



Universitatea
Transilvania
din Braşov

ŞCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea de Inginerie Electrică şi Ştiinţa calculatoarelor

Aseel Ismail Mohamed BENNAGI

Inteligenţa Artificială aplicată în caracterizarea surselor de energie regenerabilă

Artificial Intelligence applied in renewable energy sources characterization

REZUMAT

Conducător ştiinţific

Prof. Dr. Daniel Tudor COTFAS

BRAŞOV, 2026

Cuprins

Rezumat	4
1. Introducere	6
1.1 Lacune de cercetare	7
1.1.1 Lacune de cercetare în extragerea parametrilor PV bazată pe AI/metaeuristici ..	8
1.1.2 Lacune de cercetare în prognoza iradianței solare bazată pe AI	8
1.2 Scopul și obiectivele tezei	8
1.3 Structura și conținutul tezei	9
2. Inteligența artificială pentru modelarea fotovoltaică și extragerea parametrilor	11
2.1 Inteligența artificială în sistemele de energie regenerabilă	11
2.1.1 Aplicații AI cu accent pe sistemele PV	11
2.2 Modele cu circuit echivalent pentru dispozitive PV.....	11
2.2.1 Modelul cu o singură diodă (SDM)	11
2.2.2 Modelul cu două diode (DDM)	12
2.2.3 Modelul cu trei diode (TDM)	12
2.2.4 Modelarea modulelor PV	12
2.3 Analiză critică și lacune identificate în extragerea parametrilor PV	12
2.3.1 Motivația metodelor metaeuristice propuse	13
2.4 Concluzie.....	13
3. Tehnici bazate pe metaeuristici pentru extragerea parametrilor PV	15
3.1 Prezentarea capitolului	15
3.2 Algoritmul metaeuristic hibrid SSA–GSK	15
3.3 Algoritmul metaeuristic de căutare bazat pe PID	17
3.4 Metrici de performanță și evaluare statistică	19
3.5 Concluzie.....	20

4. Evaluare experimentală și benchmarking	22
4.1 Prezentarea capitolului	22
4.2 Seturi de date PV și cazuri de testare	22
4.2.1 Seturi de date experimentale	22
4.2.2 Seturi de date de referință din literatura de specialitate	23
4.3 Protocol experimental și configurație de benchmarking	24
4.3.1 Configurarea algoritmilor	24
4.4 Rezultate și discuții	24
4.5 Concluzie	26
5. Modele de prognoză a iradianței solare bazate pe AI	28
5.1 Prezentarea capitolului	28
5.2 Definirea problemei de prognoză	28
5.3 Două căi pentru prognoza iradianței solare	28
5.3.1 Calea A: prognoza iradianței solare informată fizic prin parametri extrași	28
5.3.2 Calea B: prognoza iradianței solare din măsurători, bazată pe date	28
5.4 Cadrul hibrid de nowcasting CNN–TCN–XGBoost propus	29
5.4.1 Seturi de date și caracteristicile datelor	30
5.4.2 Metrice de evaluare a performanței	30
5.5 Rezultate și discuții	31
5.5.1 Evaluarea preciziei prognozei pe setul de date din 2018	31
5.5.2 Date de măsurare din 2021	32
5.6 Concluzie	34
6. Concluzii și lucrări viitoare	36
6.1 Concluzii generale	36
6.2 Realizarea obiectivelor de cercetare	37

6.3 Direcții viitoare de cercetare	37
6.4 Valorificarea rezultatelor cercetării.....	38
Referințe	40

Rezumat

Această teză investighează metodologii avansate de inteligență artificială (AI) destinate îmbunătățirii caracterizării sistemelor fotovoltaice (PV) și prognozei iradianței solare pe orizont ultra-scurt în condiții reale de funcționare. Lucrarea este motivată de două provocări persistente în ingineria PV: dificultatea extragerii unor parametri semnificativi din punct de vedere fizic și fiabili numeric pentru modelele PV cu circuit echivalent din caracteristicile curent–tensiune măsurate și dificultatea prognozării exacte a iradianței solare pe orizonturi de 1–30 de minute în condiții atmosferice aflate în schimbare rapidă. Aceste provocări sunt cauzate de comportamentul nelinier al dispozitivelor PV, de cuplarea puternică dintre parametrii modelului și de variabilitatea rapidă și nestăționară a iradianței produse de dinamica atmosferică determinată de nori, toate acestea limitând eficiența abordărilor convenționale de identificare a parametrilor și de prognoză.

În primul rând, teza prezintă o analiză structurată și critică a metodelor AI aplicate în sistemele de energie regenerabilă, cu accent deosebit pe tehnologiile PV, și sintetizează progresele recente în tehnicile de extragere a parametrilor PV pentru modelele cu o singură diodă, cu două diode și cu trei diode (SDM/DDM/TDM). Analiza identifică lacune persistente în literatura de specialitate, inclusiv ineficiența convergenței, stagnarea prematură, robustețea limitată în condiții de funcționare diverse, dificultatea computațională crescândă pentru modelele de ordin superior și practicile neuniforme de evaluare a performanțelor care împiedică realizarea unor comparații echitabile. Aceste constatări stabilesc fundamentul științific și metodologic pentru dezvoltările propuse în capitolele următoare.

În al doilea rând, teza dezvoltă și implementează două tehnici de optimizare bazate pe algoritmi metaeuristici pentru extragerea parametrilor PV. Prima este implementarea unui algoritm hibrid SSA–GSK, care integrează dinamica populației din Salp Swarm Algorithm (SSA) cu operatorii Gaining–Sharing Knowledge (GSK), pentru a îmbunătăți capacitatea de rafinare și stabilitatea convergenței. A doua este implementarea unui algoritm de căutare bazat pe PID (PSA), care adaptează principiile controlului PID incremental la optimizare și le combină cu mecanisme de intensificare a explorării pentru a ghida soluțiile candidate prin spații de căutare neliniare și multimodale. Împreună, aceste metode sunt proiectate în mod specific pentru a aborda dificultățile structurale ale extragerii parametrilor PV, inclusiv neliniaritatea, interacțiunea parametrilor, multimodalitatea și complexitatea crescândă a modelului.

În al treilea rând, algoritmi propuși sunt evaluați în cadrul unui protocol de validare coerent și reproductibil, utilizând atât dispozitive PV măsurate experimental, cât și seturi de date de referință utilizate pe scară largă, acoperind diferite tehnologii PV și studii de caz atât la nivel de celulă, cât și la nivel de modul. Evaluarea acoperă modelele SDM, DDM și TDM și utilizează o funcție obiectiv unificată bazată pe RMSE, susținută de indicatori statistici complementari, pentru a asigura o evaluare transparentă a preciziei ajustării, repetabilității și scalabilității. Rezultatele demonstrează că PSA oferă cea mai fiabilă și scalabilă performanță pe măsură ce complexitatea modelului crește, în special pentru formulările DDM și TDM, unde cuplarea parametrilor devine mai puternică, în timp ce cadrul hibrid SSA–

GSK îmbunătățește clar performanța în comparație cu SSA independent și rămâne competitiv pe toate seturile de date. Aceste constatări confirmă că algoritmi propuși consolidează robustețea extragerii parametrilor PV pentru dispozitive, condiții de funcționare și structuri de model diverse.

În al patrulea rând, teza extinde dimensiunea operațională a sistemelor PV prin propunerea unui cadru hibrid CNN–TCN–XGBoost adaptat orizontului de prognoză pentru prognoza iradianței solare pe orizont ultra-scurt, cu timpi de anticipare între 1 și 30 de minute. Învățarea reprezentărilor prin rețele convoluționale și rețele convoluționale temporale este utilizată pentru a surprinde atât variațiile locale ale iradianței, cât și dependențele temporale mai ample pe termen scurt, în timp ce componentele XGBoost specifice fiecărui orizont oferă rafinare adaptată timpului de anticipare. Validarea prin analize pe perioade agregate și pe regimuri demonstrează o performanță generală puternică de prognoză, eroare sistematică redusă și o degradare controlată pe măsură ce orizontul de prognoză crește. În evaluarea agregată din 2018, cadrul propus a redus nRMSE cu aproximativ 7,7% la 2-minute și cu aproximativ 22,4% la 10-minute față de referința PV 2-state. Analiza pe regimuri a arătat în continuare că performanța prognozei este puternic determinată de stabilitatea atmosferică, cea mai bună performanță fiind obținută în condiții de cer senin, iar cel mai dificil comportament fiind observat în regimuri foarte variabile determinate de nori. Studiile de caz din 2021 au consolidat aceste constatări, arătând că cadrul propus este, în general, cel mai robust și adesea cel mai precis, indicând totodată că cele mai dificile condiții rămân provocatoare pe măsură ce orizontul de prognoză crește.

Teza contribuie prin: (i) îmbunătățirea și implementarea a doi algoritmi metaeuristici, PSA și hibridul SSA–GSK, pentru extragerea robustă a parametrilor PV în modelele SDM, DDM și TDM; (ii) un cadru transparent de evaluare comparativă care clarifică influența tipului de celulă, a complexității modelului și a condițiilor de evaluare asupra performanței extragerii; și (iii) o arhitectură hibridă de prognoză CNN–TCN–XGBoost care îmbunătățește predicția iradianței solare pe orizont ultra-scurt în diferite regimuri atmosferice. În ansamblu, aceste contribuții consolidează atât nivelul de modelare fundamentat fizic, cât și nivelul de predicție operațională bazat pe parametrii PV, oferind totodată o bază pentru lucrări viitoare privind gemenii digitali PV orientați spre implementare, identificarea parametrilor la fața locului și extinderea prognozei pe mai multe orizonturi temporale.

1. Introducere

Trecerea globală de la sistemele energetice bazate pe combustibili fosili către alternative durabile, cu emisii reduse de carbon, a crescut importanța surselor de energie regenerabilă (RES) [1]. Energia regenerabilă susține în prezent obiectivele climatice, creșterea economică, dezvoltarea infrastructurii și reziliența energetică prin reducerea emisiilor, diversificarea mixului energetic și limitarea expunerii la volatilitatea piețelor de combustibili [2]. De exemplu, IRENA a raportat că 91% dintre proiectele de energie regenerabilă nou puse în funcțiune în 2024 au produs electricitate mai ieftin decât cea mai ieftină alternativă pe bază de combustibili fosili, reducând costurile cu aproximativ 467 miliarde USD [3]. În cadrul acestei tranziții, inteligența artificială (AI) a devenit un instrument important pentru îmbunătățirea caracterizării, operării, prognozei și managementului tehnologiilor de energie regenerabilă [4-7].

Această teză se concentrează în mod specific pe caracterizarea bazată pe AI a sistemelor PV, în special a celulelor fotovoltaice (PVC) și a panourilor fotovoltaice (PVP), precum și pe aplicarea tehnicilor ML pentru prognoza iradianței solare. Totuși, ea este plasată într-un peisaj tehnic mai larg, în care instrumentele AI susțin planificarea, optimizarea, detectarea defectelor și operarea sistemelor de energie regenerabilă. Deși abordările bazate pe AI sunt aplicate și în alte tehnologii de energie regenerabilă, inclusiv energia eoliană, hidroenergia, biomasa și configurațiile hibride RES, energia solară PV a atras cea mai mare atenție din partea cercetătorilor AI, după cum reiese din analizele bibliometrice și din recenziile axate pe AI în domeniul PV. Această importanță reflectă creșterea rapidă a penetrării PV în sistemele energetice moderne, scăderea costurilor modulelor și comportamentele neliniare complexe ale dispozitivelor PV, care le fac deosebit de potrivite pentru abordări de modelare bazate pe date [4, 8-10].

Tehnologia PV este considerată un pilon esențial al tranziției către energia regenerabilă datorită modularității, scalabilității, costului investițional în scădere și adecvării sale atât pentru aplicații la scară utilitară, cât și pentru aplicații distribuite [11-14]. Totuși, performanța PV este puternic afectată de variabilitatea iradianței, schimbările de temperatură, umbrire, murdărire, defecte de fabricație și degradarea pe termen lung cauzată de expunerea la raze ultraviolete, cicluri termice, pătrunderea umidității și solicitările mecanice [11-17]. Acești factori creează necesitatea unor metode de caracterizare precise, capabile să identifice parametrii modelelor PV și să se adapteze condițiilor reale de funcționare.

Modelele cu circuit echivalent și caracteristicile I-V sunt utilizate frecvent pentru modelarea comportamentului PV. Modelul cu o singură diodă (SDM), modelul cu două diode (DDM) și modelul cu trei diode (TDM) descriu comportamentul I-V și P-V, însă parametrii lor principali, precum curentul fotogenerat, curentul de saturație al diodei, rezistențele serie/șunt și coeficienții de idealitate, nu pot fi măsurați direct și trebuie extrași din curbele I-V măsurate [18-20]. Metodele clasice, precum Newton–

Raphson, formulările bazate pe Lambert-W și ajustarea iterativă a curbelor, necesită adesea estimări inițiale precise, ipoteze puternice și date de înaltă calitate [21, 22].

Pentru a depăși aceste limitări, un volum mare de cercetări a aplicat algoritmi metaeuristici la extragerea parametrilor PV. Algoritmi metaeuristici precum Differential Evolution (DE), Artificial Bee Colony (ABC), Simulated Annealing (SA), Harmony Search (HS), Grey Wolf Optimizer (GWO), Whale Optimization Algorithm (WOA) și numeroase variante hibride s-au dovedit capabili să rezolve probleme de optimizare neliniară fără a necesita informații despre gradient sau ipoteze stricte [20-22]. Aceste metode sunt lipsite de derivări și pot explora spații cu dimensiuni mari, ceea ce le face potrivite pentru identificarea neliniară a parametrilor PV [21, 23, 24]. Studiile recente arată că abordările bazate pe AI și metaeuristici pot îmbunătăți precizia, convergența și robustețea în comparație cu metodele numerice convenționale, în special pentru date zgomotoase sau din lumea reală [19, 20, 23, 24]. Cu toate acestea, persistă provocări, inclusiv convergența prematură, costul computațional ridicat, performanța neuniformă între seturi de date și dificultatea formulărilor multi-obiectiv [21-24].

În paralel cu extragerea parametrilor, prognoza iradianței solare reprezintă o altă componentă esențială a caracterizării PV, deoarece producția de energie a PV depinde direct de iradianța și afectează fiabilitatea rețelei, operarea pieței, programarea rezervelor, echilibrarea sarcinii și managementul stocării energiei [25, 26]. Abordările tradiționale de prognoză a iradianței solare, inclusiv strategiile bazate pe persistență, modelele statistice de serii temporale precum autoregressive integrated moving average (ARIMA) și modelele fizice derivate din prognoza numerică a vremii, întâmpină adesea dificultăți în condiții atmosferice neliniare și aflate în schimbare rapidă [25, 26]. Modelele bazate pe AI, inclusiv Random Forest (RF), Gradient Boosting (GB), k-Nearest Neighbors (kNN), Gated Recurrent Unit (GRU), Convolutional Neural Networks (CNN) și hibridul CNN-LSTM, au demonstrat o precizie mai bună a prognozei și o capacitate îmbunătățită de a surprinde tipare temporale și meteorologice [25-33].

În ciuda acestor progrese, rămân lacune importante. Extragerea parametrilor PV și prognoza iradianței solare sunt adesea studiate separat, deși ambele sunt conectate în cadrul caracterizării PV [20, 21, 25]. Performanța prognozei depinde de o modelare PV precisă, în timp ce extragerea parametrilor poate beneficia de o mai bună înțelegere a influenței mediului [20, 25]. În plus, generalizarea limitată între tehnologii PV, climate și locații, împreună cu insuficiența datelor, zgomotul senzorilor, măsurătorile inconsistente, seturile de date incomplete și interpretabilitatea slabă, limitează încă implementarea reală a AI în sistemele PV [25-27, 33, 34].

1.1 Lacune de cercetare

În ciuda dezvoltării rapide a aplicațiilor AI în RES, rămân limitări importante în caracterizarea PV, în special în extragerea parametrilor PV și în prognoza iradianței solare pe termen ultra-scurt. Multe metode de extragere a parametrilor bazate pe AI și algoritmi metaeuristici sunt încă solicitante din punct de vedere computațional, sensibile la reglaje și insuficient validate pentru diferite tehnologii PV și condiții de funcționare. În mod similar, multe modele de prognoză bazate pe AI au dificultăți în condiții

atmosferice aflate în schimbare rapidă și prezintă performanțe inconsistente în diferite grade de acoperire a cerului cu nori.

1.1.1 Lacune de cercetare în extragerea parametrilor PV bazată pe AI/metaeuristici

Deși numeroși algoritmi metaeuristici au fost aplicați pentru extragerea parametrilor PV și PVP, rămân mai multe provocări. Multe metode necesită populații mari și un număr ridicat de iterații, ceea ce crește timpul de calcul și limitează utilizarea practică în sisteme PV în timp real sau încorporate. Convergența prematură este, de asemenea, o problemă frecventă, mai ales atunci când explorarea și exploatarea nu sunt bine echilibrate, conducând la seturi de parametri care pot să nu reprezinte cu precizie întreaga curbă I–V.

O altă limitare este generalizarea slabă a multor algoritmi între diferite tehnologii PV, niveluri de iradianță și condiții de temperatură. În plus, extinderea procesului de extragere de la SDM la modele mai complexe, precum DDM și TDM, crește numărul de parametri și întărește corelațiile dintre parametri, făcând convergența mai dificilă. Studiile existente utilizează, de asemenea, adesea seturi de date, metrice, criterii de oprire și limite ale parametrilor neuniforme, ceea ce face dificilă comparația echitabilă. Aceste lacune motivează dezvoltarea unor metode metaeuristice mai eficiente, mai robuste și evaluate prin comparații cu alte metode utilizate pentru extragerea parametrilor PV.

1.1.2 Lacune de cercetare în prognoza iradianței solare bazată pe AI

Prognoza iradianței solare pe termen ultra-scurt este importantă pentru operarea PV, controlul stocării, reducerea rampelor și controlul rețelei. Totuși, multe modele existente bazate pe AI au o capacitate limitată de a surprinde variațiile rapide ale iradianței determinate de nori, în special în condiții parțial înnorate sau atmosferice instabile. Tranzițiile bruște între stări senine și înnorate creează rampe abrupte ale iradianței, dificil de prognozat cu precizie la orizonturi de ordinul minutelor.

Mai mult, modelele de prognoză au adesea performanțe bune în condiții stabile de cer senin, dar se degradează în perioadele înnorate sau foarte variabile. Prin urmare, obținerea unei performanțe fiabile în diferite condiții ale cerului rămâne o provocare majoră. Această teză abordează aceste lacune prin dezvoltarea unor metode metaeuristice avansate pentru extragerea parametrilor PV și a unui cadru hibrid AI pentru prognoza iradianței solare pe termen ultra-scurt, cu scopul de a îmbunătăți precizia, robustețea și aplicabilitatea practică în sistemele de energie regenerabilă.

1.2 Scopul și obiectivele tezei

Pornind de la lacunele identificate mai sus, această teză urmărește să dezvolte, să implementeze și să evalueze metode avansate conduse de AI pentru PV, vizând în mod specific extragerea parametrilor PV și prognoza iradianței solare pe termen ultra-scurt, cu scopul de a îmbunătăți precizia, fiabilitatea și utilitatea reală a AI în aplicațiile de energie regenerabilă.

Obiective specifice de cercetare:

Pentru atingerea acestui scop, teza este structurată în jurul următoarelor obiective specifice de cercetare:

01. Revizuirea și analizarea metodelor AI aplicate în aplicațiile de energie regenerabilă, în special în tehnologiile PV.

02. Revizuirea și analizarea progreselor recente în modelele și algoritmi de extragere a parametrilor PV.

03. Dezvoltarea, modificarea și implementarea tehnicilor bazate pe algoritmi metaeuristici pentru extragerea robustă și precisă a parametrilor PV în condiții de funcționare diverse.

04. Dezvoltarea și implementarea modelelor bazate pe AI pentru prognoza iradianței solare pe orizont scurt și ultra-scurt.

05. Validarea și compararea metodelor propuse de extragere a parametrilor PV și a modelelor de prognoză a iradianței solare cu modele de referință consacrate.

1.3 Structura și conținutul tezei

Această teză de doctorat este organizată în șase capitole, începând cu contextul general și stadiul actual al cunoașterii continuând apoi cu dezvoltarea, implementarea și evaluarea metodelor bazate pe AI pentru caracterizarea dispozitivelor PV și terminând cu prognoza iradianței solare.

Capitolul 1 stabilește contextul și motivația tezei. Acesta introduce tranziția globală către RES și explică rolul AI în abordarea provocărilor neliniare și intensive ale sistemelor energetice moderne. Capitolul se concentrează apoi asupra PVC și PVP, identificând principalele provocări în modelarea PV, extragerea parametrilor și prognoza iradianței solare. De asemenea, definește lacunele de cercetare, scopul general și obiectivele specifice ale tezei.

Capitolul 2 prezintă o analiză a metodelor computaționale inteligente în aplicațiile de energie regenerabilă, cu accent pe tehnologiile PV. Acesta discută învățarea automată, învățarea profundă și optimizarea metaeuristică, apoi se concentrează pe modelarea PV și extragerea parametrilor bazată pe algoritmi metaeuristici. Modelele SDM, DDM și TDM sunt analizate critic din punctul de vedere al preciziei, robusteții și eficienței computaționale, oferind baza pentru metodele dezvoltate în Capitolul 3.

Capitolul 3 dezvoltă și implementează tehnici bazate pe algoritmi metaeuristici pentru extragerea parametrilor PV. Acesta formulează problema identificării parametrilor, inclusiv funcțiile obiectiv, limitele parametrilor și metricile de performanță. Pe baza limitărilor identificate în Capitolul 2, capitolul introduce algoritmi noi sau modificați, proiectați pentru a îmbunătăți comportamentul de convergență, echilibrul explorare–exploatare, precizia și robustețea în diferite condiții de funcționare.

Capitolul 4 validează algoritmi metaeuristici propuși utilizând seturi de date PV reprezentative, studii de caz și metode de referință. Acesta prezintă rezultate numerice pentru diferite PVC și PVP în diverse condiții de funcționare și evaluează comportamentul convergenței, costul computațional, robustețea și precizia în comparație cu abordările de ultimă generație.

Capitolul 5 se concentrează pe prognoza iradianței solare bazată pe AI. Acesta definește problema prognozei pe orizont scurt și ultra-scurt, descrie seturile de date și variabilele de intrare și prezintă modelele de prognoză dezvoltate, inclusiv arhitecturile, strategiile de antrenare și etapele de preprocesare ale acestora. Capitolul evaluează rezultatele în condiții meteorologice diferite utilizând metrice standard ale erorii și compară modelele propuse cu metode de referință din literatura de specialitate.

Capitolul 6 sintetizează principalele concluzii, contribuțiile originale și limitările tezei. Acesta evidențiază contribuțiile algoritmilor propuși de extragere a parametrilor prin algoritmi metaeuristici și ale modelelor de prognoză a iradianței bazate pe AI și propune direcții viitoare de cercetare, inclusiv extinderea către alte tehnologii PV, condiții de funcționare și integrarea în cadre mai ample de management al energiei regenerabile.

2. Inteligența artificială pentru modelarea fotovoltaică și extragerea parametrilor

Modelarea precisă a sistemelor PV necesită identificarea exactă a parametrilor modelului, ceea ce reprezintă o sarcină dificilă din cauza caracteristicilor neliniare ale dispozitivelor PV și a dependenței lor puternice de condițiile de funcționare. Tehnicile tradiționale analitice și numerice de extragere a parametrilor suferă adesea de probleme de convergență, sensibilitate la condițiile inițiale și robustețe redusă atunci când sunt aplicate modelelor PV complexe. Pentru a depăși aceste limitări, algoritmi de optimizare metaeuristici au fost adoptați din ce în ce mai mult ca instrumente eficiente pentru extragerea parametrilor PV.

O prezentare generală a metodelor AI relevante pentru RES, cu accent deosebit pe algoritmi metaeuristici utilizați pentru modelarea PV și identificarea parametrilor este prezentată în acest capitol. Discuția este limitată la tehnicile de optimizare și abordările de modelare utilizate direct pe parcursul acestei teze. O atenție specială este acordată aplicării algoritmilor metaeuristici celor trei modele, unde extragerea parametrilor este considerată o problemă de optimizare neliniară.

Modelele PV și metodele de extragere a parametrilor bazate pe algoritmi metaeuristici analizate în acest capitol constituie fundamentul teoretic al algoritmilor noi propuși în Capitolul 3. Abordările existente sunt analizate critic din punctul de vedere al preciziei, robusteții și eficienței computaționale, evidențiind limitările și provocările deschise ale acestora. Această analiză oferă motivația pentru dezvoltarea unor tehnici îmbunătățite de extragere a parametrilor prin algoritmi metaeuristici, introduse și validate în capitolele următoare ale tezei.

2.1 Inteligența artificială în sistemele de energie regenerabilă

2.1.1 Aplicații AI cu accent pe sistemele PV

Această teză restrânge focalizarea la două aspecte critice în care AI poate avea un impact deosebit de puternic și în care există lacune semnificative de cercetare: (i) aplicarea metodelor inteligente și metaeuristice pentru extragerea parametrilor modelelor PV și (ii) proiectarea modelelor bazate pe date pentru prognoza iradianței solare pe termen ultra-scurt. Aceste două teme constituie contribuțiile tehnice centrale ale lucrării, care sunt explorate în detaliu în secțiunile următoare.

2.2 Modele cu circuit echivalent pentru dispozitive PV

2.2.1 Modelul cu o singură diodă (SDM)

În formularea SDM, PVC este modelată ca o sursă de curent conectată în paralel cu o diodă, o rezistență de șunt R_{sh} și o rezistență serie R_s . Datorită compromisului favorabil dintre simplitatea structurală și capacitatea predictivă, acest model este cel mai frecvent adoptat atât în practica industrială, cât și în studiile academice de extragere a parametrilor [35, 36]. În acest model, trebuie identificați cinci

parametri pentru o condiție de funcționare dată: curentul I_{ph} , curentul invers de saturație I_{sd} , n , R_s și R_{sh} .

2.2.2 Modelul cu două diode (DDM)

DDM extinde SDM prin introducerea unei diode suplimentare pentru a reprezenta efectele de recombinare care apar în zona sarăcită a joncțiunii p-n. În acest mod, această configurație reflectă procesele de difuzie din regiunile cvasi-neutre, precum și fenomenele de generare-recombinare din regiunea de sarcină spațială, împreună cu rezistențele parazite serie și șunt. Ca rezultat, oferă o descriere mai realistă a comportamentului PVC decât SDM, cu introducerea unor parametri suplimentari și al unei complexități computaționale mai mari [36]. În această formulare, PVC este caracterizată prin șapte parametri necunoscuți care trebuie identificați pentru fiecare condiție de funcționare, care sunt $\{I_{ph}, I_{sd1}, I_{sd2}, n_1, n_2, R_s, R_{sh}\}$.

2.2.3 Modelul cu trei diode (TDM)

Deși modelele SDM și DDM sunt suficiente pentru multe module din siliciu cristalin, sunt adesea necesare circuite echivalente mai detaliate pentru a surprinde efectele neideale observate în dispozitive avansate sau puternic solicitate. În special, TDM introduce o a treia diode suplimentară pentru a reprezenta mecanisme suplimentare de recombinare și scurgere (de exemplu la limitele de grăunte, clustere de defecte sau regiuni degradate) care nu pot fi descrise cu precizie folosind doar modelul două diode [37]. Pentru o iradianță și o temperatură date, TDM implică 9 parametri de identificat, aceștia sunt $(I_{ph}, I_{sd1}, I_{sd2}, I_{sd3}, n_1, n_2, n_3, R_s, R_{sh})$.

2.2.4 Modelarea modulelor PV

În aplicațiile practice, PVC-urile sunt interconectate pentru a forma module, șiruri și matrici, astfel încât să se obțină specificațiile de tensiune și putere impuse de cerințele sarcinii sau de integrarea în rețea. Un PVP cuprinde de obicei mai multe celule conectate în serie și, în unele cazuri, mai multe astfel de șiruri pot fi conectate în paralel pentru a crește curentul generat. Prin urmare, modelele cu circuit echivalent introduse pentru o singură celulă pot fi extinse la nivel de modul prin considerarea configurației serie-paralel a celulelor și introducerea unor parametri corespunzători la nivel de modul [37, 38]. În concluzie în cazul modelului SDM trebuie extrași cinci parametri pentru modul, în DDM trebuie extrași șapte parametri, iar în TDM trebuie extrași nouă parametri.

2.3 Analiză critică și lacune identificate în extragerea parametrilor PV

Cercetările recente privind extragerea parametrilor PV arată progrese clare în ceea ce privește precizia și acoperirea modelării, în special pe măsură ce studiile se extind de la SDM către DDM, TDM și formulări la nivel de modul [39]. Totuși, costul computațional și ineficiența convergenței rămân bariere majore, deoarece valorile foarte scăzute ale RMSE necesită adesea populații mari, un număr ridicat de iterații sau bugete mari de evaluare [40-48].

Convergența prematură și echilibrul imperfect explorare–exploatare rămân, de asemenea, probleme persistente. Dacă explorarea se reduce prea devreme, optimizarea poate stagna în minime locale și poate produce seturi de parametri care nu reproduc fiabil întreaga caracteristică I–V [42]. Robustețea și generalizarea între tehnologii PV și condiții de funcționare nu sunt demonstrate în mod consecvent, mai ales la trecerea între diferite intervale de iradianță–temperatură [40–47, 49].

Există, de asemenea, un compromis persistent între complexitatea modelului și extracția parametrilor. Trecerea de la SDM la DDM/TDM îmbunătățește capacitatea de reprezentare a mecanismelor de recombinare și generare, dar mărește spațiul decizional și crește sensibilitatea la zgomot, inițializare și cuplarea parametrilor [50].

2.3.1 Motivația metodelor metaeuristice propuse

Motivată de aceste lacune și tendințe, această teză adoptă două direcții de cercetare complementare pentru problema extragerii parametrilor PV. Mai întâi, modifică și implementează o tehnică hibridă bazată pe algoritmi metaeuristici, care combină căutarea globală cu un mecanism suplimentar de rafinare, cu scopul de a îmbunătăți viteza de convergență și de a reduce sensibilitatea la minime locale și la cuplarea parametrilor. În al doilea rând, dezvoltă și implementează un nou algoritm metaeuristic independent, adaptat peisajului de extragere a parametrilor PV, conceput pentru a oferi convergență stabilă și estimări consecvente ale parametrilor, menținând totodată un cost computațional practic în condiții de funcționare diverse. Această direcție este motivată de constatările comparative conform cărora multe abordări existente pot fi sensibile la setările algoritmului și pot prezenta variabilitate a comportamentului de convergență între seturi de date.

Ambele abordări, metoda hibridă și algoritmi metaeuristici nou modificați și implementați, sunt astfel introduse pentru a rezolva limitările documentate privind robustețea, scalabilitatea și eficiența computațională în identificarea parametrilor celor trei modele și sunt prezentate și discutate în detaliu în Capitolul 3.

2.4 Concluzie

Acest capitol a analizat fundamentele principale ale modelării PV și ale identificării parametrilor, concentrându-se asupra modului în care caracteristicile I–V/P–V variază în funcție de iradianță, temperatură, umbrire parțială, murdărire și degradare pe termen lung [51–53]. Aceste condiții justifică utilizarea modelelor cu circuit echivalent, în principal SDM, DDM și TDM, care oferă o ierarhie precizie–complexitate pentru simularea și controlul PV [35–38, 54–58]. Totuși, trecerea de la SDM la DDM și TDM crește dificultatea extragerii parametrilor din cauza cuplării mai puternice a parametrilor, a numărului mare de parametri și compromisurilor dintre precizie, robustețe și cost computațional [50, 59–62].

Analiza a arătat, de asemenea, că metodele clasice analitice și deterministe, deși simple și rapide, pot deveni nesigure în cazul datelor limitate sau zgomotoase, al modelelor complexe sau al I–V din fișa

tehnică [63-66]. Prin urmare, identificarea parametrilor PV este formulată în mod obișnuit ca o problemă de optimizare globală. Algoritmii metaeuristici sunt potriviți pentru această sarcină deoarece sunt metode stocastice, fără derivări, care echilibrează explorarea și exploatarea în spații de căutare complexe, în special pentru ajustarea DDM și TDM [7, 20, 39, 67]. Studiile comparative evaluează de obicei aceste metode utilizând indicatori de precizie precum RMSE, comportamentul convergenței, stabilitatea statistică și costul computațional [19, 67]. Analiza a evidențiat și utilizarea tot mai frecventă a abordărilor metaeuristice hibride, care combină căutarea globală cu transformări analitice pentru a îmbunătăți stabilitatea și a reduce sarcina computațională [68-70].

Rezultatele acestei investigații asupra stadiului actual al cunoașterii au fost, de asemenea, diseminate printr-un articol de revistă publicat în *Energy Strategy Reviews*, care a analizat aplicațiile inteligenței artificiale în energia regenerabilă, inclusiv extragerea parametrilor PV și prognoza iradianței solare [7].

Pe baza lacunelor identificate în ceea ce privește robustețea, scalabilitatea, eficiența computațională și reproductibilitatea pentru identificarea SDM, DDM și TDM, Capitolul 3 prezintă soluțiile propuse. Acestea includ o tehnică hibridă de identificare metaeuristică, cu un mecanism suplimentar de rafinare pentru îmbunătățirea convergenței și reducerea sensibilității la minime locale, precum și un algoritm metaeuristic independent modificat, conceput pentru a oferi estimări stabile și consecvente ale parametrilor la un cost computațional practic pentru diferite seturi de date și condiții de funcționare.

3. Tehnici bazate pe metaeuristici pentru extragerea parametrilor PV

3.1 Prezentarea capitolului

Extragerea precisă a parametrilor PV este esențială pentru simularea și controlul fiabil al PVC și PVP. În practică, identificarea parametrilor este dificilă deoarece modelele PV cu circuit echivalent sunt neliniare, problema de optimizare este de obicei multimodala, iar cuplarea parametrilor devine mai puternică pe măsură ce dimensionalitatea modelului crește de la SDM, DDM la TDM. Aceste caracteristici pot face ca metodele convenționale de optimizare să converge lent sau să rămână blocate în minime locale și pot necesita bugete mari de evaluare pentru a obține estimări stabile [39, 42].

Acest capitol se concentrează pe dezvoltarea, modificarea și implementarea a două tehnici bazate pe metaeuristici pentru extragerea parametrilor PV: un algoritm de căutare bazat pe PID (PSA) și un algoritm hibrid SSA–GSK. Problema extragerii parametrilor PV este mai întâi formulată în termeni de variabile de decizie, funcții obiectiv și constrângeri ale parametrilor. Algoritmii propuși sunt apoi descriși în detaliu, incluzând ecuațiile de actualizare, mecanismele de tratare a constrângerilor și procedurile de implementare. Evaluarea experimentală și comparativă sunt prezentate în Capitolul 4.

3.2 Algoritmul metaeuristic hibrid SSA–GSK

Această secțiune prezintă algoritmul hibrid SSA–GSK propus, care combină mecanismul de explorare bazat pe lanț al SSA cu operatorii de învățare și schimb ai GSK [71]. Motivația hibridizării este de a exploata comportamentul complementar al celor doi algoritmi: SSA oferă o structură simplă a populației, cu o mișcare globală eficientă ghidată de un lanț lider–urmăritor, în timp ce GSK introduce schimb structurat de cunoștințe prin schemele sale de învățare junior și senior. În cadrul propus, populația SSA și mecanismul de actualizare a urmăritorilor sunt păstrate, în timp ce actualizarea liderului este reprojctată utilizând operatorii de partajare a cunoștințelor ai GSK pentru a consolida exploatarea și a îmbunătăți stabilitatea convergenței.

Fie o populație de N salpe inițializată în intervalul $[lb_j, ub_j]$. Fiecare poziție a unei salpe corespunde unui vector candidat de parametri al modelului PV identificat. La fiecare iterație, populația este evaluată și ordonată în funcție de potrivire, iar cea mai bună soluție curentă este considerată soluția de referință (sursa de hrană). În SSA clasic, poziția liderului este actualizată utilizând regula liderului SSA; totuși, în cadrul hibrid SSA–GSK, noua poziție a liderului este generată folosind operații de învățare bazate pe GSK, în timp ce salpele rămase (urmăritorii) continuă să își actualizeze pozițiile prin regula urmăritorilor SSA.

Pentru a construi actualizarea liderului bazată pe GSK, algoritmul determină mai întâi câte dimensiuni ale vectorului de decizie sunt actualizate folosind schema junior și câte sunt actualizate folosind

schema senior. Vectorul lider este apoi actualizat pe dimensiuni prin aplicarea actualizărilor junior dimensiunilor selectate D_{junior} și a actualizărilor senior dimensiunilor rămase D_{senior} .

Pentru dimensiunile atribuite schemei junior, actualizarea liderului urmează operatorul de învățare junior GSK. După ordonarea indivizilor de la cel mai bun la cel mai slab, algoritmul identifică surse de cunoștințe adecvate în jurul individului selectat și alege un individ aleator suplimentar x_r (distinct de vecinii aleși). Pentru dimensiunile junior, actualizarea candidatului se calculează utilizând [71]:

$$x_i^{\text{new}} = x_i + k_f[(x_{i-1} - x_{i+1}) + (x_i - x_r)]. \quad (1)$$

Pentru dimensiunile atribuite schemei senior, actualizarea este generată utilizând operatorul de învățare senior GSK. Doi indivizi sunt eșantionați din cele mai bune și cele mai slabe segmente ale populației ordonate, iar un individ reprezentativ x_m este selectat din segmentul median. Actualizarea candidatului pentru dimensiunile senior se calculează utilizând [71]:

$$x_i^{\text{new}} = x_i + k_f[(x_{p\text{-best}} - x_{p\text{-worst}}) + (x_i - x_m)]. \quad (2)$$

După calcularea actualizărilor pentru dimensiunile junior și senior, se formează un vector lider candidat complet. Liderul candidat este apoi evaluat, iar o regulă de acceptare rapidă este aplicată: liderul actualizat este acceptat numai dacă îmbunătățește valoarea fitness față de liderul curent; în caz contrar, liderul curent este păstrat. Această etapă de acceptare previne deteriorarea și asigură îmbunătățirea monotonă a celei mai bune soluții ori de câte ori este găsită o actualizare îmbunătățită.

După ce liderul este actualizat utilizând procedura bazată pe GSK descrisă mai sus, salpele rămase (următorii) sunt actualizate folosind regula următorilor SSA, care menține structura de lanț. Comportamentul metodei hibride este influențat de parametrii de control GSK, în special de factorul de cunoaștere k_f și de proporția p utilizată pentru definirea grupurilor elite și slabe în faza senior. Intensitatea transferului de cunoștințe în actualizarea liderului este guvernată direct de acești parametri și, în consecință, influențează comportamentul de convergență al întregului algoritm hibrid.

Experimentele SSA–GSK raportate în această teză au fost realizate utilizând următoarele setări ale parametrilor: dimensiunea populației $N = 100$, rata de cunoaștere $k_r = 0.7$, factorul de cunoaștere $k_f = 0.225$, proporția superioară și inferioară $p = 0.1$, și un număr maxim de iterații $Max_{iter} = 1100$.

Diagrama algoritmului este prezentată în Figura 1.




Figura 1 Diagrama algoritmului hibrid SSA-GSK

3.3 Algoritmul metaeuristic de căutare bazat pe PID

Deși algoritmul hibrid SSA–GSK consolidează echilibrul explorare–exploatare prin combinarea unor mecanisme de căutare complementare, sunt încă necesare îmbunătățiri suplimentare, deoarece pot apărea în continuare unele provocări legate de convergență și eficiență, în special în condiții de funcționare variabile și pentru modele PV mai complexe. Aceste considerații au motivat dezvoltarea, modificarea și implementarea unui algoritm de căutare bazat pe PID (PSA), conceput pentru a oferi un comportament stabil și o estimare robustă a parametrilor pentru SDM, DDM și TDM.

PSA este conceput pentru a oferi o identificare precisă a parametrilor, controlând în același timp costul computațional printr-un echilibru explicit între dimensiunea populației și numărul de iterații [72, 73].

PSA este motivat de conceptele controlului PID incremental, în care acțiunea de control este exprimată ca o modificare față de starea anterioară. În controlul clasic, reglarea PID combină termeni proporționali, integrali și derivați pentru a reduce abaterea dintre o valoare țintă și o valoare măsurată. PSA transferă această idee într-un cadru de optimizare, tratând cea mai bună soluție găsită până la momentul curent ca referință mobilă și utilizând termeni de corecție inspirați de PID pentru a ghida populația către această referință într-un mod stabil și controlat.

În PSA, populația de optimizare este actualizată folosind două componente complementare. Prima componentă este o etapă de corecție bazată pe PID, care conduce soluțiile către cea mai bună soluție curentă. A doua componentă este o etapă exploratorie bazată pe Lévy-flight (denumită aici termen „zero-output”), destinată îmbunătățirii capacității de căutare globală și reducerii riscului de stagnare în minime locale. Un factor de amestecare variabil în timp controlează influența relativă a exploatarea (corecția PID) și a explorării (Lévy-flight) în timpul căutării.

Populația este inițializată aleatoriu în limitele inferioare și superioare ale fiecărei variabile de decizie [72, 73]:

$$x_{ij} = (u_j - l_j) r_1 + l_j \quad (3)$$

unde $X_{i,j}$ este valoarea celei de-a j -a variabile pentru a i -a soluție candidată, l_j and u_j sunt limitele inferioară și superioară, iar $r_1 \in [0,1]$ este un număr aleator.

La fiecare iterație, PSA calculează abaterea dintre fiecare soluție candidată și cea mai bună soluție curentă [72, 73]:

$$e_k(t) = x^*(t - 1) - X(t - 1) \quad (4)$$

Unde $x^*(t)$ reprezintă vectorul celei mai bune soluții la iterația t , iar $X(t)$ reprezintă matricea care colectează toți vectorii populației la iterația t .

Corecția bazată pe PID este apoi calculată utilizând termeni proporționali, integrali și derivați [72, 73]:

$$\Delta u(t) = K_p r_2 [e_k(t) - e_{k-1}(t)] + K_i r_3 e_k(t) + K_d r_4 [e_k(t) - 2e_{k-1}(t) + e_{k-2}(t)] \quad (5)$$

Unde K_p , K_i , iar K_d sunt coeficienții fundamentali de reglare, în timp ce r_2 , r_3 și r_4 sunt vectori aleatori utilizați pentru a adăuga un comportament stochastic controlat.

Pentru a îmbunătăți explorarea, PSA utilizează și un termen de Lévy-flight [72, 73]:

$$o(t) = \left[\cos \left(1 - \frac{t}{T} \right) + \lambda r_5 L \right] e_k(t) \quad (6)$$

Unde $r_5 \in [0,1]$ este un vector aleator, iar λ este un factor de scalare dependent de generație.

Actualizarea finală a soluției combină corecția PID și explorarea Lévy utilizând un factor de amestecare η [72, 73]:

$$x(t + 1) = x(t) + \eta \Delta u(t) + (1 - \eta) o(t) \quad (7)$$

Pentru toate experimentele PSA raportate în această teză, dimensiunea populației și numărul de iterații sunt fixate la $N = 100$ și $Max_{iter} = 1100$. Coeficienții PID sunt setați astfel $K_p = 1.2$, $K_i = 2$, iar $K_d = 0.75$. Ei au fost selectați prin testări empirice repetate pe cazurile considerate de extragere a parametrilor PV pentru a obține convergență stabilă și eroare redusă de ajustare. Parametrul Lévy este setat astfel $\beta = 2$ pentru a permite salturi lungi ocazionale, menținând totodată un comportament de căutare controlat.

Diagrama algoritmului PSA este prezentată în Figura 2.




Figura 2 Diagrama algoritmului PSA

3.4 Metrici de performanță și evaluare statistică

Pentru a evalua parametrii extrași pentru cele trei modele utilizând algoritmi PSA și hibrid SSA–GSK propuși, problema de optimizare este formulată pentru a minimiza neconcordanța dintre valorile curentului măsurate obținute din seturi de date I–V experimentale sau de referință și valorile curentului

corespunzătoare prezise de modelul PV selectat folosind vectorul estimat de parametri. În această teză, RMSE este adoptată ca funcție obiectiv principală. În plus față de RMSE, sunt luate în considerare abaterea medie (MBE), deviația standard (STD) și eroarea absolută (AE) [45, 74].

RMSE pentru un vector candidat de parametri X este definită ca [45, 74]:

$$RMSE(X) = \sqrt{\frac{1}{n} \sum_{i=1}^n (I_{c,i} - I_{m,i})^2} \quad (8)$$

MBE se calculează folosind următoarea formulă [45, 74]:

$$MBE = \frac{1}{n} \sum_{i=1}^n (I_{c,i} - I_{m,i}) \quad (9)$$

STD se calculează ca [74]:

$$STD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n [(I_{c,i} - I_{m,i}) - MBE]^2} \quad (10)$$

În final, AE este definită ca [45]:

$$AE = \sum_{i=1}^n |I_{c,i} - I_{m,i}| \quad (11)$$

3.5 Concluzie

Capitolul 3 a prezentat două tehnici bazate pe algoritmi metaeuristici pentru extragerea parametrilor PV și a documentat alegerile metodologice utilizate pe parcursul tezei. Prima contribuție este algoritmul hibrid SSA–GSK, conceput pentru a combina structura populației SSA cu operatorii de învățare a cunoștințelor ai GSK, în vederea consolidării exploatarei și rafinării în etapa finală. În hibridul propus, regula de actualizare a urmăritorilor SSA este păstrată, în timp ce actualizarea liderului este reprojectată utilizând operatorii de învățare junior/senior GSK, susținuți de selecția care păstrează îmbunătățirea și de tratare explicită a limitelor pentru menținerea fezabilității și a rafinării stabile în apropierea convergenței [43, 71, 75].

A doua contribuție este PSA, care adaptează conceptele de corecție PID incrementală la optimizare prin utilizarea celei mai bune soluții curente ca referință mobilă. PSA actualizează soluțiile candidate printr-o etapă de exploatare ghidată de PID combinată cu un termen de explorare bazat pe Lévy-flight, cu un factor de amestecare variabil în timp pentru a regla explorarea față de exploatare pe parcursul iterațiilor. Au fost specificate, de asemenea, aspecte practice de implementare relevante pentru reproductibilitate, inițializare în limite, impunerea fezabilității și contabilizarea timpului de rulare al întregii bucle [72, 73].

Contribuțiile științifice rezultate din această lucrare de dezvoltare au fost diseminate prin două articole publicate: abordarea bazată pe PSA a fost publicată în Applied Sciences, în timp ce abordarea hibridă SSA–GSK a apărut în Environmental Engineering and Management Journal. Aceste publicații documentează dezvoltarea teoretică a metodelor propuse și confirmă originalitatea și relevanța științifică a contribuțiilor algoritmice prezentate în acest capitol [71, 73].

Pornind de la formularea problemei, proiectarea algoritmilor și metricile stabilite în Capitolul 3, Capitolul 4 realizează validarea experimentală și evaluarea metodelor propuse. Capitolul raportează rezultate numerice utilizând criteriile RMSE/MBE/AE definite aici și compară tehnicile propuse cu abordări de referință în configurații SDM, DDM și TDM, examinând totodată comportamentul convergenței și costul computațional.

4. Evaluare experimentală și benchmarking

4.1 Prezentarea capitolului

Acest capitol evaluează performanța celor două tehnici metaeuristice de extragere a parametrilor dezvoltate în Capitolul 3: PSA și cadrul hibrid SSA–GSK. Evaluarea este realizată pentru modelele PV cu circuit echivalent considerate în această teză, și anume SDM, DDM și TDM. Scopul este de a verifica faptul că metodele propuse pot identifica seturi de parametri semnificative din punct de vedere fizic, care permit reproducerea precisă a caracteristicilor I–V măsurate.

4.2 Seturi de date PV și cazuri de testare

Evaluarea utilizează seturi de date PV alese pentru a susține atât validarea practică, cât și evaluarea comparativă față de literatura consacrată. Pentru claritate, cazurile de testare sunt organizate în două grupuri de seturi de date în funcție de sursa lor. Primul grup constă în seturi de date experimentale măsurate în condiții de laborator sau naturale, incluzând celule din siliciu monocristalin (mSi) și celule solare multijoncțiune (MJSC). Al doilea grup cuprinde seturi de date de referință preluate din literatura de specialitate, descrise în secțiunea 4.2.2.

În ambele grupuri de seturi de date, seturile de parametri extrași sunt validate prin comparația cantitativă dintre curbele I–V prezise de model și datele măsurate, utilizând teste statistice, iar același flux de evaluare este aplicat consecvent pentru a analiza performanța în diferite tehnologii PV, tipuri de dispozitive (celulă/modul) și condiții de funcționare.

4.2.1 Seturi de date experimentale

Validarea experimentală din această teză se bazează pe măsurători I–V obținute pentru două tipuri de dispozitive PV: o celulă comercială mSi cu o suprafață activă de aproximativ 3 cm × 3 cm și o celulă solară comercială MJSC, triplă joncțiune InGaP/InGaAs/Ge, cu o suprafață activă de aproximativ 1 cm × 1 cm. Pentru MJSC, energia benzilor interzise ale joncțiunilor sunt 1,86 eV (InGaP), 1,40 eV (InGaAs) și 0,67 eV (Ge). Pentru fiecare tehnologie, au fost caracterizate inițial mai multe probe, iar un dispozitiv reprezentativ a fost selectat pentru campaniile detaliate de măsurare I–V raportate în acest capitol [76].

Toate măsurătorile I–V de laborator au fost obținute utilizând platforma de măsurare SolarLab, proiectată pentru măsurarea caracteristicilor I–V în timp ce controlează iradianța și temperatura celulei. Configurația hardware SolarLab și elementele principale ale fluxului de măsurare sunt prezentate în Figura 3. Platforma înregistrează simultan iradianța și temperatura pentru fiecare caracteristică, astfel încât fiecare curbă I–V este asociată cu condițiile sale de funcționare corespunzătoare. Controlul temperaturii este implementat ca o procedură în buclă închisă, în care dispozitivul este adus la o valoare țintă și menținut stabil în timp ce caracteristica I–V este măsurată în condiții de temperatură aproximativ constantă. Pentru a reduce perturbațiile provenite din lumina parazită, reflexii și flucuații

termice pe termen scurt în jurul dispozitivului, zona de măsurare este închisă cu un capac negru de ecranare a luminii în timpul achiziției [76].

În cadrul acestui set experimental, analiza mSi din prezentul capitol se concentrează pe o caracteristică I–V măsurată la o iradianță de 1000 W/m^2 și o temperatură a celulei de 27°C . În plus, trei seturi de date dedicate au fost măsurate pentru MJSC la iradianță de 1000 W/m^2 și pentru trei temperaturi, denumite Cazul A ($41,5^\circ\text{C}$), Cazul B ($51,3^\circ\text{C}$) și Cazul C ($61,6^\circ\text{C}$). Aceste măsurători au fost efectuate în lumină solară naturală utilizând sistemul RELab. Fiecare set de date I–V măsurat are 29 de puncte (V,I) [76].



Figura 3 Configurația experimentală [77]

4.2.2 Seturi de date de referință din literatura de specialitate

Pe lângă măsurătorile interne, această teză evaluează algoritmi de extragere propuși utilizând cinci seturi de date I–V de referință din literatura de specialitate: celula de siliciu RTC France, celula de siliciu amorf (aSi), modulul Photowatt PWP201, modulul cu film subțire PVM 752 GaAs și modulul STM6-40. Aceste seturi de date sunt utilizate frecvent deoarece oferă puncte I–V măsurate reproductibile în condiții definite de iradianță și temperatură, permițând comparația directă cu studiile publicate de extragere a parametrilor. Setul de date RTC France conține 26 de puncte măsurate la 1000 W/m^2 și 33°C [78], în timp ce setul de date aSi conține 46 de puncte la 1000 W/m^2 și 25°C [45]. La nivel de modul, setul de date PWP201 include 25 de puncte măsurate la 1000 W/m^2 și 45°C [78], setul de date PVM conține 44 de puncte măsurate la 1000 W/m^2 și 25°C [45], iar setul de date STM6-40 include 20 de puncte măsurate la 1000 W/m^2 și 51°C [79]. Aceste seturi de date sunt utilizate pentru extragerea parametrilor SDM, DDM și TDM, susținând validarea reproductibilă și comparația algoritmilor propuși în diferite tehnologii PV și condiții de funcționare.

4.3 Protocol experimental și configurație de benchmarking

4.3.1 Configurarea algoritmilor

Pentru a asigura o comparație echitabilă, PSA și SSA–GSK au fost executate utilizând același buget computațional, cu o dimensiune a populației de 100 și un număr maxim de 1100 de iterații. Pentru SSA–GSK, rata de cunoaștere (k_r), factorul de cunoaștere (k_f) și proporția superior/inferior (p) au fost setate la 0,7, 0,225 și, respectiv, 0,1. Pentru PSA, câștigurile PID au fost definite ca $K_p = 1,2$, $K_i = 2$ și $K_d = 0,75$, în timp ce exponentul Lévy β a fost setat la 2. În ambii algoritmi, criteriul de terminare a fost fixat la $T = \text{Max_iter}$.

4.4 Rezultate și discuții

Această secțiune sintetizează rezultatele extragerii parametrilor obținute cu cele două tehnici metaeuristice propuse, PSA și hibridul SSA–GSK, pentru cazurile de testare PV considerate în această teză. Fiecare set de date a fost evaluat în cadrul SDM, DDM și TDM, iar discuția se concentrează asupra preciziei ajustării, stabilității, comportamentului convergenței și costului computațional. RMSE este utilizată ca principal indicator de ajustare a curbei, fiind susținută de MBE, STD, profiluri AE, reconstrucții I–V/P–V, curbe de convergență și analiza timpului de execuție.

Tabelul 1 Sinteza principalelor rezultate din Capitolul 4 privind extragerea parametrilor

Set de date / condiție	Cele mai bune rezultate RMSE PSA	Rezultatul principal al comparației
Celulă mSi, 1000 W/m ² , 27 °C	SDM: 5.63096×10^{-4} ; DDM: 2.6216×10^{-4} ; TDM: 2.625428×10^{-4}	PSA a fost aproape de cel mai bun rezultat SDM și a devenit clar superior în DDM/TDM; a redus RMSE față de SSA–GSK cu 16,47% în SDM, 69,40% în DDM și 49,73% în TDM.
Celulă RTC France, 1000 W/m ² , 33 °C	SDM: 9.8602×10^{-4} ; DDM: 9.7078×10^{-4} ; TDM: 9.7630793×10^{-4}	PSA a atins grupul optim SDM și a produs cea mai bună precizie la nivel DDM/TDM, cu bias aproape nul, în timp ce SSA–GSK a îmbunătățit rezultatele față de SSA, dar a rămas în urma PSA.
Celulă aSi, 1000 W/m ² , 25 °C	SDM: 4.6123×10^{-5} ; DDM: 4.0943×10^{-5} ; TDM: 9.0459057×10^{-6}	PSA a obținut cea mai bună ajustare TDM raportată și a beneficiat puternic de modelul de ordin superior, reducând RMSE cu 90,94% față de SSA–GSK în TDM.
Celulă MJSC, 41,5 °C / 51,3 °C / 61,6 °C	TDM: 7.83176×10^{-5} ; 7.53160×10^{-5} ; 6.74823×10^{-5}	PSA a obținut cele mai bune ajustări pentru temperaturi și ordine de model; în TDM a redus RMSE față de SSA–GSK cu 67,40%, 78,23% și 91,98%.
Panou PVM, 1000 W/m ² , 25 °C	SDM: 2.2780×10^{-4} ; DDM: 1.6579×10^{-4} ; TDM: $1.11712928 \times 10^{-4}$	PSA a oferit cea mai precisă și stabilă estimare, TDM furnizând cel mai mic RMSE și reducând erorile localizate în apropierea regiunii de curbură.
Panou PWP201	SDM/DDM/TDM: 2.42507×10^{-3}	PSA a atins practic același optim pentru SDM/DDM/TDM, arătând că complexitatea suplimentară a modelului nu a redus semnificativ RMSE în acest caz.

Panou STM6-40, 1000 W/m ² , 51 °C	SDM: 1.72981×10^{-3} ; DDM: 1.6892×10^{-3} ; TDM: $1.68836049 \times 10^{-3}$	PSA a egalat cel mai bun grup SDM și a îmbunătățit rezultatele față de SSA–GSK cu 14,99%, 18,55% și 23,62% de la SDM la TDM.
---	---	--

Reconstrucția I–V referitoare la mSi prezentată în Figura 4 confirmă suprapunerea aproape completă dintre curba măsurată și caracteristicile SDM, DDM și TDM estimate prin PSA, în special în apropierea regiunii curbura, unde neliniaritatea diodei devine dominantă. Comportamentul convergenței din Figura 5 arată că PSA reduce rapid RMSE în primele iterații și intră apoi într-o fază stabilă de rafinare. SDM atinge platoul mai devreme, în timp ce DDM și TDM continuă să se îmbunătățească pentru o perioadă mai lungă din cauza spațiilor de căutare mai mari. Acest lucru confirmă că modelele multi-diodă oferă o precizie mai bună a ajustării, dar necesită o exploatare mai profundă pentru a ajunge la cel mai bun bazin de atracție.




Figura 4 Caracteristicile I–V ale celulei PV mSi




Figura 5 Curbele de convergență a celulei PV mSi

În cazul MJSC, PSA a furnizat cele mai bune ajustări pentru 41,5 °C, 51,3 °C și 61,6 °C și SDM, DDM și TDM, menținând în același timp un bias redus și o dispersie stabilă. În cazul modelului TDM, PSA a redus

RMSE față de SSA–GSK cu 67,40%, 78,23% și 91,98% pentru cele trei cazuri. Figura 6 arată că RMSE pentru PSA scade odată cu temperatura pentru cele trei reprezentări PV, indicând un comportament stabil în condițiile termice testate.




Figura 6 RMSE calculat pentru algoritmului PSA pentru MJSC în funcție de temperatură

4.5 Concluzie

Capitolul 4 a oferit principala validare experimentală a metodelor propuse de extragere a parametrilor. Pentru toate celulele și panourile PV testate, PSA a fost metoda cea mai fiabilă și scalabilă, în special pentru DDM și TDM, unde cuplarea parametrilor și neliniaritățile sunt mai puternice. Aceasta fie a egalat cel mai bun rezultat pentru RMSE, fie a obținut cea mai bună performanță în modelele de ordin superior, menținând totodată abaterea aproape nulă, dispersie stabilă și convergență fiabilă. SSA–GSK a îmbunătățit consecvent SSA simplu, confirmând valoarea hibridizării, dar în general a rămas în urma PSA atunci când a fost necesar obținerea unei eroari minime și o repetabilitate maximă. În ansamblu, Capitolul 4 confirmă că PSA asigură extragerea precisă, semnificativă fizic și stabilă computațional a parametrilor pentru diferite tehnologii PV, în timp ce SSA–GSK reprezintă o îmbunătățire utilă față de cadrul SSA original.

Rezultatele cercetării asociate dezvoltării algoritmilor din Capitolul 3 și investigațiilor de validare și evaluare din Capitolul 4 au fost diseminate prin două publicații în reviste. În special, PSA propus a fost publicat în Applied Sciences, în timp ce abordarea hibridă SSA–GSK a fost publicată în Environmental Engineering and Management Journal. Împreună, aceste publicații prezintă metodele propuse și evaluarea lor cuprinzătoare utilizând modelele SDM, DDM și TDM [71, 73].

Pe baza acestor fundamente de modelare și identificare a parametrilor, Capitolul 5 trece de la caracterizarea la nivel de dispozitiv la predicția operațională bazată pe date, abordând prognoza iradianței solare bazată pe AI. Acesta definește sarcinile de prognoză pe termen scurt și ultra-scurt considerate, introduce seturile de date și variabilele de intrare și prezintă modelele AI de prognoză

dezvoltate (arhitecturi, strategii de antrenare și fluxul de preprocesare). Capitolul evaluează apoi performanța în condiții meteorologice diverse utilizând metrici standard ale erorii de prognoză.

5. Modele de prognoză a iradianței solare bazate pe AI

5.1 Prezentarea capitolului

Capitolul 5 trece de la caracterizarea PV la nivel de dispozitiv la predicția la nivel operațional, abordând prognoza iradianței solare pe orizont ultra-scurt la timpi de anticipare de 1–30 de minute. Această sarcină este importantă pentru operarea în timp real a centralelor PV, optimizarea stocării, reducerea rampelor și serviciile auxiliare rapide. Capitolul formalizează problema prognozei, revizuieste stadiul actual al cunoașterii și propune un cadru hibrid de nowcasting CNN–TCN–XGBoost. Ideea centrală este că cadrul de extragere a parametrilor dezvoltat în Capitolele 3 și 4 rămâne valoros pentru interpretarea fizică și integrarea viitoare fizică–AI, în timp ce principala cale de prognoză adoptată în acest capitol este bazată pe date, deoarece variabilitatea iradianței la scară de minute este dominată de dinamica rapidă determinată de nori.

5.2 Definirea problemei de prognoză

Prognoza iradianței solare urmărește estimarea iradianței solare viitoare utilizând informațiile disponibile la momentul curent. În această teză, ținta este iradianța viitoare la orizonturi de prognoză de 1, 2, 3, 4, 5, 7, 10, 15, 20 și 30 de minute. Problema prognozei și reprezentarea învățării supervizate sunt sintetizate prin următoarele ecuații importante [80, 81]:

$$\hat{G}(t + \tau) = f_{\theta}(\Omega(t), \tau), \quad \tau \in (1, \dots, 30)\text{min} \quad (12)$$

$$X_t = [x_t, x_{t-\Delta t}, \dots, x_{t-(L-1)\Delta t}], \hat{G}(t + \tau) = f_{\theta}(X_t), \quad (13)$$

Aici, $\Omega(t)$ este setul de informații disponibil la momentul emiterii, X_t este secvența de intrare retrospectivă, iar f_{θ} este algoritmul de învățare. Învățarea directă multi-orizont este preferată deoarece strategiile recursive pot acumula erori pe măsură ce timpul de anticipare crește [81, 82].

5.3 Două căi pentru prognoza iradianței solare

5.3.1 Calea A: prognoza iradianței solare informată fizic prin parametri extrași

Calea informată fizic utilizează prognoze ale iradianței și temperaturii împreună cu parametri SDM/DDM/TDM calibrați pentru a calcula puterea PV. Parametrii extrași în Capitolele 3–4 pot susține astfel o estimare a puterii coerentă fizic. Totuși, la orizonturi de 1–30 de minute, incertitudinea principală nu este de obicei modelul de conversie PV, ci prognoza iradianței în sine, deoarece evoluția norilor generează rampe rapide dificil de prezis fără detecție locală de înaltă frecvență [81, 83, 84].

5.3.2 Calea B: prognoza iradianței solare din măsurători, bazată pe date

Calea bazată pe date învață relația dintre măsurătorile recente și iradianța solară viitoare. Aceasta este calea principală adoptată în acest capitol deoarece valorile recente ale GHI, DHI, variabilelor meteorologice, variabilelor de funcționare pentru PV acolo unde sunt disponibile și descriptorilor ciclici

ai timpului conțin informații pe termen scurt despre starea curentă a norilor, dinamica rampelor și persistența locală. Forma supervizată generală este:

$$G(t + \tau) = f_{\theta}(G(t), G(t + \tau), \dots, G(t - (L - 1)\tau), z(t), z(t + \tau)) \quad (14)$$

unde $G(t)$ agregă variabilele măsurate la momentul t . În orizonturile ultra-scurte, $G(t)$ include de obicei cel puțin iradianța solară recentă, iar $z(\cdot)$ reprezintă variabile exogene (temperatură, viteza vântului, umiditate, proxy-uri ale condițiilor cerului, codificări ale momentului zilei). Această formulare este în concordanță cu paradigma dominantă de prognoză bazată pe date sintetizată în recenziile privind prognoza PV [85].

5.4 Cadrul hibrid de nowcasting CNN–TCN–XGBoost propus

Pentru a depăși provocările prognozei iradianței solare, această teză introduce o arhitectură hibridă de nowcasting CNN–TCN–XGBoost. Proiectarea propusă combină învățarea profundă a caracteristicilor temporale cu regresia bazată pe boosting, pentru a îmbunătăți precizia și robustețea atât în regimuri atmosferice stabile, cât și volatile. În condiții de cer senin, iradianța solară evoluează de obicei lin și poate fi adesea surprinsă de modele mai simple. Totuși, în condiții înorate sau de tranziție, semnalul iradianței devine foarte nestăționar, cu fluctuații abrupte care necesită modele capabile să învețe atât tipare pe termen scurt, cât și dependențe temporale mai lungi. Cadrul hibrid propus este conceput în mod specific pentru a gestiona această variabilitate prin separarea învățării reprezentărilor de predicția numerică specifică orizontului.

În arhitectura modelului propus, CNN este utilizată pentru a surprinde variațiile rapide și locale din măsurătorile de iradianță și meteorologice de înaltă frecvență, asociate în mod obișnuit cu schimbări abrupte ale iradianței și rampe de iradianță de scurtă durată. Aceste reprezentări convoluționale sunt apoi transmise către o TCN profundă, care învață dependențe temporale pe distanțe mai lungi prin convoluții cauzale și dilatate, permițând modelului să integreze informații dintr-un context istoric mai larg fără a se baza pe structuri recurente. În loc să producă prognozele finale direct din rețeaua profundă, cadrul utilizează ieșirea CNN–TCN ca un set compact de caracteristici învățate care sintetizează dinamica recentă a iradianței. Aceste caracteristici extrase sunt apoi furnizate unor regresori XGBoost care operează specific fiecărui orizont, permițând ca fiecare timp de anticipare să fie modelat cu un regresor dedicat, capabil să corecteze erorile reziduale și să rafineze ieșirile numerice. Această combinație valorifică punctele forte complementare ale DL pentru extragerea caracteristicilor și ale GB pentru regresie robustă și corecția erorilor, reducând astfel slăbiciunile întâlnite în mod obișnuit în abordările pur statistice, modelele fizice sau metodele ML independente.

Pentru a evalua performanța în mod consecvent la timpi de anticipare intra-orari relevanți operațional, prognozele sunt generate pentru mai multe orizonturi, mai precis 1, 2, 3, 4, 5, 7, 10, 15, 20 și 30 de minute înainte. Această proiectare multi-orizont permite evaluarea atât a preciziei, cât și a stabilității

pe măsură ce timpul de anticipare crește, ceea ce este esențial pentru a determina dacă soluția propusă rămâne fiabilă dincolo de regimul de foarte scurt termen.

O diagramă a modelului hibrid propus este prezentată în Figura 7.




Figura 7 Fluxul metodologic al modelului hibrid propus pentru prognoza iradianței solare

5.4.1 Seturi de date și caracteristicile datelor

Sunt utilizate două seturi de date de măsurare. Setul de date din 2018 conține măsurători din mai 2018 eșantionate la fiecare 15 s pe Platforma Solară a Universității de Vest din Timișoara, România, și include GHI, DHI, temperatura aerului, viteza vântului și umiditatea relativă. Zilele includ un amestec de regimuri cu cer senin, înnorat/acoperit și foarte variabile. Subsetul de antrenare acoperă primele douăsprezece zile din mai (01 mai–12 mai 2018), în timp ce subsetul de testare acoperă ultimele zece zile (22 mai–31 mai 2018) [86]. Setul de date din 2021 este eșantionat la fiecare 4 s și include GHI, DHI, iradianță în plan, variabile meteorologice, tensiune PV, curent PV și caracteristici ciclice ale timpului. Datele din 2021 sunt organizate în BaseData-train, Case-CS și Case-6D-Mixed pentru a testa regimuri cu cer senin, înnorat/acoperit și foarte variabile. Modelul din 2021 a fost antrenat utilizând subsetul BaseData-train, care cuprinde măsurători colectate între 15 martie 2021 și 31 martie 2021. Modelul antrenat a fost ulterior evaluat pe două subseturi de testare: Case-CS și Case-6D-Mixed [87].

5.4.2 Metrice de evaluare a performanței

Performanța prognozei este evaluată utilizând nRMSE, nMBE, MAPE, precizia predicției P[TOL] și scorul de abilitate SS. Aceste metrice cuantifică eroarea globală, biasul sistematic, deviația relativă, procentul prognozelor din interiorul unui interval de toleranță și îmbunătățirea față de reperul 2-State [81, 87, 88]:

$$\text{nRMSE} = \frac{\sqrt{\frac{1}{N} \sum_{t=1}^N (G(t) - \hat{G}(t))^2}}{\bar{G}} \quad (15)$$

$$\text{nMBE} = \frac{\frac{1}{N} \sum_{t=1}^N (G(t) - \hat{G}(t))}{\bar{G}} \quad (16)$$

$$\text{MAPE} = \frac{100}{N} \sum_{t=1}^N \left| \frac{G(t) - \hat{G}(t)}{G(t)} \right| \quad (17)$$

$$\text{Skill Score(SS)} = 1 - \frac{\text{nRMSE}_{\text{model}}}{\text{nRMSE}_{\text{benchmark}}} \quad (18)$$

$$P[\%] = \frac{100}{N} \sum_{t=1}^N \left(\left| \frac{G(t) - \hat{G}(t)}{G(t)} \right| \leq \text{TOL} \right) \quad (19)$$

5.5 Rezultate și discuții

Modelul propus a fost evaluat pe două campanii independente de măsurare. Tabelul 2 arată că acest cadru este adecvat din punct de vedere computațional pentru nowcasting în timp real: deși antrenarea se realizează offline, inferența necesită doar aproximativ 4,17 ms/fereastră, producând în același timp toate cele zece orizonturi de prognoză.

Tabelul 2 Costul computațional al cadrului propus

Set de date	Parametri NN	Timp de antrenare	Timp de inferență
2018	327,850	326.79 s	4.178 ms/window
2021	328,810	1287.38 s	4.179 ms/window

5.5.1 Evaluarea preciziei prognozei pe setul de date din 2018

5.5.1.1 Evaluarea integrală a preciziei prognozei în regimurile solare din 2018

Pe întreaga evaluare din mai 2018, modelul propus îmbunătățește consecvent orizonturile de comparație publicate disponibile față de reperul 2-State. La 2 min, nRMSE scade de la 0,1780 la 0,16425, corespunzând unei îmbunătățiri de aproximativ 7,7%. La 10 min, nRMSE scade de la 0,2220 la 0,1723, corespunzând unei îmbunătățiri de aproximativ 22,4%. Modelul propus reduce, de asemenea, MAPE de la 6,40% la 5,60% la 2 min și de la 12,5% la 6,80% la 10 min, în timp ce P[5%] crește de la

aproximativ 57,5% la 79,81% la 10 min. Aceste rezultate confirmă că reprezentarea CNN–TCN și regresorii XGBoost specifici orizontului îmbunătățesc atât precizia, cât și acuratețea prognozei. Tabelul 3 și Figura 13 sintetizează performanța în condiții atmosferice reprezentative din 2018.

Tabelul 3 Sinteza performanței prognozei în regimuri reprezentative din 2018

Caz 2018	Regim	Rezultatul principal al modelului propus
22 May 2018	Foarte instabil	nRMSE = 0,3734 la 1 min și 0,5239 la 30 min; P[5%] scade de la 64,0% la 47,65%.
23 May 2018	Instabilitate moderată	nRMSE = 0,3160 la 1 min și 0,4903 la 30 min, îmbunătățindu-se față de 22 mai pe măsură ce variabilitatea scade.
25 May 2018	Mixt/tranziție	nRMSE = 0,1737–0,2989, iar MAPE rămâne sub 10%, arătând performanță puternică în condiții de variabilitate structurată.
30 May 2018	Cer senin	nRMSE = 0,0118–0,025, MAPE = 1,68–2,37%, iar P[5%] rămâne peste 84%.

5.5.2 Date de măsurare din 2021

5.5.2.1 Precizia modelului hibrid utilizând BaseData-train

Pentru subsetul BaseData-train din 2021, după preprocesare, setul de date a conținut 177.012 eșantioane și a fost împărțit cronologic în 70% antrenare și 30% validare. Cadrul propus obține nRMSE = 0,21393 la 1 min, crescând gradual până la 0,54783 la 30 min. MAPE crește de la 8,11% la 22,42%, în timp ce P[5%] scade de la 79,99% la 66,11%. nMBE rămâne redus pe toate orizonturile, confirmând că erorile sunt cauzate în principal de variabilitatea atmosferică, și nu de un bias sistematic.

5.5.2.2 Precizia modelului hibrid în Case-CS

Subsetul Case-CS evaluează condiții stabile de cer senin, în care evoluția iradianței este guvernată în principal de geometria solară deterministă. Modelul propus reproduce profilul diurn neted cu o consecvență ridicată. Pentru 09 iulie, nRMSE rămâne în intervalul 0,006531–0,009905, iar pentru 22 august rămâne în intervalul 0,005934–0,009019. Cele mai mari erori în condiții de cer senin apar la 22 februarie, unde nRMSE crește de la 0,01736 la 1 min la 0,03188 la 30 min, însă nMBE rămâne aproape de zero. Aceste rezultate arată că cadrul propus păstrează coerența fizică în regimuri deterministe.




Figura 8 Evaluarea modelului hibrid pentru setul de date Case-CS

5.5.2.3 Precizia modelului hibrid și comparația cu reperele în 2021 (Case-6D-Mixed)

Subsetul Case-6D-Mixed oferă cea mai puternică validare operațională deoarece include zile cu cer senin, acoperit, de tranziție și foarte variabile. La 05 aprilie, modelul propus oferă cel mai bun nRMSE la 1 min (0,2187) în comparație cu 2-State (0,2510), deși avantajul său pe orizonturi mai lungi devine mai puțin consecvent. La 20 aprilie, un regim determinat de nori face prognoza dificilă, dar modelul propus rămâne competitiv și egalează 2-State la 30 min (nRMSE = 0,9460), rămânând sub ARIMA (1,0900). La 08 mai, regimul foarte variabil confirmă robustețea modelului: la 10 min, nRMSE este 0,4698 față de 0,7560 pentru 2-State. La 11 mai, cazul de cer senin arată cea mai puternică performanță, cu nRMSE = 0,00395 la 10 min. La 19 mai, modelul propus depășește ambele repere la 30 min, cu nRMSE = 0,7685 față de 0,8880 și 1,0930. La 21 mai, modelul este cel mai puternic pe orizonturi scurte și intermediare, dar reperele devin mai competitive la 30 min.




Figura 9 Relația dintre iradianța prognozată și cea măsurată în Case-6D-Mixed

5.6 Concluzie

Capitolul 5 a dezvoltat și validat un model hibrid CNN–TCN–XGBoost pentru prognoza iradianței solare pe orizont ultra-scurt. Modelul combină detectarea rampelor locale bazată pe CNN, memoria temporală bazată pe TCN și regresia XGBoost specifică fiecărui orizont. Rezultatele din 2018 demonstrează o precizie îmbunătățită față de reperul 2-State, cu reduceri ale nRMSE de aproximativ 7,7% la 2 min și 22,4% la 10 min. Rezultatele din 2021 arată degradare controlată odată cu orizontul pe BaseData-train, erori foarte mici în condițiile de cer senin Case-CS și performanță robustă în regimurile Case-6D-Mixed. Principala limitare rămasă este dificultatea de a prognoza condiții cu rampe abrupte pe orizonturi mai lungi, unde evoluția stocastică a norilor reduce valoarea predictivă a măsurătorilor recente. Totuși, rezultatele confirmă că metoda propusă consolidează nivelul de predicție operațională bazat pe date al caracterizării PV și oferă o bază practică pentru viitori gemeni digitali PV orientați spre implementare și sisteme de prognoză multi-orizont.

Rezultatele cercetării asociate acestui capitol, inclusiv dezvoltarea cadrului hibrid de nowcasting CNN–TCN–XGBoost propus pentru prognoza iradianței solare pe orizont ultra-scurt și validarea sa prin benchmarking comparativ pe mai multe orizonturi de prognoză și regimuri atmosferice, au fost acceptate pentru prezentare la 2026 IEEE Conference on Advanced Topics on Measurement and Simulation (ATOMS 2026), cu publicare ulterioară în lucrări de conferință conforme IEEE Xplore.

6. Concluzii și lucrări viitoare

6.1 Concluzii generale

Această teză s-a concentrat pe îmbunătățirea caracterizării sistemelor fotovoltaice și a predictibilității pe orizont scurt utilizând metode avansate bazate pe AI. Ea a abordat două provocări complementare în ingineria PV: extragerea unor parametri stabili și semnificativi din punct de vedere fizic pentru modelele PV cu circuit echivalent din date I–V măsurate și prognoza iradianței solare pe termen ultra-scurt în condiții atmosferice aflate în schimbare rapidă.

Capitolul 1 a introdus contextul cercetării, motivația, lacunele și obiectivele. Acesta a evidențiat limitări cheie în extragerea parametrilor PV, inclusiv ineficiența convergenței, stagnarea prematură, robustețea slabă, dificultatea modelelor complexe precum DDM și TDM și benchmarking-ul inconsistent. Pentru prognoză, principalele provocări au fost variațiile rapide ale iradianței determinate de nori, tranzițiile bruște ale cerului, reducerea preciziei la orizonturi de ordinul minutelor și performanța instabilă în diferite regimuri atmosferice.

Capitolul 2 a revizuit aplicațiile AI în energia regenerabilă, cu accent pe extragerea parametrilor PV. Acesta a arătat că algoritmi metaeuristici sunt potriviți pentru modelele PV neliniare, însă multe abordări existente suferă încă de cost computațional ridicat, sensibilitate la complexitatea modelului și robustețe limitată, justificând necesitatea unor metode hibride de optimizare îmbunătățite.

Capitolul 3 a prezentat principalele metode de extragere a parametrilor dezvoltate în teză: algoritmul hibrid SSA–GSK și algoritmul de căutare bazat pe PID (PSA). SSA–GSK a îmbunătățit SSA prin partajarea cunoștințelor bazată pe GSK, în timp ce PSA a adaptat principiile controlului PID la optimizare. Ambele metode au fost concepute pentru a gestiona neliniaritatea, multimodalitatea, cuplarea parametrilor și complexitatea crescândă a modelelor PV.

Capitolul 4 a validat aceste metode pe modelele SDM, DDM și TDM și pe mai multe celule și panouri PV, inclusiv mSi, RTC France, aSi, MJSC, PVM, PWP201 și STM6-40. Rezultatele au arătat că ambele metode au produs parametri preciși și semnificativi fizic, PSA demonstrând cea mai puternică robustețe și scalabilitate, în special pentru modele mai complexe. Capitolul a subliniat, de asemenea, că metodele de extragere a parametrilor PV ar trebui evaluate nu doar prin RMSE, ci și prin comportamentul convergenței, timpul de rulare, repetabilitate, dimensiunea populației și bugetul de iterații.

Capitolul 5 a extins lucrarea către predicția la nivel operațional printr-un model hibrid CNN–TCN–XGBoost pentru nowcasting-ul iradianței solare pe 1–30 de minute. CNN a surprins rampele locale ale iradianței, TCN a reprezentat dependențe temporale mai lungi, iar modelele XGBoost specifice fiecărui orizont au rafinat prognozele pentru fiecare timp de anticipare. Modelul a obținut prognoze stabile cu abatere redusă și degradare controlată odată cu creșterea orizontului. În cazul din 2018, acesta a redus nRMSE cu aproximativ 7,7% la 2 minute și 22,4% la 10 minute în comparație cu reperul PV 2-state.

În ansamblu, teza contribuie cu un cadru bazat pe AI pentru caracterizarea PV prin dezvoltarea PSA și a hibridului SSA–GSK pentru extragerea robustă a parametrilor PV, stabilirea unei abordări consecutive de benchmarking între modele și dispozitive PV și propunerea unui model CNN–TCN–XGBoost conștient de orizont pentru prognoza iradianței pe termen ultra-scurt. Aceste contribuții susțin atât modelarea PV bazată pe fizică, cât și predicția operațională PV, având relevanță pentru gemeni digitali PV adaptivi și analitică PV inteligentă.

6.2 Realizarea obiectivelor de cercetare

Cercetarea doctorală a fost structurată în jurul a cinci obiective, iar fiecare obiectiv a fost atins progresiv prin capitolele tezei. Obiectivul O1, de a revizui și analiza metodele AI aplicate în aplicațiile de energie regenerabilă, în special în tehnologiile PV, a fost atins prin Capitolele 1 și 2, care au poziționat lucrarea în literatura mai largă privind energia regenerabilă și AI.

Obiectivul O2, de a revizui și analiza progresele recente în modelele și algoritmi de extragere a parametrilor PV, a fost atins în Capitolul 2 prin discuția critică a modelelor cu circuit echivalent, a metodelor clasice de extragere și a abordărilor de optimizare metaeuristică. Această analiză a identificat limitările tehnice care au motivat dezvoltările algoritmice ale tezei.

Obiectivul O3, de a dezvolta, modifica și implementa tehnici bazate pe metaeuristici pentru extragerea robustă și precisă a parametrilor PV, a fost atins în Capitolul 3 prin dezvoltarea algoritmului hibrid SSA–GSK și a PSA. Obiectivul O4, de a dezvolta și implementa modele bazate pe AI pentru prognoza iradianței solare pe orizont scurt și ultra-scurt, a fost atins în Capitolul 5 prin cadrul CNN–TCN–XGBoost propus.

Obiectivul O5, de a valida și compara prin benchmarking metodele propuse de extragere a parametrilor și de prognoză cu modele de referință consacrate, a fost atins prin Capitolele 4 și 5. Capitolul 4 a validat PSA și SSA–GSK pe mai multe dispozitive PV, structuri de model și algoritmi de referință, în timp ce Capitolul 5 a evaluat cadrul de prognoză pe diferite orizonturi, ani și regimuri atmosferice. În acest fel, teza și-a atins scopul prin combinarea dezvoltării metodologice cu validarea experimentală.

6.3 Direcții viitoare de cercetare

Rezultatele obținute în această teză deschid mai multe direcții viitoare de cercetare. Pentru extragerea parametrilor PV, lucrările viitoare ar trebui să se concentreze pe cadre de optimizare orientate spre implementare, care să păstreze robustețea metodelor propuse, reducând în același timp costul computațional. Criteriile adaptive de oprire, căutarea hibridă global–locală, optimizarea asistată de surogat și implementarea conștientă de hardware ar putea face mai practică estimarea continuă sau la nivel de teren a parametrilor.

O altă direcție este dezvoltarea unor modele adaptive de selecție a modelului, capabile să aleagă între SDM, DDM și TDM în funcție de calitatea datelor, condițiile de funcționare și scopul ingineresc. Aceasta

ar deplasa lucrarea prezentă de la optimizarea robustă a modelelor de circuit fixe către o modelare PV mai conștientă de context.

Pentru prognoză, modelul CNN–TCN–XGBoost propus poate fi extins prin integrarea unor surse de intrare mai bogate, precum imagini de la camere de cer, imagere all-sky, produse satelitare și ieșiri de prognoză numerică a vremii. Acest lucru ar fi deosebit de util în regimuri atmosferice instabile, unde rampele bruște ale iradianței rămân dificil de prezis. Lucrările viitoare ar trebui să ia în considerare și prognoza probabilistică, pentru a oferi intervale de predicție, informații privind incertitudinea și indicatori de risc al rampelor pentru programarea stocării, alocarea rezervelor și aplicațiile de suport al rețelei.

În final, integrarea mai puternică a extragerii parametrilor PV și a prognozei iradianței într-un geamăn digital PV adaptiv unificat reprezintă o direcție importantă pe termen lung. Într-un astfel de cadru, parametrii extrași ar furniza calibrare fizică, în timp ce reziduurile prognozei și anomaliile de funcționare ar putea declanșa reidentificarea adaptivă a modelului PV. Agenții AI moderni ar putea, de asemenea, să asiste acest proces prin selectarea modelelor, ajustarea setărilor de optimizare, monitorizarea convergenței și combinarea surselor de date eterogene. Prin urmare, teza oferă o bază pentru dezvoltarea viitoare a modelării, prognozei și gemenilor digitali PV activate de AI.

6.4 Valorificarea rezultatelor cercetării

Lista completă a publicațiilor și activităților de diseminare științifică asociate acestei lucrări doctorale este prezentată mai jos:

- Bennagi, A., O. AlHousrya, D.T. Cotfas, and P.A. Cotfas, Comprehensive study of the artificial intelligence applied in renewable energy. *Energy Strategy Reviews*, 2024. 54: p. 101446. <https://doi.org/10.1016/j.esr.2024.101446>
Journal Impact Factor: 9.9 (2026), Q1.
- Bennagi, A., AlHousrya, O., D.T. Cotfas, and P.A. Cotfas, Parameter extraction of photovoltaic cells and panels using a pid-based metaheuristic algorithm. *Applied Sciences*, 2025. 15(13): p. 7403. <https://doi.org/10.3390/app15137403>
Journal Impact Factor: 2.5 (2026), Q2.
- Bennagi, A., AlHousrya, O., D.T. Cotfas, and P.A. Cotfas, HYBRID SALP SWARM-GAINING AND SHARING KNOWLEDGE (SSA-GSK) METAHEURISTIC ALGORITHM FOR EXTRACTING PHOTOVOLTAIC CELL PARAMETERS. *Environmental Engineering & Management Journal (EEMJ)*, 2025. 24(5). <https://doi.org/10.30638/eemj.2025.085>
Journal Impact Factor: 0.9 (2026), Q4.
- Bennagi, A., AlHousrya, O., D.T. Cotfas, P.A. Cotfas, and M. Paulescu, Multi-Horizon Solar Irradiance Forecasting under Variable Sky Conditions through CNN-TCN Feature Learning and XGBoost. Currently under review at *Unconventional Resources Journal*.
Journal Impact Factor: 4.6 (2026), Q1.

- Bennagi, A., AlHousrya, O., D.T. Cotfas, P.A. Cotfas, and M. Paulescu, A Hybrid CNN-TCN-XGBoost Model for Multi-Horizon Solar Irradiance Forecasting. Accepted for presentation at the 2026 IEEE Conference on Advanced Topics on Measurement and Simulation (ATOMS 2026), with subsequent publication in IEEE Xplore-compliant proceedings.
- AlHousrya, O., Bennagi, A., P.A. Cotfas, and D.T. Cotfas, A novel Hybrid ant colony algorithm for solving the shortest path problems with mixed fuzzy arc weights. Alexandria Engineering Journal, 2024. 109: p. 841-855. <https://doi.org/10.1016/j.aej.2024.09.089>
Journal Impact Factor: 6.8 (2026), Q1.
- AlHousrya, O., Bennagi, A, P.A. Cotfas, and D.T. Cotfas, A Hybrid Machine Learning and IoT System for Driver Fatigue Monitoring in Connected Electric Vehicles. Machine Learning with Applications, 2026: p. 100845. <https://doi.org/10.1016/j.mlwa.2026.100845>
Journal Impact Factor: 4.9 (2026), Q1.
- AlHousrya, O., Bennagi, A, P.A. Cotfas, and D.T. Cotfas, The Role of the Industrial IoT in Advancing Electric Vehicle Technology: A Review. Applied Sciences, 2025. 15(17): p. 9290. <https://doi.org/10.3390/app15179290>
Journal Impact Factor: 2.5 (2026), Q2.
- AlHousrya, O., Bennagi, A, P.A. Cotfas, and D.T. Cotfas. IoT-Enabled Driver Health Monitoring System Using Multi-Modal Sensors and Cloud Integration. in 2025 IEEE 31st International Symposium for Design and Technology in Electronic Packaging (SIITME). 2025. IEEE. <https://doi.org/10.1109/SIITME67657.2025.11293652>
- AlHousrya, O., Bennagi, A., P.A. Cotfas, and D.T. Cotfas, Vision-Based Driver Drowsiness Detection Using Eye-State Analysis and Lightweight CNNs. Accepted for presentation at the 2026 IEEE Conference on Advanced Topics on Measurement and Simulation (ATOMS 2026), with subsequent publication in IEEE Xplore-compliant proceedings.
- Participare la atelierul proiectului UNITA, unde au fost diseminate implementarea și rezultatele cercetării legate de algoritmi de extragere a parametrilor, inclusiv PSA și algoritmi metaeuristici Hybrid SSA-GSK.

Referințe

- [1] Programme, U.N.E. Emissions gap report 2023. Broken record. Temperatures hit new highs, yet world fails to cut emissions (again). Report·No.2023. <https://www.unep.org/resources/emissions-gap-report-2023>.
- [2] Agency, I.R.E. World Energy Transitions Outlook 2023: 1.5°C Pathway. Report·No.2023. <https://www.irena.org/publications/2023/Jun/World-Energy-Transitions-Outlook-2023>.
- [3] Agency, I.R.E. Renewable power generation costs in 2024. Report·No.2024. <https://www.irena.org/Publications/2025/Jun/Renewable-Power-Generation-Costs-in-2024>.
- [4] Ejayi, C.J., D. Cai, D. Thomas, S. Obiora, E. Osei-Mensah, C. Acen, et al., Comprehensive review of artificial intelligence applications in renewable energy systems: current implementations and emerging trends. Journal of Big Data, 2025. **12**(1): p. 169. <https://doi.org/10.1186/s40537-025-01178-7>
- [5] Shoaee, M., Y. Noorollahi, A. Hajinezhad, and S.F. Moosavian, A review of the applications of artificial intelligence in renewable energy systems: An approach-based study. Energy Convers. Manag., 2024. **306**: p. 118207. <https://doi.org/10.1016/j.enconman.2024.118207>
- [6] Xiang, H., X. Li, X. Liao, W. Cui, F. Liu, and D. Li, Artificial Intelligence in Renewable Energy Systems: Applications and Security Challenges. Energies, 2025. **18**(8): p. 1931. <https://doi.org/10.3390/en18081931>
- [7] Bennagi, A., O. AlHousrya, D.T. Cotfas, and P.A. Cotfas, Comprehensive study of the artificial intelligence applied in renewable energy. Energy Strategy Reviews, 2024. **54**: p. 101446. <https://doi.org/10.1016/j.esr.2024.101446>
- [8] Zaidi, A., A bibliometric analysis of machine learning techniques in photovoltaic cells and solar energy (2014-2022). Energy Rep., 2024. **11**: p. 2768-2779. <https://doi.org/10.1016/j.egyrs.2024.02.036>
- [9] Apeh, O. and N. Nwulu, MACHINE LEARNING PREDICTIONS FOR FAULT DETECTIONS IN SOLAR PHOTOVOLTAIC SYSTEM: A BIBLIOGRAPHIC OUTLOOK. Journal of Infrastructure, Policy and Development, 2025. **9**(2): p. 9940. <https://doi.org/10.24294/jipd9940>
- [10] Mateo Romero, H.F., M.Á. González Rebollo, V. Cardeñoso-Payo, V. Alonso Gómez, A. Redondo Plaza, R.T. Moyo, et al., Applications of artificial intelligence to photovoltaic systems: a review. Appl. Sci., 2022. **12**(19): p. 10056. <https://doi.org/10.3390/app121910056>
- [11] Shahzad, N., N. Hussain, S. Umar, M.F. Azam, T. Yousaf, and A. Waqas, Impacts of soiling on solar panel performance and state-of-the-art effective cleaning methods: A recent review. Journal of Cleaner Production, 2025: p. 145119. <https://doi.org/10.1016/j.jclepro.2025.145119>
- [12] Segbefia, O.K., A.G. Imenes, and T.O. Saetre, Moisture ingress in photovoltaic modules: A review. Sol. Energy, 2021. **224**: p. 889-906. <https://doi.org/10.1016/j.solener.2021.06.055>
- [13] Ahmed, S., A. Ali, J.A. Ansari, S.A. Qadir, and L. Kumar, A Comprehensive Review of Solar Photovoltaic Systems: Scope, Technologies, Applications, Progress, Challenges and Recommendations. IEEE Access, 2025. <https://doi.org/10.1109/ACCESS.2025.3558539>

- [14] Agency, I.R.E. Renewable Power Generation Costs in 2020. Report No. 2021. <https://www.irena.org/publications/2021/Jun/Renewable-Power-Costs-in-2020>.
- [15] Shaker, L.M., A.A. Al-Amiery, M.M. Hanoon, W.K. Al-Azzawi, and A.A.H. Kadhum, Examining the influence of thermal effects on solar cells: a comprehensive review. *Sustainable Energy Research*, 2024. **11**(1): p. 6. <https://doi.org/10.1186/s40807-024-00100-8>
- [16] Rajput, P., D. Singh, K. Singh, A. Karthick, M.A. Shah, R.S. Meena, et al., A comprehensive review on reliability and degradation of PV modules based on failure modes and effect analysis. *International Journal of Low-Carbon Technologies*, 2024. **19**: p. 922-937. <https://doi.org/10.1093/ijlct/ctad106>
- [17] Al Mahdi, H., P.G. Leahy, M. Alghoul, and A.P. Morrison. A review of photovoltaic module failure and degradation mechanisms: Causes and detection techniques. in *Solar*. 2024. MDPI. <https://doi.org/10.3390/solar4010003>
- [18] Çetinbaş, İ., Parameter Extraction of Single, Double, and Triple-Diode Photovoltaic Models Using the Weighted Leader Search Algorithm. *Global Challenges*, 2024. **8**(5): p. 2300355. <https://doi.org/10.1002/gch2.202300355>
- [19] Sharma, A., A. Sharma, M. Averbukh, V. Jatelly, S. Rajput, B. Azzopardi, et al., Performance investigation of state-of-the-art metaheuristic techniques for parameter extraction of solar cells/module. *Sci. Rep.*, 2023. **13**(1): p. 11134. <https://doi.org/10.1038/s41598-023-37824-4>
- [20] Gu, Z., G. Xiong, and X. Fu, Parameter extraction of solar photovoltaic cell and module models with metaheuristic algorithms: A review. *Sustainability*, 2023. **15**(4): p. 3312. <https://doi.org/10.3390/su15043312>
- [21] Li, S., W. Gong, and Q. Gu, A comprehensive survey on meta-heuristic algorithms for parameter extraction of photovoltaic models. *Renewable and Sustainable Energy Reviews*, 2021. **141**: p. 110828. <https://doi.org/10.1016/j.rser.2021.110828>
- [22] Hao, X., P. Liu, Y. Deng, and X. Meng, A MIC-LSTM based parameter extraction method for single-diode PV model. *Front. Energy Res.*, 2024. **11**: p. 1349887. <https://doi.org/10.3389/fenrg.2023.1349887>
- [23] Chen, Y.-G., Y. Cao, K. Lu, Q. Yang, Y. Chen, and Y. Ping, Differential evolution with classified mutation for parameter extraction of photovoltaic models. *PLoS One*, 2025. **20**(10): p. e0332083. <https://doi.org/10.1371/journal.pone.0332083>
- [24] Yang, S., G. Xiong, X. Fu, S. Mirjalili, and A.W. Mohamed, Enhanced Whale optimization algorithms for parameter identification of solar photovoltaic cell models: a comparative study. *Sci. Rep.*, 2024. **14**(1): p. 16765. <https://doi.org/10.1038/s41598-024-67600-x>
- [25] Gupta, M., A. Arya, U. Varshney, J. Mittal, and A. Tomar, A review of PV power forecasting using machine learning techniques. *Progress in Engineering Science*, 2025: p. 100058. <https://doi.org/10.1016/j.pes.2025.100058>
- [26] Yu, J., X. Li, L. Yang, L. Li, Z. Huang, K. Shen, et al., Deep learning models for PV power forecasting. *Energies*, 2024. **17**(16): p. 3973. <https://doi.org/10.3390/en17163973>
- [27] Ibrahim, M.S., S.M. Gharghory, and H.A. Kamal, A hybrid model of CNN and LSTM autoencoder-based short-term PV power generation forecasting. *Electrical Engineering*, 2024. **106**(4): p. 4239-4255. <https://doi.org/10.1007/s00202-023-02220-8>

- [28] Xiang, X., X. Li, Y. Zhang, and J. Hu, A short-term forecasting method for photovoltaic power generation based on the TCN-ECANet-GRU hybrid model. *Sci. Rep.*, 2024. **14**(1): p. 6744. <https://doi.org/10.1038/s41598-024-56751-6>
- [29] Wang, B., J. Chen, Y. Zhu, J. Fan, J. Hu, and L. Tan, SP-Transformer: A Medium-and Long-Term Photovoltaic Power Forecasting Model Integrating Multi-Source Spatiotemporal Features. *Appl. Sci.*, 2025. **15**(21): p. 11846. <https://doi.org/10.3390/app152111846>
- [30] Yang, Y., Y. Liu, Y. Zhang, S. Shu, and J. Zheng, DEST-GNN: A double-explored spatio-temporal graph neural network for multi-site intra-hour PV power forecasting. *Appl. Energy*, 2025. **378**: p. 124744. <https://doi.org/10.1016/j.apenergy.2024.124744>
- [31] Zhang, F., X. Li, Z. Wang, Y. Wen, X. Zhou, Z. Wu, et al., MIPV-NWP-PINN V1. 0: Development of a Multi-scale Photovoltaic Power Forecasting Framework Integrating Numerical Weather Prediction with Physics-Informed Neural Networks. *EGUsphere*, 2025. **2025**: p. 1-23. <https://doi.org/10.5194/egusphere-2025-4439>
- [32] Wang, K., L. Wang, Q. Meng, C. Yang, Y. Lin, J. Zhu, et al., Accurate photovoltaic power prediction via temperature correction with physics-informed neural networks. *Energy*, 2025: p. 136546. <https://doi.org/10.1016/j.energy.2025.136546>
- [33] Yu, H., S. Chen, Y. Chu, M. Li, Y. Ding, R. Cui, et al., Self-attention mechanism to enhance the generalizability of data-driven time-series prediction: A case study of intra-hour power forecasting of urban distributed photovoltaic systems. *Appl. Energy*, 2024. **374**: p. 124007. <https://doi.org/10.1016/j.apenergy.2024.124007>
- [34] Dai, X., & Yang, Y, Photovoltaic Power Prediction and SHAP Interpretability Analysis Based on Multi-Model Comparative Learning. *Highlights in Science, Engineering and Technology*, 2025. **142**. <https://doi.org/10.54097/ktr7gn53>
- [35] Arabshahi, M., H. Torkaman, and A. Keyhani, A method for hybrid extraction of single-diode model parameters of photovoltaics. *Renew. Energy*, 2020. **158**: p. 236-252. <https://doi.org/10.1016/j.renene.2020.05.035>
- [36] Jordehi, A.R., Parameter estimation of solar photovoltaic (PV) cells: A review. *Renewable and Sustainable Energy Reviews*, 2016. **61**: p. 354-371. <https://doi.org/10.1016/j.rser.2016.03.049>
- [37] Ramadan, A.-E., S. Kamel, T. Khurshaid, S.-R. Oh, and S.-B. Rhee, Parameter extraction of three diode solar photovoltaic model using improved grey wolf optimizer. *Sustainability*, 2021. **13**(12): p. 6963. <https://doi.org/10.3390/su13126963>
- [38] Ahmadianfar, I., W. Gong, A.A. Heidari, N.A. Golilarz, A. Samadi-Koucheksaraee, and H. Chen, Gradient-based optimization with ranking mechanisms for parameter identification of photovoltaic systems. *Energy Rep.*, 2021. **7**: p. 3979-3997. <https://doi.org/10.1016/j.egyr.2021.06.064>
- [39] Deotti, L.M.P. and I.C. da Silva Junior, A survey on the parameter extraction problem of the photovoltaic single diode model from a current–voltage curve. *Sol. Energy*, 2023. **263**: p. 111930. <https://doi.org/10.1016/j.solener.2023.111930>
- [40] Chen, X., S. Wang, and K. He, Parameter estimation of various PV cells and modules using an improved simultaneous heat transfer search algorithm. *Journal of Computational Electronics*, 2024. **23**(3): p. 584-599. <https://doi.org/10.1007/s10825-024-02153-w>

- [41] Madhiarasan, M., D.T. Cotfas, and P.A. Cotfas, Black widow optimization algorithm used to extract the parameters of photovoltaic cells and panels. *Mathematics*, 2023. **11**(4): p. 967. <https://doi.org/10.3390/math11040967>
- [42] Ghetas, M. and M. Elshourbagy, Parameters extraction of photovoltaic models using enhanced generalized normal distribution optimization with neighborhood search. *Neural Computing and Applications*, 2024. **36**(23): p. 14035-14052. <https://doi.org/10.1007/s00521-024-09609-x>
- [43] Xiong, G., L. Li, A.W. Mohamed, X. Yuan, and J. Zhang, A new method for parameter extraction of solar photovoltaic models using gaining–sharing knowledge based algorithm. *Energy Rep.*, 2021. **7**: p. 3286-3301. <https://doi.org/10.1016/j.egy.2021.05.030>
- [44] Gao, X., Y. Cui, J. Hu, G. Xu, Z. Wang, J. Qu, et al., Parameter extraction of solar cell models using improved shuffled complex evolution algorithm. *Energy Convers. Manag.*, 2018. **157**: p. 460-479. <https://doi.org/10.1016/j.enconman.2017.12.033>
- [45] Cotfas, D.T., A.M. Deaconu, and P.A. Cotfas, Hybrid successive discretisation algorithm used to calculate parameters of the photovoltaic cells and panels for existing datasets. *IET Renewable Power Generation*, 2021. **15**(15): p. 3661-3687. <https://doi.org/10.1049/rpg2.12262>
- [46] Choulli, I., M. Elyaqouti, D. Saadaoui, S. Lidaighbi, A. Elhammoudy, and I. Abazine, DIWJAYA: JAYA driven by individual weights for enhanced photovoltaic model parameter estimation. *Energy Convers. Manag.*, 2024. **305**: p. 118258. <https://doi.org/10.1016/j.enconman.2024.118258>
- [47] Ali, F., A. Sarwar, F.I. Bakhsh, S. Ahmad, A.A. Shah, and H. Ahmed, Parameter extraction of photovoltaic models using atomic orbital search algorithm on a decent basis for novel accurate RMSE calculation. *Energy Convers. Manag.*, 2023. **277**: p. 116613. <https://doi.org/10.1016/j.enconman.2022.116613>
- [48] Abdel-Basset, M., D. El-Shahat, K.M. Sallam, and K. Munasinghe, Parameter extraction of photovoltaic models using a memory-based improved gorilla troops optimizer. *Energy Convers. Manag.*, 2022. **252**: p. 115134. <https://doi.org/10.1016/j.enconman.2021.115134>
- [49] Belabbès, F., D.T. Cotfas, P.A. Cotfas, and M. Medles, Using the snake optimization metaheuristic algorithms to extract the photovoltaic cells parameters. *Energy Convers. Manag.*, 2023. **292**: p. 117373. <https://doi.org/10.1016/j.enconman.2023.117373>
- [50] Khalifa, H., M. Ebeed, G. Magdy, S.A. Khaleel, M.I. Shehata, M.M. Salah, et al., Parameter extraction of PV models under varying meteorological conditions using a modified electric eel foraging optimization algorithm. *Sci. Rep.*, 2025. **15**(1): p. 19316. <https://doi.org/10.1038/s41598-025-98270-y>
- [51] Afonso, D., O. Mesbahi, A. Bouich, and M. Tlemçani, Influence of long-term and short-term solar radiation and temperature exposure on the material properties and performance of photovoltaic panels: A comprehensive review. *Energies*, 2025. **18**(19): p. 5072. <https://doi.org/10.3390/en18195072>
- [52] Rahman, T., A.A. Mansur, M.S. Hossain Lipu, M.S. Rahman, R.H. Ashique, M.A. Houran, et al., Investigation of degradation of solar photovoltaics: A review of aging factors,

- impacts, and future directions toward sustainable energy management. *Energies*, 2023. **16**(9): p. 3706. <https://doi.org/10.3390/en16093706>
- [53] Hishikawa, Y., T. Takenouchi, M. Higa, K. Yamagoe, H. Ohshima, and M. Yoshita, Translation of solar cell performance for irradiance and temperature from a single IV curve without advance information of translation parameters. *IEEE Journal of Photovoltaics*, 2019. **9**(5): p. 1195-1201. <https://doi.org/10.1109/JPHOTOV.2019.2924388>
- [54] Kullampalayam Murugaiyan, N., K. Chandrasekaran, M.M. Devapitchai, and T. Senjyu, Parameter Estimation of Three-Diode Photovoltaic Model Using Reinforced Learning-Based Parrot Optimizer with an Adaptive Secant Method. *Sustainability*, 2024. **16**(23): p. 10603. <https://doi.org/10.3390/su162310603>
- [55] Nguyen-Duc, T., H. Nguyen-Duc, T. Le-Viet, and H. Takano, Single-diode models of PV modules: A comparison of conventional approaches and proposal of a novel model. *Energies*, 2020. **13**(6): p. 1296. <https://doi.org/10.3390/en13061296>
- [56] Saadaoui, D., M. Elyaqouti, K. Assalaou, D.B. Hmamou, S. Lidaighbi, E.H. Arjda, et al., Parameters extraction of single diode and double diode models using analytical and numerical approach: A comparative study. *IJMoS*, 2025. **45**(2): p. 569-598. <https://doi.org/10.1080/02286203.2023.2226285>
- [57] Abdel-Basset, M., R. Mohamed, A. El-Fergany, M. Abouhawwash, and S. Askar, Parameters identification of PV triple-diode model using improved generalized normal distribution algorithm. *Mathematics*, 2021. **9**(9): p. 995. <https://doi.org/10.3390/math9090995>
- [58] Deaconu, A.M., D.T. Cotfas, and P.A. Cotfas, Extracting photovoltaic cells parameters for three diode model using HSDA algorithm. *Energy Rep.*, 2024. **12**: p. 5096-5109. <https://doi.org/10.1016/j.egyr.2024.10.052>
- [59] Gao, S., C. Xiang, M. Yu, K.T. Tan, and T.H. Lee. On Solar Photovoltaic Parameter Estimation: Global Optimality Analysis and a Simple Efficient Differential Evolution Method. in *2023 62nd IEEE Conference on Decision and Control (CDC)*. 2023. IEEE. <https://doi.org/10.1109/CDC49753.2023.10383303>
- [60] Elazab, O.S., H.M. Hasanien, M.A. Elgendy, and A.M. Abdeen, Parameters estimation of single-and multiple-diode photovoltaic model using whale optimisation algorithm. *IET Renewable Power Generation*, 2018. **12**(15): p. 1755-1761. <https://doi.org/10.1049/iet-rpg.2018.5317>
- [61] Singla, M.K., J. Gupta, M.H. Alsharif, M.-K. Kim, M. Aljaidi, and M. Safaraliev, A robust multi-objective optimization algorithm for accurate parameter estimation for solar cell models. *Soft Computing*, 2024. **28**(19): p. 11265-11277. <https://doi.org/10.1007/s00500-024-09888-5>
- [62] Ayyarao, T.S. and G.I. Kishore, Parameter estimation of solar PV models with artificial humming bird optimization algorithm using various objective functions. *Soft Computing*, 2024. **28**(4): p. 3371-3392. <https://doi.org/10.1007/s00500-023-08630-x>
- [63] Batzelis, E.I. and S.A. Papathanassiou, A method for the analytical extraction of the single-diode PV model parameters. *IEEE Transactions on Sustainable Energy*, 2015. **7**(2): p. 504-512. <https://doi.org/10.1109/TSTE.2015.2503435>
- [64] Xu, J., D. Chen, G. Bai, and W. Li, A separable nonlinear least squares approach for double-diode photovoltaic model parameter extraction. *Journal of Renewable and Sustainable Energy*, 2021. **13**(4). <https://doi.org/10.1063/5.0060563>

- [65] Toledo, F., J.M. Blanes, V. Galiano, and A. Laudani, In-depth analysis of single-diode model parameters from manufacturer's datasheet. *Renew. Energy*, 2021. **163**: p. 1370-1384. <https://doi.org/10.1016/j.renene.2020.08.136>
- [66] Anani, N. and H. Ibrahim, Performance evaluation of analytical methods for parameters extraction of photovoltaic generators. *Energies*, 2020. **13**(18): p. 4825. <https://doi.org/10.3390/en13184825>
- [67] Bouali, Y. and B. Alamri, Parameter extraction for photovoltaic models with flood-algorithm-based optimization. *Mathematics*, 2024. **13**(1): p. 19. <https://doi.org/10.3390/math13010019>
- [68] Abdel-Basset, M., R. Mohamed, I.M. Hezam, K.M. Sallam, and I.A. Hameed, Parameters identification of photovoltaic models using Lambert W-function and Newton-Raphson method collaborated with AI-based optimization techniques: A comparative study. *Expert Systems with Applications*, 2024. **255**: p. 124777. <https://doi.org/10.1016/j.eswa.2024.124777>
- [69] Mekri, A., A. Seghieur, F. Kaddour, Y. Boudouaoui, A. Chouder, and S. Silvestre, Novel Hybrid Analytical-Metaheuristic Optimization for Efficient Photovoltaic Parameter Extraction. *Electronics*, 2025. **14**(21): p. 4294. <https://doi.org/10.3390/electronics14214294>
- [70] Bakria, D., A. Beladel, B. Korich, A. Teta, R.D. Mohammedi, A.A. Laouid, et al., A novel enhanced Grey Wolf Optimizer for global optimization problems: Application to photovoltaic parameter extraction. *Energy Rep.*, 2025. **14**: p. 2782-2796. <https://doi.org/10.1016/j.egy.2025.09.027>
- [71] Bennagi, A., O. AlHousrya, D.T. Cotfas, and P.A. Cotfas, HYBRID SALP SWARM-GAINING AND SHARING KNOWLEDGE (SSA-GSK) METAHEURISTIC ALGORITHM FOR EXTRACTING PHOTOVOLTAIC CELL PARAMETERS. *Environmental Engineering & Management Journal (EEMJ)*, 2025. **24**(5). <https://doi.org/10.30638/eemj.2025.085>
- [72] Gao, Y., PID-based search algorithm: A novel metaheuristic algorithm based on PID algorithm. *Expert Systems with Applications*, 2023. **232**: p. 120886. <https://doi.org/10.1016/j.eswa.2023.120886>
- [73] Bennagi, A., O. AlHousrya, D.T. Cotfas, and P.A. Cotfas, Parameter extraction of photovoltaic cells and panels using a pid-based metaheuristic algorithm. *Appl. Sci.*, 2025. **15**(13): p. 7403. <https://doi.org/10.3390/app15137403>
- [74] Humada, A.M., M. Hojabri, S. Mekhilef, and H.M. Hamada, Solar cell parameters extraction based on single and double-diode models: A review. *Renewable and sustainable energy reviews*, 2016. **56**: p. 494-509. <https://doi.org/10.1016/j.rser.2015.11.051>
- [75] Mirjalili, S., A.H. Gandomi, S.Z. Mirjalili, S. Saremi, H. Faris, and S.M. Mirjalili, Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems. *Adv. Eng. Software*, 2017. **114**: p. 163-191. <https://doi.org/10.1016/j.advengsoft.2017.07.002>
- [76] Cotfas, D.T., P.A. Cotfas, and O.M. Machidon, Study of temperature coefficients for parameters of photovoltaic cells. *International Journal of Photoenergy*, 2018. **2018**(1): p. 5945602. <https://doi.org/10.1155/2018/5945602>
- [77] Cotfas, D.T., A.M. Deaconu, and P.A. Cotfas, Application of successive discretization algorithm for determining photovoltaic cells parameters. *Energy Convers. Manag.*, 2019. **196**: p. 545-556. <https://doi.org/10.1016/j.enconman.2019.06.037>

- [78] Easwarakhanthan, T., J. Bottin, I. Bouhouch, and C. Boutrit, Nonlinear minimization algorithm for determining the solar cell parameters with microcomputers. *IJSE*, 1986. **4**(1): p. 1-12. <https://doi.org/10.1080/01425918608909835>
- [79] Oliva, D., M. Abd El Aziz, and A.E. Hassanien, Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm. *Appl. Energy*, 2017. **200**: p. 141-154. <https://doi.org/10.1016/j.apenergy.2017.05.029>
- [80] Inman, R.H., H.T. Pedro, and C.F. Coimbra, Solar forecasting methods for renewable energy integration. *Prog. Energy Combust. Sci.*, 2013. **39**(6): p. 535-576. <https://doi.org/10.1016/j.pecs.2013.06.002>
- [81] Antonanzas, J., N. Osorio, R. Escobar, R. Urraca, F.J. Martinez-de-Pison, and F. Antonanzas-Torres, Review of photovoltaic power forecasting. *Sol. Energy*, 2016. **136**: p. 78-111. <https://doi.org/10.1016/j.solener.2016.06.069>
- [82] Chu, Y., M. Li, C.F. Coimbra, D. Feng, and H. Wang, Intra-hour irradiance forecasting techniques for solar power integration: A review. *iScience*, 2021. **24**(10). <https://doi.org/10.1016/j.isci.2021.103136>
- [83] Xu, S., R. Zhang, H. Ma, C. Ekanayake, and Y. Cui, On vision transformer for ultra-short-term forecasting of photovoltaic generation using sky images. *Sol. Energy*, 2024. **267**: p. 112203. <https://doi.org/10.1016/j.solener.2023.112203>
- [84] Zang, H., D. Chen, J. Liu, L. Cheng, G. Sun, and Z. Wei, Improving ultra-short-term photovoltaic power forecasting using a novel sky-image-based framework considering spatial-temporal feature interaction. *Energy*, 2024. **293**: p. 130538. <https://doi.org/10.1016/j.energy.2024.130538>
- [85] Iheanetu, K.J., Solar photovoltaic power forecasting: A review. *Sustainability*, 2022. **14**(24): p. 17005. <https://doi.org/10.3390/su142417005>
- [86] Paulescu, M. and E. Paulescu, Short-term forecasting of solar irradiance. *Renew. Energy*, 2019. **143**: p. 985-994. <https://doi.org/10.1016/j.renene.2019.05.075>
- [87] Paulescu, M., N. Stefu, C. Dughir, A. Sabadus, D. Calinoiu, and V. Badescu, A simple but accurate two-state model for nowcasting PV power. *Renew. Energy*, 2022. **195**: p. 322-330. <https://doi.org/10.1016/j.renene.2022.05.056>
- [88] Yang, D., J. Kleissl, C.A. Gueymard, H.T. Pedro, and C.F. Coimbra, History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Sol. Energy*, 2018. **168**: p. 60-101. <https://doi.org/10.1016/j.solener.2017.11.023>