



Academia Oamenilor de Știință din România

Proiect finanțat prin AOSR-Teams 2022

Domeniul „4. Asigurarea independenței energetice a României”



Universitatea Politehnica di București

Facultatea de Energetică

Departamentul Sisteme Electroenergetice

Pachet software bazat pe inteligență artificială pentru managementul energetic optim în scopul creșterii independenței energetice a României

Raportul intermediar numărul 3

Membrii echipei:

Ș.l. dr. ing. Dorian Sidea

Ș.l. dr. ing. Irina Picioroagă

As. drd. ing. Andrei Tudose

1. Independența energetică a României

Acest capitol prezintă o analiză a surselor de producție a energiei electrice la nivel național și diferite soluții pentru a îmbunătăți independența energetică a României cu ajutorul surselor regenerabile de tip eolian și fotovoltaic.

Datele de intrare pe care se bazează analiza de față constau în puterile produse de fiecare tip de sursă de energie primară la nivel național, pentru anul 2022. Valorile sunt disponibile public pe site-ul www.transelectrica.ro și sunt furnizate sub forma unui fișier text ce conține puterile agregate în funcție de sursa primară de energie, consumul total și soldul la intervale de timp de aproximativ 10 minute. Soldul este calculat ca diferență dintre consum și generare, prin urmare, valorile negative ale soldului reprezintă export de energie, iar cele pozitive import. Primul pas în prelucrarea celor peste 53700 de valori pentru fiecare tip de sursă primară constă în importarea datelor de intrare în mediul de programare Matlab și realizarea unei reeșantionări, pentru obținerea valorilor medii orare. Principala provocare constă în faptul că intervalele de timp nu au lungimi egale, prin urmare, valorile au fost reeșantionate în Matlab cu ajutorul funcțiilor specifice seriilor de timp. Pe baza noilor valori eșantionate la intervale constante de o oră, este posibilă determinarea unui bilanț energetic la nivel național.

Principalul scop al acestui proiect este îmbunătățirea independenței energetice a României, prin urmare obiectivul acestei analize este reducerea importurilor de energie electrică la nivel național pe durata unui an calendaristic prin dezvoltarea noilor capacități de producție din surse regenerabile de energie, precum solară și eoliană. În consecință, sunt analizate trei scenarii: S1: se consideră structura actuală a surselor de producție; S2: se consideră ipoteza eliminării surselor de producție pe bază de cărbune și S3: se consideră eliminarea surselor pe baza de cărbune simultan cu realizarea celui de-al treilea reactor nuclear la CNE Cernavodă, care generează în bandă o putere de 650 MW. Pentru fiecare dintre cele trei scenarii se vor introduce noi capacități de producție pe baza energiei regenerabile din surse de tip eolian și fotovoltaic. În acest scop, se utilizează curbe orare de producție simulate pentru durata întregului an calendaristic, cu ajutorul platformei disponibile on-line la www.renewables.ninja. Pe baza acestor curbe de producție, se realizează două variante pentru fiecare din cele trei scenarii considerate, în care se determină puterea necesară a fi instalată în surse de tip eolian (variantă notată „E”) sau fotovoltaic „F” pentru a echilibra balanța anuală.

Scenariul 1 – structura actuală a surselor de producție

În acest scenariu se păstrează structura actuală a surselor de producție și se introduc capacități noi de producție de tip eolian cu o putere instalată de 323 MW, în varianta notată S1.E, respectiv se introduce o putere suplimentară de 563 MW instalată în surse de tip fotovoltaic, în varianta notată S1.F. În ambele variante, S1.E și S1.F se obține un sold total anual de aproximativ 0 MWh, iar structura surselor de producție pentru cele două variante este prezentată în figura 1.1.




Figura 1.1 Structura surselor de producție în scenariile a) S1.E și b) S1.F.

În cazul scenariului S1, se observă că ponderea centralelor pe cărbune este de 19%, hidrocarburi 19% în timp ce sursele de tip nuclear și hidroenergetic reprezintă 20%, respectiv 25%. În scenariul S1.E ponderea surselor eoliene din mixul energetic ajunge la 14%, iar în cazul S1.F, ponderea surselor fotovoltaice atinge 4%.

Scenariul 2 – eliminarea surselor pe bază de cărbune

În cadrul celui de-al doilea scenariu, se consideră eliminarea totală a surselor pe bază de cărbune și înlocuirea acestora exclusiv cu surse de tip eolian sau fotovoltaic. Astfel, în scenariul S2.E este necesară introducerea unei puteri totale de 3680 MW instalată în surse de tip eolian, pentru echilibrarea soldului, respectiv 6430 MW în surse de tip fotovoltaic în scenariul S2.F. Structura surselor de producție pentru cele două variante este prezentată în figura 1.2.

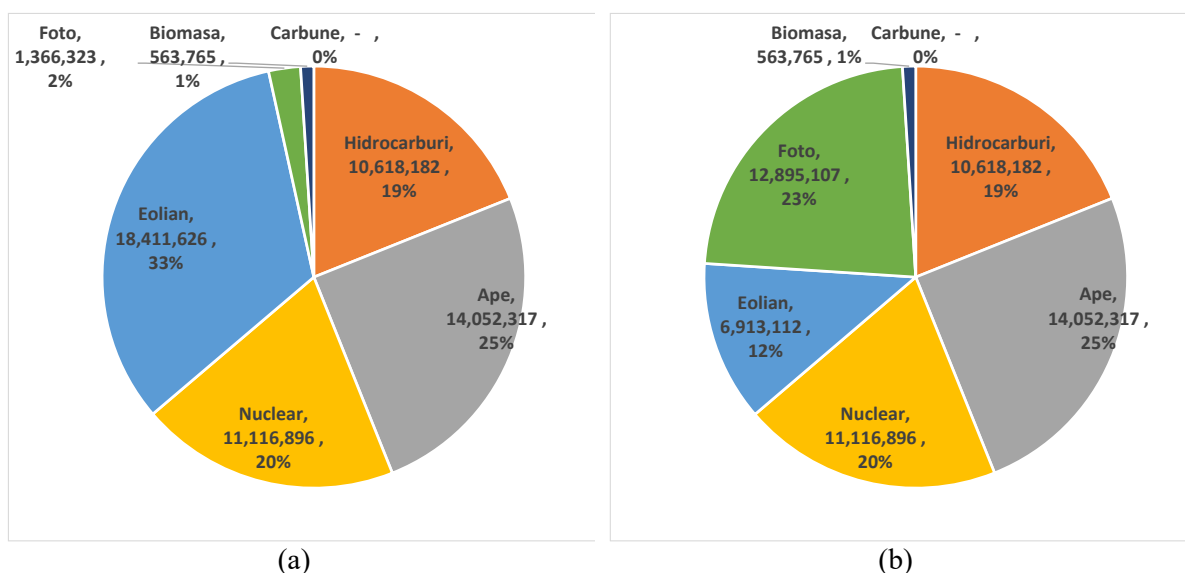


Figura 1.2 Structura surselor de producție în scenariile a) S2.E și b) S2.F.

Pe baza figurii 1.2 se poate observa că în urma eliminării surselor pe cărbuni, în varianta S2.E, sursele de tip eolian ar asigura 33% din producția anuală, în timp ce ponderile pentru celelalte tipuri de surse se păstrează nemodificate ca în scenariul S1. În varianta S2.F, prin introducerea noilor surse de tip fotovoltaic cu o putere totală 6430 MW, ponderea acestui tip de energie ajunge la 23%

Scenariul 3 – eliminarea surselor pe bază de cărbune și introducerea unui nou reactor nuclear la CNE Cernavodă

În acest scenariu, se consideră eliminarea totală a surselor pe bază de cărbune concomitent cu introducerea unui nou reactor nuclear la CNE Cernavodă, care furnizează în bandă o putere de 650 MW. Pentru echilibrarea soldului se vor introduce de asemenea noi capacități de producție de tip eolian (S3.E) și fotovoltaic (S3.F) cu o putere totală de 1870 MW, respectiv 3250 MW.

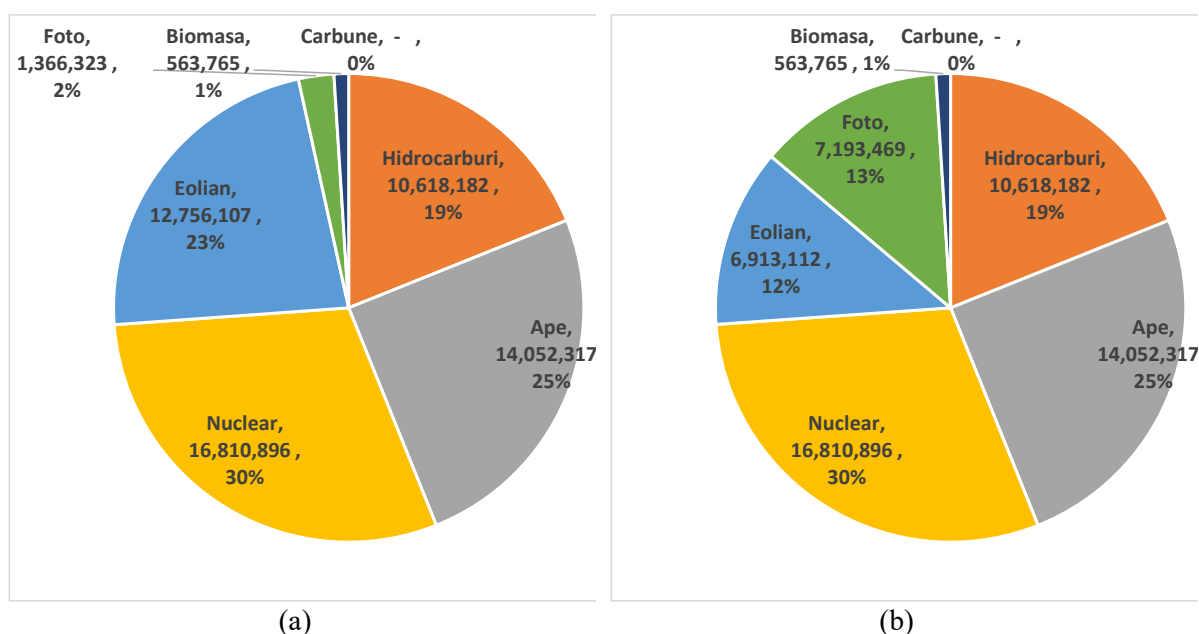


Figura 1.3 Structura surselor de producție în scenariile a) S3.E și b) S3.F.

Pe baza structurii surselor de producție prezentată în figura 1.3, se poate observa că ponderea surselor de tip nuclear crește la 30% în ambele variante. În scenariul S3.E, ponderea centralelor eoliene ajunge la 23%, iar ponderea surselor de tip fotovoltaic în scenariul S3.F ajunge la 13%.

Analiza comparativă a importurilor și exporturilor de energie electrică

În continuare este prezentată o analiză a cantităților orare de energie electrică importată și exportată la nivel național pentru cele trei scenarii considerate: S1, S2 și S3, cu cele două variante „E” și „F”, fiecare. În acest scop, se determină soldul orar, ca diferență dintre consum și producție considerând structura surselor de producție realizată în cadrul fiecărei variante. În figura următoare sunt prezentate valorile soldului orar, ordonate descrescător pentru fiecare din cele șase scenarii considerate.




Figura 1.4 Valorile soldului orar pentru fiecare scenariu, ordonate descrescător.

Pe baza figurii se poate observa că în scenariile S1.E și S1.F valorile sunt relativ apropiate datorită puterilor relativ mici de 323 MW și 563 MW instalate suplimentar în surse de tip eolian și fotovoltaic. În cazul scenariilor S2.E și S2.F, sursele bazate pe cărbuni sunt eliminate, iar balanța se echilibrează prin introducerea surselor noi cu puteri semnificative de 3680 MW în surse eoliene, respectiv 6430 MW în surse fotovoltaice. Astfel în cazul scenariului S2.F se poate observa apariția unui număr de aproximativ 1000 intervale orare cu cantități semnificative de puteri exportate, peste 2000 MW. Prin comparație, exportul realizat în scenariul S2.E cu o putere semnificativă instalată în surse de tip eolian, este moderat, fiind comparabil cu scenariul S1.E în care se păstrează structura actuală a surselor de producție. În scenariile S3, introducerea unui nou reactor nuclear conduce la reducerea puterilor necesare a fi instalate în surse de tip eolian și fotovoltaic până la valorile de 1870 MW, respectiv 3250 MW. Astfel, cantitățile orare de energie importată și exportată se mențin apropiate de cele din scenariile S1.

Soluții pentru îmbunătățirea independenței energetice la nivel național

Pe baza analizei structurii surselor de producție prezentată anterior, se poate concluziona că introducerea surselor regenerabile de energie de tip eolian și fotovoltaic reprezintă o soluție parțială a problemei asigurării independenței energetice a României, datorită atât caracterului intermitent și imprevizibil al acestora cât și al factorul de capacitate relativ redus. Sursele de tip fotovoltaic prezintă un dezavantaj suplimentar datorită faptului că vârful de producție coincide cu golul de consum. În plus, cerințele actuale privind reducerea emisiilor prin eliminarea surselor de producție bazate pe cărbune va accentua aceste probleme. Prin urmare, în continuare este prezentată o serie de soluție posibile pentru a îmbunătăți independența energetică a României.

Prima soluție propusă în contextul prezentat anterior constă în instalarea capacităților de stocare a energiei electrice în cantități mari, cu scopul de a înmagazina surplusul de energie electrică generată de sursele regenerabile și de a alimenta consumatorii în perioadele de vârf de sarcină. În acest scop, se pot considera atât centralele hidroelectrice cu acumulare prin

pompăre – precum proiectul Tarnița – cât și soluțiile de stocare bazate pe baterii, care sunt în continuă dezvoltare tehnologică.

Cea de-a doua soluție constă în dezvoltarea surselor de energie regenerabilă care nu au un caracter intermitent atât de pronunțat, precum centralele hidroelectrice, fie cu lac de acumulare, fie pe firul râului. Aceste centrale au șanse relativ mici de a fi realizate, datorită obstacolelor în dezvoltarea de baraje și lacuri de acumulare de mare capacitate. Prin urmare, dezvoltarea unui număr semnificativ de microhidrocentrale ar putea reprezenta o parte a soluției de îmbunătățire a independenței energetice.

A treia soluție, constă în dezvoltarea capacităților de producție bazate pe energie nucleară. În acest sens, este probabilă dezvoltarea de reactoare nucleare modulare de capacitate mică în parteneriat cu Statele Unite ale Americii, cât și construirea unui nou reactor nuclear la CNE Cernavodă, unde conform informațiilor publice, discuțiile sunt într-un stadiu avansat.

În realitate, pentru îmbunătățirea independenței energetice se vor implementa diferite combinații între soluțiile prezentate mai sus. Pentru aceasta, este necesară o analiză aprofundată, care să includă un calcul de optimizare din care să rezulte diferite combinații optime între soluțiile considerate, cu scopul de a obține un sold egal cu zero la nivelul unui an, minimizând puterile instalate în baterii și în centrale de tip hidroelectric sau nuclearo-electrice. Realizarea acestui calcul de optimizare se va baza pe algoritmi metaeuristici, care sunt prezentați în capitolele următoare.

2. Algoritmi metaeuristici

Algoritmii metaeuristici sunt o clasă de tehnici de calcul, inspirați din fenomene naturale și procese biologice, utilizați pentru a rezolva probleme complexe de optimizare. Spre deosebire de algoritmii determinați de optimizare, care se bazează pe modele matematice complexe care sunt aplicabile numai în cazul respectării unor seturi de ipoteze, algoritmii metaeuristici se bazează pe tehnici euristice pentru explorarea spațiului de căutare într-o manieră cât mai eficientă, cu scopul de a determina soluția optimă.

Principiul de funcționare

În literatura de specialitate există un număr impresionant de algoritmi metaeuristici și un număr și mai mare de variante îmbunătățite, modificate sau hibride ale acestora. Cu toate acestea, etapele principale ale unui algoritm metaeuristic sunt, în general, următoarele:

1. Se generează în mod aleatoriu o populație inițială de soluții candidat.
2. Se evaluează fiecare individ din populație, prin calcularea funcției obiectiv și se determină performanța pe baza acesteia.
3. Se determină noi indivizi pe baza unor operatori inspirați din lumea animalelor sau din diferite procese naturale.
4. Se formează o nouă populație cu ajutorul noilor indivizi și eventual a unor anumiți indivizi din vechea populație.
5. Se verifică condițiile de oprire și dacă nu sunt îndeplinite se reia algoritmul de la pasul 2.

Determinarea soluțiilor cu ajutorul algoritmilor metaeuristici poate fi împărțită în două procese fundamentale și anume explorarea și exploatarea. Explorarea se referă la căutarea în întregul spațiu al soluțiilor, în special în zonele mai puțin cunoscute sau neexplorate. Prin explorare, algoritmi metaeuristici pot descoperi noi regiuni ale spațiului de căutare și pot identifica soluții promițătoare. Acest proces implică generarea și evaluarea unor soluții noi și diverse, adesea prin aplicarea unor mișcări aleatoare sau prin încercarea de combinații noi între diferite componente. Prin asigurarea unui bun proces de explorare se poate evita capcana minimumului local, ceea ce conduce la o îmbunătățire semnificativă a performanței.

Exploatarea, pe de altă parte, se concentrează pe zona cunoscută a spațiului de căutare, mai exact pe regiunile care au furnizat soluții bune sau apropiate de optim în iterațiile deja parcurse. Prin exploatare, algoritmi metaeuristici se concentrează asupra rafinării și îmbunătățirii soluțiilor existente, prin aplicarea unor mișcări sau transformări specifice, pentru a se apropia cât mai mult de optimul global.

Asigurarea unui bun echilibru între procesele de explorare și exploatare este esențial pentru a obține soluții de bună calitate cu ajutorul algoritmilor metaeuristici, întrucât un proces de explorare exagerat va conduce la o căutare inefficientă și haotică, în timp ce un proces de exploatare excesiv va conduce la blocarea în capcana minimumului locale.

Exemple de algoritmi metaeuristici

Algoritmul Genetic (AG și în engleză GA – Genetic Algorithm) este primul și unul dintre cei mai cunoscuți și utilizați algoritmi metaeuristici, fiind propus de către John Holland în anii 1960 și implementat cu succes în anii 1970, pe unul dintre primele computere. Algoritmul genetic este inspirat din evoluția speciilor biologice și se bazează pe principiile selecției naturale, încrucișării și mutației. Astfel, selecția naturală este folosită pentru a acorda șanse mai bune de reproducție celor mai performanți indivizi, care vor genera urmași prin intermediul operatorului de încrucișare. Astfel, întreaga populație se va orienta către zonele spațiului de căutare cu cele mai bune valori ale funcției obiectiv, asigurând succesul procesului de exploatare. Pe de altă parte, operatorul de mutație contribuie la creșterea diversității populației, prin generarea indivizilor cu caracteristici noi, contribuind la succesul procesului de explorare a spațiului de căutare.

Algoritmul de **Optimizare cu Roiuri de Particule** (ORP și în engleză PSO – Particle Swarm Optimization) a fost propus în anul 1995 de către R. Eberhart și J. Kennedy. James Kennedy și în prezent este algoritmul metaeuristic cu cele mai multe citări, acumulând un număr impresionat de peste 79000 citări conform Google Scholar. Sursa de inspirație a algoritmului ORP este comportamentul de grup al roiurilor de insecte sau al stolurilor de păsări sau al bancurilor de pești, în care fiecare mișcarea fiecărui individ se bazează atât pe experiența proprie cât și pe experiența celorlalți indivizi din vecinătatea sa sau din întregul grup. Astfel, poziția și viteza de deplasare prin spațiul soluțiilor a fiecărui individ din populație se actualizează într-o manieră foarte eficientă, permițând algoritmului ORP să obțină performanțe foarte bune pe baza unui model matematic relativ simplu.

Algoritmul Diferențial Evolutiv (ADE și în engleză DE - Differential Evolution) este de asemenea printre primii și cei mai populari algoritmi metaeuristici, acumulând un număr de cel puțin 33000 de citări prin platforma Google Scholar, începând cu anul 1997 când a fost

introduse de către R. Stron și K. Price. Principiul ADE se bazează pe principiile selecției naturale și ale încrucișare și mutației pentru a genera indivizi cu performanțe îmbunătățite de la o generație la următoarea.

Algoritmul Lupului Cenușiu (ALC, în engleză GWO – Grey Wolf Optimization) a fost propus de S. Mirjalili în 2014, fiind inspirat din comportamentul social al haitei de lupi cenușii, care sunt organizați într-o ierarhie strictă. Astfel, cei mai performanți indivizi, denumiți lupii alfa, beta și delta dirijează restul haitei în căutarea soluției optime. Prin combinarea unui model matematic relativ simplu cu obținerea unor performanțe ridicate, ALC a devenit unul dintre cei mai populari algoritmi metaeuristici, cu un număr de peste 12000 de citări pe platforma Google Scholar.

Algoritmul Sinus-Cosinus (ASC și în engleză SCA - Sine Cosine Algorithm) a fost introdus în anul 2016 de către S. Mirjalili și se bazează pe cele două funcții trigonometrice pentru a orienta deplasarea indivizilor din populație. Astfel, pentru a determina soluția optimă, poziția fiecărui individ este modificată folosind una din funcțiile trigonometrice sinus sau cosinus. De asemenea, diferite valori generate aleator sunt utilizate pentru a determina direcția și distanța deplasării fiecărui individ. Modelul matematic al ASC este surprinzător de simplu, prin urmare pentru a obține o foarte bună performanță sunt necesare diferite îmbunătățiri.

Algoritmul Salpului Marin (ASM și în engleză SSA – Salp Swarm Algorithm) este un algoritm introdus de către S. Mirjalili în anul 2017 și inspirat din mișcarea salpului marin, care face parte din familia tunicierilor. Aceste mici vietăți marine se organizează în forma unei spirale care se rotește în jurul sursei de hrană. În cadrul ASM, indivizii se grupează de asemenea în forma unei spirale, întregul proces de căutare fiind dirijat de către cel mai performant individ. Simplitatea modelului matematic este atât un avantaj cât și un dezavantaj, care a contribuit atât la popularizarea acestui algoritm cât și la necesitatea adăugării unor îmbunătățiri pentru a obține o performanță ridicată.

Avantaje și dezavantaje

Unul dintre cele mai importante avantaje ale algoritmilor metaeuristici este capacitatea de a determina soluții de calitate, chiar și în cazul problemelor de optimizare cu un grad ridicat de complexitate sau cu spații de căutare de dimensiuni mari. Ei pot evita căderea în minimul local și pot căuta soluții optime sau aproape optime.

Un al doilea avantaj al algoritmilor metaeuristici constă în portabilitatea și flexibilitatea acestora, rezultată din capacitatea acestora de a fi aplicați cu succes pentru rezolvarea unei game largi de probleme de optimizare, întrucât tehnicile euristice care stau la baza procesului de identificare a soluției optime nu sunt dependente de anumite ipoteze stricte precum algoritmi determiniști de optimizare. Astfel, algoritmi metaeuristici pot fi utilizați pentru utilizarea problemelor cu variabile mixte reale, întregi și binare, unde anumite metode deterministe nu au aplicabilitate sau necesită diferite artificii matematice pentru a se încadra în ipotezele aferente.

De asemenea, într-un număr semnificativ de aplicații, algoritmi metaeuristici sunt relativ ușor de rulat în paralel pe mai multe nuclee de procesare din cadrul aceluiasi procesor, sau chiar din cadrul unui cluster de computere. În acest sens, este posibilă utilizarea procesării distribuite pe plăcile grafice care au număr impresionant de procesoare logice, de ordinul sutelor, chiar a

câtorva mii. Prin urmare, timpul de execuție pentru determinarea soluțiilor optime cu algoritmilor metaeuristici poate să fie semnificativ mai redus comparativ cu algoritmi determiniști, în special pentru probleme de optimizare complexe.

Principalul dezavantaj al algoritmilor metaeuristici constă în lipsa garanției găsirii soluției optime, întrucât, prin comparație algoritmi determiniști garantează găsirea soluției optime, din punct de vedere matematic prin aplicare unor modele matematice, bazate de exemplu pe derivarea funcțiilor obiectiv. Însă, soluția determinată de un algoritm metaeuristic se bazează pe explorarea spațiului de căutare, pe baza unor tehnici euristice inspirate din diverse surse precum comportamentul animalelor sau evoluția naturală. Aceste strategii de căutare nu garantează atingerea soluției optime din punct de vedere matematic, ci pur și simplu se obține cea mai bună soluție găsită de algoritmul metaeuristic. De exemplu într-o problemă de optimizare foarte simplă care presupune minimizarea unei pătratului variabile, soluția „optimă” determinată de un algoritm metaeuristic poate să fie de ordinul 10^{-10} , dar nu va ajunge aproape niciodată la soluția optimă din punct de vedere matematic zero absolut. În această situație, din punct de vedere ingineresc soluția determinată de algoritmul metaeuristic poate fi considerată corectă, dar problema apare atunci când algoritmul „cade în capcana minimului local” și determină o soluție de ordinul 10^1 . Principalul mecanism prin care se pot obține soluții inexacte constă în lipsa diversității soluțiilor candidat utilizate. Astfel, cel mai performant individ este determinat în apropiere unui minim local, iar restul populației converge în acea zonă, rezultând într-o soluție inexactă ce nu poate să fie utilizată.

Un alt mare dezavantaj rezultă din dependența performanței algoritmilor metaeuristici de setările aplicate și valorile considerate pentru parametrii acestora. În cazul alegerii greșite a acestora, algoritmul va obține o performanță foarte slabă, iar soluțiile determinate nu pot fi considerate de calitate. În general, aceste setări trebuie modificate de la o problemă la alta, iar singura metodă de a îi determina este prin încercări succesive. Prin urmare, în lipsa experienței este necesară rularea algoritmului cu setări diferite de un număr suficient de ori pentru a evidenția cele mai bune combinații între valorile parametrilor, ceea ce poate să necesită o durată relativ lungă de timp.

De asemenea, datorită operatorilor bazați pe procese aleatorii, algoritmi metaeuristici nu furnizează întotdeauna aceleași soluții. Prin urmare, pentru a obține o soluție de încredere, este necesară efectuarea unui număr de rulări succesive și de alegerea celei mai bune soluții din setul astfel rezultat.

3. Studiu privind performanțele algoritmilor metaeuristici

În acest capitol se prezintă analiza performanțelor a patru dintre cei mai populari algoritmi metaeuristici din prezent. Pentru acest scop, au fost selectați doi algoritmi clasici și anume: Algoritmul de Optimizare cu Roiuri de Particule (PSO) și Algoritmul Genetic (GA) și doi algoritmi recenți: Algoritmul Lupului Cenușiu (ALC) și Algoritmul Sinus-Cosinus (SCA). Pentru a evalua performanța acestor algoritmi metaeuristici este utilizat un set de 23 de funcții de test.

În figura 2.1 sunt prezentate soluțiile optime determinate de către fiecare algoritm aplicat: GWO, SCA, PSO și GA, în fiecare dintre cele 10 rulări succesive, ordonate în ordine crescătoare.

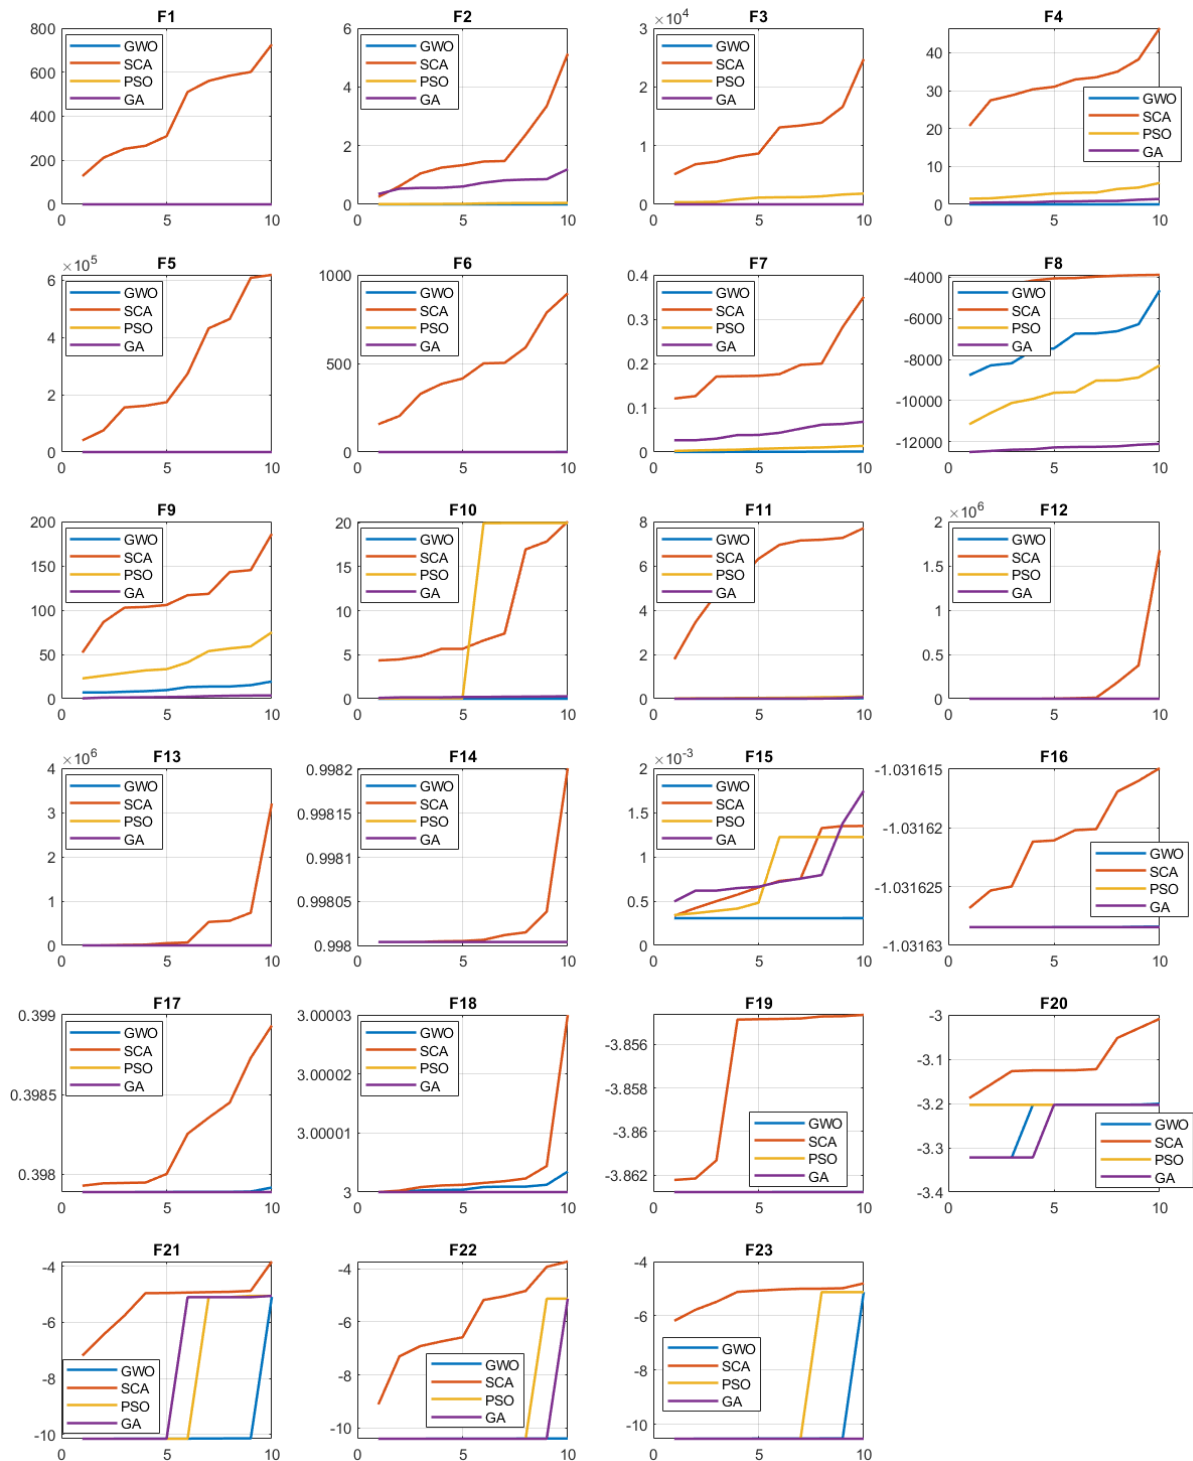


Figura 2.1 Valorile obținute de fiecare algoritm, pentru fiecare funcție de test în cele 10 rulări succesive ordonate crescător.

În cele două tabele de mai jos este prezentată o sinteză a rezultatelor obținute de către fiecare algoritm considerat: GWO, SCA, PSO și GA, astfel: valoarea minimă, medie și maximă din cele 10 rulări, respectiv deviația standard a valorilor.

Tabel 2.1

Alg. / Fct.	Valoarea minimă				Valoarea medie			
	GWO	SCA	PSO	GA	GWO	SCA	PSO	GA
F1	1.41915E-11	128.152139	0.003398104	0.025225367	2.85E-10	414.9845	0.01432	0.058246
F2	6.69191E-07	0.255207432	0.006819995	0.3507952	1.15E-06	1.829168	0.026561	0.707262
F3	0.010659349	5122.518255	371.0479745	1.308920318	5.10E-02	1.18E+04	1048.268	3.513519
F4	0.003983592	20.70311812	1.483878994	0.405315038	0.006627	32.44358	3.068259	0.792468
F5	24.92336281	40806.87343	27.97667552	41.54652789	26.1613	300300.7	80.31667	90.97989
F6	0.000220576	157.2789667	0.001882585	0.03678404	0.086446	476.6215	0.020857	0.094704
F7	0.000157802	0.120818137	0.00248622	0.02661016	0.000614	0.19656	0.007788	0.04504
F8	- 8758.468849	- 4557.331436	-11144.4423	- 12499.68178	-7122.8	-4129	-9616.35	-12294
F9	7.030289512	52.03014463	22.90151405	0.435229852	11.56343	116.0237	42.89211	2.258942
F10	2.92E-06	4.346165129	0.02771737	0.088709348	4.53E-06	9.396454	9.993568	0.195104
F11	2.40E-10	1.777007079	0.012611391	0.002165035	4.49E-03	5.783314	0.04497	0.012005
F12	1.05E-05	6.924415007	6.94E-05	0.00062353	5.12E-03	225557.3	7.30E-02	0.013235
F13	0.000135084	51.51941281	0.000389169	0.006369323	0.025693	516990.8	0.003479	0.012173
F14	0.998003838	0.99800384	0.998003838	0.998003838	0.998004	0.998029	0.998004	0.998004
F15	0.000307491	0.00033433	0.000342495	0.000495846	0.000307	0.000798	0.000811	0.000843
F16	- 1.031628453	- 1.031626829	- 1.031628453	- 1.031628453	-1.03163	-1.03162	-1.03163	-1.03163
F17	0.3978874	0.3979271	0.3978874	0.3978874	0.397891	0.398248	0.397887	0.397887
F18	3	3	3	3	3.000001	3.000004	3	3
F19	-3.8628	-3.8622	-3.8628	-3.8628	-3.86278	-3.85691	-3.86278	-3.86278
F20	-3.32196	-3.18785	-3.20310	-3.32200	-3.23837	-3.10621	-3.2031	-3.25066
F21	-10.15244	-7.18420	-10.153200	-10.153200	-9.64166	-5.2772	-8.12311	-7.62243
F22	-10.40172	-9.11003	-10.40294	-10.40294	-10.3975	-5.93602	-9.34812	-9.87553
F23	-10.53601	-6.18678	-10.53641	-10.53641	-9.98916	-5.24671	-8.91403	-10.5364

Pentru fiecare algoritm a fost contorizat numărul funcțiilor obiectiv pentru care a obținut cea mai bună valoare la cele patru criterii: valoarea minimă, medie, maximă și deviație standard.

Tabel 2.2

Alg./ Fct.	Valoarea maximă				Derivația standard			
	GWO	SCA	PSO	GA	GWO	SCA	PSO	GA
F1	5.84E-10	726.0466	0.039466	0.134858	1.78E-10	203.8017	0.011566	0.033442
F2	2.01E-06	5.127392	0.047623	1.196886	3.77E-07	1.447544	0.016206	0.236334
F3	0.202981	24736.95	1833.856	10.35918	0.060029	5890.48	527.695	2.6146
F4	0.011531	46.47944	5.655825	1.417405	0.00244	6.844256	1.327426	0.33122
F5	29.36485	618257.2	140.1914	134.8292	1.29217	214565.6	42.87443	32.27817
F6	0.504307	895.8288	0.058586	0.204713	0.167786	235.0151	0.020044	0.054894
F7	0.001188	0.350228	0.013895	0.068553	0.000327	0.069903	0.003775	0.015683
F8	-4631.55	-3877.86	-8282.37	-12099.7	1197.188	252.2146	862.4009	128.5481
F9	19.43769	186.1215	75.02335	3.683124	4.161404	36.34976	17.30301	1.099216
F10	7.32E-06	20.13097	19.95923	0.280798	1.5E-06	6.274697	10.49864	0.057152
F11	0.021743	7.70176	0.096332	0.064136	0.007796	1.946723	0.02661	0.019592
F12	0.013404	1676383	0.361272	0.105504	0.00494	524579.4	0.125034	0.032476
F13	0.151938	3203228	0.012047	0.020738	0.054974	984785.4	0.003352	0.004642
F14	0.998004	0.998201	0.998004	0.998004	8.16E-11	6.13E-05	6.27E-14	3.14E-16
F15	0.000308	0.001347	0.001223	0.001745	5.65E-09	0.000395	0.000436	0.000397
F16	-1.03163	-1.03161	-1.03163	-1.03163	1.59E-08	4.05E-06	1.52E-12	6.77E-12
F17	0.397916	0.398933	0.397887	0.397887	8.64E-06	0.000364	4.61E-13	4.45E-12
F18	3.000003	3.00003	3	3	1.01E-06	9.09E-06	1.28E-10	1.14E-09
F19	-3.86278	-3.85465	-3.86278	-3.86278	1.59E-06	0.003451	4.66E-11	1.98E-10
F20	-3.2006	-3.00886	-3.2031	-3.2031	0.057681	0.057001	2.06E-09	0.061396
F21	-5.09205	-3.83036	-5.0552	-5.0552	1.598574	0.946235	2.620874	2.667702
F22	-10.3914	-3.73089	-5.12882	-5.12882	0.003662	1.680807	2.223763	1.667822
F23	-5.12844	-4.80425	-5.12848	-10.5364	1.707889	0.435039	2.612278	1.12E-08

Se poate observa că algoritmul AG obține cea mai bună valoare minimă a funcției obiectiv pentru cel mai mare număr de funcții și anume 10, urmat de GWO cu un număr 8 și PSO cu 7. În cazul celor mai bune valori medii și maxime, algoritmul GWO le obține pentru 16, respectiv 15 funcții. Pe locul secund, se clasează GA care a obținut cele mai bune valori medii și maxime pentru 7, respectiv 8 funcții, în timp ce PSO se situează pe locul trei cu 5, respectiv 6. Pentru toate aceste trei criterii, se poate observa că algoritmul SCA nu a reușit să obțină cea mai bună valoare pentru niciuna dintre cele 23 de funcții și pentru niciunul dintre cele trei criterii: valoare minimă, medie și maximă.

În cazul deviației standard, algoritmul GWO obține cele mai mici valori pentru un număr de 11 funcții, urmat de PSO pentru un număr de 7 funcții și de GA pentru 4. Pe ultimul loc se clasează algoritmul SCA care a obținut cea mai mică valoare a abaterii standard pentru o singură funcție de test.




Figura 2.2 Valorile minime, medii și maxime obținute de fiecare algoritm, pentru fiecare funcție de test și deviația standard.

În concluzie, se poate constata că cele mai bune performanțe sunt asigurate de algoritmul GWO, urmat îndeaproape de GA și de PSO. Pentru determinarea unei soluții optime pentru îmbunătățirea independenței energetice la nivel național, se va utiliza unul dintre acești algoritmi cu posibile modificări implementate de membrii echipei pentru a îmbunătăți procesul de exploatare, precum introducerea mutației sau a metodei de învățare prin contra-exemple în cadrul GWO, respectiv a procesului de exploatare, precum modificarea parametrilor GWO pe parcursul ultimelor iterații.

4. Concluzii

În concluzie, în etapa actuală a proiectului de cercetare „Pachet software bazat pe inteligență artificială pentru managementul energetic optim în scopul creșterii independenței energetice a României” a fost realizată o analiză a asigurării independenței energetice a României la nivel național. Astfel, obiectivul analizei este reducerea până la zero a importurilor anuale de energie electrică prin instalarea de noi capacități de producere bazate pe energie regenerabilă din surse de tip eolian și fotovoltaic. În cadrul acestei analize, a rezultat că sursele regenerabile de energie reprezintă o soluție parțială a acestei probleme și că sunt necesare o serie de măsuri suplimentare precum dezvoltarea capacităților de stocare a energiei electrice sau a centralelor de tip hidroelectric sau nuclearelectric.

În realitate, niciuna dintre soluțiile identificate nu va conduce la rezolvarea problemei, ceea ce conduce la necesitatea determinării unei combinații între acestea. Datorită gradului crescut de complexitate, în cadrul proiectului se va formula o problemă de optimizare cu scopul de a menține importul de energie cât mai aproape de zero, simultan cu minimizarea puterii instalate în noi dispozitive de stocare și centrale electrice. Rezolvarea acestei probleme complexe de optimizare se va realiza cu ajutorul unui algoritm metaeuristic. În acest scop, a fost realizat un studiu comparativ privind performanțele a patru dintre cei mai populari algoritmi metaeuristici: Algoritmul de Optimizare cu Roiuri de Particule (PSO), Algoritmul Genetic (GA), Algoritmul Lupului Cenușiu (ALC) și Algoritmul Sinus-Cosinus (SCA) în optimizarea unui set de 23 de funcții de test. Rezultatele au indicat că cea mai bună performanță este obținută de GWO, urmat de GA și PSO, dar și faptul că există posibilitatea ca algoritmul ales să necesite mici îmbunătățiri sau adaptări, dat fiind gradul de complexitate a problemei.