prin metode care utilizează tehnici moderne, bazate pe inteligența artificială, în special rețelele neuronale artificiale [Kumar 2016], [Singh 2017], [Hsu2018], [Jarndal2020]. În toate situațiile este extrem de importantă cunoașterea istoricului evoluției consumului și a altor elemente care influențează consumul, pentru o perioadă de câteva ori mai mare decât cea pentru care se efectuează prognoza.

În ultimii ani se remarcă utilizarea teoriei bayesiene, rețelelor bayesiene și rețelelor neuronale bayesiene [Nabney2002], [Mackay2003], [Bolstad2004], [Koch2007], [Russell2010] la soluționarea unor aplicații din domeniul electroenergeticii. Cele mai multe aplicații vizează fiabilitatea rețelelor și sistemelor electroenergetice [Sykora2016], [Lorencin2017] și prognoza consumului [Sun2019], [Bessani2020], [Sarajcev2020]. Alte domenii de interes: estimarea stării SEE [Pegoraro2017], analiza stabilității SEE, [Chevalier2019], diagnoza și localizarea defectelor [XuB2019] etc.

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

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

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

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

Rezultatele obținute și concluziile formulate sunt de o deosebită utilitate atât pentru operatorii de distribuție, la modul general, cât și pentru Enel Distribuție Banat, în particular.

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

**Capitolul 1** are un caracter introductiv. Prima parte cuprinde încadrarea și justificarea tematicii tezei de doctorat, în contextul stadiului actual de evoluție a electroenergeticii, al preocupărilor existente pe plan mondial și în România. Partea a doua realizează o prezentare succintă a conținutului fiecărui capitol al tezei. Ultima parte a capitolului evidențiază atât modul

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

**Capitolul 2** prezintă o serie de noțiuni teoretice de bază legate de abordarea bayesiană, de rețelele bayesiene (RB), de rețelele neuronale bayesiene (RNB) și a unor elemente conexe. Noțiunile respective sunt necesare atât pentru înțelegerea aspectelor prezentate în capitolele următoare, legate de utilizarea conceptelor și modelelor bayesiene în domeniul electroenergeticii cât și a modelului matematic al prognozei consumului de energie și al instrumentului soft aferent (capitolul 6). Prima parte a capitolului trece în revistă o serie de elemente de probabilități și de statistică: probabilități condiționate, interpretare frecventistă vs. subiectivistă a probabilităților, teorema lui Bayes, legile de probabilitate etc. A doua parte se referă la învățarea automată (Machine Learning – ML) în contextul modelării probabiliste: învățarea automată bayesiană (BML), metodele de aproximare a posteriorului și a probabilităților marginale, inferența bayesiană etc. Ultima parte este consacrată exclusiv RNA bayesiene: compararea RNA "clasice" cu cele bayesiene, principiile învățării (antrenării) la RNA bayesiene, optimizarea bayesiană a parametrilor de control (noțiunea de cadru evidență, inclusiv abordarea sa numerică).

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

Înmulțirea atacurilor cibernetice asupra sistemelor de tip SCADA a condus la scăderea fiabilității SEE din acest motiv. În [Zhang2014] s-au luat în considerare șase scenarii posibile de atacuri cibernetice, utilizând un model bayesian pentru evaluarea probabilității unor atacuri reușite asupra sistemelor SCADA, care ar avea drept urmare declanșarea unor întreruptoare. Se propune un model de rată de întrerupere forțată luând în considerare atacurile reușite asupra generatoarelor și liniilor de transport al energiei electrice. Rezultatele obținute utilizând sistemul test IEEE pentru studiile de fiabilitate au demonstrat că SEE devin mai puțin fiabile în condițiile creșterii frecvenței atacurilor cibernetice reușite. [Borges2016] utilizează un model de reprezentare a mărimilor variabile în timp dependente statistic, care se poate folosi în cadrul metodelor mixte de evaluare a fiabilității prin simulare Monte Carlo non-secvențială. Modelul a fost dezvoltat prin combinarea unei metode de estimare non-parametrice a funcțiilor de densitate de probabilitate pentru variabilele continue cu măsurarea dependenței statistice neliniare și reprezentarea grafică a probabilității condiționate dată de utilizarea RB. Aplicația concretă se referă la sistemul test IEEE pentru studiile de fiabilitate, completat cu 27 ferme eoliene fictive, cu diverse serii reale de vânt. Simulările au arătat că modelul poate reproduce exact statistica seriilor istorice și să surprindă influența oricărui tip de corelare asupra indicilor de fiabilitate. Cu alte cuvinte, este la fel de precis ca simularea Monte Carlo secvențială și la fel de eficient din punctul de vedere al volumului de calcul ca cea non secvențială. Modelul se poate utiliza direct pentru a reprezenta corelația dintre puterea generată de sursele eoliene și debitul de apă intrat într-un sistem hidroenergetic. În [Sykora2016] se prezintă utilizarea RB

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

În [Massignan2019] estimarea stării statice a sistemelor electroenergetice se realizează printr-o abordare utilizând inferența bayesiană. În condițiile utilizării pe scară largă a PMU (Phasor Measurement Unit) apare problema combinării măsurătorilor obținute pe această cale cu cele oferite de sistemele SCADA clasice, în condițiile unor diferențe semnificative în ceea ce privește ratele de eșantionare și precizia. Se propune o abordare în două etape. Pentru început se realizează o estimare inițială "clasică" de tip WLS pe baza măsurătorilor furnizate de sistemele SCADA. În a doua etapă se utilizează informațiile oferite de PMU pentru a realiza o interpretare probabilistă a soluției din prima etapă. Se remarcă ameliorarea calității estimării chiar și în condițiile unui număr mai redus de PMU, inclusiv pentru nodurile care nu sunt monitorizate de PMU. [Mestav2019] are ca obiect estimarea stării sistemelor de distribuție a energiei electrice care prezintă probleme de observabilitate. Metoda propusă presupune în prima fază învățarea distribuită a injecțiilor de putere stohastice în nodurile sistemului. Apoi se utilizează o metodă de tip Monte-Carlo pentru antrenarea unei RNA cu mai multe straturi ascunse. În final se realizează un algoritm bayesian de detectare și filtrare a datelor eronate. Rezultatele obținute evidențiază avantajele unei asemenea metode de abordare în comparație cu utilizarea pseudo-măsurătorilor.

În [Augutis2012] se prezintă o metodă de evaluare a stabilității la mari perturbații a SEE pentru diverse regimuri de funcționare utilizând RB. Este vorba în esență de o tehnică de analiză hibridă, care combină metoda clasică de analiză prin modelarea în detaliu a sistemului electroenergetic cu o abordare bazată pe RB. Cea din urmă utilizează un model de estimare pentru determinarea caracteristicilor de stabilitate pentru anumite generatoare sincrone. În acest mod toate generatoarele pot fi analizate prin estimarea bazată pe abordarea bayesiană în locul unei analize utilizând modelarea în detaliu a sistemului. Avantajul major constă în reducerea substanțială a efortului de calcul, fără a altera semnificativ acuratețea rezultatelor. Calitatea rezultatelor poate fi ameliorată prin gruparea generatoarelor pe baza coerenței, apreciată pe baza unui coeficient de corelare a curbelor de oscilație (variația în timp a unghiului intern). Spre deosebire de lucrările anterioare, în [Seppanen2016] și [Ma2013] analizele se referă la stabilitatea la mici perturbații a SEE, incluzând în modelul de analiză și RB. În [Chevalier2019] se urmărește localizarea sursei oscilațiilor, în condițiile unor incertitudini în ceea ce privește parametrii generatoarelor sincrone și acuratețea măsurătorilor obținute de la sincrofazori, elemente care justifică utilizarea RB. [Vakili2015] are ca obiect analiza stabilității tensiunii, utilizând o metodă directă de tip Lyapunov, combinată cu determinarea bayesiană a celui mai rapid punct de schimbare.

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

Pentru a trata mulțimea de informații incerte legate de defectele care pot să apară în rețelele de transport al energiei electrice, diagnoza acestora este soluționată în [WangT2015] prin utilizarea unor RB speciale orientate pe obiecte. Graficul conex și fără circuite asociat RB

cuprinde atât vârfuri de tip Noisy-OR cât și Noisy-AND. Dacă un anumit vârf are valoarea "false" ("fals") când toate vârfurile antercedente au valoarea "false", atunci este un vârf de tipul Noisy-OR (seamănă cu definiția lui OR (SAU) logic, cu deosebirea că nu se poate afirma că vârfurile antercedente are valoarea "true" ("adevărat") dacă unul dintre vârfurile antercedente are valoarea "true". Dacă un anumit vârf are valoarea "true" când toate vârfurile antercedente au valoarea "true", atunci este un vârf de tipul Noisy-AND (seamănă cu definiția lui AND (ȘI) logic, cu deosebirea că nu se poate afirma că vârfurile antercedente are valoarea "false" dacă unul dintre vârfurile antercedente are valoarea "false"). Pentru antrenarea rețelei și actualizarea parametrilor săi se utilizează un algoritm de tip "backpropagation" (propagare în sens invers). Pentru a minimiza abaterea pătratică medie dintre valoarea calculată și cea măsurată se utilizează metoda gradientului conjugat [Kilyeni2015]. Per ansamblu este un model de localizare a defectelor simplu și rapid, utilizând informațiile (uneori incerte) despre acțiunea protecțiilor și starea întreruptoarelor.

În [XuT2010] se prezintă o metodă de localizare a defectelor în rețelele de distribuție rurale utilizând inferența bayesiană. Pe baza informațiilor oferite de apelurile legate de deranjamente (cele mai multe nesigure și incomplete) și a experienței personalului de exploatare (având un grad de încredere relativ scăzut) s-a realizat un model probabilistic de învățare, de raționament, bazat pe metoda bayesiană. Algoritm de localizare a defectelor a fost implementat în sistemele GIS aferente rețelelor de distribuție rurale. Diagnoza defectelor pentru cazul hidrogenatoarelor este abordată în [XuB2019], luând în considerare atât cauzele de natură electrică cât și cele de natură mecanică sau hidraulică. Metodologia utilizată are la bază un sistem expert și utilizarea RB. S-a realizat un model bayesian complet de diagnoză a defectelor, care se bazează pe cunoașterea aprofundată a vibrațiilor care apar la diverse tipuri de defecte și a caracteristicilor de defect asociate. În [Zhao2010] se prezintă un sistem de monitorizare și diagnoză a defectelor pentru transformatoarele și autotransformatoarele de mare putere, având la bază un sistem de tip multi-agent, combinat cu un algoritm de clasificare bayesiană. Din punct de vedere fenomenologic, diagnoza are la bază analiza gazelor rezultate în cuva cu ulei în cazul unor scurtcircuite interioare, care au ca efect vaporizarea uleiului determinat de arcul electric. La fel ca în cazul anterior, abordarea din [Zheng2010] a diagnozei defectelor în transformatoare are la bază analiza gazelor rezultate în cuva cu ulei în cazul unor scurtcircuite interioare, care au ca efect vaporizarea uleiului datorită arcului electric. În această lucrare se analizează comparativ mai multe tipuri de clasificatoare bayesiene (NB – Naïve Bayesian classifier, TBA Tree Augmented Naïve Bayesian classifier, GBN – General Bayesian Network classifier), cu evidențierea avantajelor și dezavantajelor. În [Zhou2012] se prezintă un model de simulare a duratei de viață a transformatoarelor din rețelele de distribuție a energiei electrice. Defectarea lor este un eveniment destul de rar, ceea ce înseamnă un volum redus de date inițiale cunoscute. Pentru a surmonta acest aspect, durata de viață a transformatorului este tratată ca o variabilă aleatoare, cu o anumită distribuție de probabilitate. Aplicând acest model probabilistic pentru un grup de transformatoare se poate estima numărul de transformatoare care trebuie înlocuite. În lucrare se propune ca modelul inițial să fie realizat pe baza informațiilor legate de siguranța în funcționare a unui număr mare de transformatoare similare. În continuare se utilizează o procedură de actualizare bayesiană pentru a incorpora cunoștințele de tip prior (anterioare) referitoare la avariile reale în modelul inițial, rezultând astfel un model avansat al duratei de viață a transformatoarelor. În final se propune o actualizare secvențială a modelului, ceea ce conduce la o manieră dinamică a ameliorării modelului duratei de viață a transformatorului.

**Capitolul 4** prezintă problemele legate de prognoza consumului de energie electrică (putere de vârf, putere orară, energie consumată, curbe de sarcină etc.) și a metodelor utilizate pentru obținerea prognozei. Prima parte a capitolului cuprinde aspecte generale legate de prognoză, clasificarea metodelor utilizate după diverse criterii, insistându-se asupra orizontului

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

Un subcapitol aparte, consistent, este dedicat metodelor care utilizează RNB, care constituie obiectul acestei teze de doctorat. Marea majoritate a exemplelor se referă la prognoza consumului de energie (putere) consumată, dar apar și situații în care obiectul prognozei este prețul energiei electrice, puterile generate de centralele eoliene sau fotovoltaice, viteza vântului, iradianța solară etc. Prima menționare a utilizării abordării bayesiene a prognozei consumului de putere apare în [Bakirtzis1997], unde se propune un predictor bayesian mixt, realizat prin combinarea unui predictor bazat pe utilizarea unei RNA cu alți doi predictorii specifici regresiei liniare. Aplicația se referă la prognoza pe termen scurt a puterii consumate în Grecia.

Exemple de aplicații pentru prognoza pe termen scurt a consumului (PTSC):

- În [Ning2010] PTSC se realizează utilizând o RNA de tip "backpropagation" cu antrenare bayesiană. Acest tip de învățare facilitează obținerea celor mai probabile valori ale hiperparametrilor, care conduc la o arhitectură optimă a RNA de tip "backpropagation". Testarea performanțelor modelului s-a realizat utilizând date de consum reale din provincia Guizhou (China), atât pentru antrenarea rețelei cât și pentru verificarea prognozelor, rezultatele dovedind superioritatea acestuia comparativ cu RNA convenționale de tip "backpropagation". S-a remarcat o creștere a vitezei de învățare, a convergenței și a acurateței prognozei.
- O metodă mai complexă este prezentată în [Ghayekhloo2015], care utilizează un algoritm de preprocesare a datelor de intrare în scopul ameliorării calității prognozei. Se utilizează o transformare discretă de tip "wavelet" pentru descompunerea componentelor sarcinii în niveluri adecvate de rezoluție, după un criteriu bazat pe entropie, urmată de o analiză de regresie, rezultând cel mai bun set de date de intrare. O analiză de corelare împreună cu o RNA furnizează o primă estimare a valorilor prognozate asociate mărimilor de intrare, urmată de o procedură de standardizare care ține cont de gradul de corelare a mărimilor de ieșire cu setul de mărimi de intrare asociate. În final rezultă cele mai potrivite date de intrare pentru RNA bayesiană. Pentru optimizarea coeficienților de ponderare ale diverselor componente ale prognozei și minimizarea erorilor valorilor prognozate se utilizează un algoritm genetic. Aprecierea performanțelor și preciziei metodei propuse pentru PTSC este realizată cu ajutorul unei baze de date consacrate de consum ("New England load data"), concluziile fiind pozitive. O abordare asemănătoare, la fel de complexă, apare și în [He2019], care prezintă o metodă hibridă de PTSC utilizând RNB recurente de tip LSTM (Long Short-Term Memory).
- [Dagdougui2019] are ca obiect prognoza pe termen scurt și foarte scurt a consumului de putere în zonele de clădiri "inteligente", cuprinzând câteva blocuri eterogene din punctul de vedere al funcționalității, utilizând modele bazate pe RNA. Lucrarea urmărește trei obiective: evaluarea performanțelor RNA considerând două tehnici de antrenare de tip "backpropagation" – regularizarea bayesiană și metoda Levenberg-Marquardt; analiza comparativă a performanțelor modelului pentru prognozele de tip "hour-ahead" și "day-ahead" aferente diverselor tipuri de clădiri; analiza influenței structurii RNA (numărul de straturi ascunse și al neuronilor din aceste straturi, numărul de intrări și de seturi de date de antrenare) asupra acurateței valorilor prognozate. Eficiența metodei propuse este demonstrată pentru cazul unui cartier din centrul orașului Montreal (Canada).
- În [Sarajcev2020] PTSC este asociată cu o tehnică de clusterizare a datelor de consum (împreună cu cei climatici), utilizând o abordare bazată pe inferența bayesiană. Aplicația concretă se referă la prognoza consumului de putere pentru orașul Newcastle (Australia).

- [Sun2019a] prezintă un interesant studiu comparativ al metodelor probabilistice de PTSC. S-au avut în vedere următoarele metode: estimarea bayesiană, estimarea bayesiană de ordin redus, regresia de tip Ridge (o tehnică de estimare a coeficienților modelelor de regresie multiplă pentru situațiile în care variabilele independente prezintă un grad de corelare ridicat), estimarea de tip LASSO (Least Absolute Shrinkage and Selection Operator – o metodă de analiză de regresie care realizează atât selecția variabilelor cât și regularizarea, în scopul ameliorării calității prognozei și a gradului de interpretare a modelului statistic) și RNA cu învățare supervizată. Concluzia studiului evidențiază faptul că estimarea bayesiană de ordin redus conduce la cele mai bune rezultate.
- Abordarea din [Bessani2020] pornește de la constatarea că pentru consumul rezidențial incertitudinea datelor este mult mai accentuată decât în cazul consumurilor agregate la nivel de medie sau înaltă tensiune. În acest context lucrarea propune un model multivariabil pentru prognoza de foarte scurtă durată a consumului, bazat pe utilizarea RB. Se ține cont de evoluția anterioară a consumului, de factorii climatici, de cei socio-economici și de pattern-urile (tiparele) de consum. Analiza concretă se referă la un ansamblu de peste 1000 consumatori rezidențiali din Dublin (Irlanda). Compararea cu rezultatele obținute prin alte metode evidențiază faptul că modelul bazat pe utilizarea RB prezintă performanțe superioare. O preocupare similară este prezentată și în [Gilanifar2020], unde RNB sunt asociate cu un model de învățare (antrenare) de tip multitasking. Fiecare task în parte se referă la antrenarea modelului PTSC pentru un anumit consumator rezidențial, iar "multitasking" înseamnă utilizarea unei combinații a modelelor individuale pentru procesul de antrenare a RNB. Un model de tip "multitasking" mai complex, asociat cu un procedeu de optimizare bayesiană, este descris în [Yang2020].

Exemple de aplicații pentru prognoza pe termen mediu și lung a consumului:

- În [Rivero2015] se realizează o prognoză pe termen lung a puterii consumate. Se utilizează o RNA cu inferență bayesiană, singura mărime de intrare fiind evoluția anterioară în timp a consumului. Ieșirea RNA furnizează prognoza consumului pentru următoarele luni. Aplicația concretă se referă la prognoza puterii consumate pentru SEE al Argentinei. Similar, în [Silva2019] se prezintă o aplicație de prognoză pe termen lung a consumului de putere pentru SEE din Brazilia, inferența bayesiană fiind utilizată pentru estimarea parametrilor modelului, ceea ce permite includerea gradului de incertitudine a prognozei realizate cu modelul propus.
- Prognoza pe termen lung a consumului de energie electrică constituie tema studiului în [Yuan2017], [He2018], [Tang2019] și [Ahmadi2020]. Pentru a ține cont de gradul de incertitudine a consumului se propune o abordare bayesiană de tip fuzzy. Rezultatele de natură deterministă sunt înlocuite cu cele de natură probabilistă, fiind indicat și intervalul de încredere (valoarea cea mai probabilă, însoțită de valoarea minimă și cea maximă).

Exemple de prognoză a puterii produse de centralele eoliene și cele fotovoltaice:

- În [Yang2013] se prezintă o abordare practică a prognozei pe termen scurt, în manieră probabilistă, a puterii generate de un parc eolian. Metoda propusă are la bază un algoritm bayesian lacunar de învățare, care conduce la o exprimare probabilistă a rezultatelor prognozei, obținută pe baza estimării densității probabiliste a ponderilor funcțiilor gaussiene. Din cauza caracterului "nestaționar" al evoluției în timp a datelor, a informațiilor despre puterea generată, se propune o strategie bazată pe descompunerea seriei temporale în componente cu o predictibilitate crescută, utilizând o transformare discretă de tip wavelet. Prognoza efectivă cu algoritmul bayesian lacunar se efectuează separat pentru fiecare componentă în parte, rezultatul final fiind obținut prin însumarea celor parțiale. Aplicația concretă se referă la un parc eolian din Oklahoma (SUA), demonstrând eficacitatea metodei propuse.

În [WangY2019] algoritmul bayesian lacunar de învățare se utilizează pentru prognoza vitezei vântului.

- Pe aceeași linie se înscriu și preocupările din [Lin2019], cu observație că se utilizează o metodă de tip multi-model. În paralel cu funcția de distribuție de probabilitate de tip Gauss se utilizează și cea de tip beta ( $\beta$ ). Testarea modelului propus s-a realizat utilizând setul de date GEFC (Global Energy Forecasting Competition) 2014, care include atât evoluția în timp a puterii generate cât și a vitezei vântului (la înălțimea de 10 m și 100 m față de sol) pentru 10 zone diferite. Setul de date, din oră în oră, se referă la o perioadă de 10 ani, fiind divizat în două sub-seturi de antrenare și un set de validare a prognozei. Primul sub-set de învățare se utilizează pentru antrenarea componentelor modelului, în timp ce al doilea are ca rol optimizarea ponderilor modelelor componente.
- Tot o perioadă de 20 de ani pentru datele cunoscute (pentru IESO – Independent Ontario Electricity System Operator) a fost utilizată și în [Sahu2019] pentru prognoza pe termen scurt a puterii generate de sursele eoliene și fotovoltaice. O parte din datele respective au fost folosite pentru antrenarea RNA, restul pentru aprecierea calității prognozei. Antrenarea s-a realizat prin regularizare bayesiană, pentru seriile temporale fiind luate în considerare regresia automată neliniară, regresia automată neliniară cu date de intrare exogene și modelul intrare – ieșire (a doua fiind considerată cea mai bună).
- În scopul evaluării riscurilor în funcționarea rețelelor de distribuție în condițiile pătrunderii pe scară largă a surselor distribuite de natură fotovoltaică, în [Tao2016] se propune utilizarea unei RNB dinamice pentru prognoza probabilistă a puterii generate de centralele fotovoltaice. Aplicația se referă la sistemul test IEEE cu 53 de noduri. O abordare similară este prezentată în [Silva2017], aplicațiile vizând situații concrete din SEE al Braziliei.
- În [Panamtash2020] se propune un model probabilistic bayesian multi-variabil pentru prognoza puterii generate în centralele fotovoltaice. Pe lângă seriile de timp referitoare la puterea generată, se evidențiază și dependența de condițiile meteo (temperatura). Pentru antrenarea rețelei se utilizează datele cunoscute din 2015 pentru o centrală fotovoltaică din SUA, calitatea prognozei fiind verificată cu ajutorul datelor din 2016 (de asemenea cunoscute).

**Capitolul 5** este destinat prezentării rețelelor neuronale artificiale (RNA). El oferă baza teoretică pentru metoda aleasă de soluționare a prognozei consumului de energie electrică și putere (prezentată în capitolul 6). Prima parte a capitolului trece în revistă aspectele generale privind RNA: terminologia de bază, structura RNA, clasificarea RNA etc. A doua parte are ca obiect prezentarea modelului RNA. Se pornește de la neuronul artificial și se ajunge la structura RNA. Un paragraf aparte este dedicat tehnicilor de învățare (antrenare) utilizate de RNA – învățarea supravegheată, respectiv cea nesupravegheată. Ultima parte este consacrată prezentării RNA de tip perceptron, cu un singur strat și cu mai multe straturi, cu o atenție specială pentru cele de tip backpropagation.

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

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

Sintetic, algoritmul acestor RNA se prezintă în maniera următoare:

#### □ Inițializarea

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



□ *Realizarea unei epoci de antrenare*

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

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

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

□ *Propagarea înainte*

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

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

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

- Se calculează ieșirile reale ale rețelei:

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

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

- Se actualizează eroarea pe epocă:

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

□ *Propagarea erorilor înapoi și ajustarea ponderilor*

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

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

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

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

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

În cazul funcției sigmoid derivata acesteia este:

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

iar gradienții erorilor pentru neuronii din stratul de ieșire devin:

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

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

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

- Se calculează gradienții erorilor pentru neuronii din stratul ascuns:

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

unde  $m$  este numărul de ieșiri ale rețelei.

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

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

□ *Trecerea la o nouă iterație*

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

□ *Verificarea condiției de terminare*

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

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

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

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

**Capitolul 6** se referă atât la modelul matematic al prognozei consumului de energie electrică și putere (inclusiv curbe de sarcină) cât și la instrumentul soft realizat pe baza modelului respectiv. Prima parte a capitolului detaliază tehnica bayesiană în contextul aplicației de prognoză, trecându-se în revistă principiile inferenței bayesiene, priorul RNA, calculul funcțiilor de eroare și al gradientului, procedura evidență, predicția și barele de eroare. A doua parte prezintă tehnica de optimizare utilizată în cadrul aplicației – metoda gradientul conjugat scalat (SCG). Ultima parte cuprinde detalii despre instrumentul soft care înglobează toate modelele matematice prezentate în acest capitol. A fost conceput în mediul Matlab, utilizând eficient toate facilitățile (de interfață și portabilitate) specifice sistemelor de operare și mediilor informatice actuale. În cadrul aplicației soft au fost implementate și o serie de proceduri din toolbox-ul Netlab al Matlab [Nabney2002], care constituie instrumente utile pentru simularea algoritmilor specifici rețelelor neuronale artificiale: mlpprior.m, mlp.m, mlpinit.m, netopt.m, scg.m, mlperr.m, errbayes.m, mlpgrad.m, gbayes.m, mlp fwd.m, evidence.m, mlpevfwd.m.

Metoda gradientului conjugat scalat (SCG – Scaled Conjugate Gradient) face parte din categoria metodelor de gradient conjugat. Versiunea clasică a metodei de gradient are la bază faptul că vectorul gradient  $g$  indică direcția celei mai mari creșteri a valorii lui  $f(x)$ . Geometric, gradientul reprezintă vectorul ortogonal la conturul lui  $f(x)$ , care trece printr-un anumit punct  $x$ . Cea mai accentuată descreștere (se caută minimumul) a valorii lui  $f(x)$  este dată de  $-g$ .

În aceste condiții algoritmul metodei este următorul [Kilyeni2015]:

- a) se inițializează valoarea lui  $x$  cu  $x_0$ , ales pe baza experienței;
- b) la o iterație oarecare  $j, j = 1, 2, \dots$ , se calculează valoarea lui  $f$  în punctul curent

$$f_j = f(x_j) \quad (6.2.1)$$

și direcția de deplasare  $d_j$ :

$$d_j = -g_j \quad (6.2.2)$$

unde  $g_j$  reprezintă valoarea curentă a gradientului

- c) la aceeași iterație  $j$  se calculează noul punct  $x_{j+1}$ :

$$x_{j+1} = x_j + \alpha_j \cdot d_j \quad (6.2.3)$$

unde scalarul  $\alpha_j$ , care se determină de regulă prin interpolare parabolică indică mărimea deplasării după direcția  $d_j$ :

$$\alpha_j = \frac{h}{2} \cdot \frac{3 \cdot f^0 - 4 \cdot f^1 + f^2}{f^0 - 2 \cdot f^1 + f^2} \quad (6.2.4)$$

unde scalarul  $h$  reprezintă pasul de căutare,  $f^0, f^1, f^2$  sunt valorile funcției  $f$  în punctele  $x^0 = x_j, x^1 = x_j + h \cdot d_j, x^2 = x_j + 2 \cdot h \cdot d_j$ ;

d) calculul se consideră terminat când modulul gradientului devine practic nul (pragul de eroare admis fiind  $\varepsilon$ ):

$$\|g_j\| < \varepsilon \quad (6.2.5)$$

Principalul dezavantaj al versiunii clasice a metodei de gradient este legat de ortogonalitatea direcțiilor de deplasare la două iterații succesive, având ca efect o mișcare în zig-zag către minim. Rezultă o convergență relativ lentă în apropierea minimului.

Metoda gradientelor conjugate elimină dezavantajul menționat mai sus [Kilyeni 2015]. Algoritmul metodei este similar cu cel al gradientului simplu, singura deosebire fiind legată de determinarea direcției de deplasare, care acum este de forma:

$$d_j = -g_j + \beta_j \cdot d_{j-1} \quad (6.2.6)$$

unde coeficientul  $\beta_j$  ține cont de "istoria" anterioară ("mixează" în direcția de la pasul curent o corecție ponderată funcție de direcția de deplasare de la pasul anterior), având expresia:

$$\beta_j = \frac{g_j \cdot g_j^T}{g_{j-1} \cdot g_{j-1}^T} \quad (6.2.7)$$

La ambele versiuni ale metodei de gradient, prezentate anterior, la fiecare pas trebuie determinată valoarea scalarului  $\alpha_j$ , care indică mărimea deplasării după direcția  $d_j$ . Metoda gradientului conjugat scalat [Moller1993] elimină acest dezavantaj. Ea oferă o modalitate de a alege direcții de căutare conjugate fără a efectua căutarea după direcția  $d_j$  și fără a calcula matricea hessiană  $H$  (matricea derivatelor de ordinul 2 ale funcției  $f$ ).

În ipoteza utilizării matricei hessiene (metode de tip Newton, care fac uz și de derivatele de ordinul 2),  $\alpha_j$  se poate calcula în maniera:

$$\alpha_j = \frac{g_j^T \cdot d_j}{d_j^T \cdot H \cdot d_j} \quad (6.2.8)$$

Pentru reducerea timpului de calcul și evitarea căutării după direcția  $d_j$ , se propune introducerea unei aproximări a lui  $H \cdot d_j$ , bazată pe o formulă diferențială finită. În acest scop se consideră  $\sigma_0$  o cantitate mică pozitivă, care se scrie sub forma:

$$\sigma = \frac{\sigma_0}{\|d_j\|} \quad (6.2.9)$$

Dezvoltând în serie Taylor și reținând termenii până la cel cu derivata de ordinul 1 inclusiv, se obține:

$$\nabla f(x_j + \sigma d_j) \approx \nabla f(x_j) + \sigma \cdot H \cdot d_j \quad (6.2.10)$$

Rezultă:

$$H \cdot d_j \approx \frac{\nabla f(x_j + \sigma d_j) - \nabla f(x_j)}{\sigma} \quad (6.2.11)$$

Se definește:

$$\theta_j = d_j^T \cdot \left[ \frac{\nabla f(x_j + \sigma d_j) - \nabla f(x_j)}{\sigma} \right] \approx d_j^T \cdot H \cdot d_j \quad (6.2.12)$$

Dacă funcția  $f$  nu are formă pătratică, atunci  $H$  s-ar putea să nu fie pozitiv definită și valoarea funcției  $f$  ar putea să crească (în loc să scadă). Acest lucru poate fi prevenit prin adăugare la matricea hessiană  $H$  a unui termen multiplicativ între  $\theta_j$  și matricea unitate:  $H + \theta_j \cdot I$ . Astfel se obține forma actualizată:

$$\alpha_j = \frac{g_j^T \cdot d_j}{d_j^T \cdot H \cdot d_j + \theta_j \cdot \|d_j\|^2} \quad (6.2.13)$$

Dacă  $\theta_j$  are o valoare mare atunci pasul  $\alpha_j$  este mic. Acest fapt reprezintă abordarea unui *model de regiune de încredere*, deoarece modelul (pentru funcție) este de încredere într-o regiune mică în jurul punctului de căutare.

Pentru a obține un minim al funcției  $f$ , matricea hessiană trebuie să fie pozitiv definită (sau cel puțin  $d_j^T \cdot H \cdot d_j > 0$ ).

Se introduce notația:

$$\delta_j = d_j^T \cdot H \cdot d_j + \theta_j \cdot \|d_j\|^2 \quad (6.2.14)$$

Dacă  $\delta_j < 0$  atunci sigur  $d_j^T \cdot H \cdot d_j < 0$  și trebuie mărit  $\theta_j$ . Algoritmul original a lui Moller [Moller1993] utilizează:

$$\bar{\theta}_j = 2 \cdot \left( \theta_j - \frac{\delta_j}{\|d_j\|^2} \right) \quad (6.2.15)$$

Apoi se fac setările:

$$\bar{\delta}_j = \delta_j + (\bar{\theta}_j - \theta_j) \cdot \|d_j\|^2 = -\delta_j + \bar{\theta}_j \cdot \|d_j\|^2 = -d_j^T \cdot H \cdot d_j > 0 \quad (6.2.16)$$

Dacă se consideră și condiția ca funcția să fie pătratică, se calculează:

$$\Delta_j = \frac{f(x_j) - f(x_j + \alpha_j d_j)}{f(x_j) - f_Q(x_j + \alpha_j d_j)} \quad (6.2.17)$$

unde  $f_Q$  reprezintă aproximarea pătratică locală a lui  $f$  de-a lungul direcției  $d_j$ :

$$f_Q(x_j + \alpha_j d_j) = f(x_j) + \alpha_j \cdot d_j^T \cdot g_j + \frac{\alpha_j^2}{2} \cdot d_j^T \cdot H \cdot d_j \quad (6.2.18)$$

Dacă  $\Delta_j \approx 1$ , aceasta este o aproximare bună și  $\theta_j$  poate să descrească. Dacă  $\Delta_j$  este mic, atunci  $\theta_j$  trebuie să crească. Simplificând relația (6.2.17) rezultă:

$$\Delta_j = \frac{2 \cdot [f(x_j) - f(x_j + \alpha_j \cdot d_j)]}{\alpha_j \cdot d_j^T \cdot d_j} \quad (6.2.19)$$

Relația (6.2.19) poate fi aplicată utilizând numai gradientul, fără a apela la derivate de ordin superior.

**Capitolul 7** este în întregime original, constituind principala parte aplicativă a lucrării. Se prezintă rezultatele obținute privind prognoza puterii consumate și a curbelor de sarcină utilizând tehnici de inteligență artificială – RNA bayesiene. S-a pornit de la cazuri simple și de la baze de date test, în scopul validării metodelor propuse și "calibrării" instrumentelor soft. În același scop au fost realizate o serie de studii comparative cu rezultatele obținute în [Deacu 2015] și [Chiș2015]. În continuare s-au analizat situații reale, referitoare la operatori de distribuție din România: Enel, Electrica, Delgaz Grid etc. Din motive de spațiu, pentru teza de doctorat s-au selectat doar o serie de studii de caz vizând Enel Distribuție Banat. O parte a rezultatelor sunt prezentate în extenso, restul în sinteză, detaliile fiind oferite în Anexe (sub formă electronică). Rezultatele obținute și pentru alte sisteme de distribuție a energiei electrice din România au fost și sunt utilizate în contractele derulate în ultimii ani prin Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor de Funcționare a SEE din cadrul Universității Politehnica Timișoara, beneficiarii fiind Enel Distribuție Banat, Electrica Muntenia Nord, Delgaz Grid (operatori importanți de distribuție a energiei electrice în România) și entități economice cu preocupări în domeniul implementării resurselor regenerabile de energie [UPT 2017], [UPT 2018], [UPT2019], [UPT2020a], [UPT 2020b].

Primul subcapitol are rolul de a valida modelele de calcul și instrumentele soft elaborate în cadrul tezei de doctorat, prin realizarea unor comparații cu rezultatele din [Deacu2015] și [Chiș2015], în scopul demonstrării calităților superioare ale metodelor utilizând RNA bayesiene. Primul set de comparații vizează operatorul Enel Distribuție Banat și UTR (Unitățile Teritoriale Rețea) componente: prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie, utilizând valorile măsurate din oră în oră (ora 1, ..., ora 24) ale puterii active consumate. Datele pe 10 ani (2001-2010) s-au utilizat pentru antrenarea RNA, iar cele pentru următorii 3 ani (2011-2013) pentru verificarea prognozelor obținute.

S-au selectat două dintre cele 5 analize efectuate (UTR Reșița și ansamblul Enel Banat), rezultând următoarele concluzii:

- în toate situațiile RNA bayesiene conduc, per total, la rezultate mai bune față de cele din [Deacu2015] (cu 12-14% pentru UTR Reșița și 6-10% pentru Enel Banat) și [Chiș2015] (cu 46% pentru UTR Reșița și 36% pentru Enel Banat);
- în ceea ce privește defalcarea pe cei 3 ani (2011, 2012, 2013), la comparația cu [Deacu2015] pentru UTR Reșița ameliorarea cea mai accentuată apare pentru anul 2011, scăzând constant în 2012 și 2013 (atât pentru prognoza orară cât și cea pentru ansamblul curbei de sarcină);
- în același context, pentru Enel Banat situația este similară pentru prognoza orară, iar la cea pentru ansamblul curbei de sarcină este practic constantă la toți anii;
- la componentele anuale apar și două excepții, când rezultatele obținute cu RNA bayesiene sunt ușor inferioare, fără a afecta concluzia globală de la primul punct.

Al doilea set de comparații vizează stații de transformare de 110/20 kV din UTR Timișoara: prognoza curbelor de sarcină definite de puterile consumate la o anumită oră a unei anumite zile pentru fiecare dintre cele 12 luni ale anului. Primii 6 ani dintre cei 8 pentru care se cunosc datele de consum (2006-2011) s-au utilizat pentru antrenarea RNA, iar ultimii 2 ani (2012 și 2013) pentru verificarea prognozelor obținute. S-a ales una dintre cele 5 stații analizate în [Deacu2015]: 110/20 kV Victoria, cu prognoze efectuate pentru ora 9 și 21 a ultimei zile de joi a fiecărei luni, a primei zile de marți și a celei de a doua zile de miercuri, rezultând următoarele concluzii:

- în toate situațiile metodele utilizând RNA bayesiene conduc, per total, la rezultate mai bune față de cele din [Deacu2015], ameliorarea fiind de 13-28% pentru prognoza curbei de sarcină în ansamblu, respectiv 9-39% pentru prognoza lunară;
- există 2 cazuri (pentru ziua de marți) când ameliorarea este foarte mare (prognoza lunară pentru ora 9 (77%) și cea a ansamblului curbei de sarcină, ora 21 (44%)), explicabile prin corelarea extrem de slabă a curbelor de sarcină cunoscute;

- tot pentru ziua de marți (ora 9) apare singura situație când rezultatul obținut cu RNA bayesiană pentru unul dintre anii pentru care s-a efectuat prognoza (2013) este inferior (cu 3,2%) celui din [Deacu2015], fără a fi afectată concluzia de la comparația globală.

Al doilea subcapitol prezintă o serie de studii de prognoză realizate atât pentru ansamblul rețelei de distribuție din cadrul Enel Distribuție Banat cât și pentru UTR componente: Arad, Deva, Reșița și Timișoara. Se efectuează prognoza curbelor de sarcină pentru ziua cea mai semnificativă de vară – 21 iunie, utilizând valorile cunoscute ale puterii medii orare din oră în oră (ora 1, ora 2, ..., ora 23, ora 24). Primii 10 ani (din cei 13 pentru care se cunosc datele de consum), 2006-2015, s-au utilizat pentru antrenarea RNA, iar ultimii 3 ani, 2016-2018, pentru verificarea prognozelor obținute. Pentru prognoza curbelor de sarcină s-au aplicat abordări bazate pe utilizarea RNA bayesiene:

- prognoza pentru ansamblului curbei de sarcină – 24 ore (RNA curba de sarcină);
- prognoza individuală pentru fiecare oră în parte (RNA orar).

Ultima parte a subcapitolului prezintă un studiu de previzionare a calității prognozelor în funcție de datele cunoscute, utilizând metoda din [Deacu2015], bazată pe diferențe finite. În final se evidențiază o serie de comentarii și concluzii, cu caracter mai general sau particular, vizând atât rezultatele concrete ale prognozelor cât și RNA utilizate. O atenție specială se acordă comparării rezultatelor obținute cu cele două metode, evidențierii calității acestora, aprecierii influenței gradului de corelare a curbelor de sarcină asupra calității prognozelor realizate.

Pentru exemplificare se prezintă rezultatele pentru UTR Arad. În figura 7.2.1 se regăesc datele referitoare la curbele de sarcină pentru o perioadă de 10 ani (2006-2015), aferente zilei cele mai semnificative de vară. Ele au fost utilizate pentru antrenarea RNA. În figura 7.2.2 sunt prezentate datele referitoare la curbele de sarcină pentru anii 2016, 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.2.1. Curbele de sarcină pentru perioada 2006-2015 (puterile în MW)




Figura 7.2.2. Curbele de sarcină pentru perioada 2016-2018 (puterile în MW)

Analiza datelor evidențiază următoarele concluzii:

- pentru perioada 2006-2015 evoluția este ambiguă, cu alte cuvinte nu există o tendință explicită de creștere sau de scădere a puterii pe ansamblu;

- curbele de sarcină "se intersectează", ceea ce înseamnă că forma lor diferă (mai ales în anumite zone orare), semnalând probleme de corelare "pe orizontală";
- pentru perioada 2016-2018 se poate remarca un trend general crescător al puterii medii orare pe ansamblu (cu mici "sincop" pentru anul 2017, zonele orară 9-13 și 18-21), ceea ce, corelat cu prima observație, poate conduce la probleme în ceea ce privește calitatea prognozelor care vor fi obținute;
- gradul de corelare a curbelor de sarcină este relativ redus (evoluție în timp și forma pe durata unei zile), ceea ce întărește previziunea de la punctul anterior.

Rezultatele obținute – valorile prognozate, diferențele față de valorile reale (în %) și abaterea pătratică relativă – sunt prezentate în tabelele 7.2.3 (RNA bayesiană, curba de sarcină) și 7.2.4 (RNA bayesiană, orar). În ultima linie a tabelului este dată valoarea indicelui de performanță ( $s_{total}$ ), definit ca suma indicilor parțiali ( $s_{2016}$ ,  $s_{2017}$ ,  $s_{2018}$ ) – suma pătratelor abaterilor celor 24 valori orare pentru anul aferent. Grafic, aceste rezultate sunt prezentate comparativ (pentru cele două metode utilizate) în figurile 7.2.3 (anul 2016), 7.2.4 (anul 2017) și 7.2.5 (anul 2018).

Tabelul 7.2.3. Curbele de sarcină prognozate (puterile în MW) pentru perioada 2016-2018 (RNA bayesiană, curba de sarcină)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	69.3	71.1	2.61	6.83	1	72.1	72.3	0.24	0.06	1	76.5	73.4	-3.99	15.91
2	64.4	64.0	-0.68	0.46	2	65.7	65.5	-0.25	0.06	2	69.9	67.1	-3.94	15.56
3	63.5	63.7	0.34	0.11	3	66.2	64.6	-2.41	5.82	3	71.3	67.9	-4.77	22.74
4	62.3	61.6	-1.18	1.40	4	64.8	62.9	-2.96	8.77	4	69.1	65.6	-5.07	25.66
5	62.2	61.0	-1.99	3.94	5	65.3	62.5	-4.26	18.15	5	69.6	65.3	-6.18	38.17
6	65.0	63.6	-2.11	4.45	6	66.1	65.1	-1.49	2.23	6	71.0	66.6	-6.17	38.02
7	67.7	71.2	5.18	26.83	7	68.9	72.1	4.60	21.19	7	73.0	72.7	-0.41	0.17
8	85.7	87.5	2.05	4.22	8	85.7	88.7	3.51	12.32	8	89.3	90.0	0.74	0.55
9	91.6	93.6	2.21	4.89	9	90.8	94.4	4.01	16.11	9	94.5	95.3	0.81	0.66
10	92.6	92.6	0.00	0.00	10	91.3	93.8	2.71	7.35	10	94.4	95.0	0.59	0.35
11	89.1	90.1	1.12	1.26	11	87.8	89.8	2.28	5.19	11	91.8	94.1	2.51	6.28
12	90.8	93.3	2.75	7.58	12	88.8	92.5	4.17	17.36	12	93.3	96.9	3.86	14.89
13	91.6	93.6	2.20	4.86	13	89.9	94.1	4.67	21.83	13	94.2	96.7	2.63	6.91
14	93.8	91.2	-2.75	7.59	14	91.5	92.4	0.95	0.90	14	94.1	93.5	-0.61	0.37
15	90.9	93.0	2.26	5.09	15	91.0	94.4	3.74	13.97	15	93.4	95.9	2.64	6.96
16	85.6	87.4	2.10	4.42	16	86.9	90.3	3.91	15.31	16	87.0	92.4	6.21	38.53
17	82.7	82.5	-0.23	0.05	17	85.9	83.6	-2.71	7.33	17	85.9	84.6	-1.46	2.13
18	81.9	83.7	2.21	4.89	18	81.5	84.7	3.93	15.43	18	84.5	85.7	1.41	2.00
19	78.6	75.7	-3.69	13.64	19	78.7	77.5	-1.50	2.26	19	83.4	79.4	-4.83	23.36
20	78.2	79.7	1.92	3.68	20	78.0	80.8	3.59	12.89	20	81.2	82.9	2.09	4.38
21	81.0	78.6	-2.98	8.88	21	79.3	79.8	0.66	0.44	21	81.3	81.1	-0.28	0.08
22	93.9	93.1	-0.83	0.69	22	95.1	94.2	-0.95	0.91	22	96.5	95.3	-1.28	1.64
23	88.4	90.7	2.60	6.77	23	90.6	92.6	2.21	4.87	23	91.4	93.9	2.74	7.48
24	76.6	79.0	3.11	9.65	24	82.5	80.8	-2.11	4.47	24	83.0	82.6	-0.53	0.28
$s_{2016}$	132.19				$s_{2017}$	215.21				$s_{2018}$	273.05			
$s_{total} = 620.45$														

Tabelul 7.2.4. Curbele de sarcină prognozate (puterile în MW) pentru perioada 2016-2018 (RNA bayesiană, orar)

2016					2017					2018				
Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă	Ora	Valoare cunoscută	Valoare prognozată	Abatere relativă [%]	Abatere pătratică relativă
1	69.3	71.1	2.54	6.44	1	72.1	73.1	1.45	2.09	1	76.5	75.3	-1.60	2.55
2	64.4	65.9	2.33	5.45	2	65.7	66.8	1.61	2.60	2	69.9	67.6	-3.26	10.63
3	63.5	64.3	1.30	1.68	3	66.2	66.7	0.70	0.49	3	71.3	69.1	-3.12	9.74
4	62.3	63.3	1.55	2.41	4	64.8	65.6	1.22	1.50	4	69.1	68.0	-1.60	2.57
5	62.2	63.7	2.40	5.78	5	65.3	65.7	0.64	0.42	5	69.6	67.8	-2.58	6.66
6	65.0	65.4	0.67	0.45	6	66.1	67.3	1.87	3.48	6	71.0	69.3	-2.43	5.89
7	67.7	68.2	0.71	0.51	7	68.9	70.1	1.71	2.94	7	73.0	72.0	-1.34	1.78
8	85.7	85.2	-0.64	0.41	8	85.7	86.9	1.35	1.81	8	89.3	88.6	-0.81	0.66
9	91.6	90.6	-1.10	1.22	9	90.8	92.1	1.45	2.10	9	94.5	93.7	-0.89	0.79
10	92.6	91.7	-0.98	0.96	10	91.3	92.7	1.55	2.40	10	94.4	93.7	-0.69	0.48
11	89.1	88.3	-0.88	0.77	11	87.8	89.7	2.16	4.64	11	91.8	91.1	-0.78	0.60
12	90.8	89.4	-1.56	2.44	12	88.8	90.7	2.15	4.63	12	93.3	92.1	-1.33	1.77
13	91.6	90.3	-1.43	2.06	13	89.9	91.7	1.98	3.92	13	94.2	93.1	-1.18	1.39
14	93.8	92.8	-1.09	1.18	14	91.5	92.9	1.53	2.33	14	94.1	93.0	-1.16	1.34
15	90.9	90.6	-0.35	0.12	15	91.0	91.8	0.90	0.81	15	93.4	93.1	-0.36	0.13
16	85.6	85.7	0.16	0.03	16	86.9	86.5	-0.48	0.23	16	87.0	87.2	0.27	0.07
17	82.7	83.4	0.88	0.77	17	85.9	84.9	-1.22	1.48	17	85.9	86.3	0.47	0.22
18	81.9	81.4	-0.64	0.41	18	81.5	82.6	1.38	1.91	18	84.5	83.9	-0.72	0.52
19	78.6	78.0	-0.76	0.57	19	78.7	80.4	2.10	4.42	19	83.4	82.8	-0.77	0.59
20	78.2	77.8	-0.45	0.20	20	78.0	79.3	1.61	2.59	20	81.2	80.7	-0.64	0.41
21	81.0	80.4	-0.71	0.51	21	79.3	80.6	1.66	2.74	21	81.3	80.8	-0.61	0.37
22	93.9	94.2	0.32	0.10	22	95.1	95.3	0.21	0.04	22	96.5	96.3	-0.17	0.03
23	88.4	88.2	-0.23	0.05	23	90.6	89.9	-0.78	0.60	23	91.4	91.6	0.22	0.05
24	76.6	78.3	2.28	5.19	24	82.5	80.9	-1.97	3.88	24	83.0	83.5	0.57	0.32
$s_{2016}$	39.72				$s_{2017}$	54.04				$s_{2018}$	49.57			
$s_{total} = 143.33$														


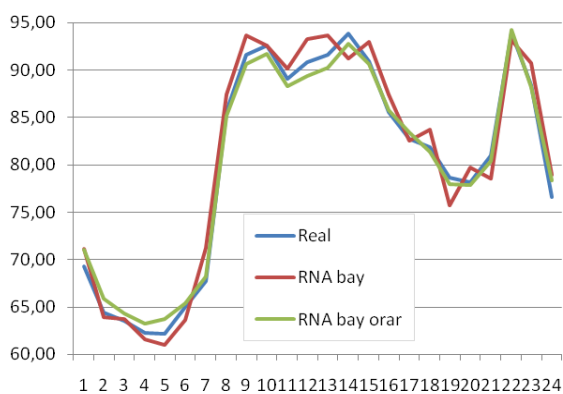


Figura 7.2.3. Analiza comparativă a rezultatelor pentru anul 2016






Figura 7.2.4. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.2.5. Analiza comparativă a rezultatelor pentru anul 2018

În tabelul 7.2.5 s-au reunit indicii de performanță pentru cele două metode de prognoză.

Tabelul 7.2.5. Valoarea comparativă a indicilor de performanță

Metoda / Indicii de performanță	$S_{2016}$	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	132.19	215.21	273.05	620.45
RNA bayesiană, orar	39.72	54.04	49.57	143.33

Analiza comparativă a rezultatelor obținute cu cele două metode de prognoză conduce la următoarele concluzii:

- rezultatele confirmă observațiile făcute la analiza curbelor de sarcină pentru perioada 2006-2015, respectiv 2016-2018;
- prognoza orară oferă rezultate mult mai bune față de cele obținute cu prognoza ansamblului curbei de sarcină (indice global de performanță 143 față de 621), situație explicabilă prin slaba corelare a formei curbelor de sarcină;
- totuși, comparativ, se poate afirma că prognoza orară reușește să "prindă" mai bine forma curbelor de sarcină pentru perioada 2016-2018;
- analiza valorii indicilor anuali de performanță ( $S_{2016}$ ,  $S_{2017}$ ,  $S_{2018}$ ) evidențiază valori practice de același ordin de mărime, totuși crescătoare, ceea ce înseamnă o ușoară alterare a calității prognozelor pe măsură ce ne îndepărtăm de zona cunoscută;
- în ton cu concluziile anterioare, la curbele de culoare roșie din fig. 7.2.3-7.2.5 (prognoza ansamblului curbei de sarcină) se observă zone unde diferența este relativ mai mare față de cele de culoare albastră și verde (consumul real, respectiv cel prognozat cu RNA orar), datorate slabei corelări a formei curbelor de sarcină.

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

La finele subcapitolului se evidențiază o serie de comentarii și concluzii, cu caracter mai general sau particular, vizând atât rezultatele concrete ale prognozelor cât și RNA utilizate. O atenție specială se acordă comparării rezultatelor, evidențierii calității metodelor utilizate, aprecierii influenței gradului de corelare a curbelor de sarcină asupra calității prognozelor realizate.

Pentru exemplificare se prezintă rezultatele pentru stația Bucovina, ora 9 a primei zile de miercuri a fiecărei luni. În figura 7.3.1, sunt prezentate datele referitoare la curbele de sarcină pentru o perioadă de 8 ani (2009-2016), utilizate pentru antrenarea RNA. În figura 7.3.2 sunt prezentate datele privind curbele de sarcină pentru anii 2017 și 2018, utilizate la verificarea rezultatelor prognozelor pentru anii respectivi.




Figura 7.3.1. Curbele de sarcină pentru perioada 2009-2016 (puterile în MW)




Figura 7.3.2. Curbele de sarcină pentru perioada 2017-2018 (puterile în MW)

Analiza rezultatelor evidențiază următoarele concluzii:

- pentru perioada 2009-2016 se observă o tendință generală de scădere a consumului în primii 4 ani, urmată de o creștere în următorii 4 ani;
- pentru 2017-2018 tendința generală este de creștere (excepție lunile martie și august);
- forma curbelor este destul de diferită, cu multe "intersecții";
- în consecință, gradul de corelare a curbelor de sarcină este relativ redus, atât în ceea ce privește evoluția în timp (pe "verticală"), cât și forma pe durata unui an (pe "orizontală");
- dacă se are în vedere ansamblul analizelor din acest subcapitol, cazul de față se situează, din acest punct de vedere, în zona mediană.

Rezultatele sunt prezentate grafic (comparativ, pentru cele două metode utilizate) în figura 7.3.3 (anul 2017) și figura 7.3.4 (anul 2018).

În tabelul 7.3.5 s-au reunit indicii de performanță pentru cele două metode de prognoză.

Analiza comparativă a rezultatelor obținute evidențiază următoarele concluzii:

- rezultatele confirmă observațiile de la analiza curbelor de sarcină;
- prognoza lunară conduce la rezultate sensibil mai bune decât cea a ansamblului curbei de sarcină (indice global de performanță 30, față de 77), explicabilă prin relativ slaba corelare a formei curbelor de sarcină;




Figura 7.3.3. Analiza comparativă a rezultatelor pentru anul 2017




Figura 7.3.4. Analiza comparativă a rezultatelor pentru anul 2018

Tabelul 7.3.5. Valoarea comparativă a indicilor de performanță

Metoda/ Indicii de performanță	$S_{2017}$	$S_{2018}$	$S_{total}$
RNA bayesiană, curba de sarcină	34.04	43.58	77.62
RNA bayesiană, lunar	12.73	18.14	30.87

- totuși, comparativ, se poate afirma că prognoza lunară (curba verde) reușește să "prindă" mai bine forma curbelor de sarcină reale (curba albastră);
- indicii anuali de performanță ( $S_{2017}$ ,  $S_{2018}$ ) au valori de același ordin de mărime, ceva mai mari cele pentru 2018 (comparativ cu 2017).

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

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

Rezultatele obținute au fost și vor fi valorificate în cadrul unor contracte de cercetare științifică și asistență tehnică derulate prin Centrul de Cercetare pentru Analiza și Optimizarea Regimurilor de Funcționare a Sistemelor Electroenergetice din cadrul Universității Politehnica Timișoara, beneficiarii fiind Enel Distribuție Banat și Dobrogea, Electrica Muntenia Nord, Delgaz Grid Iași (operatori importanți de distribuție a energiei electrice în România) și entități economice cu preocupări în domeniul implementării resurselor regenerabile de energie [UPT 2017], [UPT2018], [UPT2019], [UPT2020a], [UPT 2020b].

Activitatea de pregătire prealabilă a doctorandei și rezultatele obținute în perioada de elaborare a lucrării au fost valorificate prin 5 lucrări indexate ISI (2 în reviste, 3 în volumele unor conferințe) [Bucerzan2010], [Crăciun2013], [Bărbulescu2018], [Crăciun2018a], [Csorba 2018], 2 lucrări indexate în alte baze de date internaționale (BDI) (1 în revistă, 1 într-un volum de conferință, în curs de indexare ISI) [Crăciun2017], [Bărbulescu 2021] și 2 rapoarte științifice.

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

- rafinarea metodelor de soluționare bazate pe utilizarea RNB, în scopul creșterii eficienței și ameliorării performanțelor acestora;

- corelarea istoricului evoluției consumului cu o serie de alți factori (climatici, economici, gradul de implementare a surselor regenerabile), în măsura disponibilității acestora;
- utilizarea RNB în studii de prognoză legate de sursele regenerabile (puterea sau energia generată, viteza vântului pentru centralele eoliene, iradianța pentru cele fotovoltaice etc.);
- elaborarea unor metode care să elimine sau să corecteze unele date evident eronate în istoricul consumului;
- utilizarea RB în studii legate de fiabilitatea rețelelor de transport și de distribuție a energiei electrice, a SEE în ansamblu, estimarea stării SEE, analiza stabilității SEE, diagnoza și localizarea defectelor în rețelele electrice, transformatoare, generatoare etc.

### Bibliografie selectivă

1. [Ahmadi2020] S. Ahmadi, A.H. Fakehi, A. Vakili, M. Haddadi, S.H. Iranmanesh, A hybrid stochastic model based Bayesian approach for long term energy demand managements, *Energy Strategy Reviews*, vol.28, 2020, pp.1-13
2. [Augutis2012] J. Augutis, I. Zutautaitė, V. Radziukynas, R. Krikstolaitis, Application of Bayesian method for electrical power system transient stability assessment, *International Journal of Electrical Power & Energy Systems*, vol.42, nr.1, 2012, pp.465-472
3. [Bakirtzis1997] A. Bakirtzis, S. Kiartzis, V. Petridis, A. Kehagias, A Bayesian Combination Method for Short Term Load Forecasting, *International Journal of Electrical Power & Energy Systems*, vol.19, nr.3, 1997, pp.171-177
4. [Bărbulescu2016] C. Bărbulescu, Șt. Kilyeni, A. Deacu, Artificial Neural Network based Monthly Load Curves Forecasting, 11th IEEE International Symposium on Applied Computational Intelligence and Informatics (SACI), 2016, pp.237-242
5. [Bărbulescu2018] C. Bărbulescu, Șt. Kilyeni, A. Deacu, A. Simo, M. Crăciun, Power Consumption Forecast Quality Assessment, 7th International Conference on Computers Communications and Control (ICCCC), 2018, p.103-110
6. [Bărbulescu2021] C. Bărbulescu, Șt. Kilyeni, V. Chiș, M. Crăciun, A. Simo, Daily Load Curve Forecasting. Comparative Analysis: Conventional vs. Unconventional Methods. In: Balas V., Jain L., Balas M., Shahbazova S. (eds.) *Soft Computing Applications, SOFA 2018, Advances in Intelligent Systems and Computing*, vol. 1221, 2021, Springer, pp.3-18
7. [Bessani2020] M. Bessani, J.A.D. Massignan, T.M.O. Santos, J.B.A. London Jr., C.D. Maciel, Multiple households very short-term load forecasting using bayesian networks, *Electric Power Systems Research*, vol.189, pp.1-7
8. [Bolstad2004] W.M. Bolstad, *Introduction to Bayesian Statistics*, John Wiley&Sons, 2004
9. [Borges2016] C.L.T. Borges, J.A.S. Dias, A Model to Represent Correlated Time Series in Reliability Evaluation by Non-Sequential Monte Carlo Simulation, *IEEE Transactions on Power Systems*, vol.32, nr.2, 2017, pp.1511-1519
10. [Bucerzan2010] D. Bucerzan, M. Crăciun, V. Chis, C. Rațiu, Stream Ciphers Analysis Methods, *International Journal of Computers Communications & Control*, vol.5, nr.4, 2010, pp.483-489
11. [Chevalier2019] S. Chevalier, P. Vorobev, K. Turitsyn, A Bayesian Approach to Forced Oscillation Source Location Given Uncertain Generator Parameters, *IEEE Transactions on Power Systems*, vol.34, nr.2, 2019, pp.1641-1649
12. [Chiș2015] V. Chiș, Tehnici de inteligență artificială utilizate în studiile de prognoză din domeniul ingineriei energetice, Teză de doctorat, Universitatea Politehnica Timișoara (Conducător științific: Prof.univ.dr.ing. Ștefan Kilyeni)
13. [Crăciun2013] M. Crăciun, D. Bucerzan, C. Rațiu, A. Manolescu, Actuality of Bankruptcy Prediction Models used in Decision Support System, *International Journal of Computers Communications & Control*, vol.8, nr.3, 2013, pp.375-383

14. [Crăciun2017] M. Crăciun, Șt. Kilyeni, C. Bărbulescu, Bayesian network applications in power systems engineering. A review, *Journal of Sustainable Energy*, nr.3, 2017, p. 99-105
15. [Crăciun2018a] M. Crăciun, L.M. Csorba, Application of the Fuzzy-Pay-Off Method in the Valuation of a Financial Instrument. In: Balas V., Jain L., Balas M. (eds.), *Soft Computing Applications, SOFA 2016, Advances in Intelligent Systems and Computing*, Springer, vol.634, 2018, pp.235-250
16. [Csorba2018] L.M. Csorba, M. Crăciun, An Application of the Multi Period Decision Trees in the Sustainable Medical Waste Investments. In: Balas V., Jain L., Balas M. (eds.), *Soft Computing Applications, SOFA 2016, Advances in Intelligent Systems and Computing*, Springer, vol.634, 2018, pp.540-556
17. [Dagdougui2019] H. Dagdougui, F. Bagheri, H. Le, L. Dessaint, Neural network model for short-term and very-short-term load forecasting in district buildings, *Energy and buildings*, vol.203, pp.1-10
18. [Deacu2015] A. Deacu, Prognoza consumului de energie electrică utilizând rețele neuronale artificiale, Teză de doctorat, Universitatea Politehnica Timișoara (Conducător științific: Prof.univ.dr.ing. Ștefan Kilyeni)
19. [Ghayekhloo2015] M. Ghayekhloo, M.B. Menhaj, M. Ghofrani, A hybrid short-term load forecasting with a new data preprocessing framework, *Electric Power Systems Research*, vol.119, 2015, pp.138-148
20. [Gilanifar2020] M. Gilanifar, H. Wang, L.M.K. Sriram, E.E. Ozguven, R. Arghandeh, Multitask Bayesian Spatiotemporal Gaussian Processes for Short-Term Load Forecasting, *IEEE Transactions on Industrial Electronics*, vol.67, nr.6, 2020, pp.5132-5143
21. [HeY2018] Y. He, B. Lin, Forecasting China's total energy demand and its structure using ADL-MIDAS model, *Energy*, vol.151, 2018, pp.420-429
22. [He2019] F. He, J. Zhou, Z. Feng, G. Liu, Y. Yang, A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm, *Applied Energy*, vol. 237, 2019, pp.103-116
23. [Hsu2018] Y.Y. Hsu, T. Tung, H. Yeh, C. Lu, Two-Stage Artificial Neural Network Model for Short-Term Load Forecasting, *IFAC PapersOnLine*, vol.51, nr.28, 2018, pp.678-683
24. [Jarndal2018] A. Jarndal, S. Hussein, Forecasting of Electric Peak Load Using ANN Cascaded, ANN-NARX and GPR Techniques, *International Conference on Communications, Computing, Cybersecurity, and Informatics (CCCI)*, 2020, pp.1-5
25. [Kilyeni2014] S. Kilyeni, Metode numerice. Algoritme, programe de calcul, aplicații în energetică, *Orizonturi Universitare*, 2014
26. [Kilyeni2015] S. Kilyeni, Tehnici de optimizare în ingineria energetică, *Orizonturi Universitare*, 2015
27. [Kilyeni2015a] S. Kilyeni, Tehnici numerice de analiză asistată de calculator a regimurilor de funcționare a sistemelor electroenergetice, *Orizonturi Universitare*, 2015
28. [Koch2007] K.R. Koch, *Introduction to Bayesian Statistics*, Springer, 2007
29. [Kumar2016] S. Kumar, S. Mishra, S. Gupta, Short Term Load Forecasting Using ANN and Multiple Linear Regression, *2nd International Conference on Computational Intelligence & Communication Technology (CICT)*, 2016, pp.184-186
30. [Li2014] G. Li, H. Wu, F. Wang, Bayesian network approach based on fault isolation for power system fault diagnosis, *International Conference on Power System Technology (Powercon)*, 2014, pp.601-606
31. [Lin2019] Y. Lin, M. Yang, C. Wan, J. Wang, Y. Song, A Multi-Model Combination Approach for Probabilistic Wind Power Forecasting, *IEEE Transactions on Sustainable Energy*, vol.10, nr.1, 2019, pp.2226-2237

32. [Lorencin2017] I. Lorencin, M. Pantos, Evaluating Generating Unit Unavailability Using Bayesian Power Priors, *IEEE Transactions on Power Systems*, vol.32, nr.3, 2017, pp.2315-2323
33. [Ma2013] H. Ma, H. Li, Analysis of Frequency Dynamics in Power Grid: A Bayesian Structure Learning Approach, 2013, *IEEE Transactions on Smart Grid*, vol.4, nr.1, March 2013, pp.457-466
34. [MacKay2003] D.J.C. MacKay, *Information Theory, Inference, and Learning Algorithms*, Cambridge University Press 2003
35. [Massignan2019] J.A.D. Massignan, J.B.A. London, C.D. Maciel, M. Bessani, V. Miranda, PMUs and SCADA Measurements in Power System State Estimation through Bayesian Inference, *IEEE PowerTech*, 2019, pp.1-6
36. [Mestav2019] K.R. Mestav, J.L. Rozas, L. Tong, Bayesian State Estimation for Unobservable Distribution Systems via Deep Learning, *IEEE Transactions on Power Systems*, vol.34, nr.6, 2019, pp.4910-4920
37. [Moller1993] M.F. Moller, A Scaled Conjugate Gradient Algorithm for Fast Super-vised Learning, *Neural Networks*, vol.6, 1993, pp.525-533
38. [Nabney2002] I.T. Nabley, *Algorithms for pattern recognition*, Springer, 2002
39. [Ning2010] Y. Ning, Y. Liu, Q. Ji, Bayesian - BP Neural Network Based Short-term Load Forecasting for Power System, 3rd IEEE International Conference on Advanced Computer Theory and Engineeringv, 2010, vol.2, pp.89-93
40. [Panamtash2020] H. Panamtash, Q. Zhou, T. Hong, Z. Qu, K.O. Davis, A copula-based Bayesian method for probabilistic solar power forecasting, *Solar Energy*, vol.196, 2020, pp.336-345
41. [Pegoraro2017], P.A. Pegoraro, A. Angioni, M. Pau; A. Monti, C. Muscas, F. Ponci, Bayesian Approach for Distribution System State Estimation with Non-Gaussian Uncertainty Models, *IEEE Transactions on Instrumentation and Measurement*, vol.66, no. 11, 2017, pp.2957-2966
42. [Rivero2015] C.R. Rivero, V. Sauchelli, H.D. Patino, J.A. Pucheta, S. Laboret, Long-term Power Consumption Demand Prediction: a comparison of Energy associated and Bayesian modeling approach, *Latin America Congress on Computational Intelligence (LA-CCI)*, 2015, pp.1-6
43. [Russell2010] S.J. Russell, P. Norvig, *Artificial Intelligence. A Modern Approach*, Pearson, 2010
44. [Sahu2019] M.K. Sahu, B. Sahoo, M. Khato, S. Behera, Short-term Wind and PV Generation Forecasting of time-series using ANN, *International Conference on Intelligent Computing and Control Systems (ICICCS)*, 2019, pp.1328-1333
45. [Sarajcev2020] P. Sarajcev, D. Jakus, J. Vasilj, Ensemble learning with time-series clustering for aggregated short-term load forecasting, 20th IEEE Mediterranean Electrotechnical Conference (MELECON), 2020, pp.553-558
46. [Seppanen2016] J. Seppanen, S.K. Au, J. Turunen, L. Haarla, Bayesian Approach in the Modal Analysis of Electromechanical Oscillations, *IEEE Transactions on Power Systems*, vol.32, nr.1, 2017, pp.316-325
47. [SilvaT2017] T.V. da Silva, R.V. Monteiro, G. Guimaraes, F.A. Moura, R.M.C. Albertini, M.A. Tamashiro, Performance Analysis of Neural Network Training Algorithms and Support Vector Machine for Power Generation Forecast of Photo-voltaic Panel, *IEEE Latin America Transactions*, vol.15, nr.6, 2017, pp.1091-1100
48. [Silva2019] F.L.C. Silva, F.L.C. Oliveira, R.C. Souza, A bottom-up bayesian extension for long term electricity consumption forecasting, *Energy*, vol.167, 2019, pp.198-210
49. [Singh2017] S. Singh, S. Hussain, M.A. Bazaz, Short term load forecasting using artificial neural network, 4th International Conference on Image Information Processing (ICIIP), 2017, pp.1-5

50. [Sun2019] M. Sun, C. Feng, J. Zhang, Conditional aggregated probabilistic wind power forecasting based on spatio-temporal correlation, *Applied Energy*, vol.256, 2019, pp.1-11
51. [Sykora2016] M. Sykora, J. Markova, D. Diamantidis, Bayesian Network Application for the Risk Assessment of Existing Energy Production Units, 2nd IEEE International Symposium on Stochastic Models in Reliability Engineering, Life Science and Operations Management, 2016, pp.656-664
52. [Tang2019] L. Tang, X. Wang, X. Wang, C. Shao, S. Liu, S. Tian, Long-term electricity consumption forecasting based on expert prediction and fuzzy Bayesian theory, *Energy*, vol.167, 2019, pp.1144-1154
53. [Tao2016] L. Tao, J. He, Y. Wang, P. Zhang, H. Zhang, H. Wang, Y. Miao, Operational risk assessment of distribution network with consideration of PV output uncertainties, *China International Conference on Electricity Distribution (CICED)*, 2016, pp.1-6
54. [UPT2017] Contract UPT 21/2017, Elaborare modele de calcul și aplicarea lor pentru prognoza consumului propriu tehnologic în rețelele electrice de distribuție, *Electrica Muntenia Nord*
55. [UPT2018] Contract UPT 59/2018, Analiza și optimizarea regimurilor de funcționare pentru rețeaua electrică de distribuție, *Electrica Muntenia Nord*
56. [UPT2019] Contract UPT 63/2019, Analiza regimurilor de funcționare în vederea determinării post-calcul a consumului propriu tehnologic, *Electrica Muntenia Nord*
57. [UPT2020a] Contract UPT 14/2020, Prognoza consumului propriu tehnologic în rețelele electrice de distribuție, *DelGaz Grid Moldova*
58. [UPT2020b] Contract UPT 75/2020, Evaluarea consumului propriu tehnologic prin metode de tip post-calcul în rețele de distribuție, *Electrica Muntenia Nord*
59. [Vakili2015] S. Vakili, Q. Zhao, L. Tong, Bayesian Quickest Short-term Voltage Instability Detection in Power Systems, 54th IEEE Annual Conference on Decision and Control (CDC), 2015, pp.7214-7219
60. [WangT2015] T. Wang, Y. Zhu, Z. Gao, Fault Diagnosis for Power System Based on a Special Bayesian Network, *IEEE Region 10 TTENCON Conference*, 2015, pp.58-63
61. [WangY2019] Y. Wang, Q. Hu, D. Srinivasan, Z. Wang, Wind Power Curve Modeling and Wind Power Forecasting with Inconsistent Data, *IEEE Transactions on Sustainable Energy*, vol.10, nr.1, 2019, pp.16-25
62. [XuB2019] B. Xu, H. Li, W. Pang, D. Chen, Y. Tian, X. Lei, X. Gao, C. Wu, Bayesian network approach to fault diagnosis of a hydroelectric generation system, *Energy Science & Engineering*, vol.7, nr.5, 2019, pp.1669-1677
63. [XuT2010] T. Xu, Y. Zhou, Y. Zhang, Study and Implementation of Rural Distribution Network Fault Location Method Based on Bayesian Reference, 2nd International Conference on Information Science and Engineering, 2010, pp.1-6
64. [Yang2013] M. Yang, S. Fan, J. Lee, Probabilistic Short-Term Wind Power Forecast Using Componential Sparse Bayesian Learning, *IEEE Transactions on Industry Applications*, vol.49, nr.6, 2013, pp.2783-2792
65. [Yang2020] Y. Yang, W. Li, T.A. Gulliver, S. Li, Bayesian Deep Learning-Based Probabilistic Load Forecasting in Smart Grids, *IEEE Transactions on industrial informatics*, vol.16, nr.7, 2020, pp.4703-4713
66. [Yuan2017] X.C. Yuan, X. Sun, W. Zhao, Z. Mi, B. Wang, Forecasting China's regional energy demand by 2030: A Bayesian approach, *Resources, Conservation & Recycling*, vol.127, 2017, pp.85-95
67. [Zhang2014] Y. Zhang, Y. Xiang, L. Wang, Reliability Analysis of Power Grids with Cyber Vulnerability in SCADA System, *IEEE PES General Meeting*, 2014, pp.1-6

68. [Zhao2010] W.Q. Zhao, S.L. Zhang, D.X. Niu, Multi-Agent and Bayesian Network applied in Transformer Faults Diagnosis, 9th International Conference on Machine Learning and Cybernetics, 2010, pp.43-46
69. [Zheng2010] G. Zheng, Z. Yongli, Research of Transformer Fault Diagnosis Based on Bayesian Network Classifiers, International Conference on Computer Design and Applications (ICCD), 2010, vol.3, pp.382-385
70. [Zhou2012] D. Zhou, C. Li, Z. Wang, Power Transformer Lifetime Modeling, Prognostics & System Health Management IEEE Conference (PHM), 2012, pp.1-6