

**UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI"
DIN IAȘI**



**CONTRIBUȚII PRIVIND EXPLOATAREA OPTIMALĂ A
SISTEMELOR DE DISTRIBUȚIE A ENERGIEI ELECTRICE
CONSIDERÂND INTEGRAREA TEHNOLOGIILOR "SMART GRIDS"
- REZUMATUL TEZEI DE DOCTORAT -**

Drd. Ing. Vasilica Dandea (Ungureanu)

Conducător de doctorat: Prof. dr. ing. habil. Gheorghe Grigoraș

IAȘI, 2025

CONTRIBUȚII PRIVIND EXPLOATAREA OPTIMALĂ A SISTEMELOR DE DISTRIBUȚIE A ENERGIEI ELECTRICE CONSIDERÂND INTEGRAREA TEHNOLOGIILOR "SMART GRIDS"

Vasilica Dandea (Ungureanu)
domeniul Inginerie Energetică

Președinte comisie doctorat:
Conducător de doctorat:

Prof. dr. ing. habil. Gheorghe Grigoraș
Universitatea Tehnică "Gheorghe Asachi" din Iași

Referenți oficiali:

Comisia de îndrumare/Comisa de îndrumare
și integritate academică:

Conf. dr. ing. Ovidiu Ivanov
Universitatea Tehnică "Gheorghe Asachi" din Iași
Conf. dr. ing. Oana Beniugă
Universitatea Tehnică "Gheorghe Asachi" din Iași
Conf. dr. ing. Florina Scarlatache
Universitatea Tehnică "Gheorghe Asachi" din Iași
Conf. dr. ing. Crenguța Bobric
Universitatea "Ștefan cel Mare" din Suceava

CUPRINS

1. Introducere	1
2. Stadiul actual al implementării tehnologiilor “smart grids” în sistemele de distribuție a energiei electrice	2
2.1. Aspecte generale.....	2
2.2. Aplicabilitatea și importanța integrării conceptului „smart grids”.....	3
2.3. Tehnologii “smart grids”	4
2.3.1. Contorizarea inteligentă.....	5
2.3.2. Surse de energie regenerabilă.....	6
2.3.3. Vehiculele electrice.....	7
2.3.4. Sisteme de stocare a energiei electrice.....	7
2.4. Importanța continuității alimentării cu energie în rețelele electrice.....	8
3. Clasificarea prosumatorilor din sistemele de distribuție a energiei electrice utilizând tehnici de clustering.....	9
3.1. Tehnici de clustering.....	9
3.1.1. Definiție și aplicații actuale ale clustering în sistemele de distribuție a energiei electrice.....	9
3.1.2. Etapele procesului de clustering.....	9
3.1.3. Metode de clustering.....	10
3.1.3.1. Metoda K-medii.....	10
3.1.3.2. Metoda DBSCAN (Density-Based Spatial Clustering of Applications with Noise/Clustering spatial bazat de densitate cu detectarea valorilor atipice).	11
3.1.3.3. Metode ierarhice de clustering.....	11
3.1.3.4. Metode ce integrează modele probabilistice.....	11
3.2. Prosumatorii – un atu pentru operatorii de distribuție.....	12
3.2.1. Provocările prosumatorilor.....	12
3.2.2. Prosumatorii - Uniunea Europeană vs. România.....	12
3.3. Clasificarea prosumatorilor din sistemele de distribuție a energiei electrice bazată pe clustering.....	13
3.3.1. Pași metodologiei de clasificare a prosumatorilor.....	14
3.3.2. Algoritmul de clustering K-medii în procesul de clasificare a prosumatorilor.....	14
3.3.3. Testarea metodologiei.....	15

4. Estimarea stării rețelelor electrice de distribuție a energiei electrice active folosind profilarea utilizatorilor finali	19
4.1. Aspecte generale.....	19
4.2. Profilarea și potențialul prosumatorilor în Uniunea Europeană și România.....	19
4.3. Metodologie de determinare a profilurilor tip de putere injectată de prosumatori.....	21
4.3.1. Descrierea metodologiei.....	21
4.3.2. Testarea metodologiei.....	24
4.4. Estimarea stării rețelelor electrice de distribuție a energiei electrice active folosind profilurile de putere ale utilizatorilor finali.....	27
5. Reglajul de tensiune în sistemele de distribuție a energiei electrice cu prosumatori integrați.....	31
5.1. Aspecte generale privind reglajul de tensiune.....	31
5.2. Metode și mijloace de reglaj al tensiunii în sistemele de distribuție a energiei electrice.....	32
5.3. Sistem expert pentru reglajul de tensiune în rețelele electrice de distribuție de joasă tensiune active.....	33
5.4. Testarea sistemului expert.....	37
6. Sistemul SCADA în monitorizarea și conducerea sistemelor de distribuție a energiei electrice.....	44
6.1. Aspecte generale.....	44
6.2. Stadiul actual al abordărilor privind estimarea stării unui sistem de distribuție a energiei electrice.....	45
6.3. Metodologie de integrare optimă a sistemului SCADA pentru estimarea stării sistemelor de distribuție a energiei electrice.....	45
6.4. Testarea metodologiei	49
7. Concluzii și perspective de dezvoltare.....	56
7.1. Concluzii generale.....	56
7.2. Contribuții originale.....	56
7.3. Direcții viitoare de cercetare	57
BIBLIOGRAFIE	58
ANEXA Lista de lucrări.....	63

Capitolul 1

Introducere

Rețelele electrice evoluează prin “smart grid”, combinând infrastructura clasică cu tehnologia digitală pentru o distribuție eficientă și durabilă a energiei. Acestea promovează un sistem energetic sigur, economic și sustenabil, necesitând o abordare sistemică în tranziția către surse regenerabile.

Lucrarea propune integrarea acestor tehnologii “smart grids” în rețele de distribuție pentru a susține tranziția energetică, optimizând exploatarea SDEE prin monitorizare în timp real, generare distribuită și implicarea activă a prosumatorilor.

Lucrarea este organizată în șapte capitole, fiecare abordând un aspect strategic al integrării tehnologiilor inteligente în SDEE:

Capitolul 1 prezintă relevanța tehnologiilor „smart grids” cu IA pentru un sistem energetic decarbonizat, provocările rețelilor de distribuție și principalele obiective și contribuții ale tezei.

Capitolul 2 prezintă o analiză privind implementarea rețelilor electrice inteligente pentru optimizarea distribuției și echilibrarea energiei.

În capitolul al treilea se abordează o metodologie originală de clasificare a prosumatorilor folosind tehnici de clustering bazate pe caracteristici energetice. Analiza fiind realizată pe o bază de date reală dintr-o RD-JT al unui OD, fiind evidențiat comportamentul prosumatorilor.

Capitolul 4 abordează o metodologie de profilare a prosumatorilor pentru estimarea stării rețelilor de distribuție, folosind date de contorizare inteligentă.

Capitolul 5 abordează reglajul tensiunii în SDEE cu prosumatori integrați, propunând un SE pentru soluții flexibile și analizând metodele de reglare și impactul GD asupra rețelilor.

Capitolul 6 analizează utilizarea sistemului SCADA pentru monitorizarea și controlul SDEE, evidențiind provocările economice ale integrării acestuia și optimizarea amplasării PT-urilor și dispozitivelor RTU.

Capitolul 7 prezintă contribuțiile tezei privind integrarea prosumatorilor în SDEE și monitorizarea prin SCADA. Lucrarea aduce o contribuție semnificativă în domeniul sistemelor de distribuție a energiei electrice, propunând soluții inovative și metodologii avansate pentru integrarea tehnologiilor “smart grids”.

Capitolul 2

Stadiul actual al implementării tehnologiilor “smart grids” în sistemele de distribuție a energiei electrice

Rețeaua inteligentă (“smart grid”) este o rețea electrică care integrează eficient generatoarele și consumatorii, asigurând furnizarea de energie electrică sustenabilă și economică. Implementarea surselor regenerabile de energie necesită o abordare coordonată, de la proiectare până la utilizarea dispozitivelor electronice pentru generare, distribuție, stocare și consum eficient de energie [1].

2.1 Aspecte generale

În anul 2024, rețelele inteligente reflectă progrese semnificative în integrarea surselor regenerabile de energie, digitalizare și îmbunătățirea rezilienței infrastructurii. La nivel global, atât în țările dezvoltate cât și în cele în dezvoltare, s-au lansat programe care evidențiază capacitatea acestor tehnologii de a furniza servicii energetice stabile și accesibile din punct de vedere financiar.

O provocare majoră rămâne gestionarea volumelor mari de date generate de dispozitivele de măsură integrate în rețelele inteligente. OD se confruntă cu dificultăți în prelucrarea și analiza eficientă a acestor informații, ceea ce limitează capacitatea lor de a lua decizii optime și de a îmbunătăți performanța rețelilor.

Conform datelor recente, ponderea surselor regenerabile în producția de energie electrică a Uniunii Europene (UE) a continuat să crească. În 2023, SER au reprezentat peste 40% din producția totală de energie electrică, iar pentru 2024 au indicat o creștere suplimentară, apropiindu-se de 45% [2]. Această tendință ascendentă este rezultatul politicilor ambițioase ale UE și al investițiilor masive în SER. De exemplu, energia eoliană și cea solară au înregistrat creșteri semnificative, contribuind cu peste 25% la producția totală de energie electrică în 2023 [2].

Caracteristicile esențiale ale unei rețele inteligente includ:

- Gestionarea eficientă a consumului de energie;
- Suport pentru adaptarea în timp real la necesitățile utilizatorilor finali;
- Distribuirea descentralizată a surselor de energie regenerabilă.

2.2. Aplicabilitatea și importanța integrării conceptului „smart grids”

În ceea ce privește aplicabilitatea REI putem menționa că aceasta ajută la gestionarea în timp real a cererii și a ofertei privind energia, reglând automat consumul de energie în funcție de capacitățile acestor surse cât și de nevoile consumatorilor.

Rețelele locale susțin dezvoltarea soluțiilor locale de generare și stocare a energiei, oferind beneficii precum scăderea costurilor de întreținere, îmbunătățirea eficienței energetice, creșterea fiabilității prin detectarea rapidă a defectelor, promovarea inovației în SDEE și reducerea emisiilor de carbon prin utilizarea SER.

Prosumatorii se pot organiza în diverse forme, în funcție de programele de finanțare disponibile, de sursele de energie utilizate și de entitățile care sprijină aceste inițiative. Una dintre aceste forme implică formarea de grupuri mici, alcătuite din indivizi sau membri ai unei comunități care dețin statutul de prosumatori. Aceste grupuri pot fi extinse ulterior, permițând alăturarea altor membri ai comunității și sprijinirea acestor proiecte.

La nivelul rezidențial, cel mai des utilizat sistem pentru generarea de energie electrică este cel bazat pe panouri FV. Această popularitate se datorează scăderii semnificative a costurilor de instalare în ultimul deceniu, ca urmare a utilizării tot mai largi a acestei tehnologii (Figura 2.4).




Figura 2.4. Evoluția costurilor pentru diverse tehnologii de producere a energiei electrice [4]

REI cu capacitate de autovindecare reprezintă un pas semnificativ către un sistem energetic mai fiabil, eficient și sustenabil.

Există trei avantaje principale ale REI cu capacitate de autovindecare:

1. **Monitorizarea și reacția în timp real** la schimbările din rețea.
2. **Anticiparea evenimentelor** potențial perturbatoare.
3. **Izolarea rapidă a defectelor**, minimizând impactul acestora asupra sistemului.

Principalele motive din spatele dezvoltării și integrării conceptului de „smart grid” sunt:

- Creșterea **eficienței și fiabilității** energetice.
- **Gestionarea optimă** a resurselor existente.
- **Integrarea surselor regenerabile** de energie în sistemul energetic (a se vedea figura 2.5).




Figura 2.5. Procesul de integrare a conceptului „smart grid” [4]

Implicarea activă a consumatorilor are un impact pozitiv și asupra producătorilor de energie, care își pot reduce costurile asociate cu construirea de noi capacități de producție pentru a acoperi cererea în perioadele de vârf. OD și OT pot face estimări precise ale consumului, echilibrând eficient utilizarea centralelor clasice și a celor bazate pe energia regenerabilă.

2.3. Tehnologii „smart grids”

Tehnologiile integrate în REI acoperă toate nivelurile SDEE, de la producție la consum, unele fiind deja implementate, iar altele necesită dezvoltare și validare suplimentară. Monitorizarea în timp real a componentelor și performanțelor sistemului permite optimizarea regimurilor de funcționare, iar sistemele avansate de control contribuie la prevenirea defectelor și la integrarea eficientă a surselor.

În starea sa actuală, OD și OT se confruntă cu o serie de provocări, precum fiabilitate scăzută a componentelor, pierderi semnificative în transport și distribuție, calitate necorespunzătoare a energiei și o predispoziție la întreruperi. În plus, lipsa unor sisteme de monitorizare și control în timp real în SDEE reprezintă o oportunitate semnificativă pentru adoptarea conceptului de „smart grid”. Astfel, REI includ tehnologii avansate de detectare, metode de control și sisteme de comunicații integrate în infrastructura SDEE, acoperind atât nivelul de transport, cât și cel de distribuție a energiei electrice (a se vedea Figura 2.7).




Figura 2.7. Schema reprezentativă a tehnologiilor “smart grid” la nivel general [5]

2.3.1. Contorizarea inteligentă

Contorizarea inteligentă reprezintă una dintre componentele esențiale ale REI, facilitând monitorizarea în timp real a consumului de energie și oferind date precise atât pentru OD, cât și pentru utilizatori finali (consumatori și prosumatori).

Scopul principal al contorizării inteligente este de a oferi o vizibilitate sporită asupra consumului de energie, atât la nivel individual, cât și la nivel de SDEE.

Contorizarea inteligentă este esențială pentru:

- **Optimizarea consumului:** Consumatorii pot ajusta consumul în funcție de tarifele dinamice, reducând costurile.
- **Reducerea pierderilor:** Detectarea rapidă a pierderilor tehnice sau comerciale.
- **Îmbunătățirea calității energiei:** Monitorizarea continuă a parametrilor energetici (tensiune, current, frecvență etc.).
- **Sprijinirea prosumatorilor:** Facilitarea măsurării energiei injectate în rețea de către prosumatori.

În UE, contorizarea inteligentă a cunoscut o dezvoltare semnificativă în ultimii ani, fiind susținută de directivele europene care promovează eficiența energetică și reducerea emisiilor de gaze cu efect de seră. Conform unui raport al Comisiei Europene din 2023 [6], peste 60% din gospodăriile din UE sunt echipate cu contoare inteligente, iar țări precum Italia, Suedia și Finlanda au rate de penetrare de peste 90%. UE și-a propus ca, până în **2030**, toate gospodăriile să fie echipate cu contoare inteligente, în conformitate cu obiectivele **Pactului Verde European**. [6]

În România, implementarea contorizării inteligente a început mai lent, dar a cunoscut o accelerare în ultimii ani, în special în zonele urbane. Proiecte pilot au fost lansate în orașe precum București, Cluj-Napoca și Timișoara, iar până în 2025 se estimează că peste 50% din gospodării vor fi echipate cu contoare inteligente [6]. Acest progres este susținut de fonduri europene și de politicile naționale care urmăresc modernizarea infrastructurii energetice.

Aceste dispozitive facilitează injectarea energiei din surse regenerabile, cum ar fi panourile FV sau turbinele eoliene, în rețea, oferind date precise pentru facturare și analiză. În plus, contorizarea inteligentă sprijină prosumatorii, permițându-le să măsoare și să gestioneze energia pe care o injectează în sistem, contribuind astfel la un sistem energetic mai sustenabil și descentralizat. Prin această integrare, se reduc pierderile de energie și se îmbunătățește stabilitatea rețelei, facilitând tranziția către un viitor bazat pe energii regenerabile.

Contorizarea inteligentă reprezintă un pas esențial către un SDEE modern, eficient și sustenabil. Prin corelarea cu sursele de energie regenerabilă, contorizarea inteligentă devine un instrument cheie în tranziția către un viitor verde și eficient.

2.3.2. Surse de energie regenerabilă

UE înregistrează progrese semnificative în creșterea ponderii acoperirii consumului din SER, fiind sprijinită de politici ambițioase, investiții substanțiale și colaborarea între statele membre. Până în 2030, UE și-a propus să crească ponderea energiei regenerabile de la 20% (nivelul din 2020) la 32%. În conformitate cu Directiva privind energia curată pentru toți europenii, Uniunea Europeană își propune, de asemenea, să reducă emisiile de dioxid de carbon cu aproximativ 45% [7].

În anul 2023, ponderea energiei consumate în UE produsă din surse regenerabile a fost de **24-25%**, în creștere față de **23%** înregistrați în 2022 și **21,9%** înregistrat în 2021. Această creștere a fost determinată în principal de o expansiune semnificativă a energiei solare, precum și de o scădere a consumului de energie neregenerabilă, influențată de prețurile ridicate ale combustibililor fosili și de criza energetică.

Pentru a atinge noul obiectiv de **42,5%** până în 2030, UE va trebui să depășească ritmul de implementare a energiilor regenerabile observat în ultimul deceniu, ceea ce va necesita o transformare profundă a sistemului energetic european. Fiecare stat membru va contribui la această țință comună, cu obiective specifice pentru fiecare țară membră UE [8].

2.3.3. Vehiculele electrice

Vehiculele electrice (VE) reprezintă un element esențial în tranziția către REI sustenabile, mai ales atunci când sunt combinate cu SER și tehnologii moderne bazate pe IA. Această integrare poate duce la crearea unui ecosistem energetic eficient și prietenos cu mediul.

În raport cu producția și consumul total de energie, mobilitatea electrică reprezintă încă o componentă minoră. În România, unde producția și consumul de energie sunt de foarte mici, se estimează că 200000 de VE ar avea un impact de aproximativ **1%** asupra consumului național [10]. SDEE trebuie să ia în considerare creșterea electromobilității, deoarece VE, fiind silențioase și eficiente, vor deveni o componentă semnificativă în viitorul apropiat.

Este de remarcat faptul că majoritatea OD nu dețin stații de încărcare pentru vehicule electrice în portofoliul lor. Doar **10%** dintre OD au menționat că dețin astfel de stații, alimentate din rețelele electrice de distribuție (RED) proprii. Mai mult, peste jumătate dintre aceștia dețin mai puțin de **9%** din totalul stațiilor de încărcare disponibile [10].




Figura 2.13. Numărul total de puncte de încărcare a vehiculelor electrice [12]

2.3.4. Sisteme de stocare a energiei electrice

Energia electrică trebuie consumată în momentul producerii sale, deoarece stocarea ei este posibilă doar prin intermediul unor sisteme cu randamente ridicate. Dezvoltarea sistemelor de stocare a energiei (SSE) se bazează pe criterii precum densitatea de energie și putere, ciclul de viață, timpul de încărcare/descărcare, costuri și funcțiile pe care acestea le pot îndeplini pentru a răspunde cerințelor rețelei electrice. [15]

SSE utilizează diverse principii de conversie, inclusiv mecanică (pompaj hidro și stocare în aer comprimat), chimică (stocare de hidrogen), electromagnetică (capacități dublu strat) și termică (sisteme cu magneți supraconductori). Bateriile și sistemele de conversie a energiei

electrice în căldură sau gaze sprijină independența energetică, reduc dependența de SDEE a OD și contribuie la eficiența termică și la protejarea climei.

O problemă frecventă este creșterea nivelului tensiunii în rețea, în special în perioada de amiază, când panourile FV funcționează la capacitate maximă. Stocarea energiei în exces la nivel local poate oferi o soluție, permițând reintroducerea acesteia în RE-MT și RE-JT contribuind la planificarea dezvoltării SDEE. Energia stocată poate fi utilizată pentru a reduce vârfurile de sarcină și pentru a oferi servicii de sistem de către OD [15].

Pentru reglarea frecvenței, stabilizarea rețelei, reducerea pierderilor și gestionarea congestiilor, fiind necesară o corelare între SER și SSE [16].

2.4. Importanța continuității alimentării cu energie în rețelele electrice

În cazul SDEE din Europa, numărul și durata întreruperilor au o variație de la aproximativ **15 minute** la **400 de minute** pe an, așa cum se poate observa în Figura 2.18 [19].

Indicatorii de continuitate în alimentarea cu energie electrică, utilizați pentru evaluarea performanței unui SDEE, **SAIFI** și **SAIDI** măsoară, respectiv, cât de des apar întreruperile și cât durează acestea, fiind esențiali pentru monitorizarea, îmbunătățirea fiabilității și calității serviciilor oferite de OD [17].




Figura 2.18. Ponderea indicatorilor raportat la nivelul de întreruperi [19]

Un **SAIFI** scăzut indică o frecvență redusă a întreruperilor, ceea ce reflectă o rețea cu elemente caracterizată de o fiabilitate ridicată iar scaderea **SAIDI** semnifică o durată totală mică a întreruperilor pentru utilizatorii finali, demonstrând o performanță ridicată a rețelei în ceea ce privește continuitatea alimentării cu energie electrică. În concluzie, analiza prezentată în acest capitol a evidențiat importanța gestionării eficiente a SDEE, cu accent pe continuitatea alimentării, calitatea energiei și integrarea SER.

Capitolul 3

Clasificarea prosumatorilor din sistemele de distribuție a energiei electrice utilizând tehnici de clustering

3.1 Tehnici de clustering

3.1.1. Definiție și aplicații actuale ale clustering în sistemele de distribuție a energiei electrice

Clustering-ul reprezintă o metodă de învățare automată nesupravegheată, utilizată pentru organizarea datelor în clustere (grupuri, categorii sau zone). Aceste clustere sunt formate astfel încât elementele (obiectele sau punctele de date) incluse într-un grup (categorie, clasă) să aibă caracteristici (atribute) similare între ele, dar să difere semnificativ de elementele din alte clustere.

3.1.2. Etapele procesului de clustering

Procesul de clustering cuprinde o serie de pași esențiali, necesari pentru obținerea unor rezultate semnificative și aplicabile [22]:

1. *Stabilirea obiectivelor și analiza problemei;*
2. *Colectarea și pregătirea datelor;*
3. *Explorarea și preprocesarea datelor;*
4. *Selectarea metodei de clustering ;*
5. *Implementarea algoritmului de clustering ;*
6. *Evaluarea și validarea rezultatelor;*
7. *Interpretarea și aplicarea rezultatelor.*

Înainte de a începe procesul de clustering, este crucial să stabilim obiectivele analizei și să înțelegem problema care urmează a fi rezolvată. Aceasta implică identificarea datelor disponibile, scopul clusteringului (ce rezultate se urmăresc) și cum vor fi folosite aceste rezultate. De exemplu, segmentarea prosumatorilor în categorii/clase/zone poate ajuta la crearea de strategii de tarification și estimarea puterii injectate în rețea.

3.1.3. Metode de clustering

3.1.3.1. Metoda K-medii

K-medii este un algoritm de clustering care împarte datele de intrare în K clustere (categorii, clase, zone) unde K este stabilit în avans de către decident înainte de a începe procesul de clustering. Fiecare cluster este reprezentat prin valorile medii ale atributelor elementelor pe care le conține, aceste valori formând centrul de greutate (CG) al clusterului.

Decidentul trebuie să urmeze următoarele etape cheie în cadrul algoritmului (a se vedea Figura 3.1):

1. Alegerea inițială a pozițiilor centrelor de greutate (CG) asociate celor K clustere.
2. Atribuirea fiecărui element din baza de date celui mai apropiat CG.
3. Recalcularea pozițiilor CG pe baza elementelor atribuite fiecărui cluster.
4. Repetarea etapelor 2 și 3 până când centrele de greutate nu se mai schimbă semnificativ.




Figura 3.1. Diagrama de implementare a algoritmului K-medii [23]

Acest algoritm oferă mai multe avantaje, printre care simplitatea și eficiența calculelor în cadrul fiecărei iterații. Printre dezavantaje se numără necesitatea alegerii prealabile a numărului de clustere (K), care poate influența semnificativ rezultatele clusteringului (a se vedea Figura 3.2), precum și sensibilitatea la datele care se află în afara intervalului normal de variație al atributelor, care pot afecta poziția CG și, implicit, calitatea grupării [23].




Figura 3.2. Exemplu ilustrativ al alocării elementelor în clustere [23]

3.1.3.2. Metoda DBSCAN (Density-Based Spatial Clustering of Applications with Noise/ Clustering spatial bazat de densitate cu detectarea valorilor atipice)

DBSCAN este un algoritm de clustering bazat pe densitate care grupează elemente în funcție de densitatea lor locală și identifică valori atipice. Pașii principali sunt:

1. Selectarea aleatorie a unui element din baza de date.
2. Extinderea clusterului dacă elementul are suficienți vecini într-o rază dată („eps”).
3. Repetarea procesului până când toate elementele din baza de date supusă procesului de clustering sunt procesate.

Avantajele acestei metode se referă la capacitatea de a detecta clustere (categorii, clase, zone) de forme arbitrare și identificarea valorilor atipice, fără a necesita specificarea numărului de clustere în avans. Dezavantajul principal este dependența de parametri de intrare introduți de decident, care pot afecta performanța.

3.1.3.3. Metode ierarhice de clustering

Metodele ierarhice de clustering ierarhic construiesc o ierarhie de clustere (categorie, clase, zone) folosind o abordare aglomerativă (“bottom-up”) sau divizivă (“top-down”) [24]. Etapele de bază pe care decidentul trebuie să le ia în considerare în interiorul algoritmului sunt următoarele [24]:

1. Fiecare element din baza de date constituie inițial un cluster separat.
2. La fiecare pas, cele mai apropiate două clustere sunt combinate într-un ”principal” cluster.
3. Repetarea etapelor 1 și 2 până când toate elementele sunt grupate într-un singur cluster sau se atinge un număr dorit de clustere.

Ca aplicații ale metodelor care fac parte din această categorire pot fi amintite clasificarea tiparelor de consum și producție a consumatorilor/prosumatorilor din SDEE [24].

3.1.3.4. Metode ce integrează modele probabilistice

Modelul Gaussian Mixture este un model probabilistic care aparține categoriei metodelor de clustering în care se presupune că datele de intrare sunt generate dintr-un amestec de mai multe distribuții Gaussiene.

Unul dintre principalele avantaje ale acestui model este atribuirea probabilistică a elementelor la clustere, care permite o analiză flexibilă și identificarea de clustere cu forme eliptice. Totuși, există și câteva dezavantaje semnificative, cum ar fi numărul mare de iterații necesare pentru a atinge criteriul de convergență (ceea ce poate crește timpul de calcul), precum

și necesitatea specificării în avans a numărului de distribuții gaussiene (clustere), care poate reprezenta un impediment în lipsa unor informații prealabile.

3.2. Prosumatorii – un atu pentru operatorii de distribuție

3.2.1. Provocările prosumatorilor

Prezența pe scară largă a prosumatorilor devine posibilă datorită noilor tehnologii, revoluției digitale și cerințelor utilizatorilor finali privind calitatea energiei. Transformarea consumatorilor pasivi în prosumatori activi în diferite sectoare, posibilitatea dezvoltării de μ REI și noile metode de tranzacționare în era digitală a internetului, sunt elementele definitorii ale strategiei unei piețe digitale unice [28], anunțată în mai 2016 de către Comisia Europeană, bazată pe trei piloni:

- acces online la bunuri și servicii digitale;
- crearea unui mediu în care rețelele și serviciile digitale pot deveni mai competitive;
- digitalizarea ca motor de creștere.

Un prosumator trebuie să îndeplinească toate sarcinile unui consumator, dar și pe cele ale unui producător de energie electrică. Ei pot vinde energia produsă și injectată în rețeaua OD, către furnizorul cu care au un contract în calitate de utilizatori finali [29][30].

3.2.2. Prosumatorii - Uniunea Europeană vs. România

Uniunea Europeană (UE) și-a asumat angajamentul de a atinge obiectivele stabilite în Acordul de la Paris privind Schimbările Climatice pentru a asigura producerea de energie nepoluantă [30]. În vederea îndeplinirii acestui angajament, UE a fixat obiective climatice și energetice pentru anul 2030, care includ:

- Reducerea emisiilor GES cu cel puțin 40% până în 2030, comparativ cu 1990;
- Consumul de energie regenerabilă de 32% în 2030;
- Îmbunătățirea eficienței energetice cu 32,5% în 2030;
- Interconectarea pieței de energie electrică la un nivel de 15% până în 2030.

Obținerea acestor valori este rezonabilă, având în vedere că ponderea energiei regenerabile în producția de energie electrică a UE a suferit o creștere spectaculoasă între 2005 și 2017, de la 15% la aproape 31% [30]. Tehnologiile care au contribuit la această creștere sunt asociate cu energia eoliană și solară. Figura 3.3 prezintă tendința asociată cu acest obiectiv, având ca bază anul 2015 [30].

De asemenea, autorii studiului prezentat în [30] au estimat că aproximativ 50% dintre utilizatorii finali ar putea deveni prosumatori, asigurând o pondere de 45% din cererea de energie în 2050. Pentru a atinge acest obiectiv, numărul prosumatorilor ar trebui să crească la 112 milioane (în 2030). În 2050, se estimează că 264 de milioane de prosumatori vor injecta energie în SDEE.




Figura 3.3. Ponderea acoperirii cererii de energie de către SER și prosumatorii din UE[%] [31]

Conform scenariului furnizat în cadrul *Proiectului Strategiei de Renovare pe Termen Lung* [34], măsurile vor implica o creștere a consumului de energie din capacitățile FV de pe acoperișuri cu 2,5 TWh până în 2030, reprezentând 46,3% din creșterea totală prognozată a producției de energie electrică din capacitățile fotovoltaice pentru anul 2030.

Intrarea în vigoare a Legii nr. 184/2018 a dus la stabilirea cadrului de reglementare de către ANRE pentru energia produsă în centrale electrice din surse regenerabile cu o putere electrică instalată de cel mult 27 kW, ajungând în prezent la o valoare de cel mult 100 kW.

3.3. Clasificarea prosumatorilor din sistemele de distribuție a energiei electrice bazată pe clustering

În această secțiune este propusă o metodologie originală de clasificare a prosumatorilor în categorii de importanță, bazată pe analiza caracteristicilor energetice, prin tehnici de clustering. Plecând de la considerentele prezentate în Secțiunile 3.1 și 3.2, a fost selectat algoritmul K-medii datorită avantajelor sale evidențiate în subsecțiunea 3.1.3.1.

Clasificarea se bazează pe două caracteristici energetice esențiale pentru identificarea regimurilor optime de exploatare a rețelelor din SDEE și anume puterea orară injectată și energia anuală totală furnizată.

Testarea metodologiei a fost realizată folosind o bază de date corespunzătoare prosumatorilor conectați la o RE-JT dintr-o zonă rurală aparținând unui OD din România. Rezultatele obținute au confirmat performanța algoritmului de clustering K-medii în procesul de

extragere rapidă a caracteristicilor energetice ale prosumatorilor din bazele de date de dimensiuni mari, care pot fi utilizate de către OD în procesul de luare a deciziilor privind regimurile optime de exploatare. Metodologia poate reprezenta unul dintre pașii pe care OD trebuie să-i parcurgă în procesul de tranziție către implementarea conceptului “*smart grids*” în RED.

3.3.1. Pașii metodologiei de clasificare a prosumatorilor

Foarte multe studii din diverse domeniile de activitate au evidențiat în ultimii ani o explozie a interesului cercetătorilor de folosirea a tehnicilor speciale de explorare a datelor din baze de mari dimensiuni [37].




Figura 3.5. Pașii metodologiei de explorare a datelor în domeniul energetic [38]

În Figura 3.5 [38] sunt prezentați pașii procesului de extragere a datelor bazat pe clustering integrați în metodologia propusă.

3.3.2. Algoritmul clustering în procesul de clasificare a prosumatorilor

Algoritmul K-medii preia din baza de date a OD înregistrări în format vectorial $P = \{p_i, i = 1: n\}$, reprezentând valorile de intrare, unde fiecare vector are două elemente $p_i = [p_i^1, p_i^2]$, unde n este numărul de prosumatori. Cele două elemente ale fiecărui vector se referă la caracteristicile energetice ale fiecărui prosumator asociate valorilor medii ale puterii orare (P_{av}), necesare pentru a estima starea rețelei prin calculele de regim, și energiei (W_t) anuale.

Obiectivul procesului de clustering este de a grupa vectorii $p_i, i = 1, \dots, n$ în K clustere (categorii) notate cu $C = \{C_k \mid k = 1: K\}$.

Centrul de greutate (CG) al fiecărei categorii $C_k, k = 1: K$, este notat cu m_k . Procesul de clustering are în vedere minimizarea funcției obiectiv [40], [41], [42]:

$$F(P, C) = \sum_{k=1}^K \sum_{p \in C_k} D(p, m_k) \quad (3.1)$$

unde $D(p, m_k)$ reprezintă distanța Euclidiană calculată în spațiul cu două dimensiuni:

$$D(p, m_k) = \sqrt{\sum_{i=1}^{n_k} (p_i - m_k)^2} \quad (3.2)$$

unde n_k reprezintă numărul prosumatorilor din clusterul (categoria) C_k , $k = 1, \dots, K$.

Algoritmul începe prin selectarea aleatoare a CG clusterelor (categoriilor), după care aceste centre sunt actualizate iterativ. La final, algoritmul identifică o partiție care corespunde unui minim local al funcției $F(P, C)$. În funcție de datele de intrare, pot apărea situații în care soluția obținută nu reprezintă soluția globală optimă.

Pentru testarea calității partiției se pot calcula diverși indicatori de performanță. Unul dintre cei folosiți în literatura de specialitate este coeficientul de siluetă [41]. CSG pentru o partiție în K categorii (clustere) poate fi calculat utilizând formula [42]:

$$CS^{(K)} = \frac{1}{n_k} \sum_{i=1}^{n_k} \left(\frac{x_i - y_i}{\max\{x_i, y_i\}} \right) \quad (3.6)$$

$$x_i = \frac{\sum_{j \in X, j \neq i} \text{dist}(v_i, v_j)}{n_X - 1} ; \quad y_i = \min_{X \neq Y} \frac{\sum_{j \in Y, j \neq i} \text{dist}(v_i, v_j)}{n_Y} \quad (3.7)$$

unde: n_X și n_Y – numărul de prosumatori din categoriile (clusterelor) X și Y asociate cu partiției, iar $\text{dist}(v_i, v_j)$ – distanța calculată între caracteristicile prosumatorilor v_i , și v_j din baza de date.

3.3.3 Testarea metodologiei

Testarea metodologiei a fost făcută pe o bază de date formată din caracteristicile energetice ale prosumatorilor racordați într-o RE- JT dintr-o zonă rurală ce aparține unui OD din România. Baza de date conține înregistrările a 41 de prosumatori integrați în sistemul de contorizare inteligentă (SCI) al OD pe parcursul unui an.

Referitor la caracteristicile tehnice ale instalațiilor de generare, 41 de prosumatori au panouri FV cu puterea instalată cuprinsă între 1,5 și 10 kW, fiind în categoria utilizatorilor finali rezidențiali, iar un prosumator, aparținând categoriei prosumatorilor industriali, cu o putere instalată de 25,5 kW. Figura 3.6 prezintă evoluția racordărilor la rețea a prosumatorilor respectivi.

Din analiza preliminară a valorilor puterilor active înregistrate în SSI, nu toți cei 41 au injectat energie în RED în fiecare lună. Acest aspect este evidențiat în Figura 3.6 și Figura 3.7, în care se indică numărul de luni în care fiecare prosumator a injectat energie în rețea. Totodată, această evoluție ne indică și câți prosumatori s-au racordat la rețea în fiecare lună. Analiza datelor a subliniat faptul că prosumatorii nu au injectat energie în rețea în primele două luni (ianuarie și februarie). De asemenea, au existat consumatori care, în ultimele zece luni, nu au injectat energie

în fiecare lună, a se vedea Figura 3.8. Doar 10 prosumatori (23,8%) au avut energiile injectate în decursul celor 10 luni, celelalte având injecții între 2 și 9 luni.




Figura 3.6. Numărul de prosumatori racordați la rețea în fiecare lună din perioada de un an analizată




Figura 3.7. Numărul de luni în care fiecare prosumator a injectat energie în rețea

Pe baza acestor rezultate, Figura 3.9 prezintă valorile energiilor anuale injectate în rețea de fiecare dintre cei 41 de prosumatori. Se poate observa faptul că majoritatea acestora 62% (26 prosumatori) au valoarea energiei sub 2000 kWh/an, 21% (9 prosumatori) au înregistrat energii anuale injectate între 2000 și 4000 kWh/an și 17% (7 prosumatori) au injectat în rețea o energie de peste 4000 kWh/an.[39]




Figura 3.8. Numărul de prosumatori cu energie injectată în rețea în funcție de numărul de luni




Figura 3.9. Energia anuală injectată de fiecare prosumator în rețea [kWh]

În procesul de extragere a informațiilor "ascunse" în scopul identificării categoriilor de prosumatori caracterizate de cele două caracteristici energetice asociate valorilor medii ale puterii orare injectate (P_{av}), necesare pentru a estima starea rețelei prin calculele de regim, și energiei (W_t) anuale au fost considerați doar prosumatorii rezidențiali care au injectat cel puțin o zi energie în rețea.[40]

Puterea orară medie injectată se calculează cu ajutorul relației:

$$P_{av,i} = \frac{\sum_{h=1}^{24} P_{h,i|P_h>0}}{N_{h|P_h>0}} \quad (3.8)$$

unde se vor lua în considerare doar orele la care puterea injectată este pozitivă ($P_h > 0$, $h = 1, \dots, 24$).

În etapa de preprocesare, toate profilurile care au avut valori orare egale cu zero au fost eliminate din analiză. Acest aspect este evidențiat și în Figurile 3.6 – 3.8 în care au fost folosite doar datele diferite de valoarea 0.

În continuare au fost extrase atributele privind valorile medii ale puterii orare, energiei zilnice, lunare și anuale pentru fiecare prosumer pentru a fi utilizate în procesul de clusterizare.

Astfel, a rezultat o mulțime $P = \{p_i, i = 1: n\}$, reprezentând valorile de intrare, unde fiecare vector $p_i, i = 1, \dots, 41$ are două elemente $p_i = [P_{av}, W_t]$.

Algoritmul K-medii a fost rulat pentru un număr de categorii prestabilit $K = 2, \dots, K_{max}$ [40], unde:

$$K_{max} = \sqrt{n} = 6 \quad (3.9)$$

Testarea calității celor 5 partiții a fost evaluată pe baza unui test intern pentru fiecare categorie și a calculului unui coeficient de siluetă global (CSG) [43], [44], determinat folosind relațiile (3.6) și (3.7).

Partiția optimă corespunde celei cu valoarea maximă a CSG. În acest caz, partiția optimă a fost identificată pentru gruparea în 4 categorii, $K_{opt} = 4$. CSG având valoarea de 0,764, reprezentând valoarea maximă obținută dintre toate cele 5 partiții evaluate ($K = 2, \dots, 6$).

Valorile gradului de încredere în medie se încadrează în una din următoarele categorii:

- între 0 și 17% media este strict reprezentativă
- între 17% și 35% media este moderat reprezentativă
- între 35% și 50% media este reprezentativă în sens larg
- 50% media este nereprezentativă

Gradul de încredere s-a calculat ca raport între abaterea standard (σ) și media (m), înmulțit cu 100 pentru a fi exprimat în procente.




Figura 3.11. Reprezentarea clusterelor obținute pe categorii (C1-C4) după puterea medie orară și energia totală

Repartizarea prosumatorilor pe categorii, în funcție de cele două caracteristici energetice, este prezentată în Figura 3.11. Această prezentare detaliată permite o înțelegere mai nuanțată a diversității comportamentelor de consum și producție, oferind un punct de plecare solid pentru elaborarea de strategii de integrare eficientă a prosumatorilor în SDEE. Aceste rezultate reflectă existența a două profiluri principale de prosumatori, diferențiate prin capacitatea de producție și comportamentul de injecție a energiei în rețea.

Capitolul 4

Estimarea stării rețelelor electrice de distribuție a energiei electrice active folosind profilarea utilizatorilor finali

4.1 Aspecte generale

Profilarea prosumatorilor reprezintă o etapă esențială în optimizarea regimurilor de funcționare ale SDEE, deoarece aceștia sunt utilizatori finali care generează energie electrică în principal din surse regenerabile (sisteme FV sau eoliene), o consumă parțial, iar surplusul îl injectează în rețea. Integrarea eficientă a prosumatorilor în SDEE aduce beneficii semnificative atât pentru stabilitatea și eficiența SDEE exploatată de către OD, cât și pentru societate în general.

Procesul de profilare implică analiza amănunțită a tiparelor de consum și producție, precum și identificarea caracteristicilor specifice fiecărui prosumator (putere instalată, tipul sursei, gradul de autoconsum). Aceste informații permit OD-ului să optimizeze investițiile în infrastructură, să îmbunătățească managementul sarcinii și să dezvolte strategii eficiente pentru exploatarea SDEE [38].

Deși profilarea prosumatorilor oferă multiple avantaje, există și provocări, cum ar fi:

- **Variabilitatea capacității de producție:** SER asociate panourilor FV, sunt dependente de condițiile meteorologice, ceea ce face dificilă prognoza exactă a capacității de producție a energiei electrice.
- **Managementul datelor:** Volumul mare de date provenit de la contoarele inteligente montate la prosumatori necesită infrastructuri de comunicații și informatice robuste pentru transmiterea, stocarea, procesarea și analiza informațiilor.
- **Integrarea tehnologică:** Integrarea unor tehnologii noi, precum SSE și VE, necesită o coordonare atentă și o adaptarea continuă a rețelei la solicitările utilizatorilor finali.

4.2. Profilarea și potențialul prosumatorilor în Uniunea Europeană și România

Prosumatorii din UE și România beneficiază de dreptul legal de a produce, stoca și de a vinde energie regenerabilă, conform acordurilor UE. Sistemele de producere bazate pe panouri FV

instalate pe acoperișuri oferă un potențial enorm pentru generarea distribuită, transformând cetățenii în participanți activi în tranziția energetică. Contribuția lor crește semnificativ ponderea energiei regenerabile, reducând dependența de sursele convenționale. Deși România încă exploatează insuficient acest potențial, cadrul legislativ actual permite racordarea prosumatorilor prin stimulente și modernizarea rețelei.

Figura 4.1 ilustrează numărul potențial de prosumatori din categoria utilizatorilor finali rezidențiali care au instalat panouri FV din Europa, iar Figura 4.2 prezintă potențialul capacității panourilor FV instalate la utilizatorii finali rezidențiali (în GW) [55].

Valorile prezentate în Figurile 4.1 și 4.2 au fost estimate ținând cont de numărul real de clădiri din fiecare țară, suprafața disponibilă de acoperiș și o proporție estimată pentru instalațiile panourilor FV[55] [56].




Figura 4.1. Numărul potențial de prosumatori rezidențiali cu panouri fotovoltaice instalate în Europa [55]




Figura 4.2. Capacitate instalată estimată a sistemelor FV rezidențiale în Europa, în [GW] [55]

Din analiza solicitărilor de racordare la rețeaua OD din România s-a constatat că majoritatea certificatelor de racordare emise de OD certificate cu calitatea de prosumator aparțin persoanelor fizice, cu un procent de 96 %, restul de 4 % aparțin prosumatorilor persoane juridice, a se vedea Figura 4.4 [58]. Figura 4.5 evidențiază structura puterii instalate pe tipuri de organizare (persoane fizice și persoane juridice)[54].




Figura 4.4. Distribuția prosumatorilor în funcție de forma de organizare [58]




Figura 4.5. Pondere puterii instalate în funcție de forma de organizare [58]

4.3. Metodologie de determinare a profilurilor tip de putere injectată de prosumatori

4.3.1. Descrierea metodologiei

Metodologia de profilare a puterii injectate de prosumatori se bazează pe colectarea, procesarea și analiza datelor privind puterea injectată în rețea de fiecare prosumator. Metodologia preia din baza de date a OD profilurile puterii orare injectate provenite de la contoarele inteligente ale prosumatorilor înregistrate pentru fiecare zi din an.

Metodologia propusă nu doar facilitează o înțelegere mai bună a comportamentului prosumatorilor dintr-o anumită zonă de rețea și sezon, dar poate contribui și la creșterea eficienței energetice a SDEE.

Etapele integrate la nivelul metodologiei propuse sunt prezentate în Figura 4.6, iar detaliile sunt prezentate în continuare [59].

Etapă 1. Încărcarea din baza de date a SCI a profilurilor puterii injectate de prosumatori în rețea. Integrarea prosumatorilor în SCI permite contoarelor să comunice valorile puterii injectate către baza de date în timp real. Timpul de eșantionare poate fi de 15, 30 sau 60 minute. Profilurile sunt memorate în matricea $[P]$ de dimensiune $(N_z \times T)$, unde N_z reprezintă numărul de zile dintr-un an, iar T are semnificația perioadei de analiză (în general, o zi caracterizată de 24 de intervale de eșantionare). Datele pot fi, de asemenea, centralizate pe diverși FEE cu care prosumatorul are încheiat un contract.

$$[P]_{N_z \times T} = \begin{bmatrix} P_{1,1}^{(1)} & P_{1,2}^{(1)} & \dots & P_{1,T}^{(1)} \\ P_{2,1}^{(2)} & P_{2,2}^{(2)} & \dots & P_{2,T}^{(2)} \\ \dots & \dots & P_{z,t}^{(p)} & \dots \\ P_{N_z,1}^{(N)} & P_{N_z,T}^{(N)} & \dots & P_{N_z,T}^{(N)} \end{bmatrix} \quad (4.1)$$

unde: N – numărul de prosumatori; T – intervalul de analiză (în general, o zi cu 24 de intervale de eșantionare $\Delta t = 1$ oră); N_z – numărul zilelor dintr-un an; z – o zi dintr-un an ($z = 1, \dots, N_z$); $P_{z,t}^{(p)}$ – puterea injectată de prosumatorul p , $p = 1, \dots, N$, în ziua z , $z = 1, \dots, N_z$, și ora t , $t = 1, \dots, T$.

Etapă 2. Procesul de preprocesare a datelor înregistrate în matricea $[P]$ care conține profilurile de putere orară injectată corespunzătoare fiecărui prosumator. Profilurile care conțin pe parcursul unei zile toate valorile egale cu 0 (fără putere injectată în rețea) sau valorile atipice (care depășesc capacitatea instalată a sistemului de panouri FV) sunt eliminate din matricea $[P]$.




Figura 4.6. Etapele metodologiei de profilare propuse

Etapa 3. Extragerea caracteristicilor prosumatorilor. Capacitatea instalată a sistemului de panouri FV și energia anuală injectată sunt extrase pentru fiecare prosumator p , $p = 1, \dots, N$ și înregistrate în matricea $[PF]$. Aceste caracteristici reprezintă pentru OD indicatori semnificativi care caracterizează comportamentul prosumatorului [49].

$$[PF]_{N \times 2} = \begin{bmatrix} C_i^{(1)} & W_i^{(1)} \\ \vdots & \vdots \\ C_i^{(p)} & W_i^{(p)} \\ \vdots & \vdots \\ C_i^{(N)} & W_i^{(N)} \end{bmatrix} \quad (4.2)$$

unde $C_i^{(p)}$ – capacitatea instalată a sistemului de panouri FV instalat la prosumatorul p , $p = 1, \dots, N$; $W_i^{(p)}$ – energia anuală injectată în rețea de către prosumatorul p .

Etapa 4. Clasificarea prosumatorilor. Prosumatorii sunt grupați în clase reprezentative folosind o metodă de clustering. Algoritmul de grupare K-medii a fost folosit în cadrul metodologiei datorită simplității sale în implementare și calității partiției finale [60].

Datele de intrare ale algoritmului sunt reprezentate de valorile normalizate ale fiecărui element din matricea $[PF^*]$.

$$C_i^{(p)*} = \frac{C_i^{(p)} - C_{i,max}^{(p)}}{C_{i,max}^{(p)} - C_{i,min}^{(p)}}; \quad W_i^{(p)*} = \frac{W_i^{(p)} - W_{i,max}^{(p)}}{W_{i,max}^{(p)} - W_{i,min}^{(p)}} \quad (4.3)$$

$$C_{i,max}^{(p)*} = \max_{p=1,...,N} \{C_i^{(p)}\}; \quad C_{i,min}^{(p)*} = \min_{p=1,...,N} \{C_i^{(p)}\} \quad (4.4)$$

$$W_{i,max}^{(p)*} = \max_{p=1,...,N} \{W_i^{(p)}\}; \quad W_{i,min}^{(p)*} = \min_{p=1,...,N} \{W_i^{(p)}\} \quad (4.5)$$

Algoritmul K-medii grupează prosumatorii caracterizați de valorile normalizate înregistrate în matricea $[PF^*]$ pe fiecare linie în K clase, unde K este parametrul de intrare. Algoritmul va atribui în final fiecărei clase k , $k = 1, ..., K$, în funcție de distanța Euclidiană calculată în raport cu CG al clasei. După asocierea tuturor prosumatorilor la una dintre cele k clase, coordonatele CG al fiecărei clase este recalculat, iar procesul se repetă până când condiția de convergență este atinsă.

Algoritmul identifică partiția optimă a prosumatorilor în clasele K din intervalul $[2, K_{MAX}]$ în care K_{MAX} este calculat cu relația [38]:

$$K_{MAX} = \sqrt{N} \quad (4.6).$$

Algoritmul va rula pentru fiecare dintre partițiile $K = 2, ..., K_{MAX}$ și va identifica partiția optimă în urma identificării valorii maxime a unui indicator de performanță identificat prin coeficientul de siluetă global (CSG) calculat cu ajutorul relației (3.6) din Capitolul 3.

Algoritmul are la bază următoarea expresie pentru funcția obiectiv [59]:

$$F = \sum_{k=1}^K \sum_{i=1}^N \|PF_i^{*(k)} - c_k\|^2 \quad (4.7)$$

unde $\| * \|$ este distanța Euclideană calculată între linia $PF_i^{(k)}$ din matricea $[PF^*]$ asociată prosumatorului p , $p = 1, ..., N$, alocat clasei k și centrul de greutate c_k al clasei.

Etapa 5. Extracția profiluri tip de putere injectată de prosumatori (PTPI-P) pentru fiecare sezon. Profilurile de putere injectată ale prosumatorilor alocați fiecărei clase k , $k=1, ..., K$, asociată partiției optime sunt extrase din baza de date (matricea $[P]$), luând în considerare lunile asociate fiecărui sezon. Astfel, PTPI-P asociate fiecărui sezon sunt obținute pe baza medierii orare a tuturor profilurilor normalizate atribuite claselor de prosumatori.

$$P_{t,s}^{(k)} = \frac{\sum_{i=1}^{N_k} P_{z,t}^{(p)*}}{N_k}; \quad t = 1, ..., T; \quad k = 1, ..., K \quad (4.8)$$

unde: s – sezonul (iarnă, primăvară, toamnă și iarnă); N_k – numărul de prosumatori alocați clasei k , $k = 1, \dots, K$; $P_{z,t}^{(p)*}$ - puterea injectată normalizată a prosumatorului p în ziua z din sezonul s și ora t .

Factorul de normalizare a puterii injectate orare este reprezentat de capacitatea instalată a sistemului de panouri FV instalat la prosumator:

$$P_{z,t}^{(p)*} = \frac{P_{z,t}^{(p)}}{C_i^{(p)}}; \quad p = 1, \dots, N; \quad z = 1, \dots, N_z \quad (4.9)$$

4.3.2. Testarea metodologiei

Metodologia propusă a fost testată folosind o bază de date care conține profilurile de putere orară injectată înregistrate în fiecare zi pentru un număr de 50 de prosumatori racordați la RD-JT dintr-o zonă rurală aflată în portofoliul unui OD din România. Dintre cei 50 de prosumatori, nu toți au fost avut injecții de putere în rețea (8 dintre aceștia nu au avut valori înregistrate în baza de date).

Procesul de preprocesare a fost inițializat pentru a elimina din baza de date profilurile zilnice care au înregistrat toate valorile orare egale cu 0 (fără putere injectată în rețea) sau valori atipice (care depășesc capacitatea instalată a sistemului de panouri FV instalat la prosumator).

Extragerea caracteristicilor prosumatorilor s-a realizat folosind înregistrările din baza de date a OD care conține capacitatea instalată, C_i , aprobată și profilurile zilnice de putere injectată asociate fiecărui prosumator din matricea $[P]$ din care s-a calculat energia totală injectată, W_i , de fiecare prosumator în perioada analizată (1 an)[61].

În prima etapă a algoritmului, numărul maxim de clustere (clase), K_{MAX} , în care pot fi grupate prosumatorii este determinat cu ajutorul relației (4.6), rezultând un număr de 6 clase.

Ulterior, partiția optimă, K_{opt} , este identificată pe baza valorii maxime înregistrate de CSG, calculat pentru fiecare partiție K , $K = 2, \dots, 6$. Valoarea maximă $CSG = 0,7974$, a fost obținută pentru $K_{opt} = 3$.

Figura 4.8 prezintă valorile calculate pentru fiecare partiție K , în care s-a evidențiat cu culoarea roșie soluția optimă.




Figura 4.8. Valorile coeficientului global de siluetă pentru partițiile $K = 2 \div 6$




Figura 4.9. Analiza coeficienților de siluetă pentru partiția optimă $K_{opt} = 3$

Figura 4.9 prezintă coeficienții de siluetă calculați pentru partiția optimă a prosumatorilor, evidențiind o clasificare clară pe baza caracteristicilor tehnice analizate. Rezultatele demonstrează o separare distinctă între clase, cu valori ridicate ale CS, ceea ce indică o grupare eficientă a prosumatorilor în funcție de caracteristicile energetice folosite. Distribuția pe clase reflectă diferențele semnificative între profilele de injecție de putere a prosumatorilor, confirmând validitatea metodei de clustering aplicate [62].

Diagrama prezintă valorile coeficienților de siluetă pentru fiecare clasă (C1, C2 și C3), reflectând calitatea grupării prosumatorilor. Valorile apropiate de +1 indică clustere bine separate, în timp ce cele apropiate de 0 sau negative sugerează suprapuneri între clase. Rezultatele confirmă validitatea partiției alese, cu majoritatea clustrelor prezentând valori pozitive semnificative.

Curtilele sunt indicatori statistici care împart setul de date în mai multe părți cu valori egale:

$$x_{\frac{1}{4}} = \text{Cuartila}_1; x_{\frac{2}{4}} = \text{Cuartila}_2; x_{\frac{3}{4}} = \text{Cuartila}_3; x_{\frac{4}{4}} = \text{Cuartila}_4 \quad (4.10)$$

unde $x \in \{C_i, W_i\}$.

În literatură, cercetătorii mai prezintă și Cuartila_0 care este asociată valorii minime a variabile analizate. [56]

Indicatorii statistici, *media* (m_{x_c}) și *dispersia* (σ_{x_c}) sunt calculați cu ajutorul următoarelor relații matematice:

$$m_{x_c} = \frac{\sum_{i=1}^{N_c} x_i^{(c)}}{N_c}; \quad \sigma_{x_c} = \sqrt{\frac{\sum_{i=1}^{N_c} (x_i^{(c)} - m_{x_c})^2}{N_c}}, \quad c \in \{C_1, C_2, C_3\}, \quad x_c \in \{C_i, W_i\} \quad (4.11)$$

unde N_c reprezintă numărul de prosumatori din fiecare clasă c , $c \in \{C_1, C_2, C_3\}$.




Figura 4.11. Reprezentarea boxplot a puterii instalate a sistemelor de panouri FV montate la prosumatorii clasificați în fiecare clasă obținută în urma procesului de clustering




Figura 4.12. Reprezentarea boxplot a energiei anuale injectate de prosumatorii clasificați în fiecare clasă obținută în urma procesului de clustering

Analiza reprezentărilor boxplot, care ilustrează asimetria și dispersia datelor privind puterea instalată și energia anuală injectată în rețea, evidențiază trei aspecte principale:

- existența a două valori atipice în cazul capacității instalate pentru prosumatorii din clasa C1;
- variații relativ apropiate ale energiei anuale injectate între cele trei clase de prosumatori;
- variație semnificativă a capacității instalate în clasa C3, cu valori cuprinse între 2,5 și 12 kW, ceea ce confirmă faptul că energia anuală injectată a fost parametrul dominant în procesul de clustering.

În etapa următoare, profilurile de putere injectată ale prosumatorilor din fiecare clasă au fost extrase din baza de date (matricea $[P]$), luând în considerare datele lunare corespunzătoare fiecărui sezon. Profilele tip de putere injectată (PTPI-P) pe sezoane au fost obținute prin medierea orară a profilurilor normalizate, utilizând relațiile (4.8) și (4.9). Reprezentările grafice corespunzătoare sunt ilustrate în Figurile 4.13 - 4.15.




Figura 4.13. PTPI-P asociate prosumatorilor din clasa C1 pentru fiecare sezon




Figura 4.14. PTPI-P asociate prosumatorilor din clasa C2 pentru fiecare sezon




Figura 4.15. PTPI-P asociate prosumatorilor din clasa C3 pentru fiecare sezon

Analiza PTPI-P obținute evidențiază următoarele aspecte:

- PTPI-P asociate sezoanelor de primăvară și de iarnă pentru prosumatorii din clasa C1 sunt foarte apropiate. PTPI-P asociate claselor C2 și C3 prezintă diferențe începând cu ora la care este înregistrată puterea maximă injectată.
- Ora la care puterea injectată are valoarea maximă diferă în cazul clasei C1: ora 12 (sezonul de toamnă), ora 13 (sezonul de iarnă) și ora 14 (sezoanele de primăvară și vară). Clasele C2 și C3 au aceeași oră la care se înregistrează valoarea maximă a puterii injectate (ora 13).
- Ultimele ore de injecție a puterii în rețea sunt similare pentru cele trei clase: ora 16 (sezonul de iarnă), ora 17 (sezonul de toamnă), ora 18 (sezonul de primăvară) și ora 20 (sezonul de vară).
- Puterea injectată crește de la C1 către C3, acesta fiind un comportament normal datorat capacității instalate ridicate și a cantităților semnificative de energie anuală injectată.

4.4. Estimarea stării rețelelor electrice de distribuție a energiei electrice active folosind profilurile de putere ale utilizatorilor finali


Starea SDEE poate fi estimată cu ajutorul profilurilor tip de putere cerută (PTPC) de utilizatorii finali și de putere injectată (PTPI-P) în rețea de către prosumatori. Folosind aceste profiluri, OD pot dezvolta strategii pentru exploatarea optimă a SDEE, asigurând o funcționare eficientă a acestora, asigurând totodată și o calitate corespunzătoare a tensiunii de alimentare. Astfel, în cadrul acestui paragraf se va analiza impactul utilizării PTPC și PTPI asupra estimării stării SDEE prin evaluarea tensiunilor în noduri și a pierderilor de putere/energie. Rezultatele vor fi comparate cu cele opțiune folosind metoda exactă în care datele sunt preluate direct de la contoarele inteligente instalate la utilizatorii finali racordați la rețea [62].

Evaluarea impactului profilurilor tip PTPC și PTPI-P s-a făcut pentru estimarea stării unei RD-JT ce alimentează o zonă rurală dintr-un SDEE, a cărei topologie este prezentată în Figura 4.16. Caracteristicile rețelei analizate sunt următoarele:

- Rețeaua este alimentată de la un PT MT/JT care are un transformator cu $S_n = 250$ kVA fără reglaj sub sarcină.
- 95 de stâlpi, primul stâlp la care sunt racordați utilizatorii finali este stâlpul P8.
- Lungimea totală este de 3,5 km.
- 146 de utilizatori finali racordați la rețea, dintre care 23 prosumatori și 123 consumatori.

- 145 de utilizatori finali au bransament monofazat (24 sunt racordați la faza *a*, 65 la faza *b* și 57 la faza *c*) și 1 utilizator final cu bransament trifazat.
- Consumatorii aparțin primelor două categorii asociate consumului de energie (Categorია I – până în 400 kWh/an și Categoria II – între 400 și 1250 kWh/an).
- Toți prosumatorii au sisteme de panouri FV cu capacitatea instalată de 3 kW (20 prosumatori, reprezentând 87% din total) și 5 kW (3 prosumatori, reprezentând 13% din total), fără SSE. Energia anuală injectată în rețea a acestor prosumatori a fost sub 2000 kWh/an, ceea ce îi clasifică în clasa C1 determinată în paragraful 4.3 (caracterizată de capacități instalate de sub 5 kW și energie anuală injectată de sub 2200 kWh/an).

Prin simularea comportamentului acestor profiluri în condiții reale, se pot identifica limitele de integrare a prosumatorilor în rețelele existente și se pot propune soluții tehnice și operaționale pentru optimizarea funcționării rețelei în contextul creșterii penetrării GD de mică putere.



Tabelul 4.6. Caracteristicile tehnice ale tronsoanelor de rețea

Nr.crt.	Lungimea [km]	Număr faze	Secțiunea conductorului [mm ²]		Tip conductor
			Fază	Neutru	
1	0,120	3	50	50	T*
2	2,080	3	50	50	C**
3	0,960	3	35	35	C**
4	0,280	1	25	25	C**
5	0,080	1	16	25	C**

T* - torsardat; C** - clasic

Figura 4.16. Topologia RD-JT analizată

Profilurile tip ale puterilor cerute de consumatorii clasificați în categoriile I (< 400 kWh/an) și II (400 ÷ 1200 kWh/an) ale consumurilor anuale de energie sunt prezentate în Figurile 4.17 și 4.18 [63]. Aceste profiluri evidențiază tiparele de consum specifice zonelor rurale, marcate de variații sezoniere și o dependență crescută de anumite intervale orare, aspecte esențiale pentru dimensionarea corectă a rețelei și pentru implementarea unor soluții de management a sarcinii adaptate nevoilor locale.




Figura 4.17. Profilurile tip ale puterilor cerute (PTPC) de consumatorii clasificați în categoria I




Figura 4.18. Profilurile tip ale puterilor cerute de consumatorii clasificați în categoria II

În continuare, estimarea stării RD-JT analizate s-a făcut prin determinarea valorilor variabilelor de stare cu ajutorul calculelor de regim efectuate cu algoritmul “înainte/înapoi” (“forward/backward”) [64] pentru o zi reprezentativă considerând două scenarii:

- **Scenariul 1.** Utilizarea profilurilor PTPC pentru consumatori și PTPI pentru prosumatori;
- **Scenariul 2.** Utilizarea profilurilor de putere încărcate din SCI.

Rezultatele obținute pentru cele două scenarii permit compararea impactului diferitelor abordări de modelare a consumului și producției asupra performanței RD-JT. Scenariul bazat pe profiluri tip oferă o imagine generală, utilă pentru analize strategice și planificare pe termen lung, în timp ce scenariul bazat pe date reale din sistemul de contorizare inteligentă oferă un nivel mai ridicat de acuratețe, evidențiind fluctuațiile reale ale consumului și injectiei de energie. Această comparație evidențiază importanța utilizării datelor de contorizare inteligentă în evaluarea stării rețelei și în fundamentarea deciziilor de investiții și exploatare.




Figura 4.19. Comparare între pierderile de energie în conductoarele de fază și neutru, respectiv totale, calculate în cele două scenarii




Figura 4.20. Comparație între valorile minime înregistrate în rețea la nivelul stâlpilor, calculate în cele două scenarii




Figura 4.21. Comparație între valorile maxime înregistrate în rețea la nivelul stâlpilor calculate în cele două scenarii

Rezultatele obținute la nivelul pierderilor de putere și energie evidențiază faptul că există un dezechilibru la nivelul sarcinilor de pe cele trei faze (faza *b* este cu mult mai încărcată decât celelalte două faze, *a* și *c*) ceea ce conduce la pierderi suplimentare cu valori mari în conductorul de nul, apropiate cu cele de pe faza *b*. În aceste condiții, OD trebuie să aplice măsuri tehnice care să conducă la echilibrarea sarcinii pe cele trei faze.

Erorile calculate între pierderile de energie, valorile minime și maxime ale tensiunii de fază calculate în cele două scenarii sunt prezentate în Figura 4.22 (a, b, c). Aceste erori oferă o perspectivă relevantă asupra diferențelor generate de metodele de estimare a sarcinii, evidențiind sensibilitatea rețelei la variațiile de consum și producție.




Figura 4.22. Reprezentarea radar a erorilor procentuale calculate pentru pierderile de energie, tensiunile minime și maxime

Rezultatele obținute au confirmat performanța cadrului propus în estimarea stării RD-JT dintr-un SDEE care integrează prosumatori cu sisteme de panouri FV în cazul unui studiu de caz în care au fost analizate două scenarii: S1 - bazat pe profilurile tip pentru puterea cerută de consumatori și pentru puterea injectată de prosumatori și S2 - bazat pe profilurilor de putere înregistrate în SCI. Între cele două scenarii s-au înregistrat erori procentuale foarte mici atât la nivelul pierderilor de energie, cât și al celui asociat tensiunilor de fază minime și maxime.

Capitolul 5

Reglajul de tensiune în sistemele de distribuție a energiei electrice cu prosumatori integrați

5.1. Aspecte generale privind reglajul de tensiune

Pentru rețelele cu penetrare ridicată a prosumatorilor, utilizarea transformatoarelor cu CPRS poate fi îmbunătățită prin integrarea IA în procesele de reglare a tensiunii. Această abordare permite creșterea gradului de penetrare în limita capacității infrastructurii existente, asigurând stabilitatea sistemului.

Majoritatea studiilor care au evaluat efectele prosumatorilor, în special cei care au instalat sisteme de panouri FV, s-au concentrat pe profilul de tensiune din RD-JT, așa cum se observă în Figura 5.1 [64]. Din analiza reprezentării grafice pot fi evidențiate diferențele semnificative între profilurile de tensiune în cele două scenarii. În primul scenariu și anume **RD-JT pasivă, fără prosumatori integrați** se observă că tensiunea se menține într-un interval relativ stabil, determinat de caracteristicile topologice ale rețelei și de sarcina consumatorilor, existând posibilitatea de a scădea sub valoarea minimă la vârful de sarcină. În al doilea scenariu **RD-JT activă, cu prosumatori integrați** se pot observa fluctuații mai mari ale tensiunii, cauzate de injecțiile de putere ale sistemelor de panouri FV montate la prosumatori, care variază în funcție de condițiile meteorologice și de nivelul cantității de energie consumată local.




Figura 5.1. Evoluția tensiunii în RD-JT în absența și în prezența prosumatorilor cu sisteme de panouri FV instalate [65]

5.2. Metode și mijloace de reglaj al tensiunii în sistemele de distribuție a energiei electrice

Sistemele de reglare a tensiunii în rețelele de distribuție joasă tensiune (RD-JT) utilizează diverse abordări tehnologice, dintre care două metode fundamentale se remarcă prin aplicarea lor practică.

Prima metodă, denumită *menținerea tensiunii constante*, stabilizează nivelul tensiunii indiferent de fluctuațiile sarcinii. Această tehnică este frecvent implementată în rețelele echipate cu transformatoare MT/JT fără reglaj sub sarcină. Dezavantajul principal constă în dificultatea de a determina poziția optimă care să garanteze parametri normali în toate punctele rețelei, mai ales în condițiile variațiilor simultane ale consumului și generării fotovoltaice.

A doua abordare, *compensarea căderii de tensiune* pe linie, oferă o soluție dinamică prin monitorizarea parametrilor de rețea. Dispozitivele specializate măsoară tensiunea și curentul pe partea de joasă tensiune a stațiilor de transformare, iar prin calculul unei impedanțe echivalente raportate la un punct virtual de sarcină se realizează corecția necesară. Sistemul ajustează automat poziția comutatorului de ploturi pentru a menține tensiunea la valoarea prestabilită, utilizând mecanisme de întârziere și zone tampon pentru evitarea oscilațiilor bruște [70].

În situații cu penetrare ridicată a GD, particularitățile circulațiilor de putere impun adaptări metodologice. Creșterea semnificativă a energiei injectate în rețea poate duce la reducerea circulațiilor de putere prin transformator sau chiar la inversarea direcției fluxului energetic. Aceste fenomene creează scenarii complexe de reglaj, unde tensiunile pot scădea sub limitele admise pe anumite faze cu consumatori neechilibrați.

Transformatoarele din PT MT/JT pot fi echipate cu comutatoare de ploturi cu reglaj sub sarcină (CPRS) pentru a regla tensiunea în limitele admisibile în toate nodurile SDEE. Aceste dispozitive ajustează tensiunea pe partea de joasă tensiune prin modificarea treptată a prizei de funcționare (9, 17 sau 35 poziții disponibile) [75].

Mecanismul de control al CPRS funcționează pe principiul "pas cu pas". Dispozitivul primește un semnal de comandă care determină modificarea plotului (în creștere sau descreștere față de poziția mediană) pentru a menține tensiunea aproape de valoarea de referință U_{ref} [77]. Inițial proiectate pentru a compensa căderile de tensiune pe linie, CPRS-urile pot provoca acum creșteri neintenționate ale tensiunii din cauza energiei injectate de prosumatori. În acest context, în continuare se dezvoltă și testează o soluție eficientă și rezilientă de reglaj al tensiunii bazată pe un sistem expert propusă pentru a elimina problemele legate de depășirile limitelor admisibile stabilite

de către standardul de performanță care sunt din ce în ce în RED-JT având un grad de penetrare ridicat al prosumatorilor cu sisteme de panouri FV montate.

5.3. Sistem expert pentru reglajul de tensiune în rețelele electrice de distribuție de joasă tensiune active

Un sistem expert (SE) este o componentă a IA care utilizează reguli bazate pe cunoștințe pentru a identifica soluții la probleme specifice din diverse sisteme/procese, printre care și SDEE. Proiectarea și dezvoltarea structurii acestuia este similară unui program informatic avansat care încearcă să imite capacitățile unui expert uman prin colectarea surselor de cunoștințe utilizate pentru a îndeplini unul sau mai multe obiective. Astfel, cunoștințele sunt preluate de la un expert uman și transformate într-un set de reguli care reprezintă cunoștințele din domeniu. Principalele componente ale unui SE sunt următoarele: modulul bazei de cunoștințe, motorul de inferență, modulul de luare a deciziilor, facilități de explicare și interfața cu utilizatorul.

Figura 5.2 prezintă structura SE propus pentru reglajul de tensiune în RD-JT active (având un grad de penetrare ridicat al prosumatorilor cu sisteme de panouri FV montate). [87]

Baza de informații a SE include două categorii: baza de reguli și baza de date. Baza de reguli stochează reguli și fapte, în timp ce cealaltă, împărțită în partiții statice și dinamice, este asociată cu înregistrarea faptelor imuabile (care nu se schimbă).




Figura 5.2. Structura SE propus utilizat pentru reglajul tensiunii în RD-JT active [87]

Motorul de inferență accesează datele care, printr-un raționament bazată pe reguli, decide dacă este necesar să modifice sau nu poziția plotului de funcționare al transformatorului din PT MT/JT care alimentează RD-JT astfel încât toate tensiunile să fie între limitele admisibile impuse prin standardul de performanță. În SE, un set de reguli de tipul IF-THEN reprezintă cunoștințele domeniului, iar datele sunt asociate unei mulțimi de fapte referitoare la situația curentă. Datele și regulile sunt apoi comparate cu faptele din baza de date. Când condițiile unei reguli corespund unui fapt, sistemul activează regula și componenta sa activă este executată. Fiecare regulă are sintaxa următoare:

„Dacă condițiile sunt îndeplinite, atunci se iau măsuri.”

Raționamentul bazat pe reguli, integrat în motorul de inferență și utilizat pentru analiza datelor, are următoarea desfășurare a etapelor pe care le integrează prezentată în continuare.

Baza de cunoștințe conține regulile concepute pentru a îndruma SE în îndeplinirea sarcinii sale (nivelul corespunzător de tensiune conform standardului de performanță). Astfel, SE are un obiectiv, iar motorul de inferență încearcă să găsească dovezile care să-l susțină. Mai întâi, baza de cunoștințe este interogată pentru a găsi regulile care ar putea duce la soluția dorită. Astfel de reguli trebuie să aibă obiectivul integrat în componenta THEN (acțiunea) [87]. Dacă o astfel de regulă este găsită și componenta condiției asociate cu IF corespunde informațiilor din baza de date, atunci regula este activată și obiectivul este demonstrat.

Informațiile colectate la momentul de timp t de către contoarele inteligente (puteri active și reactive) instalate la utilizatorii finali (prosumatori și consumatori) sunt trimise către concentratorul de date de la nivelul PT MT/JT prin sistemul de comunicație. Datele corespund unui regim permanent de funcționare al RD-JT active, unde poziția plotului, identificată prin variabila α , corespunde momentului de timp anterior ($t-1$), cu $t = 1, \dots, T$, unde T reprezintă perioada analizată.

SE stabilește poziția plotului de funcționare începând cu momentul t , $t = 1, \dots, T$, pe baza datelor obținute din calculele de regim permanent realizate folosind algoritmul propus în [86], utilizând poziția plotului de funcționare din momentul de timp anterior ($t-1$), $\alpha_{(t-1)}$, și informațiile din baza de date (statice și dinamice) [87].

Pasul următor confirmă disponibilitatea datelor pentru a determina valorile limită (inferioară, $U^{\min}$, și superioară, $U^{\max}$) ale tensiunii de fază la nivelul tuturor nodurilor (stălpilor) din RD-JT activă.

$$U_{t,\alpha(t-1)}^{\min} = \min_{\gamma \in \{a,b,c\}} \{U_{t,\alpha(t-1)}^{\{\gamma\}}\}, \quad U_{t,\alpha(t-1)}^{\max} = \max_{\gamma \in \{a,b,c\}} \{U_{t,\alpha(t-1)}^{\{\gamma\}}\} \quad (5.1)$$

$$e = 1, \dots, NE, \quad t = 1, \dots, T, \quad \alpha = 1, \dots, N_{plot}$$

unde: γ – indexul folosit pentru fazele RD-JT, $\gamma \in \{a, b, c\}$; NE – variabila care se referă la numărul total de noduri din RD-JT; e – indexul asociat unui anumit nod din RD-JT; N_{plot} – numărul total de ploturi al CPRS; α – indexul corespunzător poziției plotului de funcționare; T – numărul total de momente de timp definite în perioada analizată pentru achiziția de date (este identic cu numărul total de eșantioane); t – un moment din perioada de timp analizată; $U_{t,\alpha(t-1)}^{(\gamma)}$ - tensiunea pe faza γ , cu $\gamma \in \{\gamma_a, \gamma_b, \gamma_c\}$, calculată în fiecare nod (stâlp) e , $e = 1, \dots, NE$, pentru momentul de timp t , $t = 1, \dots, T$, determinată pentru poziția α a plotului corespunzătoare cu momentul de timp anterior ($t-1$).; $U_{t,\alpha(t-1)}^{min}$, $U_{t,\alpha(t-1)}^{max}$ – valorile limită inferioară și superioară ale tensiunii de fază din RD-JT determinate la momentul de timp t pentru poziția α a plotului corespunzătoare cu momentul de timp anterior ($t-1$).

Procesul de reglaj al tensiunii la fiecare moment de timp t este iterativ, având drept criteriu de oprire valorile admisibile (minimă și maximă) ale tensiunii de fază din RD-JT:

$$U_{t,\alpha(t-1)}^{min} \geq U_{RD-JT}^{min}, U_{t,\alpha(t-1)}^{max} \leq U_{RD-JT}^{max} \quad t = 1, \dots, T; \quad \alpha = 1, \dots, N_{plot} \quad (5.2)$$

Dacă valorile $U_{t,\alpha(t-1)}^{min}$, $U_{t,\alpha(t-1)}^{max}$ depășesc valorile admisibile (U_{RD-JT}^{min} și U_{RD-JT}^{max}) specificate în standardele de performanță a serviciului de distribuție a energiei electrice, atunci plotul de funcționare este modificată cu o poziție $\Delta\alpha_t^{(k)}$ în fiecare iterație k , $k = 1, \dots, N_{iter}$, unde N_{iter} este numărul maxim de iterații admise de decident, asociată momentului de timp t , pe baza următoarelor reguli [75, 83]:

$$\text{IF} \left\{ \left(U_{t,\alpha(t-1)}^{min} < U_{RD-JT}^{min} \right) \text{AND} \left(U_{t,\alpha(t-1)}^{max} \leq U_{RD-JT}^{max} \right) \right\} \text{ THEN } \Delta\alpha_t^{(k)} = \alpha_{(t-1)} + 1 \quad (5.3)$$

$$\text{IF} \left\{ \left(U_{t,\alpha(t-1)}^{min} \geq U_{RD-JT}^{min} \right) \text{AND} \left(U_{t,\alpha(t-1)}^{max} > U_{RD-JT}^{max} \right) \right\} \text{ THEN } \Delta\alpha_t^{(k)} = \alpha_{(t-1)} - 1 \quad (5.4)$$

$$\text{IF} \left\{ \left(U_{t,\alpha(t-1)}^{min} < U_{RD-JT}^{min} \right) \text{AND} \left(U_{t,\alpha(t-1)}^{max} > U_{RD-JT}^{max} \right) \right. \\ \left. \text{AND} \left(\left(U_{t,\alpha(t-1)}^{max} - U_{t,\alpha(t-1)}^{min} \right) > \Delta U_\alpha \right) \right\} \text{ THEN } \Delta\alpha_t^{(k)} = \alpha_{(t-1)} - 1 \quad (5.5)$$

$$\text{IF} \left\{ \left(U_{t,\alpha(t-1)}^{min} < U_{RD-JT}^{min} \right) \text{AND} \left(U_{t,\alpha(t-1)}^{max} > U_{RD-JT}^{max} \right) \right. \\ \left. \text{AND} \left(\left(U_{t,\alpha(t-1)}^{min} - U_{t,\alpha(t-1)}^{max} \right) > \Delta U_\alpha \right) \right\} \text{ THEN } \Delta\alpha_t^{(k)} = \alpha_{(t-1)} + 1 \quad (5.6)$$

unde:

$$\Delta U_{t,\alpha(t-1)}^{min} = U_{RD-JT}^{min} - U_{t,\alpha(t-1)}^{max}; \quad t = 1, \dots, T, \alpha = 1, \dots, N_{plot} \quad (5.7)$$

$$\Delta U_{t,\alpha(t-1)}^{max} = U_{t,\alpha(t-1)}^{max} - U_{RD-JT}^{max}; \quad t = 1, \dots, T, \alpha = 1, \dots, N_{plot} \quad (5.8)$$

În relațiile (5.7) și (5.8), ΔU_α reprezintă modificări ale plotului de funcționare cu o poziție. Totuși, plotul de funcționare poate fi modificat doar dacă sunt respectate restricțiile referitoare la banda moartă (BM) a CPRS [88]:

$$\left(\frac{U_{t,\alpha(t-1)}^{max} - U_r}{U_{ref}} \right) > BM; \left(\frac{U_r - U_{t,\alpha(t-1)}^{min}}{U_{ref}} \right) > BM; \quad t = 1, \dots, T, \alpha = 1, \dots, N_{plot} \quad (5.9)$$

unde U_{ref} este tensiunea de referință.

Când abaterea tensiunii depășește limita BM, având valoarea $\Delta U_\alpha/2$, se poate modifica plotul de funcționare. Utilizarea benzii moarte poate preveni efectul operațiilor inutile de schimbare a plotului.

Figura 5.3 prezintă organigrama procesului de reglaj a tensiunii în RD-JT utilizând raționamentul bazat pe reguli integrat în SE propus.




Figura 5.3. Organigrama procesului de reglaj a tensiunii în RD-JT utilizând raționamentul bazat pe reguli integrat în SE [75]

5.4. Testarea sistemului expert

SE proiectat și dezvoltat a fost testat folosind RD-JT alimentată dintr-un SDEE printr-un PT MT/JT (20/0.4 kV) prezentată în paragraful 4.4. al Capitolului 4.

PT este echipat cu un transformator de distribuție 20/0,4 kV cu următoarele specificații tehnice [87]:

- Puterea nominală: $S_n = 250$ kVA;
- Pierderile de putere în sarcină: $\Delta P_{Cu} = 2,35$ kW;
- Pierderile de putere mers la gol: $\Delta P_{Fe} = 0,27$ kW;
- CPRS are 9 ploturi (cu interval de reglaj $\pm 10\%$ față de plotul median), unde plotul median este 5, cu pas de reglaj de 2,5%, și un număr maxim de 700000 comutații fără a intra în operații de mentenanță [87].

RED-JT are 146 utilizatori finali racordați, dintre care 23 prosumatori și 123 consumatori. Toți utilizatorii finali sunt integrați în SCI, iar datele referitoare la profilurile de putere activă și reactivă sunt disponibile. Contoarele transmit valorile puterilor măsurate la un interval de 60 de minute concentratorul de date montat la nivelul PT MT/JT. Din analiza profilurilor de putere activă s-a constatat că 32 dintre cei 123 de consumatori au valori egale cu zero, astfel încât în continuare se vor prezenta detalii tehnice asociate celor 91 de consumatori care au consumuri de putere în perioada de analiză. În acest context, numai 114 utilizatori finali vor fi considerați în analiza efectuată, dintre care 23 prosumatori (asociați unui grad de penetrare de 20%).

Figura 5.4 prezintă sinteza asociată utilizatorilor finali referitoare la tipul de branșament (monofazat sau trifazat) și faza de racordare (a, b sau c).




Figura 5.4. Sinteza a utilizatorilor finali referitoare la tipul de branșament și faza de racordare

RD-JT este situată într-o zonă cu un potențial solar foarte ridicat, astfel încât se preconizează o creștere semnificativă a numărului de consumatori care doresc să devină prosumatori având

sistemul de producere a energiei bazat pe panouri FV, considerând contextul actual favorabil din România.

În cadrul studiului au fost considerate mai multe scenarii caracterizate de următorii indicatori: gradul de penetrare (GP), $GP \in \{0\%, 10\%, 20\%, 30\%, 40\%, \text{și } 50\%\}$; evoluția consumului, EC , $EC \in \{-10\%, -5\%, 0\%, +5\%, +10\%\}$; și producția de energie a panourilor FV, PE_{FV} , din luna care include ziua analizată, $PE_{FV} \in \{m_{PE}^{FV} - 2\sigma_{PE}^{FV}, m_{PE}^{FV}, m_{PE}^{FV} + 2\sigma_{PE}^{FV}\}$, unde m_{PE}^{FV} and σ_{PE}^{FV} reprezintă media și dispersia calculate pentru PE asociate unui sistem cu panouri FV cu o anumită capacitate instalată din zona geografică în care se află RD-JT, pentru o lună dintr-un an (în cazul nostru, iunie).

$$m_{P,t}^{\{S_{FV}\}} = \frac{1}{N_z} \sum_{z=1}^{N_z} P_{t,z}^{\{S_{FV}\}}, \quad t = 1, \dots, 24 \quad (5.10)$$

$$\sigma_{P,t}^{\{S_{FV}\}} = \sqrt{\frac{1}{N_z} \sum_{d=1}^{N_z} \left(P_{t,z}^{\{S_{FV}\}} - m_{P,t}^{\{S_{FV}\}} \right)^2}; \quad t = 1, \dots, 24 \quad (5.11)$$

unde: N_z reprezintă numărul de zile din perioada analizată (o lună – iunie); $P_{t,z}^{\{S_{FV}\}}$ corespunde puterii produse la momentul de timp t , $t = 1, \dots, 24$, din ziua z de sistemul cu panouri FV S_{FV} , unde $S_{FV} \in \{3 \text{ kW}, 5 \text{ kW}\}$.

Cazul real este asociat gradului de penetrate de 20%. Dar pentru o comparație sugestivă în care să fie evidențiat impactul tranziției de la o RD-JT pasivă la RED-JT activă cu integrare din ce în ce mai ridicată a numărului de prosumatori s-au considerat și grade de penetrare mai mici decât cel real.

Cunoscând valorile m_{PE}^{FV} și σ_{PE}^{FV} , PE_{FV} cu o probabilitate (nivel de încredere) de 0,95 aparținând intervalului de încredere considerat $[m_{EP}^{PV} - 2\sigma_{EP}^{PV}, m_{EP}^{PV} + 2\sigma_{EP}^{PV}]$. Aceasta înseamnă că, în aproape toate cazurile, valorile nu vor depăși intervalul specificat. Chiar și în situația celor 5% din cazuri, erorile vor avea valori mici [89].

Profilurile tip de generare au fost obținute prin introducerea locației geografice a RD-JT, a modului de instalare a panourilor FV (pe acoperiș) și a tipului de panouri în platforma PVGIS [90].

Figurile 5.5 și 5.6 prezintă profilele de generare ale celor două sisteme pe panouri FV (3 și 5 kW) obținute pe baza prelucrărilor statistice folosind indicatorii media (m_{PE}^{FV}) și dispersia (σ_{PE}^{FV}): $m_{EP}^{FV} - 2\sigma_{EP}^{FV}$ (producție de energie scăzută), m_{PE}^{FV} (producție medie de energie) și $m_{EP}^{FV} + 2\sigma_{EP}^{FV}$ (producție de energie ridicată), determinate pentru luna iunie și utilizate în scenariile analizate.

Bara de MT a PT a fost aleasă în studiul nostru ca fiind nodul de echilibru folosit în calculele de regim permanent, dar toate rezultatele prezentate în continuare se vor referi numai la RD-JT pentru a evidenția impactul SE prospus asupra stării rețelei.




Figura 5.5. Profilurile sistemului de panouri FV cu o putere instalată de 3 kW asociate unor producții scăzute de energie ($m - \sigma$), medie (m) și ridicată ($m + \sigma$)




Figura 5.6. Profilurile sistemului de panouri FV cu o putere instalată de 5 kW asociate unor producții scăzute de energie ($m - \sigma$), medie (m) și ridicată ($m + \sigma$)

Numărul scenariilor obținute din combinațiile dintre cei trei indicatori este:

$$N_{SC} = GP \times EC \times PE_{FV} = 5 \times 5 \times 3 = 75,$$

la care se adaugă scenariul de bază (S_0), reprezentat de situația actuală în care $GP = 0$, $EC = 0$, and $PE_{PV} = 0$, a se vedea Tabelul 5.2.

Figura 5.7 prezintă agregarea puterilor active la nivelul barei de JT (0,4 kV) a PT pentru ziua analizată asociată scenariului S_0 (RD-JT pasivă, fără prosumatori integrați) în studiul de caz.

Această reprezentare permite observarea variației consumului total de energie activă pe parcursul unei zile caracteristice, fără influența injectiilor din surse regenerabile. Se evidențiază un profil de sarcină clasic, cu două vârfuri principale – dimineața și seara – specifice consumului rezidențial tradițional.

În scenariul S_0 , plotul de funcționare al transformatorului este $\alpha_t = 8$, indiferent de momentul de timp (identificat la nivel de oră) t , $t = 1, \dots, 24$. Se pot observa diferențe mari între sarcinile injectate în RD-JT pe cele trei faze, cu un efect negativ asupra pierderilor de energie din cauza valorii mari a gradului de dezechilibru care se reflectată prin circulații suplimentare de putere în conductorul neutru, a se vedea Figura 5.8.

Cele mai mari pierderi de energie sunt pe faza b (48,4%), urmate de cele în conductorul neutru (38,5%), faza c (9,6%) și faza a (3,4%). Valorile prezentate au fost raportate la pierderile totale de energie (77,03 kWh).




Figura 5.7. Agregarea competențelor active la nivelul JT (0,4 kV) al SDEE pentru ziua analizată din iunie asociată cu scenariul S0




Figura 5.8. Pierderile de energie în conductoarele RED-JT în perioada analizată (24 de ore)

Valorile obținute evidențiază, de asemenea, un grad de dezechilibru ridicat al încărcării celor trei faze, ceea ce reprezintă o caracteristică comună a SDEE din România. Astfel, OD ar trebui să rezolve problema dezechilibrului încărcării fazelor înainte de a integra prosumatori, care ar putea cauza probleme suplimentare, așa cum va fi prezentat în continuare. În ceea ce privește calitatea tensiunii, toate tensiunile fazelor la nivelul fiecărui nod (stâlp) se încadrează în intervalul admisibil $[-10\%, +10\%]$, conform Standardului European EN 50160 [91], chiar în cazul în care se păstrează aceeași poziție pentru plotul de funcționare $\alpha = 8$. Figura 5.9 prezintă variația tensiunii de fază pe întreaga perioadă analizată la nivelul stâlpului de capăt P88, în care se pot observa multe valori foarte apropiate de limita inferioară ($U^{min} = 0,9 \cdot U_n$).




Figura 5.9. Valorile tensiunilor de fază la nivelul stâlpului de capăt (P88)

Analiza valorilor prezentate a evidențiat faptul că în 40 de scenarii (53,3%) din numărul total (75 scenarii), valoarea maximă a tensiunii pe fază înregistrată în RD-JT a depășit limita superioară admisibilă (1,1 u.r.). Valorile exprimate în unități relative au fost determinate prin raportarea

valorilor absolute în urma calcului de regim permanent la valoarea normală ($U_n=230V$). Toate valorile care depășesc 1,1 u.r. au fost evidențiate în tabel cu caractere albine. Aceste situații au fost înregistrate pe fazele a și c , unde sarcina solicitată de consumatori a fost mică, iar puterea injectată de prosumatori a fost mare, ceea ce a dus la creșteri între 0,005 u.r. ($GP = 20\%$, $EC = 10\%$ și PE^H_{FV}) și 0,185 u.r. ($GP = 50\%$, $EC = -10\%$ și PE^H_{FV}).

În ceea ce privește pierderile de energie, valori mai reduse decât în scenariul de bază, $S0$ ($\Delta W = 77,03$ kWh) au fost înregistrate în 58 de scenarii (77,33% din numărul total) Valori mai ridicate, evidențiate cu albine în tabel, au fost înregistrate pentru $GP = 40\%$, 50% , PE^H_{FV} și toate valorile considerate pentru variabila EC , $EC \in \{-10, -5, 0, 5, 10\}$. De asemenea, pierderile de energie scad de la valori mai mici către cele mai mari ale variabilei EC și cresc de la stânga la dreapta de la valori mai mici către cele mai ridicate ale variabilelor GP și PE^H_{FV}), situații des întâlnite în RD-JT. Cele mai mici pierderi de energie corespund scenariilor $S31 - S35$ cu $GP = 30\%$ și pentru toate valorile variabilei EC , $EC \in \{-10, -5, 0, 5, 10\}$, și PE^L_{FV} .

Figura 5.10 prezintă matricea de calitate a tensiunii care cuprinde valorile maxime posibile ale tensiunii de fază în RD-JT, evidențiind scenariile critice (culoare roșie și dimensiune mai mare a caracterelor), astfel încât să OD să poată lua în considerare măsurile corective care se impun. Liniile matricei corespund valorilor variabilei EC (de sus în jos, de la valori mici la valori mari), iar coloanele sunt asociate diverselor cazuri corespunzătoare valorilor variabilelor PE^H_{FV} și GP care se succed una după alta, de la stânga la dreapta.

Fără implementarea unor mecanisme automate de reglare și monitorizare în timp real, pot apărea abateri semnificative de tensiune care afectează calitatea alimentării. Astfel, este esențială dezvoltarea unei strategii de control adaptiv care să asigure menținerea parametrilor de funcționare în limitele normate, chiar și în condiții de funcționare variabilă.




Figura 5.10. Matricea de calitate a tensiunii asociată valorilor maxime posibile înregistrate în toate scenariile analizate fără aplicarea SE propus pentru reglajul tensiunii




Figura 5.11. Matricea de calitate a tensiunii asociată valorilor maxime posibile înregistrate în toate scenariile analizate cu aplicarea SE propus pentru reglajul tensiunii

Astfel, rezultatele au fost obținute prin aplicarea controlului tensiunii bazat pe SE pentru scenariile cu probleme de tensiune identificate în pasul anterior. Tabelele 5.5 și 5.6 prezintă datele asociate acestor scenarii, evidențiate cu caracterere aldine. Pentru scenariile fără probleme de tensiune, valoarea maximă a tensiunii corespunde stării de echilibru fără aplicarea controlului tensiunii bazat pe SE. Problemele de tensiune au fost eliminate pentru 30 din cele 40 de scenarii în care valorile maxime ale tensiunii pe fază au depășit limita superioară admisă.

Scenariile critice cu probleme de tensiune, (S56 – S60 și S71 – S75), identificate cu culoare roșie și caractere aldine în Tabelul 5.5 și în matricea de calitate a tensiunii asociată valorilor maxime posibile înregistrate în toate scenariile analizate prezentată în Figura 5.11, sunt asociate variabilelor $GP \in \{40\%, 50\%\}$, PE_{FV}^H și $EC \in \{-10\%, -5\%, 0\%, 5\%, 10\%\}$, chiar dacă valoarea maximă a tensiunii pe fază a fost redusă cu valori între 0,12 u.r. (scenariul S56, $GP = 40\%$, PE_{FV}^H și $EC = -10\%$), ceea ce reprezintă 9,5%, și 0,15 u.r. (scenariul S75, $GP = 50\%$, PE_{FV}^H și $EC = +10\%$), ceea ce reprezintă 11,6%. Totuși, cel puțin 95% din intervalele de timp, tensiunile de fază au avut valori în intervalu $[-10\%, +10\%]$.

Pierderile de energie în conductoarele rețelei pentru scenariile (S26 – S30), unde $GP = 20\%$, PE_{FV}^H și $EC \in \{-10\%, -5\%, 0\%, 5\%, 10\%\}$, și (S36 – S40), unde $GP = 30\%$, PE_{FV}^A și $EC \in \{-10\%, -5\%, 0\%, 5\%, 10\%\}$, sunt ușor mai mici, între 0,21% (S26 și S36) și 5,16% (S30). Pentru toate celelalte scenarii (S41 – S45 și S51 – S75), valorile sunt mai mari, în special pentru S56 – S60, unde $GP = 40\%$, PE_{FV}^H și $EC \in \{-10\%, -5\%, 0\%, 5\%, 10\%\}$, și S71 – S75, unde $GP = 50\%$, PE_{FV}^H și $EC \in \{-10\%, -5\%, 0\%, 5\%, 10\%\}$.

Ultimele scenarii critice au probleme de tensiune (după cum a fost subliniat anterior) din cauza cantității mari de energie injectată de prosumatori în rețea. În ceea ce privește aceste scenarii, un alt indicator de calitate a tensiunii, I_{CT} , a fost folosit pentru a cuantifica variațiile de tensiune și arată procentul intervalelor de timp în care abaterile tensiunii pe fază depășesc limitele admisibile.

$$I_{CT} = \frac{\sum_{e=1}^{NE} \sum_{t=1}^T \left(\sum_{\gamma \in \{a,b,c\}} \left(\left| \frac{U_{e,t}^{(\gamma)} - U_n}{U_n} \right| \right) \right)}{N_{\gamma} \cdot NE \cdot T} \quad (5.12)$$

unde semnificația tuturor variabilelor a fost indicată în paragraful anterior.

Valorile indicatorului I_{CT} prezentate în lucrarea extinsă indică faptul că valorile superioare ale tensiunilor de fază în nodurile (la nivelul stâlpilor) RD-JT pentru toate cele 10 scenarii critice sunt poziționate în afara intervalului $[-10\%, +10\%]$, cu un procent între 1,73% și 4,98%. Procente mai mari, între 4,49% și 4,98%, au fost înregistrate în cazul scenariilor S71 – S75. În aceste condiții, OD trebuie să fie foarte atenți și să ia măsuri suplimentare pentru a îmbunătăți nivelul de tensiune

în RD-JT, iar una dintre aceste măsuri poate fi echilibrarea încărcării fazelor [92], având în vedere gradul mai mare de dezechilibru evidențiat în scenariul de bază, S0.

Reglajul de tensiune a fost tratat ca o problemă multi-obiectiv, unde plotul optim de funcționare, α_t^{opt} , determinat pentru fiecare moment de timp t , $t = 1, \dots, T$, conduce la minimizarea pierderile de energie și abaterilor de tensiune, în prezența restricțiilor tehnice asociate regimurilor de funcționare ale RD-JT [92].

Tabelul 5.8 prezintă erorile asociate pierderilor de energie între cele două metode, calculate cu ajutorul relației:

$$\delta \Delta W = \left(\frac{\Delta W_{MO} - \Delta W_{SE}}{\Delta W_{MO}} \right) * 100, [\%] \quad (5.13)$$

unde: ΔW_{MO} reprezintă pierderile de energie calculate cu metoda multi-obiectiv (MO) și ΔW_{SE} corespunde pierderilor de energie determinate cu SE propus.

Analiza datelor a evidențiat faptul că pierderile de energie sunt ușor mai mici în cazul SE propus comparativ cu metoda MO, cu diferențe între 0,85% ($GP = 50\%$, PE_{FV}^A și $EC = 10\%$) și 3,54% ($GP = 20\%$, PE_{FV}^A și $EC = -10\%$), a se vedea Tabelul 5.8.

Tabelul 5.8. Erorile dintre pierderile de energie calculate cu metoda MO și SE propus, [%]

CEC [%]	GP [%]														
	10			20			30			40			50		
	EP_{PV}^L	EP_{PV}^A	EP_{PV}^H	EP_{PV}^L	EP_{PV}^A	EP_{PV}^H	EP_{PV}^L	EP_{PV}^A	EP_{PV}^H	EP_{PV}^L	EP_{PV}^A	EP_{PV}^H	EP_{PV}^L	EP_{PV}^A	EP_{PV}^H
	$m_{EP}^{PV} - 2\sigma_{EP}^{PV}$	m_{EP}^{PV}	$m_{EP}^{PV} + 2\sigma_{EP}^{PV}$	$m_{EP}^{PV} - 2\sigma_{EP}^{PV}$	m_{EP}^{PV}	$m_{EP}^{PV} + 2\sigma_{EP}^{PV}$	$m_{EP}^{PV} - 2\sigma_{EP}^{PV}$	m_{EP}^{PV}	$m_{EP}^{PV} + 2\sigma_{EP}^{PV}$	$m_{EP}^{PV} - 2\sigma_{EP}^{PV}$	m_{EP}^{PV}	$m_{EP}^{PV} + 2\sigma_{EP}^{PV}$	$m_{EP}^{PV} - 2\sigma_{EP}^{PV}$	m_{EP}^{PV}	$m_{EP}^{PV} + 2\sigma_{EP}^{PV}$
-10	2,50	2,85	2,96	2,84	3,54	2,87	3,19	3,32	1,60	3,46	2,05	0,00	3,04	1,04	0,00
-5	2,18	2,10	2,10	2,08	2,78	2,99	2,29	3,60	1,56	3,02	2,28	0,00	2,90	1,02	0,00
0	1,89	1,77	1,64	1,75	2,31	2,68	1,91	2,60	1,61	2,14	2,05	0,00	2,18	1,16	0,00
5	1,50	1,78	1,68	1,77	2,19	2,60	1,84	2,50	1,41	2,10	1,77	0,00	2,31	0,94	0,00
10	1,34	1,61	1,47	1,79	1,84	2,32	1,60	2,21	1,38	1,80	1,50	0,00	2,08	0,85	0,00

Diferențe mari au fost înregistrate la nivelul variabilelor de optimizare (ploturile de funcționare ale CPRS). Comparația dintre cele două metode a fost realizată doar pentru scenariile critice, cu probleme de tensiune, a se vedea Tabelele 5.10 – 5.12 din lucrarea extinsă. Cu toate că există diferențe la nivelul variabilelor de optimizare, abaterilor asociate pierderilor de energie și abaterilor de tensiune au avut valori apropiate, ceea ce sugerează performanța SE propus.

Comparația cu una dintre cele mai eficiente metode prezentate în literatură de specialitate a demonstrat eficiența SE, cuantificată prin pierderi mai mici de energie și numărul mai mic de comutări ale CPRS pentru determinarea plotului optim de funcționare.

Capitolul 6

Sistemul SCADA în monitorizarea și conducerea sistemelor de distribuție a energiei electrice

6.1 Aspecte generale

Datorită necesității tot mai mari de introducere în SDEE a sistemelor moderne de automatizare a distribuției, conceptele de monitorizare și control integrate au suferit schimbări semnificative în ultimii ani, trecând de la o conducere bazată pe echipamente și dispozitive analogice la una care să folosească tehnologii numerice [93]. O astfel de provocare a condus la tranziția accelerată către un sistem SCADA inteligent (Smart Supervisory Control and Data Acquisition System), un sistem care integrează module de procesare a datelor bazate pe tehnici de IA.

Prin utilizarea modulelor bazate pe PLC și microprocesoare cu capabilități de procesare în timp real, sistemul asigură informații critice despre starea SDEE monitorizat. Aceste funcționalități permit:

1. Monitorizarea și controlul PT;
2. Managementul distribuitorilor de MT/JT ;
3. Monitorizarea și reglarea sarcinii utilizatorilor finali.

Din perspectiva arhitecturii software, un sistem SCADA poate integra una sau mai multe dintre aceste funcții, așa cum este ilustrat în Figura 6.2 [96].

Conform studiului, aproximativ 96% dintre OD utilizează un sistem SCADA pentru controlul stațiilor electrice. Aceștia îl folosesc în principal pentru:

- Menținerea tensiunii pe barele SET (ÎT/MT);
- Echilibrarea sarcinii;
- Monitorizarea curenților de circulație;
- Protecția împotriva suprasarcinilor;
- Detectarea defectelor la transformatoare.

6.2. Stadiul actual al abordărilor privind estimarea stării unui sistem de distribuție a energiei electrice

Determinarea numărului optim de PT-uri MT/JT integrate în SCADA pentru monitorizarea în timp real a stării SDEE reprezintă o problemă complexă din punct de vedere tehnic și economic pentru OD. Această problemă necesită dezvoltarea de metodologii avansate care să integreze:

- Algoritmi matematici pentru modelarea precisă a regimurilor de funcționare;
- Strategii de implementare eficiente din punct de vedere al costurilor;
- Sisteme de achiziție și procesare a datelor în timp real.

Profilurile reprezentative de sarcină au fost estimate folosind Sisteme Neuro-Fuzzy în cadrul studiului [97], pentru analiza datelor istorice. Diverse caracteristici, cum ar fi valoarea curentă a sarcinii, sarcinile înregistrate pentru ultimele 24 de ore și factorii modelului de estimare asociat unei săptămâni, au fost utilizate pentru a genera cea mai bună adaptare pentru o perioadă de o zi sau săptămână. Algoritmul propus a fost testat într-o RD-MT, obținând o eroare medie absolută procentuală (MAPE) de aproximativ 4%.

6.3. Metodologie de integrare optimă a sistemului SCADA pentru estimarea stării sistemelor de distribuție a energiei electrice

În cadrul acestui paragraf se prezintă o metodologie originală pentru amplasarea optimă a dispozitivelor RTU din sistemul SCADA în PT-uri pentru estimarea stării SDEE care include trei straturi, a se vedea Figura 6.3 [110]. Fiecare strat integrează abordări originale pentru atingerea obiectivelor propuse și găsirea soluțiilor la problemele tehnice subliniate în paragraful anterior:

- Prima etapă permite determinarea claselor de PT-uri cu caracteristici similare din punct de vedere al sarcinii tranzitate folosind algoritmului de clustering K-medii.
- Stratul 2 identifică clasele „candidat” și PT-urile pilot (care reprezintă soluția optimă) în care vor fi amplasate dispozitivele RTU integrate în SCADA. PT-urile pilot vor fi identificate având la bază minimizarea unei funcții obiectiv care integrează erorile de estimare obținute cu ajutorul modelelor de regresie liniară multiplă între PT-urile din clasele neincluse în mulțimea de „clase candidate” și PT-urile pilot.
- Stratul 3 permite estimarea stării SDEE pe baza sarcinii măsurate în PT-urile pilot și a sarcinilor determinate cu ajutorul modelelor de regresie pentru celelalte PT-uri. De asemenea, la nivelul acestui strat se află și un modul care verifică respectarea tuturor restricțiilor tehnice, având integrate funcții suplimentare necesare pentru a asista decidentul în implementarea strategiilor de exploatare optimă a SDEE.

Cele trei straturi vor fi detaliate în lucrarea extinsă pas cu pas, urmate de formulele și calcule aferente analizei de mai jos.

Testarea cadrului propus pe o zonă dintr-un SDEE urban reprezentată de o RD-MT cu 39 de posturi de transformare a demonstrat beneficii semnificative printre care includem și:

1. Reducerea costurilor de integrare

- Soluția optimă necesită integrarea doar a 12 din 39 PT-uri în sistemul SCADA (30,7%);
- Economie de aproximativ 70% față de monitorizarea completă a tuturor stațiilor.

2. Îmbunătățirea estimării stării SDEE

- Precizie crescută în determinarea parametrilor de stare (tensiuni, circulații de puteri, pierderi de puteri);
- Eficiență sporită în managementul SDEE.

Stratul 1

Pasul 1. Informațiile colectate din fiecare PT MT/JT al SDEE referitoare la profilurile de putere activă și reactivă (PPA și PPR) înregistrate în urma campaniilor de măsurători de sarcină și tensiune realizate de OD sunt preluate de către modulul de intrare. Profiluri PPA și PPR sunt înregistrate în baza de date și memorate în matricile $[P]$ și $[Q]$, având dimensiunile $T \times N_{EDS}$. Semnificația celor două variabile sunt exemplificate în lucrarea extinsă.

Pasul 2. Se calculează coeficienții de corelație între oricare două PT-uri, n și m , cu $n, m \in \{N_{EDS}\}$ și cu $n \neq m$, din SDEE analizat, iar valorile se memorează în matricea $[CC]$ de dimensiune $(N_{EDS} \times N_{EDS})$:

$$CC_{P_n, P_m} = \frac{Cov(P_n, P_m)}{\sigma_{P_m} \cdot \sigma_{P_n}} \quad (\forall) n, m \in \{N_{EDS}\}; \quad n \neq m \quad (6.3)$$

unde $Cov(P_m, P_n)$ reprezintă covarianța între două PPA (asociate PT-urilor n și m) din mulțimea PT-urilor; σ_{P_n} and σ_{P_m} reprezintă dispersia puterii active în cele două PT-uri, m și n , înregistrate în intervalul de timp T .

$$\sigma_n = \sqrt{\frac{1}{T} \sum_{t=1}^T (P_{t,n} - \bar{P}_n)^2}; \quad \bar{P}_n = \frac{1}{T} \sum_{t=1}^T P_{t,n} \quad n \in \{N_{EDS}\} \quad (6.4)$$

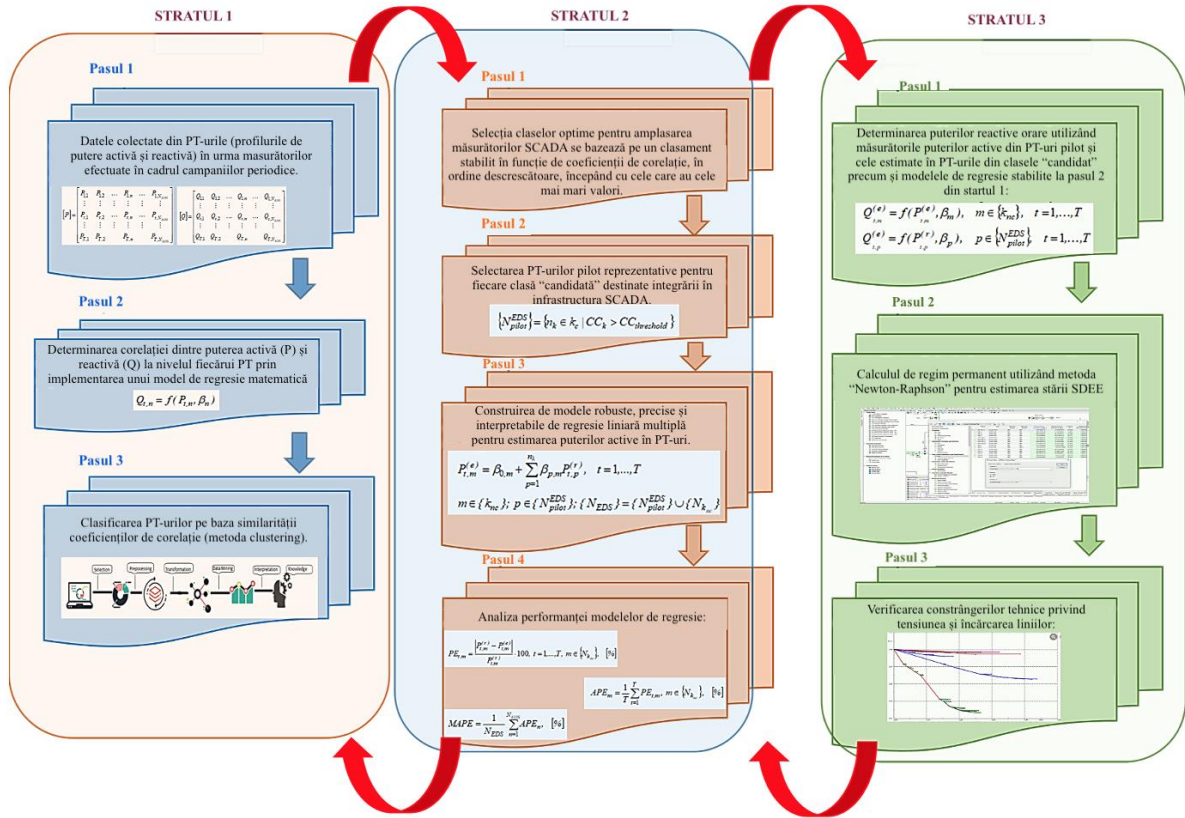


Figura 6.3. Etapele metodologiei de integrare optimă a sistemului SCADA în SDEE pentru estimarea stării SDEE [112]

Pasul 3. Se determină clasele de PT-uri caracterizate de valori apropiate ale coeficienților de corelație pe baza unui proces de clustering. Partiția optimă în clase reprezentative de PT-uri va fi identificată folosind algoritmul de clustering K-medii [113] la care se adaugă un test intern al claselor bazat pe un indicator de performanță asociat coeficientului global de siluetă (SGC) [114].

Stratul 2

Pasul 1. Se determină clasele „candidat” (notate cu k_c , $k_c \in \{K_{opt}\}$) ale PT-urilor pentru amplasarea echipamentelor RTU ale sistemului SCADA în scopul monitorizării sarcinii tranzitate, în interiorul cărora, se va întocmi un clasament în funcție de valorile coeficienților de corelație, în ordine descrescătoare, începând cu cele care au cele mai mari valori. Decidentul poate impune un prag, CC_{prag} , pentru valoarea medie a CC pentru a determina cele mai performante clase „candidat” [116].

Pasul 2. Identificarea mulțimii PT-urilor pilot care vor fi integrate în sistemul SCADA și care aparțin fiecărei clase „candidat”.

$$\{N_{pilot}^{EDS}\} = \{n_k \in k_c | CC_k > CC_{prag}\} \quad (6.14)$$

unde n_k reprezintă numărul de PT-uri din fiecare clasă „candidat” $k_c, k_c \in \{K_{opt}\}$.

PT-urile pilot vor reprezenta locațiile optime unde vor fi efectuate de către dispozitivele RTU integrate în sistemul SCADA, măsurători în timp real astfel încât să poată fi efectuate calculele de regim permanent în scopul estimării stării SDEE.

Pasul 3. Determinarea modelelor de regresie liniară multiplă pentru estimarea puterii active în PT-urile din celelalte clase care nu au fost incluse în mulțimea claselor „candidat”. Modelele vor utiliza PT-urile pilot identificate ca regresori la Pasul 2.

$$P_{t,m}^{(e)} = \beta_{0,m} + \sum_{p=1}^{n_k} \beta_{p,m} P_{t,p}^{(r)}, \quad t = 1, \dots, T, m \in \{k_{nc}\}; p \in \{N_{pilot}^{EDS}\} \quad (6.15)$$

$$\{N_{EDS}\} = \{N_{pilot}^{EDS}\} \cup \{N_{k_{nc}}\}$$

unde: $\{N_{k_{nc}}\}$ – mulțimea PT-urilor care nu sunt incluse în clasele „candidate”; $\{N_{pilot}^{EDS}\}$ – mulțimea PT-urilor pilot integrate în sistemul SCADA; $\{N_{EDS}\}$ – mulțimea PT-urilor din SDEE analizat; $P_{t,m}^{(e)}$ – valoarea puterii active orare estimate în PT-ul „ m ” din mulțimea $\{N_{k_{nc}}\}$, la ora $t, t=1, \dots, T$, în [kW]; $P_{t,p}^{(r)}$ – valoarea puterii active orare măsurate în PT-ul pilot „ p ” din mulțimea $\{N_{pilot}^{EDS}\}$, în [kW]; $\beta_{0,m}$ – coeficientul constant al modelului de regresie liniară multiplă asociat fiecărui PT din mulțimea $\{N_{k_{nc}}\}$; $\beta_{p,m}$ – coeficienții corespunzători fiecărui regresor asociat fiecărui PT pilot „ p ” din mulțimea $\{N_{pilot}^{EDS}\}$ în modelul de regresie liniară multiplă pentru fiecare PT din mulțimea $\{N_{k_{nc}}\}$.

Pasul 4. Analiza performanței modelelor de regresie pe baza următorilor indicatori de performanță: eroarea procentuală (PE), eroarea procentuală medie (APE) și eroare medie absolută procentuală (MAPE):

$$PE_{t,m} = \frac{|P_{t,m}^{(r)} - P_{t,m}^{(e)}|}{P_{t,m}^{(r)}} \cdot 100, \quad t = 1, \dots, T, \quad m \in \{N_{k_{nc}}\}, \quad [\%] \quad (6.16)$$

$$APE_m = \frac{1}{T} \sum_{t=1}^T PE_{t,m}, \quad m \in \{N_{k_{nc}}\}, \quad [\%] \quad (6.17)$$

$$MAPE = \frac{1}{N_{EDS}} \sum_{n=1}^{N_{EDS}} APE_n, \quad [\%] \quad (6.18)$$

Stratul 3

Pasul 1. Determinarea puterilor reactive orare utilizând valorile puterilor active măsurate în timp real în PT-urile pilot și valorile estimate în celelalte PT-uri neintegrate în clasele „candidat” și modelele de regresie stabilite la Pasul 3 din stratul 2.

$$Q_{t,m}^{(e)} = f(P_{t,m}^{(e)}, \beta_m), \quad m \in \{k_{nc}\}, \quad t = 1, \dots, T \quad (6.19)$$

$$Q_{t,p}^{(e)} = f(P_{t,p}^{(r)}, \beta_p), \quad p \in \{N_{pilot}^{EDS}\}, \quad t = 1, \dots, T \quad (6.20)$$

Pasul 2. Calculul regimului permanent utilizând metoda Newton-Raphson pentru determinarea stării SDEE.

Pasul 3. Verificarea restricțiilor tehnice referitoare la valorile tensiunilor din noduri și încărcarea elementelor de rețea (liniile electrice și transformatoarele de putere din PT-uri).

6.4. Testarea metodologiei

Un SDEE care cuprinde 39 PT-uri MT/JT (20/0,4 kV) dintr-o zonă urbană, alimentate prin trei distribuitori (D1, D2 și D3) care pleacă dintr-o SET ÎT/MT (110/20 kV), a fost utilizat pentru testarea metodologiei propuse în paragraful 6.3 [110]. Topologia SDEE analizat este ilustrată în Figura 6.3.




Figura 6.4. Topologia SDEE test cu 39 de PT-uri

Figura 6.6 prezintă puterea instalată pe fiecare distribuitor $S_{inst}^{(D)}$, $\{D\} \in \{D_1, D_2, D_3\}$ rezultată ca sumă a puterilor nominale ale transformatoarelor din PT-urile alimentate de fiecare dintre aceștia.

$$S_{inst}^{(D)} = \sum_{tr=1}^{N_{tr}^{(D)}} S_{n,tr}^{(D)}, \quad \{D\} \in \{D_1, D_2, D_3\} \quad (6.21)$$

Pasul 1 al *stratului 1* din cadrul metodologiei a presupus construirea bazelor de date formate de PPA și PPR, înregistrate într-o structură matriceală, conform relațiilor (6.1) și (6.2), care reprezintă rezultatul campaniilor de măsurători de sarcină și tensiune (MST) efectuată de OD în PT-uri pe parcursul unei săptămâni în perioada de vârf de sarcină a SDEE analizat.




Figura 6.6. Puterea instalată pe fiecare dintre cei trei distribuitori de MT ai SDEE analizat

Figurile 6.7 și 6.8 ilustrează, prin reprezentări de tip boxplot, variația puterilor active și reactive orare în perioada studiată. [117 – 118].




Figura 6.7. Reprezentarea boxplot a puterilor active în PT-urile din SDEE analizat în perioada de studiu (o săptămână)




Figura 6.8. Reprezentarea boxplot a puterilor reactive în PT-urile din SDEE analizat în perioada de studiu (o săptămână)

Cuartilele sunt indicatori statistici care împart un set de date ordonat crescător în patru părți egale:

$$x_{\frac{1}{4}} = \text{Cuartila}_1; x_{\frac{2}{4}} = \text{Cuartila}_2; x_{\frac{3}{4}} = \text{Cuartila}_3; x_{\frac{4}{4}} = \text{Cuartila}_4 \quad (6.22)$$

unde $x \in \{P, Q\}$.

Analiza valorilor indicatorilor statistici prezentați în Tabelele 6.3 și 6.4 evidențiază următoarele aspecte:

- 14 PT-uri au variații mari ale puterilor active și reactive (9, 10, 12, 14, 17, 22, 27, 29, 30, 31, 33, 34, 38 și 39),
- 7 PT-uri prezintă variații relativ reduse ale puterilor active și reactive (1, 2, 3, 4, 23, 24 și 25),
- 18 PT-uri au înregistrat variații normale ale puterilor active și reactive în perioada analizată.

Pasul 2 al stratului 1 presupune calculul coeficientului de corelație dintre profilurile de putere activă înregistrate din fiecare două PT-uri din SDEE analizat. Coeficienții sunt înregistrați în matricea $[CC]$, având dimensiunea $[39 \times 39]$. Figura 6.9 prezintă reprezentarea valorilor sub forma unei hărți termice (heatmap) asociate matricei $[CC]$, care conține valori cuprinse între -0,1 și 0,99. Majoritatea coeficienților de corelație au înregistrat valori peste 0,6 însă există și valori apropiate de 0 sau chiar negative, ceea ce indică faptul că, pe măsură ce o variabilă crește, cealaltă are o tendință inversă.




Figura 6.9. Harta termică asociată coeficienților de corelație

Aplicarea algoritmului de clustering K-medii, utilizat în *Pasul 3* al stratul 1, a condus la gruparea PT-urilor în clustere (clase) cu caracteristici similare în ceea ce privește valorile coeficienților de corelație. Numărul maxim de clustere (denumite în continuare clase) a corespuns unei partiții cu 6 clustere folosind relația (6.7). Testarea efectuată pentru a verifica performanța procesului de grupare s-a bazat pe coeficientul global de siluetă, CGS. În final, partiția optimă a fost identificată pentru un număr de 5 clase, pentru care CGS a avut valoarea 0,7168), a se vedea Figura 6.10. Reprezentarea coeficienților de siluetă determinați în interiorul fiecărei clase asociate partiției optime, $K_{opt} = 5$, este prezentată în Figura 6.11.




Figura 6.10. Valorile coeficientului global de siluetă pentru partițiile $K = 2 \div 6$




Figura 6.11. Coeficienții de siluetă determinați pentru fiecare clasă din partiția optimă $K_{opt} = 5$

Figura 6.12 evidențiază ponderea fiecărei clase și numărul de PT-uri pe care le include. Analiza datelor a indicat faptul că cea mai reprezentativă clasă este C5 (care conține 12 PT-uri) cu o pondere de 30,77%, urmată de clasele C1 și C2 (ambele incluzând 10 PT-uri) cu o pondere de 25,64%, C3 (5 PT-uri, 12,82%) și C4 (2 PT-uri, 5,13%).




Figura 6.12. Ponderea fiecărei clase și numărul de PT-uri alocate

Doi dintre cei trei distribuitori (D1 și D2) au posturile de transformare (PT) distribuite în toate cele cinci clase, în timp ce distribuitorul D3 are PT-uri aparținând doar trei clase (C1, C2 și C5).

Tabelul 6.5 prezintă indicatorii statistici (cuartile, medie și dispersie) calculați pentru fiecare clasă de posturi de transformare (PT) rezultată din procesul de clustering.

Tabel 6.5. Indicatori statistici ai claselor corespunzătoare partiției optime

Clasa	Cuartila					m_{CC}	σ_{CC}
	0	1	2	3	4		
C1	0,69	0,71	0,73	0,75	0,8	0,74	0,04
C2	0,51	0,57	0,595	0,68	0,71	0,62	0,07
C3	0,57	0,59	0,63	0,64	0,65	0,62	0,03
C4	0,40	0,40	0,40	0,40	0,40	0,40	0
C5	0,75	0,77	0,79	0,81	0,82	0,79	0,02

Analiza datelor a evidențiat următoarele concluzii: clasa cu cele mai mari valori ale cuartilelor este C5, având o variație în intervalul [0,75; 0,82], iar cele mai mici valori sunt asociate clasei C4 (coeficientul de corelație mediu având valoarea 0,4). Tendința indicatorului medie, m_{CC} , este aceeași, cu valoarea cea mai mare înregistrată pentru clasa C5 ($m_{CC} = 0,79$), urmată de C1 ($m_{CC} = 0,74$), C2 ($m_{CC} = 0,62$), C3 ($m_{CC} = 0,62$) și C4 ($m_{CC} = 0,4$).

Cea mai mare variație a coeficientului de corelație aparține clasei C2 (între 0,57 și 0,68), urmată de C3 (între 0,59 și 0,64), C1 (între 0,71 și 0,75) și C5 (între 0,77 și 0,81), a se vedea reprezentările boxplot din Figura 6.14. Clasa C4 (care conține doar 2 PT-uri) nu a fost luată în considerare, fiind nereprezentativă pentru analiză.

Rezultatele obținute cu metoda hibridă propusă, clustering-regresie liniară multiplă (C-RLM) au fost comparate cu două alte metode din literatură pentru a demonstra performanța abordării propuse: metoda regresiei liniare simple (RLS) și metoda bazată pe profilurile caracteristice de putere (PCP). [109]




Figura 6.15. Reprezentare radar a erorilor medii procentuale [%]

Rezultatele indică o îmbunătățire substanțială a procesului de estimare, subliniată de valorile erorilor medii procentuale obținute la nivelul PT-urilor cu metoda propusă (C-RLM), comparativ cu metodele RLS și PCP.

Tabelul 6.7. Indicatorii statistici ai erorilor medii [%]

Metoda	Cuartila				
	0	1	2	3	4
RLS	4,1	7,4	11,8	17,6	30,9
PCP	3,1	7,6	9,0	11,2	25,4
C-RLM	0,0	0,00	2,8	4,2	6,3

Tabelul 6.7 și Figura 6.16, care conțin indicatorii statistici asociați cuartilelor 0 - 4, întăresc această concluzie, evidențiind o scădere a valorii maxime de la 30,9% (obținută în cazul metoda RLS) și 25,4% (obținută cu metoda PCP) la 6,3% și o valoare mediană (cuartila 2) de la 11,8% (calculată pentru metoda RLS) și 9,0% (calculată pentru metoda PCP) la 2,8%. Metoda RLS a condus la cea mai mare variație a valorilor erorilor procentuale medii, în intervalul [4,1%, 30,9%], urmată de metoda PCP cu valori în intervalul [3,1%, 25,4%]. Metoda propusă, C-RLM, are cea mai mică variație a erorilor, în intervalul [0,0%, 6,3%].

Figura 6.17 prezintă valorile erorii medii absolute procentuale (MAPE) calculate pentru cele trei metode. Valoarea mediană a MAPE scade de la 12,8% în cazul metodei RLS, la 9,9% în cazul metodei PCP și 2,6% (aproape 3%) în cazul metodei propuse C-RLM. Această scădere semnificativă a valorii medianei MAPE sugerează o îmbunătățire considerabilă a preciziei prognozelor odată cu utilizarea metodei propuse C-RLM. Comparativ cu metodele tradiționale, C-RLM reușește să minimizeze eroarea de prognoză, indicând o performanță superioară în estimarea valorilor de putere activă și reactivă. Aceste rezultate subliniază eficiența metodei propuse în adaptarea la variabilitatea datelor, demonstrându-și potențialul de a îmbunătăți acuratețea prognozelor, esențială pentru exploatarea optimă a SDEE. Prin urmare, utilizarea C-RLM ar putea contribui la o mai bună planificare a resurselor și la reducerea costurilor operaționale asociate cu exploatarea SDEE.




Figura 6.17. Reprezentarea radar a erorii medii absolute procentuale, în [%]

În continuare, stratul 3 a metodologiei va folosi rezultatele obținute cu metoda propusă C-RLM pentru a estima starea SDEE pentru o perioadă de o zi (24 ore). Având în vedere că tensiunile calculate la nivelul PT-urilor cu metoda Newton-Raphson pe baza puterilor estimate sunt foarte apropiate de datele reale, fiind situate între limitele admisibile [+10%, -10%] față de tensiunea nominală, doar variabilele de stare obținute din calculele de regim efectuate cu ajutorul puterilor active și reactive reale și estimate la nivelul PT-urilor MT/JT vor fi prezentate: puterile active și reactive injectate (P_{inj} și Q_{inj}) în nodul de echilibru (considerat bara de 20 kV a SET ÎT/MT), puterile active și reactive cerute (P_{cer} și Q_{cer}) la nivelul PT MT/JT din SDEE, pierderile de putere activă și reactivă (ΔP și ΔQ), precum și puterea reactivă capacitivă a cablurilor (Q_{cap}) fiind analizate.

Prezența valorilor atipice, dar în limite acceptabile, sugerează că metoda poate fi aplicată cu încredere pentru monitorizarea în timp real și pentru luarea deciziilor SDEE, mai ales în contextul digitalizării și al creșterii numărului de prosumatori.

Totuși, toate variabilele de stare au valorile MAPE-uri sub 1%, așa cum se poate observa în Figura 6.19, ceea ce indică o performanță remarcabilă a procesului de estimare.




Figura 6.19. Erorile absolute procentuale medii (MAPE) ale variabilelor de stare corectate

Tabelul 6.12 prezintă o comparație între valorile agregate ale variabilelor de stare obținute în ambele cazuri (real și estimat) și erorile calculate.

Tabelul 6.12. Valorile agregate ale variabilelor de stare în perioada analizată (o zi)

Caz	$W_{P_{inj}}$ [MWh]	$W_{Q_{inj}}$ [MVarh]	$W_{P_{cer}}$ [MWh]	$W_{Q_{cer}}$ [MVarh]	ΔW_P [MWh]	ΔW_Q [MVarh]	$W_{Q_{cap}}$ [MVarh]
Date reale	316,20	199,96	315,11	211,29	1,092	0,692	12,030
Date estimate	315,77	199,95	314,67	211,29	1,096	0,693	12,028
Eroare [%]	0,138	0,007	0,140	0,004	0,330	0,032	0,014

Analiza procesului de estimare a puterii pentru perioada studiată a evidențiat:

- O scădere a erorii medii absolute procentuale de la 12,8% (metoda RLS [107])
- La 9,9% (metoda PCP [110])
- Până la 2,6% (metoda propusă C-RLM)

Această îmbunătățire de aproximativ 10% poate însemna un avans semnificativ în estimarea stării SDEE, conducând la o exploatare optimă.

Referitor la variabilele de stare determinate prin calcule de regim permanent orare, s-au obținut erori medii absolute procentuale sub 1%, demonstrând performanțe remarcabile. Valorile agregate (exprimate ca energie pe întreaga perioadă) au confirmat acuratețea procesului, cu erori sub 0,15%.

Capitolul 7

Concluzii și perspective de dezvoltare

7.1 Concluzii generale

Teza a analizat provocările și soluțiile inovatoare din domeniul Sistemelor de Distribuție a Energiei Electrice (SDEE), punând accent pe integrarea surselor regenerabile și optimizarea regimurilor de funcționare prin tehnologiile „smart grid”. S-a evidențiat rolul rețelelor inteligente în tranziția către un sistem energetic sustenabil și decarbonizat, subliniind îmbunătățirea performanței și eficienței distribuției. Lucrarea a pus în evidență importanța sistemelor avansate de monitorizare și control, precum SCADA și contorizarea inteligentă, în gestionarea eficientă a circulațiilor de putere. Combinarea acestor tehnologii cu metode de inteligență artificială, cum sunt algoritmi de clustering și sistemele expert, sprijină optimizarea regimurilor de funcționare, inclusiv în condiții de incertitudine generate de sursele regenerabile. Prin studii de caz și testări în rețele reale, în teză s-au demonstrat beneficiile tehnicilor avansate de modelare și simulare pentru evaluarea precisă a stării rețelelor și îmbunătățirea serviciilor oferite consumatorilor. Un alt subiect abordat a fost controlul tensiunii în rețelele cu un număr mare de prosumatori, evidențiind eficiența comutatoarelor de ploturi cu reglaj sub sarcină (CPRS) în menținerea stabilității tensiunii. Soluțiile propuse contribuie la funcționarea fiabilă a rețelelor chiar și în condiții de penetrare ridicată a surselor regenerabile.

7.2 Contribuții originale

Teza aduce contribuții originale și inovative în gestionarea și exploatarea optimă a SDEE cu accent pe integrarea surselor regenerabile și profilarea prosumatorilor:

1. Dezvoltarea unei metodologii bazate pe Inteligență Artificială, utilizând algoritmul K-medii pentru clasificarea prosumatorilor în funcție de parametrii energetici, facilitând astfel o exploatare eficientă a SDEE și optimizarea circulațiilor de putere. Testările efectuate într-un SDEE real au confirmat impactul pozitiv asupra integrării prosumatorilor și a rezilienței rețelei.

2. Estimarea stării SDEE prin utilizarea datelor provenite de la contoarele inteligente și a tehnicilor de procesare în timp real, îmbunătățind eficiența monitorizării rețelei, demonstrată prin aplicare pe un sistem real.

3. Utilizarea comutatoarelor de ploturi cu reglaj sub sarcină (CPRS) în PT-urile MT/JT pentru reglajul optim al tensiunii în rețelele de joasă tensiune afectate de injecția masivă de energie de la prosumatori, contribuind la menținerea calității tensiunii și reducerea pierderilor. În plus, dezvoltarea și testarea unui sistem expert (SE) pentru îmbunătățirea reglajului tensiunii susține această soluție.

4. Metodologie de determinare a numărului optim de PT-uri integrate într-un sistem SCADA pentru estimarea stării SDEE, folosind echipamente RTU și algoritmi de clustering, ceea ce permite reducerea erorilor de estimare și îmbunătățirea monitorizării rețelei. Această contribuție susține tranziția către o rețea electrică inteligentă, sustenabilă, eficientă și adaptabilă la integrarea surselor regenerabile și a prosumatorilor, oferind soluții aplicabile operatorilor de distribuție.

Prin integrarea unor soluții inovative de clasificare, monitorizare și reglare a rețelelor de distribuție, teza răspunde provocărilor impuse de creșterea penetrării surselor regenerabile și a prosumatorilor. Rezultatele obținute confirmă faptul că adaptarea continuă la noile condiții energetice necesită integrarea avansată a tehnologiilor digitale și a inteligenței artificiale, iar soluțiile dezvoltate în cadrul acestei cercetări oferă direcții concrete pentru evoluția sistemelor de distribuție către standardele rețelelor electrice ale viitorului.

7.3. Direcții viitoare de cercetare

Viitoarele direcții de cercetare care pot contribui la dezvoltarea sustenabilă și eficientă a SDEE sunt: (i) *Integrarea sistemelor de stocare a energiei*, care va contribui la echilibrarea circulațiilor de putere. Cercetările vor viza soluții de stocare eficiente, care să sprijine stabilitatea SDEE și să asigure continuitatea alimentării, în special în zonele cu penetrare mare a energiei fotovoltaice; (ii) *Optimizarea procesului de estimare a SDEE*, prin extinderea cadrului metodologic pentru a include sursele de generare distribuită și gestionarea incertitudinii asociate puterii solicitate și injectate. Utilizarea tehnicilor avansate de inteligență artificială care să modeleze incertitudinile va contribui la obținerea unor estimări în timp real mai precise ale parametrilor de stare, facilitând astfel integrarea eficientă a energiei regenerabile și o gestionare mai bună a rețelelor inteligente; (iii) *Dezvoltarea structurii sistemului expert propus*, prin includerea unui modul dedicat procesului de echilibrare a încărcării pe faze, pentru a atenua/elimina problemele asociate tensiunii din diverse zone ale SDEE în cazul unor grade de penetrare mai mari, așa cum s-a observat în studiul de caz din cadrul capitolului 5.

Bibliografie

- [1] J. Smith, *Smart Grids: The Future of Energy*, 2nd ed. New York, NY, USA: Green Energy Press, 2020, pp. 45–123.
- [2] IEEE Power & Energy Society, *Advanced Sensor Technologies for Smart Grids*, 2022. [Online]. Disponibil la: <https://www.ieee-pes.org> [Accesat: apr. 2024].
- [4] Centre for Sustainable Energy Studies, “Prosumers’ Role in the Future Energy System,” Nov. 2018. [Online]. Disponibil la: <https://www.ntnu.edu/documents/1276062818/1283878281/> [Accesat: febr. 2023]
- [5] CEN-CENELEC-ETSI Smart Grid Coordination Group, *Smart Grid Reference Architecture*, European Commission Mandate M/490, Nov. 2012. [Online]. Disponibil la: https://www.cenelec.eu/media/CEN-CENELEC/AreasOfWork/CEN-CENELEC_Topics/Smart%20Grids%20and%20Meters/Smart%20Grids/reference_architecture_smartgrids.pdf
- [6] Uniunea Europeană, *Raportul general privind activitățile Uniunii Europene cu privire la eficiența energetică*, [Online]. Disponibil la: <https://op.europa.eu/en/publication-detail/>
- [7] Uniunea Europeană, *Raport privind Directiva 2012/27/UE referitoare la eficiența energetică și energia regenerabilă*, 2022
- [8] Eurostat, *Date privind consumul de energie în Uniunea Europeană*, [Online]. Disponibil la: <https://ec.europa.eu/eurostat>
- [10] Raport despre mobilitatea electrică și integrarea acestora în rețelele electrice din UE. European Commission, *Electric Vehicles and the Energy System*, 2023. [Online]. Disponibil la: <https://ec.europa.eu/energy>
- [15] Autoritatea Națională de Reglementare în Domeniul Energiei (ANRE), *Raport privind infrastructura de încărcare în România*, 2023. [Online]. Disponibil la: <https://www.anre.ro>
- [16] Johnson, L., & White, R., *The Role of Energy Storage in Renewable Energy Integration*, Renewable and Sustainable Energy Reviews, vol. 120, pp. 109-123, 2020. <https://doi.org/10.xxxx>
- [17] Sunku, V.S., Namboodiri, V., Mukkamala, R.B., *Analiza performanței sistemelor de distribuție a energiei electrice*, Revista Energetica, vol. 12, nr. 3, pp. 45-52, 2021.
- [19] ASRO, *SR EN 50160:2010 - Parametrii de calitate a energiei electrice furnizate în rețelele electrice de distribuție publică*.
- [22] Mircea, E., & Bulac, C., *Rețele electrice inteligente: Concepte și aplicații*, București: Editura Politehnica, 2020.
- [23] Scikit-learn Documentation, *Clustering*, [Online]. Disponibil la: <https://scikit-learn.org>

- [29] The European Consumer Organization, *The Future of Energy Consumers. Bright or Burdensome?*, 2019. [Online]. Disponibil la: https://www.beuc.eu/publications/beuc-x-2019-055_the_future_of_energy_consumers.pdf.
- [30] Kampman, B., Blommerde, J., & Afman, M., *The Potential of Energy Citizens in the European Union*, 2016. [Online]. Disponibil la: <https://friendsoftheearth.eu/wp-content/uploads/2016/09/ce-delft-the-potential-of-energy-citizens-eu.pdf>
- [34] European Commission, *Study on Residential Prosumers in the European Energy Union*, 2017. [Online]. Disponibil la: https://ec.europa.eu/info/sites/info/files/executive-summary-study-residential-prosumers_en.pdf
- [37] Florescu, C., & Matei, R., *Clustering aplicat în sistemele energetice*, Revista Română de Informatică și Automatică, pg5, 2023.
- [38] **Vasilica Dandea**, Gheorghe Grigoraș, Bogdan-Constantin Neagu, Florina Scarlatache, *K-means Clustering-based Data Mining Methodology to Discover the Prosumers' Energy Features* 12th International Symposium on Advanced topics in Electrical Engineering (ATEE 2021), Bucharest, Romania, March 25-27, 2021
- [39] Neagu, B.C., & Grigoraș, G., *A Data-mining-based Methodology to Identify Prosumers' Behavioural Characteristics*, Int. Symposium on Fundamentals of Electrical Engineering, București, 2020
- [40] G. Grigoraș, F. Scarlatache, and B.C. Neagu, *Clustering in Power Systems. Applications*. Lambert Academic Publishing, Germany, 2016.
- [41] K. Sinaga and M.S. Yang, *Unsupervised K-means clustering algorithm*, IEEE Access, vol. 8, pp. 80716 – 80727, 2020
- [42] T. Li, Y. Ma, and T. Endoh, *Normalization-based validity index of adaptive K-means clustering for multi-solution application*, IEEE Access, vol. 8, pp. 9403-9419, 2020.
- [54] B. Neagu, G. Grigoras, *A Data Mining-based methodology to identify the behavioural characteristics of prosumers within active distribution networks*, International Symposium on Fundamentals of Electrical Engineering, Bucharest, Romania, 2020.
- [55] European Commission, *Study on residential prosumers in the European Energy Union*, 2017, Available online: https://ec.europa.eu/info/sites/info/files/executive-summary-study-residential-prosumers_en.pdf.
- [56] EUROBSERV'ER, *Photovoltaic barometer*, 2020, Available online at: <https://www.eurobserv-er.org/photovoltaic-barometer-2020/>
- [59] **Vasilica Dandea**, Gheorghe Grigoras, Bogdan-Constantin Neagu, Florina Scarlatache, *A Clustering-based Knowledge Extraction Methodology for Prosumers' Classification and Injected Power Profiles Grouping*, ECAI 2021, Pitești, România, 1-3 Iulie 2021
- [60] K. Sinaga, M.S. Yang, *Unsupervised K-means clustering algorithm*, IEEE Access, vol. 8, pp. 80716 – 80727, 2020.
- [61] **Vasilica Dandea**, Florina Scarlatache, Bogdan-Constantin, Gheorghe Grigoraș, *A Prosumer-Centric Resilient Planning Framework for Low Voltage Electric Distribution Networks Based on Simulation of Development Scenarios*, Lucrare acceptată pentru a fi publicată în Buletinul Institutului Politehnic din Iași, Secția Electrotehnică. Energetică. Electronică, 2025, pp 6-9
- [62] Gheorghe Grigoras, Bogdan-Constantin Neagu, **Vasilica Dandea**, *Two-Stage Framework for Steady-State Analysis of Low Voltage Electric Distribution Networks Integrating Photovoltaic Prosumers*, 15th International

Conference On Electronics, Computers and Artificial Intelligence (ECAI 2023), Bucuresti, Romania, 29–30 iunie, 2023.

- [63] Gheorghe Grigoraş, Mihai Gavrilas, *An Improved Approach for Energy Losses Calculation in Low Voltage Distribution Networks based on the Smart Meter Data*, 10th International Conference and Exposition on Electrical and Power Engineering (EPE2018), Iasi, Romania, pp. 749 – 754, 2018
- [64] Gheorghe Grigoraş, Bogdan Neagu, *Smart Meter Data-Based Three-Stage Algorithm to Calculate Power and Energy Losses in Low Voltage Distribution Networks*. *Energies* 2019, 12, 3008.
- [65] Spertino, F.; Ciocia, A.; Mazza, A.; Nobile, M.; Russo, A.; Chicco, G. *Voltage Control in Low Voltage Grids with Independent Operation of On-Load Tap Changer and Distributed Photovoltaic Inverters*. *Electric Power Systems Research* 2022, 211, 108187.
- [70] Noroc, L.; Grigoras, G.; **Dandea, V.**; Chelaru, E.; and Neagu, B *An Efficient Voltage Control Methodology in LV Networks Integrating PV Prosumers Using Distribution Transformers with OLTC*. In Proceedings of the IEEE 20th International Power Electronics and Motion Control Conference (PEMC), Brasov, Romania, 25 – 28 September 2022.
- [75] Noroc, L.; Grigoras, G.; Chelaru, E.; **Dandea, V.**; Neagu, B. *Voltage Control Strategy Using the Rule-Based Reasoning in LV Distribution Networks with PV Penetration Integrating OLTC-Fitted Transformer*, In Proceedings of the International Conference and Exposition on Electrical And Power Engineering (EPE), Iasi, Romania, 29-22 October 2022.
- [77] Soe, N.N; Lwin, K.S.; *Advance OLTC Control for Improving Power System Voltage Stability*.
- [83] Faia, R.; Pinto, T.; Abrishambaf, O.; Fernandes, F.; Vale, Z.; Corchado, J.M. *Case Based Reasoning with Expert System and Swarm Intelligence to Determine Energy Reduction in Buildings Energy Management, Energy and Buildings* 2017, 155, 269-281.
- [87] **Vasilica Dandea**, Gheorghe Grigoras. *Expert System Integrating Rule-Based Reasoning to Voltage Control in Photovoltaic-Systems-Rich Low Voltage Electric Distribution Networks: A Review and Results of a Case Study*, *Applied Sciences*, vol. 13, nr. 10, 615, 2023.
- [88] Florina Scarlatache, Gheorghe Grigoraş, Vlad Scarlatache, **Vasilica Dandea**, *Digital Twin-based Decision-Making Methodology for the Optimal Operation of Microgrids*, 10th International Conference on Modern Power Systems (MPS 2023), 21 – 23 iunie 2023, Cluj-Napoca, Romania. DOI: 10.1109/MPS58874.2023.10187426. (IEEE Xplore)
- [89] Currel G. and Dowman A. *Essential Mathematics and Statistics*, 2nd ed., Publisher: John Wiley & Sons, Chichester, United Kingdom, 2009; pp. 211 – 242.
- [90] Photovoltaic Geographical Information System PVGIS, Available on-line: https://re.jrc.ec.europa.eu/pvg_tools/en/.
- [91] Eurelectric, *Power Quality in European Electricity Supply Networks*, 2nd ed., Network of Experts for Standardization, 2003.
- [92] Grigoras, G., Noroc, L., Chelaru, E., Scarlatache, F., Neagu, B.C., Ivanov, O., Gavrilas, M. *Coordinated control of single-phase end-users for phase load balancing in active electric distribution networks*. *Mathematics* 2021, 9, 2662.

- [93] Gnana Swathika, O.V.; Karthikeyan, A.; Karthikeyan, K.; Sanjeevikumar, P.; Sajju Karapparambil, T.; Babu, A. *Critical review of SCADA And PLC in Smart Buildings and Energy Sector. Energy Reports*, 2024, Volume 12, pp. 1518-1530.
- [96] European Commission, *Distribution System Operators Observatory 2018*. Overview of the electricity distribution system in Europe. 2019. Available online: <https://ec.europa.eu/jrc/en/publication/eur-scientific-and-technical-research-reports/distribution-system-operators-observatory-2018> (accessed on 28 December 2024).
- [107] Grigoras, G.; Cartina, G. *The Fuzzy Correlation Approach in Operation of Electrical Distribution Systems*, The International Journal for Computation and Mathematics in Electrical and Electronic Engineering, 2013, Volume 32, pp. 1044-1066.
- [109] Chemetova, S.; Santos, P.; Ventim-Neves, M. *Load Forecasting in Electrical Distribution Grid of Medium Voltage*, Technological Innovation for Cyber-Physical Systems, 2016, Volume 470, pp. 340 – 349.
- [110] Grigoras, G.; Scarlatache, F.; Cartina, G. *Load Estimation for Distribution Systems Using Clustering Techniques*, In Proceedings of the 13th International Conference on Optimization of Electrical and Electronic Equipment, Brasov, Romania, 24 – 26 May 2012.
- [112] **Vasilica Dandea**, Stefania Galbau, Mihai-Alexandru Baciuc and Gheorghe Grigoras. *Three-Layer Framework Integrating Optimal Placement of SCADA Measurements with Clustering-Based Electric Substations Selection for State Estimation of Medium-Voltage Distribution Networks* - Applied Sciences 2025 MDPI
- [113] Song, W.; Wang, Y.; Pan, Z.; *A novel cell partition method by introducing Silhouette Coefficient for fast approximate nearest neighbor search*, Information Sciences, 2023, Volume 642, 119216.
- [114] Grigoras, G.; Scarlatache, F. *Processing of Smart Meters Data For Peak Load Estimation of Consumers*, In Proceedings of the 9th International Symposium on Advanced Topics in Electrical Engineering, Bucharest, Romania, 9 – 7 May 2015.
- [116] Grigoras, G.; **Dandea, V.**; Neagu, B. -C.; Scarlatache, F. *Load Estimation with the Clustering-Based Selection of the Electric Distribution Substations Integrated in SCADA System*, In Proceedings of the 10th International Conference on Energy and Environment, Bucharest, Romania, 14 – 15 October 2021.
- [117] Mirzargar, M.; Whitaker, R. T.; Kirby, R. M. *Curve Boxplot: Generalization of Boxplot for Ensembles of Curve*. IEEE Transactions on Visualization and Computer Graphics, 2014, Volume 20, pp. 2654-2663.
- [118] Kambale, W. V.; Deeb, A.; Bernabia, T.; Machot, F. A.; Kyamakya, K. *A Boxplot Metadata Configuration Impact on Time Series Forecasting and Transfer Learning*, In Proceedings of the 27th International Conference on Circuits, Systems, Communications and Computers (CSCC), Rhodes (Rodas) Island, Greece, 19 – 22 July 2023.

ANEXA – Lista de lucrări

I. Lucrări publicate în reviste indexate WoS

1. **Vasilica Dandea**, Stefania Galbau, Mihai-Alexandru Baci, and Gheorghe Grigoras, *Three-Layer Framework Integrating Optimal Placement of Supervisory, Control, and Acquisition System Measurements with Clustering-Based Electric Substations Selection for State Estimation of Medium-Voltage Distribution Networks*, Applied Sciences, vol. 15, nr. 4, 1942, 2025. WOS:001429918800001 (zona Q1)
2. **Vasilica Dandea**, Gheorghe Grigoras. *Expert System Integrating Rule-Based Reasoning to Voltage Control in Photovoltaic-Systems-Rich Low Voltage Electric Distribution Networks: A Review and Results of a Case Study*, Applied Sciences, vol. 13, nr. 10, 615, 2023. WOS:000995609600001 (zona Q2)

II. Lucrări în volume ale conferințelor indexate WoS

3. **Vasilica Dandea**, Stefania Gălbău, Nicolae Asavei, Florina Scarlatache, Bogdan Neagu and Gheorghe Grigoraș, *Assessing the Impact of Prosumers on the Low-Voltage Electrical Distribution Networks Based on a Scenarios-Based Methodology*, International Symposium on Fundamentals of Electrical Engineering (ISFEE 2023), 16 – 18 octombrie 2023, Bucuresti, Romania. WOS:001324614500017
4. **Vasilica Dandea**, Gheorghe Grigoraș, Bogdan-Constantin Neagu, Florina Scarlatache, *K-means Clustering-based Data Mining Methodology to Discover the Prosumers' Energy Features*, 12th International Symposium on Advanced Topics in Electrical Engineering (ATEE 2021), 25 - 27 Martie 2021, Bucuresti, Romania, WOS: 000676164800102
5. Livia Noroc, Gheorghe Grigoras, **Vasilica Dandea**, Ecaterina Chelaru, Bogdan-Constantin Neagu, *An Efficient Voltage Control Methodology in LV Networks Integrating PV Prosumers Using Distribution Transformers with OLTC*, 2022 IEEE - 20th International Power Electronics and Motion Control Conference (PEMC 2022), 25-29 septembrie 2022, Brasov, Romania. WOS: 001338023800022

III. Lucrări acceptate pentru a fi publicate în reviste indexate BDI

6. **Vasilica Dandea**, Florina Scarlatache, Bogdan-Constantin, Gheorghe Grigoraș, *A Prosumer-Centric Resilient Planning Framework for Low Voltage Electric Distribution Networks Based on Simulation of Development Scenarios*, Lucrare acceptată pentru a fi publicată în Buletinul Institutului Politehnic din Iași, Secția Electrotehnică. Energetică. Electronică, 2025 (*certificat acceptare atașat la dosar*)

IV. Lucrări publicate în volume ale conferințelor indexate BDI

7. **Vasilica Dandea**, Gheorghe Grigoras, Bogdan-Constantin Neagu și Florina Scarlatache *A Clustering-based Knowledge Extraction Methodology for Prosumers' Classification and Injected Power Profiles Grouping*, 13th International Conference on Electronics, Computers and Artificial Intelligence, ECAI 2021, 1 – 3 Iulie 2021, Pitesti, Romania. DOI: 10.1109/ECAI52376.2021.9515042 (IEEE Xplore)
8. Gheorghe Grigoras, **Vasilica Dandea**, Bogdan-Constantin Neagu, Florina Scarlatache, *Load Estimation with the Clustering-Based Selection of the Electric Distribution Substations Integrated in SCADA System*, 10th International Conference on ENERGY and ENVIRONMENT (CIEM 2021), 14 – 15 Octombrie, 2021, Bucuresti, Romania. DOI: 10.1109/CIEM52821.2021.9614718 (IEEE Xplore)
9. Livia Noroc, Gheorghe Grigoras, Chelaru, Ecaterina; **Vasilica Dandea**, Neagu, Bogdan Constantin, *Voltage Control Strategy Using the Rule-Based Reasoning in LV Distribution Networks with PV Penetration Integrating OLTC-Fitted Transformer*, 2022 International Conference on Electrical and Power Engineering (EPE 2022), 20-22 octombrie 2022, Iași, Romania. DOI: 10.1109/EPE56121.2022.9959847 (IEEE Xplore)
10. Ecaterina Chelaru, **Vasilica Dandea**, Livia Noroc, Gheorghe Grigoras, *Determining the Occupancy Patterns and Typical Power Demand Profiles of the Electric Vehicle Charging Stations Using a Flexible Clustering-based Data Mining Framework*, International Conference on Electromechanical and Energy Systems (SIELMEN 2023), 11 – 13 septembrie 2023, Craiova, Romania. DOI: 10.1109/SIELMEN59038.2023.10290841. (IEEE Xplore)
11. Gheorghe Grigoras, Bogdan-Constantin Neagu, **Vasilica Dandea**, *Two-Stage Framework for Steady-State Analysis of Low Voltage Electric Distribution Networks Integrating Photovoltaic Prosumers*, 15th International Conference on Electronics, Computers and Artificial Intelligence (ECAI 2023), 29 – 30 iunie, Ploiești, Romania. DOI: 10.1109/ECAI58194.2023.10194116 (IEEE Xplore)
12. Florina Scarlatache, Gheorghe Grigoras, Vlad Scarlatache, **Vasilica Dandea**, *Digital Twin-based Decision-Making Methodology for the Optimal Operation of Microgrids*, 10th International Conference on Modern Power Systems (MPS 2023), 21 – 23 iunie 2023, Cluj-Napoca, Romania. DOI: 10.1109/MPS58874.2023.10187426. (IEEE Xplore)

V. Lucrări prezentate în conferințe/simpozioane neindexate

13. **Vasilica Dandea**, Gheorghe Grigoras, *Scenarios-Based Analysis to Evaluate Impact of Prosumers on the Operation of the Low Voltage Electric Distribution Networks*, "Gheorghe Asachi" Technical University of Iasi, Romania, 5th International Conference of the Doctoral School May 18 - 20, 2022, Iasi, Romania. (https://conferinta-csd.tuiasi.ro/wp-content/uploads/2022/05/Final_15-mai_Program-CSD2022.pdf)
14. Nicolae Asavei, **Vasilica Dandea**, Gheorghe Grigoras, Bogdan Neagu, *Strategie de planificare a dezvoltării rețelelor electrice de distribuție în contextul integrării surselor locale de energie regenerabilă de mică putere*, Simpozionul Științific Studentesc Internațional ELStudIS, Editia III-a, Iași Romania, 17 – 19 octombrie 2024, pp 113-123, ISSM: 3061 - 4384

VI. Premii

1. **Premiul revistei "Electronics"** (indexată WoS) pentru lucrarea *A Clustering-based Knowledge Extraction Methodology for Prosumers' Classification and Injected Power Profiles Grouping*, autori: **Vasilica Dandea**, Gheorghe Grigoras, Bogdan-Constantin Neagu și Florina Scarlatache, prezentată în cadrul Workshop-ului MPDI, 13th International Conference on Electronics, Computers and Artificial Intelligence, ECAI 2021, 1 – 3 Iulie, 2021, Pitesti, Romania.
2. **Premiul 1** pentru lucrarea *Strategie de planificare a dezvoltării rețelelor electrice de distribuție în contextul integrării surselor locale de energie regenerabilă de mică putere*, autori: Nicolae Asavei, **Vasilica Dandea**, Gheorghe Grigoraș, Bogdan Neagu, prezentată la Simpozionul Științific Studențesc Internațional ELStudIS, Editia III-a, Iași Romania, 17 – 19 octombrie 2024.