MINISTERUL EDUCAȚIEI ȘI CERCETĂRII

UNIVERSITATEA NAȚIONALĂ DE ȘTIINȚĂ ȘI TEHNOLOGIE POLITEHNICA BUCUREŞTI

ȘCOALA DOCTORALĂ INGINERIE ENERGETICĂ

Rezumat

Monitorizarea și controlul sistemelor electroenergetice cu ajutorul tehnicilor de inteligență artificială

Student-Doctorand: ing. **Andrei-Marius TUDOSE**

Conducător științific: **Prof. dr. ing. Constantin BULAC**

București
Iulie 2025

REZUMAT

Cercetarea doctorală propusă se concentrează pe dezvoltarea și aplicarea unor metode avansate bazate pe inteligență artificială în domeniul energetic, cu accent pe optimizarea funcționării rețelelor electrice, prognoza consumului de energie și integrarea surselor regenerabile. În prima parte a tezei sunt analizate fundamentele teoretice ale algoritmilor de inteligență artificială – rețele neuronale artificiale, metode de clusterizare, algoritmi evolutivi și logica fuzzy – și este evaluat stadiul actual al aplicațiilor acestora în sectorul electroenergetic. Pe această bază, sunt dezvoltate modele performante de prognoză a consumului de energie electrică folosind rețele neuronale de tip convoluțional, capabile să încorporeze variații sezoniere și anomalii, precum cele apărute în perioada pandemiei COVID-19 sau influența prosumatorilor. Rezultatele obținute sunt validate prin indicatori statistici relevanți și sunt comparate cu rezultatele oficiale ale Transelectrica, evidențiind superioritatea abordărilor bazate pe deep learning.

În cea de-a doua parte a lucrării sunt investigate metode de optimizare evolutivă pentru probleme critice ale sistemelor electroenergetice. Sunt propuse și analizate îmbunătățiri ale algoritmului Salpului Marin. Aplicațiile practice se axează pe repartizarea optimă a puterii reactive și alocarea capacității de racordare a surselor regenerabile, ambele esențiale pentru funcționarea sigură și eficientă a rețelelor moderne.

SUMMARY

The proposed doctoral research focuses on the development and application of advanced methods based on artificial intelligence in the energy sector, with an emphasis on optimizing the operation of power grids, forecasting energy consumption, and integrating renewable energy sources. The first part of the thesis analyses the theoretical foundations of artificial intelligence algorithms—artificial neural networks, clustering methods, evolutionary algorithms, and fuzzy logic—and evaluates the current state of their applications in the power systems sector.

Building on this foundation, high-performance models for forecasting electricity consumption are developed using convolutional neural networks, capable of incorporating seasonal variations and anomalies such as those arising during the COVID-19 pandemic or the influence of prosumers. The results are validated through relevant statistical indicators and compared with official data provided by Transelectrica, highlighting the superiority of deep learning-based approaches.

The second part of the thesis investigates evolutionary optimization methods for addressing critical problems in power systems. Improvements to the Salp Swarm Algorithm are proposed and analyzed. Practical applications focus on the optimal allocation of reactive power and the assignment of grid connection capacity for renewable energy sources—both essential for the safe and efficient operation of modern power networks.

1.INTRODUCERE

Motivația studiului

Inteligența artificială reprezintă unul din motoarele principale ale digitalizării și eficientizării proceselor din numeroase domenii, având un impact puternic asupra societății moderne. Printre cele mai relevante aplicații ale acestora în viața cotidiană se pot enumera prelucrarea imaginilor, transformarea automată a discursului în text, conducerea autonomă a autovehiculelor și sugestia de reclame pentru clienți [1]. Odată cu avansurile tehnologice în domeniul inteligenței artificiale (e.g., dezvoltarea unor algoritmi performanți și creșterea puterii de procesare ale componentelor hardware), integrarea acestor tehnici în monitorizarea, operarea și controlul sistemelor electroenergetice a devenit o prioritate pentru o mare parte a comunității academice, dorindu-se realizarea tranziției către era digitală.

Importanța subiectului se reflectă și în numărul articolelor și cărților publicate de-a lungul timpului. După cum se observă în figura de mai jos ultimii ani au cunoscut o creștere în ceea ce privește numărul publicațiilor care implică aplicații ale inteligenței artificiale în domeniul sistemelor electroenergetice. În anul 2024 numărul publicațiilor indexate în platforma Google Scholar în acest domeniu a trecut de pragul de 30 000.

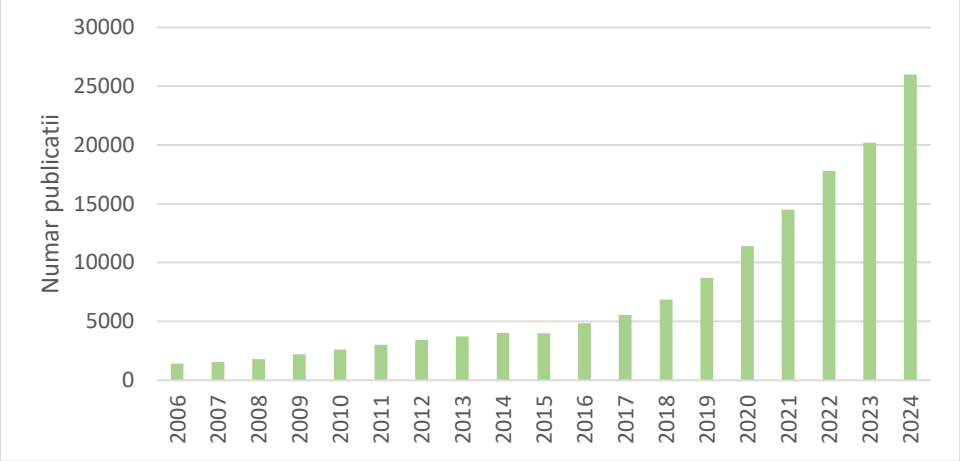


Fig. 1.1 Numărul publicațiilor indexate în baza de date Google Scholar în perioada 2006−2024 folosind cuvinte cheie: “artificial intelligence” și “power systems”

În contextul actual, în care este se dorește și se impune generarea unei cantități cât mai mari de energie din surse regenerabile, cu scopul de a reduce emisiile de gaze cu efect de seră, monitorizarea și controlul sistemelor electroenergetice devine o sarcină din ce în ce mai dificilă. Dificultatea de expansiune a infrastructurii rețelelor electrice din motive economice, tehnice și de mediu conduce la necesitatea de operare a sistemelor electroenergetice moderne aproape de capacitatea acestora. Pentru asigurarea unei fiabilități și siguranțe în funcționare, aplicarea unor metode de optimizare a funcționării este vitală. Astfel, se impune controlul inteligent al dispozitivelor din cadrul unui sistem electroenergetic pentru a atinge diverse obiective de natură tehnică sau economică. Numărul mare de echipamente și de puncte de

consum fac ca aceste sarcini să fie dificile, dar cu ajutorul noilor tehnologii precum *Big Data* și IoT (*Internet of Things*) [2] aceste provocări pot fi rezolvate prin utilizarea de algoritmi inteligenței pentru monitorizare, diagnoză și control.

Scopul studiului

Principalele *obiective ale tezei de doctorat* sunt de identificare a soluțiilor pentru trei probleme importante în funcționarea sistemelor electroenergetice, și anume prognoza consumului de energie electrică, optimizarea funcționării rețelei electrice prin repartiția optimă a puterii reactive și alocarea optimă a capacității disponibile în rețeaua electrică. În acest sens, se investighează posibilitatea de aplicare a tehnicilor bazate pe inteligență artificială în rezolvarea acestor probleme.

Necesitatea unor algoritmi moderni și performanți de prognoză este esențială, în contextul în care caracteristicile de consum se modifică și astfel actualele metodologii devin neperformante și greu adaptabile. O consecință recentă a modificării curbei de consum la nivelul sistemului național o reprezintă integrarea masivă a prosumatorilor, a căror energie produsă nu este cuantificată și agregată la nivelul dispecerului, astfel că pe timpul zilelor însorite consumul scade în mod sensibil.

Datorită interesului ridicat din partea investitorilor de a implementa un număr mare de centrale bazate pe surse regenerabile, rețeaua electrică actuală nu poate integra toate cererile, rezultând astfel costuri ridicate cu întărirea și modernizarea rețelei pentru a putea satisface cererea. În acest sens, ANRE a modificat regulamentul de racordare [3] și stipulează necesitatea unei metodologii de alocare a capacității rețelei electrice. În acest sens, teza de doctorat propune o metodă bazată pe algoritmi IA pentru maximizarea puterii ce poate fi instalate în rețea.

Structura tezei doctorale

Teza doctorală este structurată pe șase capitole. Primul Capitol prezintă stadiul actual al cercetărilor privind aplicarea algoritmilor de inteligență artificială în domeniul energetic, dovedind utilitatea și interesul în rezolvarea diverselor probleme care apar în proiectarea și exploatarea sistemelor electroenergetice folosind tehnici IA. Capitolul expune un studiu bibliografic pentru aplicarea de diverși algoritmi, precum rețele neuronale artificiale, tehnic de clusterizare, algoritmi metaeuristici sau logica fuzzy.

Al doilea Capitol detaliază modul de funcționare al rețelelor neuronale artificiale. Având în vedere aplicabilitatea largă a acestor algoritmi, precum și complexitatea problemelor din domeniul energetic, se prezintă mai multe variații de rețele neuronale: perceptron multistrat, rețele neuronale recurente și rețele neuronale de convoluție. De asemenea, sunt expuse și metode de îmbunătățire a acurateței prin diverse tehnici de împiedicare a fenomenului de supraantrenare.

În Capitolul 3 se abordează problema prognozei consumului de energie electrică, evidențiind în prima parte factorii ce influențează consumul de energie. Se prezintă o metodă de prognoză pentru ziua următoare a consumului la nivelul sistemului energetic național, bazată pe rețele neuronale. Comparând rezultatele cu cele ale unei regresii multiliniare și rezultatele oficiale ale Transelectrica se demonstrează superioritatea rețelelor neuronale. Analiza a fost făcută în două perioade care au produs schimbări majore în sistemul energetic, și anume

pandemia COVID-19 în care din cauza restricțiilor de desfășurare a numeroase activități a fost schimbat tiparul de consum, precum și în anul 2025, în care prosumatorii au început să joace un rol puternic în producția internă. Se evidențiază astfel că diverse fenomene socio-economice trebuie luate în calcul în realizarea prognozelor și modelele trebuie adaptate periodic la ultimele cerințe.

Capitolul 3 prezintă o serie de algoritmi de calcul evolutiv, precum algoritmul genetic, algoritmul furnicilor leu sau algoritmul salpului. De asemenea, se propun îmbunătățiri ale mecanismelor de funcționare pentru cel din urmă și se evaluează performanța versiunii standard și a celei îmbunătățite utilizând funcții de referință în domeniul optimizărilor.

Una dintre cele mai importante probleme de optimizare în sistemele electroenergetice este cea de repartiție optimă a puterii reactive, având ca scop menținerea nivelului de tensiune în benzile admisibile și reducerea pierderilor de putere. Formularea problemei este prezentată în al 5-lea Capitol, unde se evaluează performanțele pentru algoritmului de optimizare a salpului îmbunătățit pe două rețele de test.

Capitolul 6, "*Alocarea optimă a capacității disponibile de racordare a surselor de energie în rețelele electrice*" abordează o problemă importantă în ceea ce privește tranziția domeniului energetic către surse regenerabile. Din cauza costurilor mari de modernizare și expansiune a rețelelor electrice, pentru a crește gradul de integrare a surselor regenerabile de energie, este necesar ca rețeaua electrică să fie exploatată cât mai aproape de limitele de funcționare. În acest sens, se propune un algoritm de optimizare pentru alocarea în mod optim a capacității noilor surse de generare într-o rețea electrică.

2.STADIUL ACTUAL AL UTILIZĂRII ALGORITMILOR BAZAȚI PE INTELIGENȚĂ ARTIFICALĂ ÎN DOMENIUL ENERGETIC

2.1. Rețele neuronale artificiale

Avansul tehnologic înregistrat de-a lungul ultimului deceniu în domeniul inteligenței artificiale, în special în zona rețelelor neuronale, creează posibilitatea ca aceste tehnici să poată fi utilizate într-o plajă largă de domenii, obținând rezultate foarte bune. Stadiul curent al cercetărilor în zona rețelelor neuronale se datorează mai multor factori, printre care:

- Crearea unor comunități puternic implicate axate pe studiul rețelelor neuronale, pe diferite platforme (ex: GitHub, StackOverflow);
- Apariția programelor software specializate (ex: Scikit-Learn, Tensorflow, PyTorch, Matlab etc.) care permit implementarea unor arhitecturi complexe;
- Apariția unor componente hardware performante, precum unitățile de procesare grafică (GPU) care să permită un efort mare de calcul, reducând astfel durata necesară antrenării rețelelor neuronale.

Rețelele neuronale artificiale sunt în general utilizate pentru rezolvarea problemelor cu învățare supervizată, care presupun determinarea unei funcții care poate face corespondența între valorile de intrare și de ieșire ale unui proces, pe baza unui set de exemple intrare−ieșire. Fig. 2.1 ilustrează principalii pași parcurși în cadrul determinării unui model cu învățare supervizată:

- Împărțirea setului inițial de perechi de valori intrare−ieșire în două subseturi, unul pentru antrenare și unul pentru testare;
- Antrenarea modelului, presupunând determinarea funcției de corespondență între valorile de intrare și valorile de ieșire pe baza exemplelor din setul de antrenare;
- Aplicarea modelului obținut pe valorile de intrare ale exemplelor din setul de testare;
- Compararea rezultatelor obținute de model cu valorile de ieșire corecte și evaluarea erorilor;
- Modificarea parametrilor modelului și reantrenarea acestuia, până când valoarea erorilor sunt satisfăcătoare.

Învățarea supervizată implică două categorii de probleme ce pot fi rezolvate:

- Probleme de clasificare, în care scopul modelului este să identifice clasa reprezentativă a unui exemplu dintr-un set predefinit de clase. O provocare actuală în domeniul inteligenței artificiale o reprezintă procesarea de imagini, rețelele neuronale fiind utilizate în scopul recunoașterii a diferitor elemente din imagini;
- Probleme de regresie, în care modelul produce, pe baza intrărilor, una sau mai multe valori reale, reprezentând o estimare a ieșirii dintr-un proces. Prognoza consumului de energie face parte din această clasă de probleme, ieșirile rețelei neuronale reprezentând valorile prognozate pe intervalele de timp considerate.

Flexibilitatea și diversitatea arhitecturilor rețelelor neuronale conduce la necesitatea studierii mai multor tipologii, pentru alegerea celei mai bune pentru rezolvarea problemei considerate. În continuare vor fi prezentate principalele tipologii de rețele neuronale utilizate în rezolvarea problemelor de clasificare și regresie.

Exemplu	Mărimi intrare	Mărimi ieșire
1	$[x_{1,1}, x_{2,1}, \dots, x_{n,1}]$	$[y_{1,1}, y_{2,1}, \dots, y_{a,1}]$
2	$[x_{1,2}, x_{2,2}, \dots, x_{n,2}]$	$[y_{1,2}, y_{2,2}, \dots, y_{a,2}]$
⋮	⋮	⋮
n	$[x_{1,m}, x_{2,m}, \dots, x_{n,m}]$	$[y_{1,b}, y_{2,b}, \dots, y_{a,b}]$

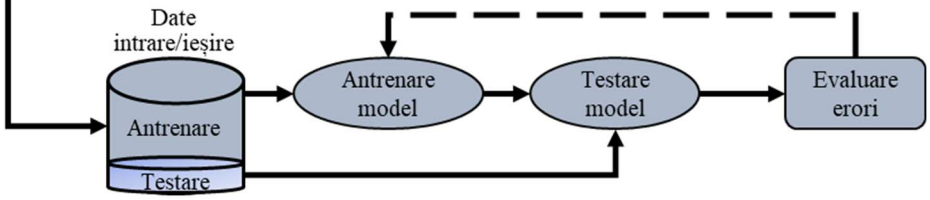


Fig. 2.1 Ilustrarea unui algoritm cu învățare supervizată

2.1.1. Aplicații ale rețelelor neuronale în monitorizarea și controlul sistemelor electroenergetice

Numărul aplicațiilor rețelelor neuronale în sectorul energetic a cunoscut o creștere semnificativă în ultimele două decenii, având în vedere succesul acestor tehnici într-o largă varietate de domenii de activitate (procesare de imagini, marketing, transport, etc.). În continuare vor fi prezentate succint principalele utilizări ale rețelelor neuronale artificiale în monitorizarea și controlul sistemelor electroenergetice.

- *Prognoza consumului și producției de energie electrică*

Un interes major acordat subiectului prognozei în domeniul energiei poate fi observat din numărul publicațiilor în literatura de specialitate. Fig. 2.2 prezintă evoluția numărului de articole și cărți indexate în platforma Google Scholar, segregând principalele obiective de prognozat: consum, generare din surse fotovoltaice, generare din surse eoliene, prețul energiei [4]. Se observă o creștere accentuată a numărului de publicații de-a lungul anilor, înregistrându-se o dublare a numărului anual de publicații în 2024 față de anul 2020 . Cel mai mare interes o prezintă problema prognozei consumului de energie electrică, însumând aproximativ 70% din numărul total de publicații regăsite în această categorie. Acest fapt se datorează numărului mare de variații ale problemei, existând multiple orizonturi de timp pentru care se poate realiza prognoza (termen foarte scurt, scurt, mediu sau lung) și a nivelului de agregare (consum individual, zonal sau național).

Numeroase articole abordează rețelele neuronale ca metodă de rezolvare a problemelor de prognoză în sistemele electroenergetice. Dintre acestea, o bună parte se ocupă de prognoza consumului de energie electrică la nivel de sistem [5], [6], în timp ce studiile din ultimii ani s-au concentrat și pe niveluri de agregare scăzute, până la nivel de clădire [7], [8]. De asemenea, literatura prezintă numeroase studii privind prognoza producției din surse eoliene sau

fotovoltaice [9], [10]. În general, prognozele de producție se realizează pe perioade scurte de timp, din cauza caracterului stohastic al factorilor meteorologici (ex: viteza și direcția vântului, nebulozitatea, iradiația solară etc.).

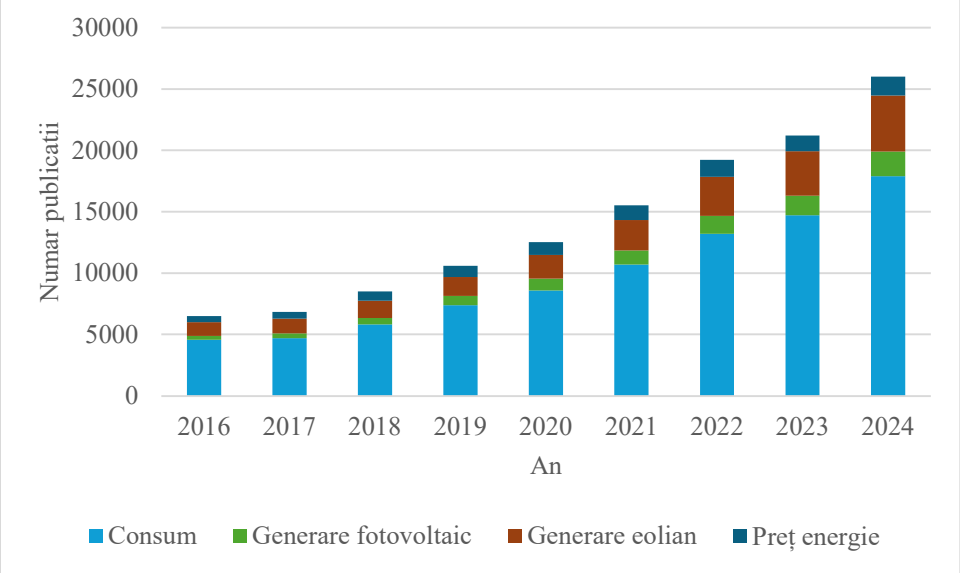


Fig. 2.2 Evoluția numărului de publicații indexate în platforma Google Scholar folosind cuvintele cheie: "load forecasting", "solar power forecasting", "wind power forecasting", "electricity price forecasting"

Considerând gradul mare de incertitudine asociat sarcinilor electrice, cauzat de o plajă largă de factori (i.e., meteorologici, economici și sociali), o cantitate mare de date și metode avansate de calcul sunt necesare pentru a obține o precizie satisfăcătoare a prognozei de consum pe termen scurt. În acest sens, numeroase metode au fost propuse de-a lungul anilor pentru a rezolva această problemă complexă. Metodele clasice se bazează pe modele statistice, de analiză a seriilor de timp, printre care ARIMA (*Autoregressive Integrated Moving Average*) [11] și variații ale acestei metode: ARIMA cu variabile exogene (ARIMAX) și ARIMA cu componente periodice (SARIMA) [12]. Pentru o mai bună adaptare la natura consumului aflată în continuă schimbare, numeroase studii aplică tehnici moderne de calcul, precum algoritmii genetici [13] sau logica fuzzy [14]. Modele bazate pe învățarea automată au captat atenția comunității academice, dovedindu-se să aibă o eficiență ridicată în a rezolva probleme complexe, permițând realizarea unor modele performante, care pot incorpora și modela dependențele neliniare dintre consum și diferiți factori externi. Printre metodele frecvent utilizate se pot enumera mașinile cu suport vectorial (*support vector regression*) [15] și rețelele neuronale artificiale de tip perceptron multistrat [16].

Rețelele neuronale reprezintă o metodă eficientă de a rezolva problema consumului de energie, având în vedere capabilitatea acestora de a învăța și a extrage informațiile relevante doar din datele prezentate, fără a necesita prelucrarea acestora. În literatura de specialitate s-au folosit numeroase tipuri de rețele neuronale, fiecare având propriile avantaje. Bouktif *et. al.* [5] au studiat performanța rețelelor neuronale de tip recurent, LSTM și GRU, pentru prognoza consumului de energie electrică la nivelul sistemului electroenergetic francez. Au fost studiate mai multe arhitecturi în cadrul studiului, cea mai bună obținând o eroare medie de 200 MW. În lucrarea [17], autorii au propus un ansamblu de rețele neuronale de convoluție pentru

prognoza consumului de energie electrică a orașului New York pentru ziua următoare. Antrenarea rețelelor neuronale a fost realizată în paralel, realizându-se ulterior o medie a rezultatelor oferite de fiecare rețea neuronală în mod individual, această tehnică purtând denumirea de *bootstrap aggregation*, atingându-se o eroare medie relativă de 33%. În [18], autorii propun o arhitectură ce implică o rețea neuronală de convoluție cu dilatare, care evidențiază relația dintre valorile de la aceeași oră înregistrate în zile diferite. Studiul de caz implică prognoza pentru ziua următoare a statului Texas, obținându-se o eroare medie relativă de 2.7%. Lucrarea [19] prezintă o metodologie bazată pe rețele neuronale de tip MLP pentru prognoza puterii produse de centrale eoliene. Metodologia implică utilizarea tehnicilor de clusterizare, pentru a grupa perioadele de timp similare și a construi modele diferite pentru fiecare cluster. Tabelul 2.1 prezintă o analiză sumară a literaturii de specialitate din domeniul prognozei consumului și producției de energie electrică.

Tabelul 2.1 Analiza literaturii privind metodele de prognoză

Referința	**Tipul prognozei**	**Orizontul de timp prognozat**	**Nivelul de analiză**	**Metoda folosită**
Bouktif *et. al.* [5]	Consum	Termen mediu	Național (Franța)	LSTM / GRU
Tang *et. al.* [20]	Consum	Termen scurt	Național (Slovacia)	RNR bidirecțională
Dorado Rueda *et. al.* [6]	Consum	Termen scurt	Național (Franța)	RNC cu dilatare
Nichiforov *et. al.* [7]	Consum	Termen scurt	Clădire	MLP autoregresiv
Dagdougui *et. al.* [8]	Consum	Termen scurt	Clădire	MLP
Dong *et. al.* [17]	Consum	Termen scurt	Oraș	RNC
Shen *et. al.* [18]	Consum	Termen scurt	Regional (Texas)	RNC
Hernández *et. al.* [16]	Consum	Termen scurt	Microrețea	MLP
Nichiforov *et. al.* [21]	Consum	Termen scurt	Oraș	MLP autoregresiv
Pramono *et. al.* [22]	Consum	Termen scurt	Național (Elveția + New England)	CNN-LSTM
Agrawal *et. al.* [23]	Consum	Termen lung	Regional (New England)	LSTM
Sangrody *et. al.* [24]	Consum	Termen lung	Regional (New England)	MLP + RNR
Sadaei *et. al.* [25]	Consum	Termen scurt	Oraș	RNC + fuzzy

Han *et. al.* [26]	Consum	Termen scurt + mediu	Oraș	RNC / LSTM
Liu *et. al.* [9]	Generare eoliene	Termen foarte scurt	−	LSTM
Wu *et. al.* [19]	Generare eoliene	Termen scurt	−	MLP + clusterizare
Gensler *et. al.* [27]	Generare fotovoltaic	Termen scurt	−	LSTM + autoencoder
Lin *et. al.* [10]	Generare fotovoltaic	Termen scurt	−	RNC temporală
Wang *et. al.* [28]	Generare fotovoltaic	Termen scurt	−	LSTM+regresie gaussiana

- *Estimarea stării statice*

Starea unui sistem electroenergetic presupune determinarea tuturor mărimilor de stare atașate nodurilor și laturilor acestuia:

- injecțiile de putere activă și reactivă în nodurile rețelei;
- modulele și argumentele tensiunilor în fiecare nod al rețelei;
- circulațiile de puteri activă și reactivă prin laturile rețelei.

Estimarea stării statice reprezintă un proces indispensabil operării sistemelor electroenergetice în timp real, presupunând determinarea mărimilor de stare cu o acuratețe suficient de bună, pe baza unui număr limitat de informații. Datele utilizate de un estimator de stare pot proveni din diverse surse:

- măsurători ale variabilelor de stare;
- prelucrarea modelului matematic al sistemului;
- informații cunoscute fără a fi realizate măsurători, denumite pseudo-măsurători (ex: valoarea de consemn a tensiunii la nodurile generatoare) [29].

Metodele clasice de calcul al regimului permanent necesită cunoașterea unui număr fix de mărimi și variabile pentru a putea converge către soluție. Aceste metode de calcul nu pot fi aplicate în timp real, existând mai multe dificultăți în sistemele electroenergetice reale:

- erori ale aparatelor de măsură și mijloacelor de telecomunicație;
- absența aparatelor de măsură în anumite noduri din sistem;
- întârzierea măsurătorilor;
- erori în parametrii rețelei.

Pentru rezolvarea acestor surse de erori, estimatoarele de stare trebuie să conțină proceduri performante de filtrare și detecție a datelor eronate [30]. În ultimii ani, în literatură au fost propuse soluții bazate pe rețele neuronale pentru estimarea stării. Miranda *et. al.* [31] au propus utilizarea unei rețele neuronale de tip *autoencoder*, a cărei arhitectură generală este prezentată în Fig. 2.3. Acest tip de rețea neuronală reconstruiește intrarea primită la ieșire, având scopul de a filtra eventualele date eronate primite la intrare. Pentru rezolvarea problemei estimării stării statice, *autoencoder*-ul primește la intrare toate modulele și argumentele tensiunilor

nodale, iar pentru a simula eventuale erori de măsură, unele valori sunt alterate, rețeaua neuronală fiind capabilă să reconstruiască valorile reale cu o precizie de 99%. Având în vedere creșterea numărului de atacuri cibernetice din ultima perioadă [32], lucrarea [33] a propus o rețea neuronală autoregresivă pentru a identifica datele false injectate în estimatoarele de stare. Dezvoltarea conceptului de *smart grid* a determinat creșterea interesului în aplicarea unor tehnici specifice rețelelor de transport și în sectorul distribuției, printre care și problema estimării stării [34], [35].

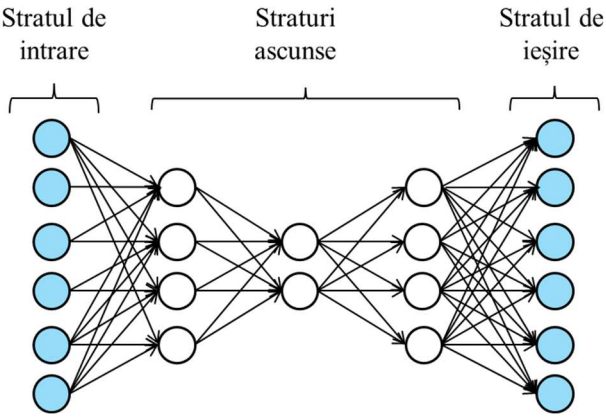


Fig. 2.3 Arhitectura generală a unui autoencoder

- *Evaluarea securității*

Pentru asigurarea unui nivel corespunzător de securitate în funcționarea sistemelor electroenergetice se impune aplicarea unor metode de evaluare în timp real a securității și a riscului de declanșare a unui colaps. Metodele clasice prezintă dezavantajul efortului computațional ridicat, ceea ce conduce la un timp de calcul inacceptabil pentru luarea deciziilor într-un sistem de timp real. Pentru rezolvarea acestei provocări, tehnicile recente utilizează rețele neuronale artificiale pentru a evalua starea sistemului la un moment dat. Shi *et. al.* [36] au studiat problema identificării modului de oscilație al regimurilor tranzitorii din sistemele electroenergetice. Astfel, au propus o rețea neuronală de convoluție care primește măsurători fazoriale în timp, clasificând pe baza acestor informații regimul tranzitoriu într-una din cele trei categorii: stabil, oscilatoriu instabil sau aperiodic instabil. Acuratețea modelului pe rețelele test analizate a atins valoarea de 97%, depășind performanța obținută cu alte tehnici de inteligență artificială, precum arborii de decizie, sau mașinile cu suport vectorial. În mod similar, lucrarea [37] propune utilizarea rețelelor neuronale de convoluție pentru evaluarea securității stării statice. Fiind de asemenea o problemă de clasificare, ieșirea rețelei neuronale este reprezentată de nivelul de securitate al regimului sistemului: stare normală, stare de alertă, stare de urgență. Rezultatele au arătat o acuratețe a rețelei neuronale de peste 90% pentru toate rețelele test studiate. Bulac *et. al.* [38] au dezvoltat un program bazat pe RNA pentru evaluarea riscului de declanșare a instabilității de tensiune într-un sistem electroenergetic, realizând teste pe rețeaua IEEE 30.

- *Localizarea, izolarea și restaurarea defectelor*

O altă provocare importantă în funcționarea sistemelor electroenergetice ce poate fi rezolvată cu ajutorul rețelelor neuronale este aceea de localizare a defectelor pe o linie electrică.

Identificarea locației se face cu dificultate, în special la liniile în cablu, unde linia este îngropată în pământ. În ultimii ani, tehnologiile bazate pe transportul energiei la tensiune continuă au cunoscut o creștere importantă a interesului. În [39] se analizează problema identificării distanței la care s-a produs un defect pe o linie de tensiune continuă cu ajutorul rețelelor neuronale de convoluție. Performanța metodei prezentate este ridicată, atingând erori maxime de ordinul sutelor de metri. Lucrarea [40] prezintă o metodologie bazată pe rețele neuronale pentru identificarea defectelor în rețelele de distribuție, obținând rezultate promițătoare în ceea ce privește distanța estimată de identificare a locului de defect. Dezvoltarea acestor tehnici va conduce la reducere costurilor și a duratei de identificare și reparare a defectelor în liniile electrice, crescând astfel și gradul de continuitate în alimentarea consumatorilor, fiind un indicator esențial în operarea rețelelor electrice. [41]

2.2. Tehnici de clusterizare

Tehnicile de inteligență artificială în care datele nu pot fi aranjate sub forma unor perechi de valori intrare−ieșire, existând doar mărimi de intrare, fac parte din clasa de probleme cu învățare nesupervizată. Scopul algoritmilor din această clasă este de a extrage anumite trăsături din setul de date și a le utiliza ulterior. Principalul tip de probleme care se pot rezolva prin învățare nesupervizată sunt problemele de *clustering*, care presupun identificare exemplelor de intrare similare și gruparea acestora în *clustere*. Aplicațiile acestor tehnici de *clusterizare* includ reducerea dimensiunii problemei și identificare anumitor caracteristici ale exemplelor pe baza similarității acestora. Printre cele mai frecvent utilizate tehnici de clusterizare se numără *k-means,* fuzzy *c-means* [42] și hărțile cu auto-organizare SOM (*Self Organizing Map*), denumite și rețele neuronale Kohonen. [43]

2.2.1. Algoritmul k-means

Metoda k-means este una din cele mai utilizate tehnici de clusterizare. Aceasta presupune alegerea unui număr de clustere, reprezentate de câte un punct în spațiul de căutare distribuite în mod aleator, denumite centroide. Procesul iterativ al algoritmului va repartiza optim locația centroidelor astfel încât acestea să sintetizeze trăsăturile esențiale ale datelor de intrare.

Primul pas al algoritmul îl reprezintă alegerea numărului de clustere. Scopul algoritmului este a minimiza funcția obiectiv:

$$MIN\ J = \sum_{i=1}^{N}\sum_{j=1}^{C} a_{ij} \left\| x_i - c_j \right\|^2 \tag{2.1}$$

, unde N reprezintă numărul de date, C reprezintă numărul de clustere. Notația $||x_i - c_j||^2$ reprezintă distanța euclidiană dintre punctul x_i și centrul clusterului j.

Ulterior inițilizării centroidelor, pentru fiecare punct se determină distanța față de toate centroidele și se determină valoarea a_{ij}.

$$a_{ij} = \begin{cases} 1,\ dacă\ \left\| x_i - c_j \right\| \text{ este minim} \\ 0,\ \text{altfel} \end{cases} \qquad i=\overline{1, N}, j=\overline{1, C} \tag{2.2}$$

După alocarea fiecărui punct unui cluster se recalculează poziția centroidelor folosind următoarea ecuația:

$$c_j = \frac{\sum_{i=1}^{N} a_{ij} x_i}{\sum_{i=1}^{N} a_{ij}}, \quad \overline{j=1, C} \tag{2.3}$$

Algoritmul k-means presupune aplicarea în mod iterativ a ecuațiilor (2.1)-(2.3) pentru un număr prestabilit de iterații sau până când diferența valorilor funcției obiectiv de la două iterații succesive este inferioară unui prag.

Provocarea majoră în cazul utilizării algoritmilor de clusterizare este alegerea numărului optim de clustere [44]. Pentru algoritmul k-means o metodă de evaluare a numărului de clustere este metoda cotului (en: *elbow method*). Aceasta presupune realizarea algoritmului cu mai multe valori pentru numărul de clustere. Se consideră ca variantă optimă numărul de clustere de la care diferența dintre performanțe devine neglijabilă.

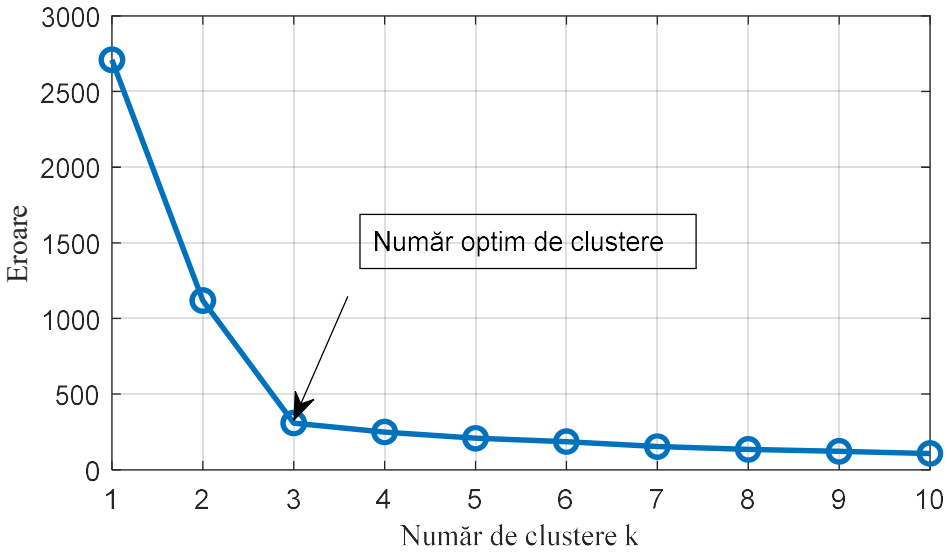


Fig. 2.4 Reprezentare grafică a utilizării metodei cotului

2.2.2. Algoritmul fuzzy c-means

Această metodă este funcționează similar cu algoritmul k-means, tehnica implicând de asemenea logica fuzzy prin care se definește noțiune de grad de apartenență la un cluster. În metoda fuzzy c-means, un punct din setul de date nu mai aparține unui singur cluster reprezentativ, ci aparține tuturor clusterelor cu diferite grade de încredere. Funcția obiectiv se definește în continuare:

$$MIN\ J = \sum_{i=1}^{N} \sum_{j=1}^{C} \mu_{ij}^{m} \left\| x_i - c_j \right\|^2 \tag{2.4}$$

, unde μ_{ij} reprezintă gradul de apartenență al punctului x_i la clusterul c_j, iar m reprezintă parametrul fuzzy, ales arbitrar în cazul algoritmului.

Valorile gradelor de apartanență la fiecare cluster se calculează conform formulei urmtoare:

$$\mu_{ij}=\frac{1}{\sum_{k=1}^{N}\left(\frac{\left\|x_i-c_j\right\|^2}{\left\|x_i-c_k\right\|^2}\right)^{\frac{2}{m-1}}} \quad i=\overline{1,N}, j=\overline{1,C} \tag{2.5}$$

Se observă că μ_{ij} va avea valori diferite de zero pentru toate cele C clutere. Acest aspect oferă o flexibilitate mai mare algoritmului comparativ cu metoda k-means, având în vedere că un punct poate aparține simultan mai multor clustere [45].

Noile poziții ale centroidelor se calculează similar cu metoda k-means:

$$c_j=\frac{\sum_{i=1}^{N}\mu_{ij}^m x_i}{\sum_{i=1}^{N}\mu_{ij}^m}, \quad \overline{j=1,C} \tag{2.6}$$

Provocarea principală a metodei fuzzy c-means este alegerea numărului optim de clustere, similar metodei k-means. În literatura de specialitate au fost propuși mai mulți indicatori de performanță [46].

Tabelul 2.2 Indicatori de performanță pentru algoritmul fuzzy c-means

Denumire indicator	Formulă de calcul	Obiectiv
Coeficient de repartiție (PC)	$PC=\frac{1}{N}\sum_{i=1}^{N}\sum_{j=1}^{C}\mu_{ij}^m$	Maximizare
Coeficient de repartiție modificat (MPC)	$MPC=1-\frac{C}{C-1}\left(1-\sum_{i=1}^{N}\sum_{j=1}^{C}\mu_{ij}^2\right)$	Maximizare
Entropia repartiției (PE)	$PE=-\frac{1}{N}\sum_{i=1}^{N}\sum_{j=1}^{C}\mu_{ij}\ln(\mu_{ij})$	Minimizare
Coeficient Xie-Beni (XB)	$XB=\frac{\sum_{i=1}^{N}\sum_{j=1}^{C}\mu_{ij}\left\|x_i-c_j\right\|^2}{N(\min\{c_i-c_k\})}$	Minimizare

2.2.3. Rețele neuronale Kohonen (Hărți cu auto-organizare)

Hărțile cu auto-organizare reprezintă o tehnică de învățare nesupervizată utilizată pentru clusterizarea datelor de intrare. Acestea au o structură de tip rețea, formată din noduri care sunt conectate cu nodurile adiacente, după cum poate fi observat în Fig. 2.5. Pentru o problemă în care datele de intrare sunt caracterizate de n valori, un nod în rețeaua Kohonen reprezintă un vector cu n dimeniuni, caracterizat de poziția sa în rețea.

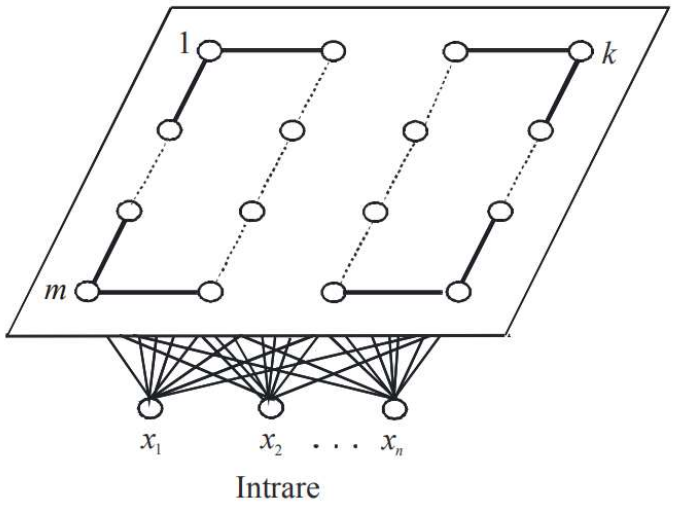


Fig. 2.5 Structura de bază a unei rețele Kohonen (Sursă: *[47]*)

Se consideră un vector de intrare V=[v_1,v_2...v_n], o rețea Kohonen formată dintr-o matrice bidimensională cu dimensiunea *m x k* și nodurile din rețea W_j = [$w_{1,j}$, $w_{2,j}$,..., $w_{n,j}$], $j = \overline{1, m \cdot k}$. Acest exemplu V este prezentat rețelei Kohonen, calculându-se distanța de la vectorul de intrare la fiecare nod al rețelei, selectându-se ulterior distanța minimă. Nodul pentru care această distanță este minimă se numește nodul cel mai reprezentativ (*Best Matching Unit - BMU*). Distanța dintre un nod al rețelei și vectorul de intrare se calculează pe baza distanței euclidiene.

$$dist_j = \sqrt{\sum_{i=1}^{n}(v_i - w_{i,j})^2} \qquad \text{j=1,2...m} \cdot \text{k} \tag{2.7}$$

$$\text{BMU}=\min\{\text{dist}_1, \text{dist}_2 ... \text{dist}_{\text{m·k}}\} \tag{2.8}$$

După ce a fost determinat nodul cel mai reprezentativ din rețea, se actualizează ponderile acestui nod și ale nodurilor vecine pe baza relației (2.9).

$$w_{i,j} = w_{i,j} + \eta\Lambda(v_i - w_{i,j}) \tag{2.9}$$

În relația (2.10) Λ reprezintă funcția de vecinătate care determină gradul de influență al BMU pentru celelalte noduri din rețea. Acesta se calculează cu relația următoare:

$$\Lambda = \exp(-\frac{dist(j, j^*)^2}{2\sigma^2}) \tag{2.10}$$

, unde σ este raza de vecinătate, calculată cu ajutorul relației (2.11).

$$\sigma = \sigma_0 \exp(-\frac{iter}{\lambda}) \tag{2.11}$$

În relația (2.11) λ reprezintă o constantă care conduce la scăderea razei de vecinătate pe parcursul procesului de antrenare. Modul de calcul al acesteia este prezentat în relația (2.12).

$$\lambda = \frac{iter_\max}{\log(\sigma_0)} \tag{2.12}$$

Procesul prezentat anterior se repetă pentru fiecare vector de intrare din setul de date. După ce toate elementele au fost prezentate rețelei, aceasta ajustându-și ponderile corespunzător, se trece la o nouă iterația, în care procesul este repetat. Pe măsură ce antrenarea ajunge la un număr mai ridicat de iterații, influența BMU asupra vecinilor nu va mai fi atât de puternică. În general, parametrul σ_0 este ales ca fiind jumătate din numărul de linii sau de coloane a rețelei Kohonen, astfel că influența unui noi BMU va afecta în prima iterație aproximativ jumătate din rețea.

Rezultatele obținute în lucrarea [48] arată că rețelele Kohonen au o acuratețe mai bună la clasificarea elementelor în clusterul lor reprezentativ. De asemenea, acestea obțin rezultate mai bune comparativ cu alte metode de clustering atunci când setul de date este mic. Într-o ultimă concluzie se arată că SOM sunt mai puțin sensibile atunci când setul de date conțin și date eronate. Ca urmare a robusteții oferite de rețelele Kohonen, acest capitol va descrie fundamentele și algoritmul de antrenare ale acestei metode, urmând să fie prezentate rezultate obținute în literatura de specialitate.

2.2.4. Aplicații ale tehnicilor de clusterizare

În [49], autorii au aplicat algoritmul k-means pentru identificare tiparelor de consumatori rezidențiali, cu scopul de a dezvolta aplicații de răspuns al cererii de către operatorii locali al pieței de energie. În lucrarea [50], autorii au dezvoltat o tehnică de analiza a datelor bazate pe metode de clusterizare pentru identificarea furturilor de energie în rețelele electrice de joasă tensiune, identificând tipare neobișnuite pentru diverși consumatori. Acuratețea metodei propuse a fost de 96.73%, având o performanță superioară față de tehnicile tradiționale. Cu ajutorul tehnicilor de clusterizare, Sanati *et. al.* [51] propun eficientizarea acționării protecțiilor într-o microrețea, prin implementarea unei logici de funcționare dependentă de locația echipamentelor în rețea și de locul de defect, atingând o viteză de eliminare a defectelor de sub 500 ms.

Având în vedere cererea crescută privind vehiculele electrice, încărcarea lor devine o provocare în operarea rețelelor electrice. Pentru reducerea timpilor de așteptare și echilibrarea rețelei, autorii lucrării [52] propun gruparea centrelor de încărcare a vehiculelor electrice în clustere, astfel încât stațiile de încărcare să poată avea o programare optimizată în funcție de ordinea și urgența încărcării anumitor vehicule. O altă provocare actuală în domeniul energetic este dată de creșterea numărului de prosumatori, care pot produce suprasarcini în rețelele electrice de joasă și medie tensiune. O metodă comună pentru încurajarea aplatizării curbei de sarcină o reprezintă implementarea de programe de răspuns al cererii. În acest sens, în [53] a fost propusă o metodă de clusterizare bazată pe tehnica k-means prin care au fost identificate 6 tipare de consum pentru prosumatori, ulterior fiind evaluată din punct de vedere economic implementarea unui program de răspuns la cerere bazat pe tarifare diferențiată în funcție de ora de consum.

Datorită numărului tot mai mare de date colectate din sistemele electroenergetice, aplicațiile de prognoză pot folosi tehnici de clusterizare pentru preprocesarea datelor. În acest mod pot fi

realizate prognoze mai precise. În [54] autorii propun clusterizarea consumurilor istorice folosind metoda fuzzy c-means și realizarea unui algoritm de prognoză bazat pe rețele neuronale pe fiecare tipar identificat anterior. Modelul propus atinge o eroare medie de 2.15%, față de 5.49% atins cu un model care utilizează doar rețele neuronale.

Odată cu dezvoltarea surselor regenerabile de energie, piața de energie se modifică și în multe țări se creează piețe separate în funcție de zonă. G. Poyrazoglu [55] a propus aplicarea tehnicilor de clusterizare pentru segmentarea pieței de energie electrică din Turcia, rezultând o partiționare optimă în 3 clustere.

2.3. Algoritmi bazați pe tehnici de calcul evolutiv

Algoritmii de calcul evolutiv au devenit recent o alternativă populară pentru soluționarea problemelor complexe de optimizare ce introduc dificultăți în rezolvarea prin metode tradiționale deterministe. Aceștia reprezintă o clasă de metode de optimizare bazate pe diverse mecanisme și fenomene regăsite în natură (e.g., comportamentul social al diverselor specii de animale), care găsesc soluția optimă pornind de la un set de soluții inițiale, într-o manieră iterativă.

Importanța integrării algoritmilor de optimizare în operarea și dezvoltarea sistemelor electroenergetice se reflectă în interesul ridicat al comunității academice pentru acest domeniu. Totodată, utilizarea tehnicilor de optimizare bazate pe inteligență artificială devine din ce în ce mai frecventă datorită performanțelor algoritmilor recent propuși în literatură, precum și a avansului tehnologic al componentelor hardware, care permit rezolvarea problemelor solicitante din punct de vedere computațional. În Fig. 2.6 este prezentată evoluția anuală a publicațiilor indexate în platforma Google Scholar ce abordează probleme de optimizări în sistemele electroenergetice. Se observă o creștere semnificativă a numărului de articole și cărți, înregistrând în anul 2024 18000 de publicații, cu 16 % mai mult față de anul precedent și de două ori mai mult față de anul 2019.

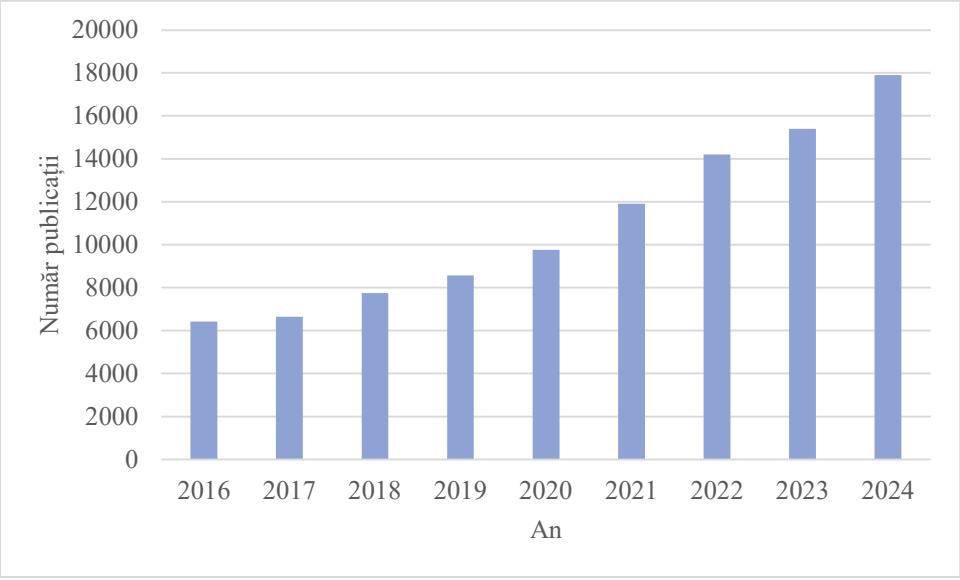


Fig. 2.6 Evoluția numărului de publicații indexate în platforma Google Scholar folosind cuvintele cheie „tehnici de calcul evolutiv” (en: evolutionary computation) și “sisteme electroenergetice” (en: power systems)

2.3.1. Aplicații ale algoritmilor de optimizare metaeuristici în monitorizarea și controlul sistemelor electroenergetice

Problemele de optimizare a circulațiilor de puteri sunt fundamentale pentru a asigura o operare eficientă din punct de vedere economic al sistemelor electroenergetice [56]. Avansurile tehnologice în domeniul transportului energiei electrice (ex: dispozitivele FACTS), precum și apariția a noi algoritmi de optimizare în literatură a făcut ca aceste probleme clasice de optimizare să prezinte un interes crescut în continuare.

- *Repartiția optimă a puterii reactive și circulația optimă de puteri*

Problema repartiției optime a puterii reactive prezintă un interes ridicat, datorită beneficiilor ce pot fi aduse în procesul de operare a rețelelor electrice. În acest sens, numeroase articole abordează această problemă de optimizare utilizând diverse tehnic de rezolvare. Dintr-un total de 190000 de articole publicate în acest domeniu, printre cei mai comuni algoritmi utilizați se numără algoritmul genetic (AG), optimizarea cu roiuri de particule (PSO), algoritmul diferențial evolutiv (ADE), călirea simulată (SA), algoritmul lupului cenușiu (GWO), optimizarea cu colonii de furnici (ACO) și algoritmul balenei (WOA). Algoritmii metaeuristici de generație veche, precum AG, PSO și SA, sunt printre cei mai utilizați în rezolvarea problemelor de optimizare. După cum se poate observa în Fig. 2.7 , aceștia sunt utilizați în peste 50% din lucrările publicate. Cu toate acestea, datorită performanțelor superioare ale algoritimilor de generație nouă, gradul de utilizare al acestora pentru rezolvarea problemelor reale de optimizare crește.

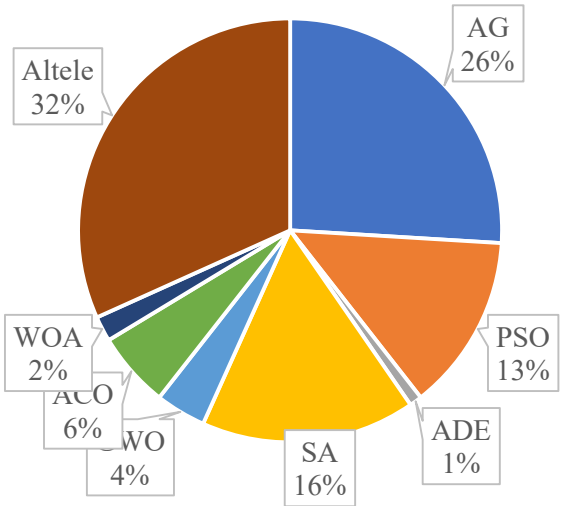


Fig. 2.7 Distribuția algoritmilor metaeuristici de optimizare utilizați pentru rezolvarea repartiției optime a puterii reactive

În [57] algoritmul de optimizare al balenei este utilizat pentru a reduce pierderile de putere activă, realizând un studiu de caz pe sistemul electroenergetic național al Algeriei. Lucrarea [58] a propus un algoritm sinus-cosinus modificat pentru a crește performanța algoritmului standard. Varianta modificată a obținut rezultate cu 9% mai bune față de algoritmul de bază,

atunci când s-a luat în considerare drept obiectiv minimizarea pierderilor de putere. Tabelul 2.3 prezintă o scurtă taxonomie privind publicațiile care abordează rezolvarea problemei ORPD cu ajutorul algoritmilor de optimizare metaeuristici.

Tabelul 2.3 Analiză a publicațiilor privind repartiția optimă a puterii reactive

Referința	**Tipul rețelei studiate**	**Algoritm utilizat**	**Funcția obiectiv**	**Simplu obiectiv / Multi-obiectiv**
Medani *et. al.* [57]	Transport	Algoritmul balenei (WOA)	ΔP	✓ / ✗
Abdel-Fatah *et. al.* [58]	Transport	Algoritmul sinus-cosinus modificat (M-SCA)	ΔP / U_{dev} / VSI	✓ / ✗
Aljohani *et. al.* [59]	Transport	Optimizarea cu roiuri de particule (PSO)	ΔP / U_{dev} / VSI	✓ / ✓
Ela *et. al.* [60]	Transport	Diferențială evolutivă (DE)	ΔP / U_{dev} / VSI	✓ / ✗
Sidea *et. al.* [61]	Distribuție	Optimizarea cu roiuri de particule (PSO)	ΔP / U_{dev}	✗ / ✓
Duman *et. al.* [62]	Transport	Căutare gravitațională (GSA)	ΔP / U_{dev} / VSI	✓ / ✗
Sahli *et. al.* [63]	Transport	Optimizarea cu roiuri de particule și căutare tabu hibridizată (PSO-TS)	ΔP / U_{dev}	✓ / ✗
M. Basu [64]	Transport	Algoritmul Diferențial evolutiv (ADE)	ΔP / U_{dev} / VSI	✓ / ✓
Sulaiman *et. al.* [65]	Transport	Algoritmul lupului cenușiu (GWO)	ΔP / U_{dev}	✓ / ✗
Chen *et. al.* [66]	Distribuție	Optimizarea cu roiuri de particule și logică fuzzy (fuzzy−PSO)	ΔP	✓ / ✗

ΔP – minimizarea pierderilor de putere activă

U_{dev} – minimizarea abaterilor tensiunilor nodale de la valoarea de referință

VSI – minimizarea indicatorilor de stabilitate de tensiune

Spre deosebire de ORPD, optimizarea circulației de puteri (*optimal power flow* − OPF) abordează și optimizarea circulației de putere activă, pe lângă cea de putere reactivă, având în general scopul de a minimiza costul de operare al unui SEE (e.g., costul combustibililor din centralele electrice). În mod tradițional, problema OPF a fost rezolvată pentru rețelele de transport [67], [68]. Odată cu dezvoltarea rețelelor electrice distribuție și a conceptului de microrețea [69], ideea coordonării elementelor active de rețea pentru a obține un cost de operare cât mai mic a început să fie abordată în literatura de specialitate [70], [71]. Tabelul 2.4

centralizează articole care au la bază utilizarea metodelor metaeuristice pentru rezolvarea problemei OPF.

Tabelul 2.4 Analiză a publicațiilor privind circulația optimă de putere

Referința	**Tipul rețelei studiate**	**Algoritm utilizat**	**Funcția obiectiv**	**Simplu obiectiv / Multi-obiectiv**
Vaisakh *et. al.* [67]	Transport	Diferențială evolutivă (DE)	F_c, U_{dev}, VSI	✓ / ✗
Mohamed *et. al.* [72]	Transport	Algoritmul roiului de molii (MSA)	F_c, E_c, ΔP, U_{dev}, VSI	✓ / ✗
Duman *et. al.* [73]	Transport	Căutare gravitațională (GSA)	F_c,U_{dev}, VSI	✓ / ✗
Roy & Paul [74]	Transport	Algoritmul krill-ului (KOA)	F_c, U_{dev}, VSI	✓ / ✓
Adaryani *et. al.* [68]	Transport	Algoritmul coloniei de albine (ABC)	F_c, E_c, ΔP, U_{dev}, VSI	✓ / ✗
Moradi *et. al.* [70]	Distribuție	Algoritmul armonic − algoritmi genetici hibrid (HS−GA)	F_c, U_{dev}, VSI	✓ / ✓
Nikmehr *et. al.* [75]	Microrețele	Optimizarea cu roiuri de particule (PSO)	O_c	✓ / ✗
Mohammad *et. al.* [71]	Microrețele	Algoritmul licuriciului (FA)	O_c	✓ / ✗

ΔP – minimizarea pierderilor de putere activă

U_{dev} – minimizarea abaterilor tensiunilor nodale de la valoarea de referință

VSI – minimizarea indicatorilor de stabilitate de tensiune

F_c – minimizarea costului combustibilului

O_c – minimizarea costului operării rețelei

3.CONCLUZII

3.1. Concluzii generale

Odată cu dezvoltarea tehnicilor bazate pe inteligență artificială, preocuparea pentru implementarea acestora în diverse domenii tehnice a crescut. Odată cu digitalizarea sectorului energetic, volumul, varietatea și viteza de date ce poate fi accesat a crescut în mod sensibil, astfel că tehnicile de inteligență artificială devin pretabile pentru interpretarea tiparelor și extragerea trăsăturilor din date. În teza de doctorat au fost abordate două direcții diferite de aplicații, pe de-o parte utilizarea rețelelor neuronale în prognoza consumului de energie electrică și pe de altă parte alocarea optimă de capacități de producție cu ajutorul tehnicilor de calcul evolutiv.

Prognoza consumului de energie electrică reprezintă o unealtă vitală în operarea și planificarea sistemelor electroenergetice. Cu toate că acest domeniu a fost studiat în trecut, puterea rețelelor neuronale de procesare și interpretare a tiparelor face ca prognoza consumului să fie din nou în atenția comunității academice. De-a lungul studiilor doctorale s-au identificat două perioade cu schimbări majore cauzate de fenomene diferite. În primul rând, perioada pandemiei COVID-19 a afectat dramatic comportamentul societății și au putut fi profilate momente de restricții ale circulației, în consecință și de oprire a unei părți importante din activitatea economică, având efecte majore pentru consumul de energie la nivel național. În al doilea rând, odată cu stimularea masivă a utilizatorilor de a deveni prosumatori prin montarea de panouri fotovoltaice și permiterea de injecție în rețea, energia produsă de acești utilizatori a făcut ca la orele prânzului din zilele însorite consumul înregistrat în sistemele SCADA să fie sensibil mai redus față de zile similare ale anilor trecuți. În cadrul tezei de doctorat au fost dezvoltate mai multe arhitecturi de rețele neuronale, care includ rețele neuronale de tip perceptron multistrat, celule LSTM și rețele neuronale de convoluție. În urma studiului de caz s-a identificat că modelul cel mai performant este cel bazat pe rețele neuronale de convoluție, datorită capacității de extragere a trăsăturilor din datele apropiate din punct de vedere cronologic. Modelul de rețea neuronală propus în această teză de doctorat a fost utilizat și adaptat la nevoile din momentele de timp enunțate, performanța fiind în ambele cazuri superioară modelului utilizat în cadrul Transelectrica. Totodată capacitatea de automatizare a procesului devine atractivă, datorită necesarului de resurse mai reduse.

Pe fondul scopului declarat al statelor membre ale Uniunii Europene de a reduce dependența sectorului energetic de combustibili fosili prin sprijinirea investitorilor privați de a realiza noi capacități de producție bazate pe surse regenerabile, cererea de realizare de astfel de proiecte a crescut în ultimii ani, rețeaua electrică din România nefiind pregătită să permită racordarea tuturor proiectelor. Din cauza dificultății de expansiune și modernizare a rețelelor electrice, generate de obținerea tuturor autorizațiilor necesare și a costurilor ridicate, nevoia de exploatare a sistemul cât mai aproape de capacitatea maximă a devenit stringentă. În acest sens, este necesară realizarea unor studii complexe de alocare optimă a capacității disponibile în rețeaua electrică, astfel încât să nu fie necesare lucrări de modernizare sau extindere. Pentru

rezolvarea acestei probleme a fost propus un model matematic al problemei de optimizare. Metodologia propusă de alocare optimă a capacității se realizează pe două etape. În prima etapă, puterea instalată suplimentar în rețea se maximizează având în vedere limitele de funcționare ale elementelor de rețea și tensiunile nodale. De asemenea, se au în vedere capabilitățile de control ale tensiunii dintr-un sistem electroenergetic și se realizează un management optim al acestora. A doua etapă a metodologiei presupune rearanjarea puterilor determinate în prima etapă cu scopul de a reduce pierderile de putere. Metodologia este comparată cu o strategie în care controlul tensiunii nu este utilizat și cu o tehnică aleatorie, rezultatele arătând că modelul propus oferă rezultate robuste. Pentru rezolvarea problemei s-au utilizat tehnici de calcul evolutiv.

Algoritmul de optimizare propus are la bază algoritmul salpului marin, ale cărui mecanisme sunt inspirate de comportamentul salpului, o specie de nevertebrate asemănătoare meduzelor, în procesul de căutare a hranei. Metodele de optimizare bazate pe tehnici de calcul evolutiv prezintă avantaje față de metodele deterministe, precum viteza de calcul și adaptabilitatea la probleme complexe fără o modelare detaliată a ecuațiilor de funcționare. Plecând de la algoritmul standard de optimizare, s-au adus multiple îmbunătățiri pentru creșterea performanței, versiunea îmbunătățită fiind în primă fază testată pe funcții matematice de optimizare, urmând ca metoda să fie testată pentru rezolvarea problemei de repartiție optimă a puterii reactive, rezultatele fiind superioare altor algoritmi frecvent utilizați în literatura de specialitate.

3.2. Contribuții

Principalele contribuții aduse de teza de doctorat sunt expuse în continuare.

a) *Realizarea unui studiu al literaturii de specialitate* privind stadiul actual al aplicațiilor bazate pe inteligență artificială în domeniul energetic;

b) Analiza factorilor ce influențează consumul de energie electrică, identificându-se astfel necesitatea adaptării modelelor de prognoză la contextul socio-economic actual;

c) Implementarea unui model bazat pe rețele neuronale pentru prognoza consumului de energie electrică la nivelul SEN, realizat într-o primă etapă în perioada pandemiei COVID-19, ulterior modelul fiind adaptat pentru gestionarea influenței aduse de prosumatori;

d) *Propunerea unui algoritm de optimizare bazat pe tehnici de calcul evolutiv*. Modelul propus pornește de la varianta standard a algoritmului salpului marin, pentru care au fost propuse noi mecanisme, precum învățarea prin contraexemplu, introducerea unui noi tip de salp, precum și încrucișare și mutație. Validarea performanței algoritmului a fost realizată pe baza a mai multor funcții de referință din domeniul optimizărilor;

e) *Evaluarea performanței algoritmului propus în rezolvarea problemei repartiției optime a puterii reactive* pentru două rețele de tip test. Au fost considerate atât maniere de optimizare cu un singur obiectiv, cât și optimizare multicriterială (minimizarea pierderilor de putere concomitent cu reducerea deviațiilor tensiunilor de la o valoare de referință);

f) Dezvoltarea unui model de optimizare pentru alocarea optimă a capacității disponibile într-o rețea electrică pentru a asigura o putere maximă ce poate fi instalată suplimentar

într-un sistem electroenergetic fără a fi nevoie de lucrări de modernizare sau expansiune a rețelei, care propun investiții majore;

g) *Diseminarea rezultatelor cercetării* în multiple conferințe naționale și internaționale precum și în jurnale internaționale pe perioada stagiului doctoral.

Articole publicate în reviste de specialitate

1. N. Anton, C. Bulac, B. Dobrin, **A. Tudose** – „Optimal Placement Of Phasor Measurement Units Using Multi-Criteria Analysis", *U.P.B. Sci. Bull., Series C*, **Vol. 86**, Iss. 4, 2024, WOS: 001380943300028.
2. **A.M. Tudose**, D.O. Sidea, I.I. Picioroaga, N. Anton, C. Bulac – „Increasing Distributed Generation Hosting Capacity Based on a Sequential Optimization Approach Using an Improved Salp Swarm Algorithm", *Mathematics*, **12(1)**, 48, Dec. 2023, DOI: 10.3390/math12010048, WOS: 001140674900001.
3. I. Picioroaga, M. Luca, **A. Tudose**, D. Sidea, M. Eremia, C. Bulac – "Resilience-Driven Optimal Sizing of Energy Storage Systems in Remote Microgrids", *Mathematics*, **15(22)**, 16002, Noi. 2022, DOI: 10.3390/su152216002, WOS: 001113328600001.
4. D.O. Sidea, **A.M. Tudose**, I.I. Picioroaga, C. Bulac – „Two-Stage Optimal Active-Reactive Power Coordination for Microgrids with High Renewable Sources Penetration and Electrical Vehicles Based on Improved Sine−Cosine Algorithm", *Mathematics*, **11(1)**, 45, Dec. 2022, DOI: 10.3390/math11010045, WOS: 000909656200001.
5. I. I. Picioroaga, **A. M**.**Tudose** , D. O. Sidea, C. Bulac – „Supply Restoration in Active Distribution Networks Based on Soft Open Points with Embedded DC Microgrids". *Mathematics*, **10(2)**, 211, Ian. 2022, DOI: 10.3390/math10020211, WOS: 000746279600001.
6. I. Picioroaga, **A. M. Tudose**, D. Sidea, C. Bulac, L. Toma – „Power Supply Restoration in Active Distribution Networks with High Photovoltaic Penetration Based on Soft Open Points". *Revue roumaine des sciences techniques-serie electrotechnique et energetique*, **66(3)**, 181-186, Dec. 2021, WOS: 000738293800001.
7. **A. M. Tudose**, I. I. Picioroaga, D. O. Sidea,, C. Bulac and V. Boicea, "Short-term load forecasting using convolutional neural networks in COVID-19 context: The Romanian case study", *Energies*, **vol. 14**, Iul. 2021, DOI: 10.3390/en14134046 WOS: 000672003000001.
8. **A. M. Tudose**, I. I. Picioroaga, D. O. Sidea, and C. Bulac, " NEURAL NETWORKS APPLICATION IN SHORT-TERM LOAD FORECASTING", *The UPB Scientific Bulletin, Series C*, **vol. 83**, no. 2, Iun. 2021, WOS: 000692193500018
9. **A. M. Tudose**, I. I. Picioroaga, D. O. Sidea, and C. Bulac, "Solving Single- and Multi-Objective Optimal Reactive Power Dispatch Problems Using an Improved Salp Swarm Algorithm," *Energies*, **vol. 14**, no. 5, p. 1222, Feb. 2021, DOI: 10.3390/en14051222, WOS: 000628120100001.

Articole publicate în volumele unor manifestări științifice

1. R. Micu, **A. Tudose**, A. Iantoc, I. Picioroaga, C. Bulac, „Electricity Price Forecasting on Day Ahead Market via a Multivariate CNN-LSTM Model", 2024 IEEE International Conference And Exposition On Electric And Power Engineering (EPEi), Iasi, Romania, oct. 17-19 2024, DOI: 10.1109/EPEi63510.2024.10758141.

2. I. Picioroaga, **A. Tudose**, D. Sidea, M. Calin-Arhip, „The Optimal Placement and Sizing of Soft Open Points to Enable Distributed Generation Hosting in Southern Romania", 2024 59th International Universities Power Engineering Conference (UPEC), Cardiff, Țara Galilor, 2-6 sep. 2024, DOI: 10.1109/UPEC61344.2024.10892422.
3. D.O. Sidea, **A.M. Tudose**, I.I Picioroagã, N. Anton, C. Bulac, „Performace Comparison of Metaheuristic Algorithms on Solving the Optimal Power Flow in a Active Distribution Network", 2023 11th International Conference on ENERGY and ENVIRONMENT (CIEM), București, Romania, 26-27 oct. 2023, DOI: 10.1109/CIEM58573.2023.10349771
4. D.O. Sidea, I.I. Picioroagă, **A.M. Tudose**, C. Podar, N. Anton, C. Bulac, "Optimal reactive power dispatch considering load variation in distribution networks using an improved sine-cosine algorithm", 2022 International Conference and Exposition on Electrical And Power Engineering (EPE), Iași, Romania, 20-22 oct. 2022, DOI: 10.1109/EPE56121.2022.9959076.
5. **A. Tudose**; R. Micu; I. Picioroaga; D. Sidea; A. Mandis; C. Bulac, „Power Systems Security Assessment Based on Artificial Neural Networks", 2022 International Conference and Exposition on Electrical And Power Engineering (EPE), Iași, Romania, 20-22 oct. 2022, DOI: 10.1109/EPE56121.2022.9959761
6. V.A. Ion; E.E. Gemil; M. Arhip-Calin; **A. Tudose**; N. Anton; G. Serițan, "A Survey of microgrid operation influence on power quality", 2022 57th International Universities Power Engineering Conference (UPEC), Istanbul, Turcia, 30 aug.-02 sep. 2022, DOI: 10.1109/UPEC55022.2022.9917884, WOS: 000886926200086
7. D.O. Sidea, **A.M. Tudose**, I.I. Picioroagă, L. Toma, C. Bulac, „Adapted Grey Wolf Optimizer for Dynamic Economic Dispatch in a Hybrid Microgrid", 10th International Conference on ENERGY and ENVIRONMENT (CIEM), București, România, 14-15 Oct., 2021, DOI: 10.1109/CIEM52821.2021.9614704.
8. I. I. PICIOROAGA, **A. M. TUDOSE**, D. O. SIDEA, C. BULAC and L. TOMA, "Application of Soft Open Points for Increasing the Supply Restoration in Active Distribution Networks," 2021 12th International Symposium on Advanced Topics in Electrical Engineering (ATEE), 2021, pp. 1-6, DOI: 10.1109/ATEE52255.2021.9425287, WOS: 000676164800131
9. I. I. Picioroaga, **A. Tudose**, D. O. Sidea, C. Bulac and M. Eremia, "Two-level Scheduling Optimization of Multi-microgrids Operation in Smart Distribution Networks," 2020 International Conference and Exposition on Electrical And Power Engineering (EPE), 2020, pp. 407-412, DOI: 10.1109/EPE50722.2020.9305614**.**
10. D. O. Sidea, I. I. Picioroaga, **A. M. Tudose**, C. Bulac and I. Tristiu, "Multi-Objective Particle Swarm optimization Applied on the Optimal Reactive Power Dispatch in Electrical Distribution Systems," 2020 International Conference and Exposition on Electrical And Power Engineering (EPE), 2020, pp. 413-418, DOI: 10.1109/EPE50722.2020.9305548.
11. **A. M. Tudose**, D. O. Sidea, I. I. Picioroaga, V. A. Boicea and C. Bulac, "A CNN Based Model for Short-Term Load Forecasting: A Real Case Study on the Romanian Power System," 2020 55th International Universities Power Engineering Conference (UPEC), Torino, Italy, 2020, pp. 1-6, DOI: 10.1109/UPEC49904.2020.9209768, WOS: 000627771000011

3.3. Perspective de dezvoltare a cercetării

Direcțiile viitoare de cercetare vizează continuarea atât studiilor prezentate în cadrul tezei de doctora, cât și abordarea de noi tematici esențiale pentru tranziția sectorului energetic către o pondere crescută de capacități de producere din surse regenerabile:

- Îmbunătățirea algoritmului de prognoză a consumului de energie prin utilizarea de tehnici avansate de tip *Deep Learning*, precum metodele de ansamblu;
- Aplicarea algoritmului de alocare optimă a capacității pentru sistemul electroenergetic din România și identificarea de măsuri pentru crearea asigurarea unui cadru sustenabil în ceea ce privește instalarea de noi surse de producere a energiei. De asemenea, se propune analiza statistică a producției din surse regenerabile, pentru a identifica mixul energetic optim;
- Analiza influenței instalațiilor de stocare în SEN, atât din punct de vedere al funcționării rețelei electrice, cât și din punct de vedere economic.

BIBLIOGRAFIE

[1] Y. LeCun, Y. Bengio et G. Hinton, «Deep learning,» *Nature,* vol. 521, pp. 436-444, 2015.

[2] Y. Saleem, N. Crespi, H. Rehmani et R. Copeland, «Internet of Things-Aided Smart Grid: Technologies, Architectures, Applications, Prototypes, and Future Research Directions,» *IEEE Access,* vol. 7, pp. 62962-63003, 2019.

[3] ANRE, *ORDIN nr. 53 din 30 iulie 2024,* 2024.

[4] R. Micu, A. Tudose, A. Iantoc, I. Picioroaga et C. Bulac, «Electricity Price Forecastin on Day Ahead Market via a Multivariate CNN-LSTM Model,» chez *2024 IEEE International Conference and Exposition On Electric And Power Engineering (EPEi)*, Iasi, Romania, oct. 2024.

[5] Bouktif, S.; Fiaz, A.; Ouni, A.; Serhani, M.A. Single and Multi-Sequence Deep Learning Models for Short and Medium Term Electric Load Forecasting. Energies 2019, 12, 149..

[6] F. D. Rueda, J. D. Suárez et A. d. R. Torres, «Short-Term Load Forecasting Using Encoder-Decoder WaveNet: Application to the French Grid,» *Energies,* vol. 14, p. 2524, 2021.

[7] C. Nichiforov, G. Stamatescu, I. Stamatescu, N. Arghira, I. Făgărăşan et S. S. Iliescu, «Embedded On-line System for Electrical Energy Measurement and Forecasting in Buildings,» chez *2019 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, Metz, France, 2019.

[8] H. Dagdougui, F. Bagheri, H. Le et L. Dessaint, «Neural network model for short-term and very-short-term load forecasting in district buildings,» *Energy and Buildings,* vol. 203, p. 109408, 2019.

[9] H. Liu, X.-w. Mi et Y.-f. Li, «Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network,» *Energy Conversion and Management,* vol. 156, pp. 498-514, 2018.

[10] Y. Lin, I. Koprinska et M. Rana, «Temporal Convolutional Neural Networks for Solar Power Forecasting,» chez *2020 International Joint Conference on Neural Networks (IJCNN)*, Glasgow, UK, 2020.

[11] G. Juberias, R. Yunta, J. G. Moreno et C. Mendivil, «A new ARIMA model for hourly load forecasting,» chez *1999 IEEE Transmission and Distribution Conference*, New Orleans, LA, USA, 11-16 Aprilie 1999.

[12] S. Bercu et F. Proia, «A SARIMAX coupled modelling applied to individual load curves intraday forecasting,» *Journal of Applied Statistics,* vol. 40, pp. 1333-1348, 2013.

[13] B. A. Høverstad, A. Tidemann, H. Langseth et P. Öztürk, «Short-Term Load Forecasting With Seasonal Decompositon Using Evolution for Parameter Tuning,» *IEEE Transactions on Smart Grid ,* vol. 6, pp. 1904-1913, 2015.

[14] H. Çevik et M. Çunkaş, «Short-term load forecasting using fuzzy logic and ANFIS,» *Neural Computing and Applications ,* vol. 26 , pp. 1355-1367, 2015.

[15] E. Ceperic, V. Ceperic et A. Baric, «A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines,» *IEEE Transactions on Power Systems ,* vol. 28, pp. 4356-4364, 2013.

[16] L. Hernández, C. Baladrón, J. M. Aguiar, B. Carro, A. Sánchez-Esguevillas et J. Lloret, «Artificial neural networks for short-term load forecasting in microgrids environment,» *Energy,* vol. 75, pp. 252-264, 2014.

[17] X. Dong, L. Qian et L. Huang, «A CNN based bagging learning approach to short-term load forecasting in smart grid,» chez *2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*, San Francisco, CA, USA, 2017.

[18] Y. Shen, Y. Ma, S. Deng, C.-J. Huang et P.-H. Kuo, «Shen, Y.; Ma, Y.; Deng, S.; Huang, C.-J.; Kuo, P.-H. An Ensemble Model based on Deep Learning and Data Preprocessing for Short-Term Electrical Load Forecasting,» *Sustainability ,* vol. 13, p. 1694, 2021.

[19] W. Wu et M. Peng, «A Data Mining Approach Combining K -Means Clustering With Bagging Neural Network for Short-Term Wind Power Forecasting,» *IEEE Internet of Things Journal,* vol. 4, n° %14, pp. 979-986, 2017.

[20] X. Tang, Y. Dai et T. Wang, «Short-term power load forecasting based on multi-layer bidirectional recurrent neural network,» *IET Gener. Transm. Distrib.,* vol. 13, pp. 3847-3854, 2019.

[21] C. Nichiforov, G. Stamatescu, I. Stamatescu, I. Făgărășan et S. S. Iliescu, «Building Electrical Load Forecasting through Neural Network Models with Exogenous Inputs,» chez *23rd International Conference on System Theory, Control and Computing (ICSTCC)*, Sinaia, Romania, 2019.

[22] Pramono, S.H.; Rohmatillah, M.; Maulana, E.; Hasanah, R.N.; Hario, F. Deep Learning-Based Short-Term Load Forecasting for Supporting Demand Response Program in Hybrid Energy System. Energies 2019, 12, 3359. https://doi.org/10.3390/en12173359.

[23] R. K. Agrawal, F. Muchahary et M. M. Tripathi, «Long term load forecasting with hourly predictions based on long-short-term-memory networks,» chez *2018 IEEE Texas Power and Energy Conference (TPEC)*, College Station, TX, USA, 2018.

[24] H. Sangrody, N. Zhou, S. Tutun, B. Khorramdel, M. Motalleb et M. Sarailoo, «Long term forecasting using machine learning methods,» chez *2018 IEEE Power and Energy Conference at Illinois (PECI)*, Champaign, IL, USA, 2018.

[25] H. J. Sadaei, P. C. de Lima e Silva, F. G. Guimarães et M. H. Lee, «Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series,» *Energy,* vol. 175, pp. 365-377, 2019.

[26] L. Han, Y. Peng, Y. Li, B. Yong, Q. Zhou et L. Shu, «Enhanced Deep Networks for Short-Term and Medium-Term Load Forecasting,» *IEEE Access,* vol. 7, pp. 4045-4055, 2019.

[27] A. Gensler, J. Henze, B. Sick et N. Raabe, «Deep Learning for solar power forecasting — An approach using AutoEncoder and LSTM Neural Networks,» chez *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2016.

[28] Y. Wang, B. Feng, Q.-S. Hua et L. Sun, «Short-Term Solar Power Forecasting: A Combined Long Short-Term Memory and Gaussian Process Regression Method,» *Sustainability,* vol. 13, p. 3665, 2021.

[29] R. E. Larson, W. F. Tinney et J. Peschon, «State Estimation in Power Systems Part I: Theory and Feasibility,» *IEEE Transactions on Power Apparatus and Systems,* Vols. %1 sur %2PAS-89, n° %13, pp. 345-352, 1970.

[30] J. Chen et A. Abur, «Placement of PMUs to Enable Bad Data Detection in State Estimation,» *IEEE Transactions on Power Systems,* vol. 21, n° %14, pp. 1608-1615, 2006.

[31] V. Miranda, J. Krstulovic, H. Keko, C. Moreira et J. Pereira, «Reconstructing Missing Data in State Estimation With Autoencoders,» *IEEE Transactions on Power Systems,* vol. 27, n° %12, pp. 604-611, 2012.

[32] G. Liang, J. Zhao, F. Luo, S. R. Weller et Z. Y. Dong, «A Review of False Data Injection Attacks Against Modern Power Systems,» *IEEE Transactions on Smart Grid,* vol. 8, n° %14, pp. 1630-1638, 2017.

[33] M. Ganjkhani, S. N. Fallah, S. Badakhshan, S. Shamshirband et K.-w. Chau, «A Novel Detection Algorithm to Identify False Data Injection Attacks on Power System State Estimation,» *Energies,* vol. 12, p. 2209, 2019.

[34] M. Biserica, Y. Besanger, R. Caire, O. Chilard et P. Deschamps, «Neural Networks to Improve Distribution State Estimation—Volt Var Control Performances,» *IEEE Transactions on Smart Grid,* vol. 3, n° %13, pp. 1137-1144, 2012.

[35] E. Manitsas, R. Singh, B. C. Pal et G. Strbac, «Distribution System State Estimation Using an Artificial Neural Network Approach for Pseudo Measurement Modeling,» *IEEE Transactions on Power Systems,* vol. 27, n° %14, pp. 1888-1896, 2012.

[36] Z. Shi, W. Yao, L. Zeng, J. Wen, J. Fang, X. Ai et J. Wen, «Convolutional neural network-based power system transient stability assessment and instability mode prediction,» *Applied Energy,* vol. 263, p. 114586, 2020.

[37] Y. Du, F. Li, J. Li et T. Zheng, «Achieving 100x Acceleration for N-1 Contingency Screening With Uncertain Scenarios Using Deep Convolutional Neural Network,» *IEEE Transactions on Power Systems,* vol. 34, n° %14, pp. 3303-3305, 2019.

[38] C. Bulac, I. Tristiu, A. Mandis et L. Toma, «On-line Power Systems Voltage Stability,» chez *THE 9th INTERNATIONAL SYMPOSIUM ON ADVANCED TOPICS IN ELECTRICAL ENGINEERING*, Bucharest, Romania, 2015.

[39] S. Lan, M. Chen et D. Chen, «A Novel HVDC Double-Terminal Non-Synchronous Fault Location Method Based on Convolutional Neural Network,» *IEEE Transactions on Power Delivery,* vol. 34, n° %13, pp. 848-857, 2019.

[40] M. Dashtdar, R. Dashti et H. R. Shaker, «Distribution network fault section identification and fault location using artificial neural network,» chez *2018 5th International Conference on Electrical and Electronic Engineering (ICEEE)*, Istanbul, Turkey, 2018.

[41] A. Tudose, R. Micu, I. Picioroaga, D. Sidea, A. Mandis et C. Bulac, «Power Systems Security Assessment Based on Artificial Neural Networks,» chez *2022 International Conference and Exposition on Electrical And Power Engineering (EPE)*, Iasi, Romania, 2022.

[42] J. Bezdek, R. Ehrlich et W. Full, «Fuzzy C-Means clustering-algorithm,» *Computers & Geosciences,* pp. 191-203, 1984.

[43] T. Kohonen, «The self-organizing map,» *Proceedings of the IEEE,* vol. 78, n° %19, pp. 1464-1480, 1990.

[44] C. Aggarwal et C. Reddy, Data Clustering: Algorithms and Application, Boca Raton, Florida, SUA: CRC Press, 2014.

[45] I. Picioroaga, A. Tudose, D. Sidea et C. Bulac, «Supply Restoration in Active Distribution Networks Based on Soft Open Points with Embedded DC Microgrids,» *Mathematics,* vol. 10, p. 211, 2022.

[46] J. Zhou, Y. Zheng, Y. Xu, H. Liu et D. Chen, «A Heuristic T-S Fuzzy Model for the Pumped-Storage Generator-Motor Using Variable-Length Tree-Seed Algorithm-Based Competitive Agglomeration,» *Energies,* vol. 11, p. 944, 2018.

[47] C. Bulac, *** *Note de curs Tehnici de Inteligență Artificială.*

[48] A. A. Osama, «Comparisons Between Data Clustering Algorithms,» *Int. Arab J. Inf. Technol.,* n° %15, pp. 320-325, 2008.

[49] B. Bhuiyan et I. Khan, «Household Energy Consumption Clustering Using ‘k-means' Algorithm: A Bangladesh Case Study,» chez *2024 IEEE International Conference on Power, Electrical, Electronics and Industrial Applications (PEEIACON)*, Rajshahi, Bangladesh, 2024.

[50] S. Agarwal et R. Sodhi, «A novel power theft and data breach detection technique for low-voltage distribution networks,» *Electric Power Systems Research,* vol. 243, p. 111503, 2025.

[51] S. Sanati, A. Mosayebi et I. Kamwa, «Advanced Rapid Directional Over-Current Protection for DC Microgrids Using K-Means Clustering,» *IEEE Transactions on Power Delivery,* vol. 39, n° %12, pp. 1088-1099, 2024.

[52] V. Srividhya, S. Gowriswari, N. V. Antony, S. Murugan, K. Anitha et M. Rajmohan, «Optimizing Electric Vehicle Charging Networks Using Clustering Technique,» chez *2024 2nd International Conference on Computer, Communication and Control (IC4)*, Indore, India, 2024.

[53] P. Sudta et S. Singh, «An approach to prosumer modeling and financial assessment with load clustering algorithm in an active power distribution network,» *Sustainable Energy, Grids and Networks,* vol. 38, p. 101249, 2024.

[54] F. Liu, T. Dong, Q. Liu, Y. Liu et S. Li, «Combining fuzzy clustering and improved long short-term memory neural networks for short-term load forecasting,» *Electric Power Systems Research,* vol. 226, p. 109967, 2024.

[55] G. Poyrazoglu, «Determination of Price Zones during Transition from Uniform to Zonal Electricity Market: A Case Study for Turkey,» *Energies,* vol. 14, n° %14, p. 1014, 2021.

[56] K. Lee, Y. Park et J. Ortiz, «Optimal real and reactive power dispatch,» *Electric Power Systems Research,* vol. 7, n° %13, pp. 201-212, 1984.

[57] K. b. o. Medani, S. Sayah et A. Bekrar, «Whale optimization algorithm based optimal reactive power dispatch: A case study of the Algerian power system,» *Electric Power Systems Research,* vol. 163, pp. 696-705, 2018.

[58] S. Abdel-Fatah, M. Ebeed et S. Kamel, «Optimal Reactive Power Dispatch Using Modified Sine Cosine Algorithm,» chez *2019 International Conference on Innovative Trends in Computer Engineering (ITCE)*, Aswan, Egypt, 2019.

[59] T. M. Aljohani, A. F. Ebrahim et O. Mohammed, «Single and Multiobjective Optimal Reactive Power Dispatch Based on Hybrid Artificial Physics–Particle Swarm Optimization,» *Energies,* vol. 12, n° %112, p. 2333, 2019.

[60] A. A. E. Ela, M. Abido et S. Spea, «Differential evolution algorithm for optimal reactive power dispatch,» *Electric Power Systems Research,* vol. 81, n° %12, pp. 458-464, 2011.

[61] D. O. Sidea, I. I. Picioroaga, A. M. Tudose, C. Bulac et I. Tristiu, «Multi-Objective Particle Swarm optimization Applied on the Optimal Reactive Power Dispatch in Electrical Distribution Systems,» chez *2020 International Conference and Exposition on Electrical And Power Engineering (EPE)*, Iasi, Romania, 2020.

[62] S. Duman, Y. Sönmez, U. Guvenc et N. Yörükeren, «Optimal reactive power dispatch using a gravitational search algorithm,» *IET Generation, Transmission & Distribution,* vol. 6, p. 563, 2012.

[63] Z. Sahli, A. Hamouda, A. Bekrar et D. Trentesaux, «Reactive Power Dispatch Optimization with Voltage Profile Improvement Using an Efficient Hybrid Algorithm,» *Energies,* vol. 11, n° %18, p. 2134, 2018.

[64] M. Basu, «Multi-objective optimal reactive power dispatch using multi-objective differential evolution,» *International Journal of Electrical Power & Energy Systems,* vol. 82, pp. 213-224, 2016.

[65] M. H. Sulaiman, Z. Mustaffa, M. R. Mohamed et O. Aliman, «Using the gray wolf optimizer for solving optimal reactive power dispatch problem,» *Applied Soft Computing,* vol. 32, pp. 286-292, 2015.

[66] S. Chen, W. Hu, C. Su, X. Zhang et Z. Chen, «Optimal reactive power and voltage control in distribution networks with distributed generators by fuzzy adaptive hybrid particle swarm optimisation method,» *IET Generation, Transmission & Distribution,* vol. 9, n° %111, pp. 1096-1103, 2015.

[67] K. Vaisakh et L. Srinivas, «Evolving ant direction differential evolution for OPF with non-smooth cost functions,» *Engineering Applications of Artificial Intelligence,* vol. 24, n° %13, pp. 426-436, 2011.

[68] M. Rezaei Adaryani et A. Karami, «Artificial bee colony algorithm for solving multi-objective optimal power flow problem,» *International Journal of Electrical Power & Energy Systems,* vol. 53, pp. 219-230, 2013.

[69] D. Sidea, A. Tudose, I. Picioroaga et C. Bulac, «Two-Stage Optimal Active-Reactive Power Coordination for Microgrids with High Renewable Sources Penetratrion and Electrical Vehicles Based on Improved Sine-Cosine Algorithm,» *Mathematics,* vol. 11, n° %11, p. 45, 2022.

[70] M. Moradi, M. Abedini et S. Hosseinian, «Optimal operation of autonomous microgrid using HS–GA,» *International Journal of Electrical Power & Energy Systems,* vol. 77, pp. 210-220, 2015.

[71] S. Mohammadi, B. Mozafari et S. Soleymani, «Optimal operation management of microgrids using the point estimate method and firefly algorithm while considering uncertainty,» *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES,* vol. 22, pp. 735-753, 2014.

Cuprinsul tezei de doctorat

1. Introducere 10

2. Stadiul actual al utilizării algoritmilor bazați pe inteligență artificală în domeniul energetic 13

2.1. Rețele neuronale artificiale 13
2.1.1. Aplicații ale rețelelor neuronale în monitorizarea și controlul sistemelor electroenergetice 14
2.2. Tehnici de clusterizare 19
2.2.1. Algoritmul k-means 19
2.2.2. Algoritmul fuzzy c-means 20
2.2.3. Rețele neuronale Kohonen (Hărți cu auto-organizare) 21
2.2.4. Aplicații ale tehnicilor de clusterizare 23
2.3. Algoritmi bazați pe tehnici de calcul evolutiv 24
2.3.1. Aplicații ale algoritmilor de optimizare metaeuristici în monitorizarea și controlul sistemelor electroenergetice 25
2.4. Logica fuzzy 28
2.4.1. Aplicațiile logicii fuzzy în monitorizarea și controlul sistemelor electroenergetice 29

3. Rețele Neuronale Artificiale 32

3.1. Rețele neuronale artificiale de tip perceptron multistrat 32
3.2. Rețele neuronale recurente (RNR) 32
3.3. Rețele neuronale cu memorie de scurtă durată persistentă (LSTM) 33
3.4. Rețelele neuronale de convoluție 35
3.5. Funcții de activare 37
3.6. Algoritmul de antrenare a rețelelor neuronale 39
3.7. Metode de îmbunătățire a performanței rețelelor neuronale 40

4. Prognoza consumului de energie electrică utilizând concepte deep learning 43

4.1. Aspecte generale privind progrnoza consumului de energie electrică 43
4.1.1. Clasificare a problemelor de prognoză în funcție de orizontul de timp 43
4.1.2. Factori de influență asupra consumului de energie electrică 44
4.2. Efectele pandemiei COVID-19 asupra consumului de energie electrică 47
4.3. Modele propuse pentru prognoza consumului de energie electrică la nivel național 49
4.3.1. Selectarea datelor de intrare 50
4.4. Antrenarea și evaluarea modelului bazat pe RNA 52
4.4.1. Regresie liniară multiplă 53
4.5. Studiu de caz 53
4.5.1. Descrierea setului de date 53
4.5.2. Evaluarea performanței modelului propus 54
4.5.3. Reevaluarea modelului pentru anul 2025 61

5. Algoritmi de optimizare bazați pe tehnici de calcul evolutiv 69

5.1. Algoritmii genetici 70
5.2. Optimizarea cu roiuri de particule (Particle Swarm Optimization) 72
5.3. Algoritmul furnicilor leu (Ant Lion Optimizer) 74
5.4. Algoritmul salpului (Salp Swarm Algorithm) 74

5.4.1. Algoritmul salpului marin pentru probleme de optimizare cu un singur obiectiv 74
5.4.2. Algoritmul Salpului Marin pentru probleme de optimizare multicriterială 75
5.5. Îmbunătățiri propuse Algoritmului Salpului Marin 77
5.5.1. Tehnica de învățare prin contraexemplu 77
5.5.2. Ierarhia socială și implementarea salpilor exploratori 77
5.5.3. Operatori de încrucișare și de mutație 78
5.5.4. Mecanismul supraviețuirii celui mai adaptat 78
5.6. Validarea algoritmilor de optimizare 79

6. Rezolvarea problemei repartiției optime a puterii reactive 81

6.1. Aspecte generale privind repartiția optimă a puterii reactive în sistemele electroenergetice 81
6.2. Formularea problemei 82
6.2.1. Funcții obiectiv 82
6.2.2. Restricții de egalitate și inegalitate 84
6.3. Studiu de caz 85
6.3.1. Validarea metodei de calcul a regimului permanent 85
6.3.2. Descrierea setului de date 86
6.3.3. Rezultatele repartiției optime a puterii reactive considerând un singur obiectiv 88
6.4. Rezultatele repartiției optime a puterii reactive considerând optimizare multicriterială 95

7. Alocarea optimă a capacității disponibile de racordare a surselor de energie în rețelele electrice 98

7.1. Creșterea gradului de integrare a surselor regenerabile de energie 98
7.1.1. Considerente generale 98
7.1.2. Metode de creștere a gradului integrare a surselor regenerabile în rețelele electrice 99
7.1.3. Reducerea temporară a producției 99
7.1.4. Managementul sarcinilor 100
7.1.5. Monitorizarea în timp real a capacității de transport a liniilor electrice 103
7.1.6. Instalații de stocare 103
7.1.7. Investiții de modernizare a rețelei eletrice 104
7.1.8. Reglajul tensiunii 106
7.2. Formularea problemei 106
7.2.1. Funcții obiectiv 106
7.2.2. Restricții de egalitate și inegalitate 107
7.2.3. Adaptarea modelului matematic pentru algoritmi de calcul evolutiv 108
7.3. Studiu de caz 109
7.4. Rezultatele problemei de creștere a gradului de integrare a noilor surse 113
7.4.1. Rezultatele primei etape 113
7.4.2. Rezultatele celei de-a doua etape 116

8. Concluzii finale 119

8.1. Concluzii generale 119
8.2. Contribuții 120
8.3. Perspective de dezvoltare a cercetării 123

Bibliografie 124