UNIVERSITATEA NAȚIONALĂ DE ȘTIINȚĂ ȘI TEHNOLOGIE POLITEHNICA BUCUREȘTI

Facultatea de Energetică

Departamentul de Producere și Utilizare a Energiei

TEZĂ DE DOCTORAT

Rezumat

Optimizarea proceselor de reabilitare energetică a clădirilor existente

Autor: Ing. NICOLAE I. Adriana-Elena

Conducător științific: Prof. dr. ing. NECULA Horia

București, 2025

CUPRINS

CAPITOLUL 1 6
CAPITOLUL 2 8
2.1 ALGORITMII GENETICI 8
2.1.1 Algoritmul Genetic simplu (GA) 8
2.1.2 Algoritmul Genetic de Sortare Nedominant II (NSGA II) 9
2.1.3 Algoritmul Genetic Cuantic (QGA) 10
2.2 OPTIMIZAREA CU ROI DE PARTICULE (PSO) 10
2.3 ALȚI ALGORITMI DE OPTIMIZARE 11
2.3.1 Algoritmul de Căutare al Ciorilor (CSA) 11
2.3.2 Algoritmul de Optimizare cu Colonii de Furnici (ACO) 12
2.3.3 Algoritmul de Optimizare Inspirat din Comportamentul de Hrănire al Pisicii de Mare (Manta-Ray) (MRFO) 13
2.4 COMPARAȚIE ÎNTRE ALGORITMII DE OPTIMIZARE 14
2.4.1 Avantajele algoritmilor de optimizare 14
2.4.2 Dezavantajele algoritmilor de optimizare 14
CAPITOLUL 3 16
3.1 DESCRIEREA MECANISMULUI FUNCȚIONAL ALGORITMULUI GENETIC 16
3.2 DESCRIEREA MECANISMULUI FUNCȚIONAL ALGORITMULUI GENETIC DE SORTARE NEDOMINANT 19
CAPITOLUL 4 22
4.1 STUDIU DE CAZ 1 – Optimizarea fluxului termic unitar utilizând GA 22
4.1.1 Definirea problemei de optimizare și prezentarea algoritmului utilizat 22
4.1.2 Rezultate 25
4.2 STUDIU DE CAZ 2 – Optimizarea energiei necesare pentru încălzire utilizând NSGA – II 27
4.2.1 Descrierea anvelopei clădirii neizolate termic 28
4.2.2 Definirea problemei de optimizare 29
4.2.3 Prezentarea algoritmului utilizat 33
4.3 STUDIU DE CAZ 3 – Optimizarea simultană a energiei necesare pentru încălzire și răcire utilizând NSGA – II 35
CAPITOLUL 5 38
5.1 DETERMINAREA NECESARULUI DE ENERGIE PENTRU PREPARAREA APEI CALDE DE CONSUM 38
5.2 ALEGEREA POMPELOR DE CĂLDURĂ OPTIME CU AJUTORUL MODELULUI MATEMATIC IMPLEMENTAT ÎN PYTHON 39
5.2.1 Prima modelare în care primează criteriul financiar 39
5.2.2 Cea de-a doua modelare în care primează criteriile tehnice 41

5.3 VERIFICAREA APLICABILITĂȚII PRACTICE A REZULTATELOR MODELULUI MATEMATIC 43
5.4 SIMULAREA UNUI SISTEM HIBRID FORMAT DIN POMPĂ DE CĂLDURĂ, PANOURI SOLARE TERMICE ȘI PANOURI FOTOVOLTAICE 45

INTRODUCERE

Sectorul clădirilor are un rol esențial în strategia energetică a Uniunii Europene (UE), fiind unul dintre principalii consumatori de energie. În Uniunea Europeană sunt trei sectoare dominante din punct de vedere al distribuției consumului final de energie și anume: transporturi, clădiri rezidențiale și industrie. 75% dintre clădirile din UE sunt clădiri rezidențiale, iar majoritatea (circa 80%) au fost construite înainte de anul 1991, perioadă în care cerințele privind eficiența energetică în clădiri erau reduse, ceea ce explică nivelul scăzut al performanței lor energetice și lipsa unei izolații termice corespunzătoare. Acestea subliniază nevoia urgentă de măsuri orientate spre reducerea consumului energetic în sectorul clădirilor.

În acest context, prezenta teză de doctorat, împărțită în cinci capitole, se concentrează asupra strategiilor de optimizare a consumului de energie în clădirile rezidențiale.

CAPITOLUL 1 oferă o analiză detaliată a impactului energetic al clădirilor asupra consumului de energie, atât la nivelul Uniunii Europene, cât și în context național. De asemenea, sunt prezentate metode și strategii menite să crească eficiența energetică în sectorul clădirilor.

CAPITOLUL 2 prezintă o cercetare amplă privind aplicațiile practice ale algoritmilor de optimizare în sectorul clădirilor. Sunt prezentate articole din literatura de specialitate privind optimizarea consumului de energie în clădiri prin intermediul următorilor algoritmi: Algoritmul Genetic simplu, Algoritmul Genetic de Sortare Nedominant II, Algoritmul Genetic Cuantic, Optimizarea cu roi de particule, Algoritmul de Căutare al Ciorilor, Algoritmul de Optimizare cu Colonii de furnici, Algoritmul de Optimizare Inspirat din Comportamentul de Hrănire al Pisicii de Mare. De asemenea, este realizată o amplă comparație între aceștia, cu menționarea principalelor avantaje, dezavantaje și aplicabilitate practică.

CAPITOLUL 3 descrie mecanismele funcționale a doi dintre acești algoritmi și anume Algoritmul Genetic simplu și Algoritmul Genetic de Sortare Nedominant II. În cadrul acestui capitol sunt descrise metodele de selecție, încrucișare și mutație aplicabile în cazul acestor algoritmi.

CAPITOLUL 4 prezintă trei studii de caz, fiecare descriind câte un model de optimizare a consumului de energie în clădiri. Primul studiul de caz presupune optimizarea fluxului termic unitar transmis prin perete izolat termic, prin placa peste sol sau prin plafonul izolat, utilizând un Algoritm Genetic simplu. Al doilea studiu de caz propune o metodă de a identifica configurația optimă a anvelopei termice a unei clădiri rezidențiale ce va asigura necesarul minim de energie

pentru încălzire, luând în considerare și restricțiile de preț obținute printr-un studiu de piață specific. Această optimizare este realizată prin intermediul Algoritmului Genetic de Sortare Nedominant II implementat utilizând libraria Pymoo (Optimizare Multiobiectiv în Python). Acest algoritm este aplicat în cazul clădirii studiate ai cărei pereți exteriori, placă peste sol și plafon se izolează cu polistiren expandat, polistiren extrudat și vată minerală, iar ferestre și ușile se înlocuite cu elemente cu caracteristici termice superioare prezentate în subcapitolul 4.2.2 la pagina 82. Modelul NSGA-II este dezvoltat cu scopul de a găsi soluția optimă într-un spațiu de căutare considerat a fi compus din grosimi și conductivități termice ale materialelor de izolație și proprietăți termice ale ușilor și ferestrelor. Cel de-al treilea subcapitol descrie o problemă multiplă de optimizare detaliind aplicarea Algoritmului Genetic de Sortare Nedominant II în cazul aceleași clădiri izolate termic cu scopul de a minimiza simultan necesarul de energie pentru încălzire și necesarul de energie pentru răcire, ținând cont de asemenea de restricțiile de preț.

CAPITOLUL 5 este împărțit în patru subcapitole. În primul subcapitol este calculat necesarul de energie pentru prepararea apei calde de consum. Cel de-al doilea subcapitol prezintă model matematic implementat în Python în vederea alegerii celei mai bune opțiuni dintr-o multitudine de pompe de căldură disponibile care poate acoperi cea mai mare parte din necesarul de energie pentru încălzire și pentru prepararea apei calde de consum, luând în considerare și costul de achiziție al acestor pompe. În cadrul celui de-al treilea subcapitol se verifică aplicabilitatea practică a rezultatelor modelului matematic, cu ajutorul software-ului GeoT*SOL. În vederea îmbunătățirii randamentului global al sistemului simulat anterior, în subcapitolul 4 se simulează un sistem hibrid format din pompa de căldură, panouri solare termice și panouri fotovoltaice.

CAPITOLUL 1
CONTEXT ȘI MOTIVAȚIE

Consumul energetic al fiecărei țări depinde de nivelul său de dezvoltare economică, de tipul resurselor naturale disponibile, de particularitățile condițiilor climaterice și de legislația aplicabilă. Clădirile reprezintă unul dintre principalii consumatori de energie, cu o pondere în permanentă creștere, ceea ce le conferă un rol esențial în strategia energetică a Uniunii Europene. Odată cu aderarea la Uniunea Europeană, România are obligația de a se conforma obiectivelor impuse de Directiva UE 2024/1275 privind performanța energetică a clădirilor [1]. Unul dintre obiective este ca toate clădirile construite după anul 2030 să fie încadrate în categoria clădirilor cu emisii zero. Un alt obiectiv vizează atingerea aceluiași standard în cazul clădirile existente până în 2050. Astfel, fiecare stat membru ale UE trebuie să elaboreze un plan național care să stabilească etapele de renovare progresivă și să implementeze măsuri concrete în vederea reducerii consumului de energie și a emisiilor de gaze cu efect de seră (GHG) în sectorul clădirilor.

Conform Eurostat [2], în Uniunea Europeană în anul 2023 au fost trei sectoare dominante din punct de vedere al distribuției consumului final de energie și anume: transporturi (31%), clădiri rezidențiale (26%) și industrie (25%). Cea mai mare parte a consumului energetic din sectorul clădirilor în Uniunea Europeană este asociată încălzirii spațiilor (62,5%), urmată de încălzirea apei (15,1%) [2]. În 2023, gazul natural a furnizat aproape o treime din energie utilizată în clădiri (29,5%), urmat de electricitate (25,9%) și de sursele regenerabile (23,5%). Restul consumului a fost acoperit de produsele petroliere (10,3%), căldura rezultată prin ardere (8,5%) și cărbune (2,2%). Țările care se bazează preponderant pe gazul natural sunt: Belgia, Germania, Italia, Luxembourg, Ungaria, Olanda, Slovacia și Georgia. Cel mai mare consum de electricitate se înregistrează în: Bulgaria, Spania, Cipru, Malta, Portugalia, Suedia, Norvegia și Albania [2]. Sursele regenerabile predomină în: Cehia, Estonia, Croația, Letonia, Austria, Slovenia, Moldova și Serbia. În Irlanda se utilizează în principal produsele petroliere într-o proporție de 41,72% pentru acoperirea consumului de energie în clădiri [2].

Conform Agenției Internaționale de Energie [3], sectorul clădirilor este responsabil în prezent pentru o pondere majoră a emisiilor de dioxid de carbon de aproximativ 26% din totalul emisiilor de acest tip din sectorul energetic, 8% reprezentând emisii directe și 18% fiind emisii indirecte rezultate din producerea energiei electrice și termice utilizate în clădiri. Institutul European pentru

Performanța Clădirilor [4] raportează o reducere a emisiile de gaze cu efect de seră (GHG) în sectorul clădirilor de aproximativ 15% față de anul 2015, dar ținta este de a reduce cu 28% emisiile GHG până în 2030, raportat la anul 2015. Aceste statistici subliniază necesitatea adoptării unor acțiuni prompte menite să reducă impactul energetic al clădirilor asupra consumului de energie și asupra emisiilor GHG din întreaga UE. Din acest motiv, cercetările se concentrează continuu pe dezvoltarea și aplicarea unor noi metode de îmbunătățire a eficienței energetice a clădirilor existente.

Conform datelor prezentate de Institutul European pentru Performanța Clădirilor [5], 75% dintre clădirile din UE sunt rezidențiale, iar aproximativ 80% dintre acestea au fost construite înainte de 1991, când nu existau directive clare privind eficiența energetică. Aceste clădiri au o izolație termică inadecvată sau inexistentă. Aceeași sursă arată că o parte substanțială a clădirilor din Europa sunt mai vechi de 60 de ani, mai mult de 37% din clădirile rezidențiale fiind construite înainte de anii 1960 [5]. Țările cu clădirile cele mai vechi din UE sunt Suedia, Franța, Cehia, Danemarca și Bulgaria.

În România clădirile rezidențiale reprezintă aproximativ 95% din sectorul clădirilor [6]. Cele mai numeroase sunt blocurile din mediul urban (42,5% din totalul locuințelor). Clădirile rezidențiale sunt în general vechi, cu grad redus de izolație termică, 70% dintre acestea fiind construite înainte de 1980. În aceste clădiri consumul mediu anual de energie pentru încălzire are valori între 180 și 240 kWh /m^2 [6]. Consumul mare de energie în clădiri conduce la necesitatea implementării unor strategii de creștere a eficienței energetice atât la nivelul clădirilor noi, cât și la nivelul clădirilor existente. Strategia energetică a României pentru perioada 2025-2035 prevede ca până în 2030 16% dintre clădirile rezidențiale vechi să fie renovate, iar până în anul 2035 acest procent să crească până la 20-22% [7].

Utilizarea unor echipamente electrice și electrocasnice mai eficiente din punct de vedere energetic în clădiri, schimbarea stilului de viață al locatarilor în sensul adoptării unui comportament mai ecologic, izolarea anvelopei clădirilor cu materiale termoizolante, adoptarea soluțiilor constructive cu uși și ferestre eficiente din punct de vedere energetic, sunt numai câteva măsuri ce pot contribui la reducerea consumului de energie în clădiri.

CAPITOLUL 2
APLICAȚII ALE ALGORITMILOR DE OPTIMIZARE ÎN SECTORUL CLĂDIRILOR

Algoritmii de optimizare metaeuristică sunt metode de căutare inteligentă utilizate pentru identificarea soluțiilor optime în probleme complexe, unde abordările tradiționale sunt ineficiente sau imposibil de aplicat. În contextul actual în care clădirile trebuie să respecte standarde tot mai stricte privind consumul de energie și emisii de gaze cu efect de seră, rolul acestor algoritmi în creșterea eficienței energetice a clădirilor este esențial.

2.1 ALGORITMII GENETICI

2.1.1 Algoritmul Genetic simplu (GA)

Primele aplicații ale Algoritmilor Genetici sunt prezentate de către John Holland în lucrarea sa fundamentală [8]. În această lucrare este studiat fenomenul biologic al adaptării, conform căruia organismele evoluează prin recombinarea materialului genetic, proces ce le permite să supraviețuiască și să se adapteze confruntărilor din mediul înconjurător.

Un studiu cuprinzător al literaturii de specialitate arată că GA poate fi aplicat cu succes și în analiza infrastructurii energetice a clădirilor. Un exemplu relevant este cercetarea realizată în Oman în anul 2020, când un algoritm GA, integrat cu EnergyPlus, este implementat în scopul optimizării performanței energetice a trei clădiri rezidențiale situate în orașele Salalah, Muscat și Buraimi [9]. Studiul are ca obiective principale: reducerea consumului anual de energie, diminuarea impactului asupra mediului și optimizarea costurilor pe durata ciclului de viață.

Lei Xia et al. [10] propun o strategie de proiectare optimizată a unui sistem hibrid format din pompă de căldură geotermală și colector fotovoltaic-termic integrat (PVT), utilizând o Rețea Neuronală Artificială combinată cu un Algoritm Genetic (GA).

În 2019, un algoritm GA este implementat prin intermediul platformei de optimizare GenOpt și integrat cu simulări dinamice în TRNSYS în vederea determinării combinației optime dintre caracteristicile constructive ale unei clădiri multifamiliale situate în nordul Italiei și sistemele energetice utilizate, în scopul minimizării costului global al clădirii pe durata de viață [11]. Se au în vedere următoarele sisteme: pompe de căldură, panouri fotovoltaice și sisteme de ventilație cu recuperare de căldură.

2.1.2 Algoritmul Genetic de Sortare Nedominant II (NSGA II)

Un alt algoritm evolutiv construit pe structura algoritmului GA este Algoritmul Genetic de Sortare Nedominant II (NSGA-II). La fel ca un GA, NSGA-II utilizează operatori evolutivi precum selecția, încrucișarea și mutația. Spre deosebire de GA, NSGA-II folosește sortarea nedominată, sortarea pe baza distanței de aglomerare și elitismul pentru a menține diversitatea soluțiilor. Acest algoritm este de asemenea descris în detaliu în cadrul Capitolului 3.

F. Ascione et. al. [12] utilizează un algoritm NSGA -II implementat în MATLAB și integrat cu EnergyPlus în vederea optimizării consumului energetic anual total pentru încălzirea spațiului și a apei calde, pentru răcire și electricitate, al costului investiției inițiale cu tehnologia bazată pe surse regenerabile de energie utilizată, precum și optimizarea costului global total acestei tehnologii pe durata de viață.

În anul 2017, în China este implementat un algoritm NSGA-II în MATLAB în vederea optimizării consumului de combustibil al unui sistem de trigenerare alimentat de o microturbină cu gaz și a creșterii eficienței exergetice a sistemului în exploatarea clădirii [13].

Un alt studiu propune o metodă de analiză a performanței energetice, economice și de mediu a strategiilor de renovare energetică aplicate clădirilor rezidențiale, în contextul schimbărilor climatice globale [14]. Astfel, algoritmul NSGA-II este integrat cu EnergyPlus și aplicat unei clădiri rezidențiale unifamiliale situate în sudul Italiei în scopul identificării soluțiilor optime pentru renovarea acesteia, luând în considerare simultan următoarele obiective: minimizarea consumului de energie primară, a emisiilor de gaze cu efect de seră și a costurilor globale.

A. Ciardiello et. al. prezintă un studiu cuprinzător privind combinarea rezultatelor simulării realizate cu EnergyPlus cu algoritmul NSGA-II implementat in Python, în vederea optimizării consumului anual de energie și îmbunătățirii performanței energetice a unei clădiri rezidențiale din Italia, prin determinarea configurațiilor optime privind caracteristicile anvelopei și forma clădirii [15]. Rezultatele arată că alegerea formei geometrice optime conduce la economia de până la 60,6% a consumului total de energie față de cazul de referință.

Un studiu recent din 2024 propune o metodologie hibridă care combină o Optimizare Bayesiană cu arbori de decizie extremi amplificați prin gradient (BO-XGBoosts) cu un algoritm NSGA-II pentru optimizarea simultană a consumului de energie, a iluminatului natural și a confortului termic în clădirile rezidențiale [16]. Conform rezultatelor, implementarea configurației optime identificate conduce la o reducere a consumului de energie cu 44,1%, o scădere a indicelui

de disconfort termic cu 10,9% și o îmbunătățire a performanței de iluminare naturală cu 1,7%, în comparație cu varianta constructivă inițială.

2.1.3 Algoritmul Genetic Cuantic (QGA)

Algoritmul Genetic Cuantic (QGA) reprezintă o variantă a GA clasic, ce integrează concepte din mecanica cuantică, cum ar fi q-biții și principiul suprapunerii cuantice [17]. Spre deosebire de GA, unde operatorul de mutație joacă un rol esențial în diversificarea populației, QGA utilizează operatori de rotație cuantică. Acest lucru îi conferă o eficiență sporită în evitarea minimelor locale.

Bolun Li, Pingfang Hu, Na Zhu, Fei Lei și Lu Xing [18] utilizează un Algoritm Genetic Cuantic (QGA) și un Algoritm Genetic Simplu (SGA) în vederea optimizării consumului de combustibil al unui sistem hibrid CCHP-GSHP destinat încălzirii și răcirii unei clădiri rezidențiale din China. Acest sistem este format dintr-o centrală de trigenerare (CCHP) și o pompă de căldură geotermală (GSHP).

În 2021 este de asemenea utilizat un algoritm QGA în vederea optimizării consumului anual de energie al unei clădiri de birouri prin identificarea celei mai eficiente configurații a anvelopei clădirii [19]. Rezultatele obținute arată că, prin implementarea configurației optime determinate cu ajutorul algoritmului QGA, consumul anual de energie poate fi redus cu aproximativ 15–20%, iar costurile totale de exploatare cu până la 35,3%, în comparație cu modelul de referință.

2.2 OPTIMIZAREA CU ROI DE PARTICULE (PSO)

Algoritmul cu roi de particule (PSO) este o metodă de optimizare metaeuristică inspirată din comportamentele speciilor din natură, cum ar fi zborul păsărilor sau deplasarea peștilor în bancuri. În cadrul algoritmului, fiecare particulă reprezintă o soluție posibilă și este caracterizată printr-o poziție și o viteză, care se modifică pe parcursul procesului de căutare. Actualizarea poziției se realizează pe baza experienței proprii (cea mai bună soluție individuală identificată) și a experienței întregului roi (cea mai bună soluție globală) [20]. Astfel, particulele explorează spațiul soluțiilor printr-un mecanism colaborativ, fără a utiliza mutația sau încrucișarea [21].

Navid Delgarm et. al. integrează rezultatele simulărilor energetice realizate cu EnergyPlus cu algoritmul de Optimizare cu roi de particule (PSO) implementat în MATLAB, în vederea optimizării consumului anual de energie pentru răcire, încălzire și iluminat în cazul clădirilor situate în patru regiuni climatice diferite din Iran [22].

J. Kim et. al. [23] utilizează un model hibrid format din algoritmul PSO și algoritmul Hooke–Jeeves (HJ) în vederea optimizării consumului total de energie într-o școală din Seul. Algoritmul are rolul de a identifica configurațiile optime de sisteme verzi și sisteme de energie regenerabilă (panouri solare fotovoltaice și panouri solare termice) care oferă un echilibru între confort termic și eficiență energetică.

Yixiang Gao et. al. [24] prezintă de asemenea o strategie de optimizare a consumului de energie în clădiri, bazată pe reducerea acestuia în timpul orelor de vârf. Algoritmul PSO este folosit în vederea determinării setărilor optime de temperatură interioară și debit de aer pentru fiecare zonă termică din clădire în vederea obținerii unui echilibru între asigurarea confortului termic al ocupanților și reducerea consumului de energie al HVAC. Rezultatele arată că aplicarea configurației optime are potențialul de a reduce consumul de energie cu 19,09% și costurile asociate cu 30,72% comparativ cu cazul de referință, neoptimizat.

PSO este de asemenea utilizat pentru a determina configurația optimă care să maximizeze capacitatea de producție și eficiența energetică unui sistem fotovoltaic instalat pe clădiri comerciale, luând în considerare și aspectele financiare [25].

T. V. Dixit et. al. [26] propun utilizarea algoritmului PSO pentru determinarea unghiului optim de înclinare anual al colectoarelor solare în diverse locații geografice din India. Optimizarea are ca obiectiv maximizarea radiației solare incidente colectate de suprafața panoului, prin ajustarea unghiului de înclinare în funcție de latitudine și condițiile climatice locale.

În 2021 este utilizat algoritmul PSO în vederea determinării combinației optime de tehnologii regenerabile (panouri fotovoltaice, turbine eoliene și baterii de stocare a energiei) care să acopere cea mai mare parte din consumul energetic al unei clădiri din Algeria, să maximizeze fracția de energie livrată din surse regenerabile (RF) și să minimizeze costul energie [27].

2.3 ALȚI ALGORITMI DE OPTIMIZARE

Pe lângă algoritmii prezentați anterior, alți algoritmi populari de optimizare sunt Algoritmul de Căutare al Ciorilor (CSA), Algoritmul de Optimizare cu Colonii de Furnici (ACO) și Algoritmul de Optimizare Inspirat din Comportamentul de Hrănire al Pisicii de Mare (Manta-Ray) (MRFO).

2.3.1 Algoritmul de Căutare al Ciorilor (CSA)

Algoritmul de Căutare al Ciorilor (CSA) este o metodă metaeuristică inspirată din modul în care ciorile își ascund hrana și folosesc memoria pentru a regăsi locurile de depozitare. Astfel,

fiecare cioară reține cea mai bună poziție (locație) a hranei și poate decide să urmărească o altă cioară pentru a-i descoperi ascunzătoare. Dacă cioara urmărită realizează că este observată, își modifică locația pentru a-și proteja rezervele. Probabilitatea de conștientizare reprezintă șansa ca o cioară să detecteze urmărirea. De asemenea, parametrul denumit distanță de zbor indică raza maximă pe care o poate o poate parcurge o cioară într-o singură iterație [28].

Un algoritm Algoritm Multiobiectiv de Căutare al Ciorilor (MOCSA) este realizat în Iran, când Mahdi Gharibi și Alireza Askarzadeh propun o strategie de proiectare optimizată a unui sistem hibrid de producere a energiei format din panouri fotovoltaice, generator Diesel, pile de combustie, electrolizor și rezervor cu hidrogen [29].

Ghaffari et. al. [30] propun de asemenea un model de optimizare a performanței unui sistem hibrid, instalat într-o clădire din Kerman, Iran, format din panouri fotovoltaice, turbine eoliene, un generator Diesel și un sistem de stocare a energiei. Scopul lucrării este de a determina configurația optimă a acestui sistem care să asigure reducerea costurilor de investiție, instalare, operare și mentenanță ale acestuia pe durata sa de viață, asigurând totodată un nivel prestabilit de fiabilitate și o pondere ridicată a energiei regenerabile, peste un prag minim impus.

Yukai Ke et. al. [31] folosesc Algoritmul Îmbunătățit de Căutare al Ciorilor (ICSA) pentru a optimiza consumul de energie în clădirile de birouri din Australia. Acest algoritm este comparat cu algoritmul PSO și Algoritmul de Optimizare cu Colonii de Furnici (ACO). Rezultatele arată că viteza de convergență a algoritmului ICSA către soluția optimă este de 2 până la 7 ori mare decât a celorlalți doi algoritmi. De asemenea, ICSA demonstrează performanțe superioare în ceea ce privește calitatea soluțiilor optime, deoarece rezultatele arată că prin aplicarea configurațiilor optime rezultate se poate reduce consumul de energie cu 11.8% și 14,05%.

2.3.2 Algoritmul de Optimizare cu Colonii de Furnici (ACO)

Algoritmul de Optimizare cu Colonii de Furnici este un algoritm metaeuristic inspirat de comportamentul furnicilor în găsirea celor mai scurte drumuri între colonie și sursa de hrană [32]. În natură, furnicile lasă în urma lor o substanță chimică denumită feromon, care servește drept ghid pentru celelalte furnici. Traseele cu o concentrație mai ridicată de feromon devin mai atractive și sunt urmate cu o probabilitate mai mare. Prin analogie, algoritmul utilizează o populație de „furnici” ce explorează spațiul soluțiilor posibile. Probabilitatea de alegere a soluției este influențată de cantitatea de feromon existentă și de calitatea soluțiilor anterioare. După fiecare iterație, se adaugă feromon în cazul soluțiilor bune și se elimină treptat feromonul în cazul

soluțiilor mai puțin bune pentru a evita stagnarea. Astfel, în timp, populația converge spre soluții tot mai bune.

În anul 2017 este folosit un algoritmul ACO în vederea optimizării consumul total de energie în clădiri prin identificarea combinațiilor optime de variabile de control și design [33]. Variabilele de decizie sunt: parametrii sistemului HVAC, setările temperaturii țintă pentru încălzire și răcire, programarea ciclurilor de funcționare, reglarea debitului de aer sau a fluxului de agent termic, izolația termică, tipul, suprafața și orientarea ferestrelor, programarea iluminatului artificial, controlul echipamentelor electrice pentru a minimiza consumul în perioadele de vârf. Rezultatele obținute confirmă că după aplicarea configurației optime, consumul anual de energie este redus cu aproximativ 11,4% față de consumul clădiri comerciale fără implementarea măsurilor de economisire a energiei. Acest algoritm este îmbunătățit un an mai târziu de aceeași cercetători [34]. Aceștia utilizează un Algoritmul de Optimizare cu Colonii de Furnici pentru Variabile Mixte (ACOMV-M) în scopul optimizării consumului total de energie într-o clădire comercială din Australia. Variabilele de decizie sunt tipul și grosimea izolației termice, umbrirea și tipul de ferestre utilizate. Rezultatele arată că utilizarea configurației optime poate conduce la o scădere a consumului de energie cu 8,7% în comparația cu consumul de energie al clădirii de referință.

K. Bamdad et.al. [35] utilizează de asemenea un algoritm ACO cu scopul optimizării consumului de energie în cazul a două clădiri de birouri situate in orașe australiene diferite.

2.3.3 Algoritmul de Optimizare Inspirat din Comportamentul de Hrănire al Pisicii de Mare (Manta-Ray) (MRFO)

MRFO este un algoritm metaeuristic inspirat din cele trei comportamente biologice de hrănire ale Pisicii de Mare și anume: hrănirea în lanț (indivizii își urmează liderul pentru a se apropia de sursa de hrană), în spirală (mișcări spiralate în jurul prăzii) și prin rotații (în jurul celei mai bune surse de hrană găsite). Algoritmul inițializează o populație aleatorie de indivizi, apoi pozițiile indivizilor sunt actualizate conform celor trei mecanisme pentru a menține diversitatea populației.

Algoritmul MRFO este utilizat în vederea optimizării consumului de energie pentru încălzire, răcire și iluminat, prin ajustarea anvelopei și a formei unei clădiri rezidențiale din China [36]. Rezultatele arată că MRFO are o convergență mai rapidă și o capacitate mai bună de a evita minimele locale comparativ cu algoritmii PSO și GA. De asemenea, alegerea unei forme optime a clădirii conduce la o reducere a consumului energetic între 8% și 15%, comparativ cu formele de referință nemodificate.

2.4 COMPARAȚIE ÎNTRE ALGORITMII DE OPTIMIZARE

2.4.1 Avantajele algoritmilor de optimizare

Algoritmul genetic (GA) este recunoscut pentru flexibilitatea sa ridicată, fiind capabil să rezolve atât probleme discrete, cât și continue, spre deosebire de PSO, care este mai potrivit pentru probleme continue [37]. Comparativ cu ACO, care este specializat în probleme combinatoriale, GA oferă o aplicabilitate mai largă, fiind capabil să gestioneze probleme cu reprezentări complexe și variabile mixte. Comparativ cu CSA și MRFO, GA are o capacitate excelentă de explorare. Prin utilizarea operatorilor genetici precum încrucișarea și mutația, GA explorează eficient spațiul de soluții, evitând stagnarea prematură.

Algoritmul PSO poate rezolva probleme complexe de optimizare cu o eficiență ridicată, fiind ideal pentru probleme continue de optimizare și în special pentru probleme de dimensiuni mari. Acest algoritm este cunoscut pentru simplitatea și ușurința sa de implementare, are o acuratețe de predicție ridicată și are un timp de convergență mai scurt decât GA [38]. Performanțele PSO nu sunt foarte sensibile la dimensiunea populației, fiind suficient ca numărul de particule să nu fie prea mic [39].

Studiile arată că ACO converge mai repede către soluția optimă comparativ cu algoritmul PSO. Alt avantaj al algoritmului, conform referinței [40], este rulare neîntreruptă și adaptabilă schimbării în timp real a datelor de intrare.

Performanța CSA este mai mare decât performanța algoritmilor PSO și GA, algoritmul CSA având o eficiență ridicată în problemele de optimizare. Acest algoritm este ușor de implementat și este mai fezabil decât GA sau PSO. Conform [31], viteza de convergență a algoritmului CSA către soluția optimă este de 2 până la 7 ori mare decât viteza de convergență a algoritmilor ACO și PSO.

2.4.2 Dezavantajele algoritmilor de optimizare

Principalele dezavantaje ale GA sunt convergența lentă către soluția optimă, sensibilitatea reglării parametrilor, riscul blocării în minime locale, dificultățile întâmpinate în problemele foarte mari, complexitatea crescută spre deosebire de PSO, ACO și CSA [41] [42] [43].

Dezavantajele algoritmului PSO sunt slaba gestiune a optimizării discrete și riscul mare de convergență prematură [44] [45]. Pentru a minimiza aceste probleme, cercetătorii combină PSO cu GA și ACO [46]. Performanța algoritmului depinde într-o mare măsură de setarea parametrilor, deoarece valorile necorespunzătoare ale coeficienților de inerție și atracție pot determina fie o

explorare prea lentă, fie instabilitate în procesul de căutare [47] [48]. Algoritmul are o performanță slabă în cazul dimensiunilor foarte mari [49]. În plus, dacă viteza maximă nu este controlată corespunzător, particulele pot oscila prelungit în jurul unei soluții fără a reuși să se stabilizeze [50].

Principalul dezavantaj al algoritmului ACO este timpul incert până la convergență [51]. Un alt dezavantaj ACO este riscul de convergență prematură [32]. Dacă intensificarea feromonului este prea rapidă, toate furnicile pot începe să urmeze aceeași rută devreme, blocându-se într-un optim local. La fel ca GA și PSO, ACO este de asemenea sensibil la setarea parametrilor precum rata de evaporare a feromonului, ponderea acestuia sau contribuția informației euristice, deoarece setările nepotrivite pot duce la explorare insuficientă a spațiului de căutare [52]. Eficiența algoritmului ACO este strâns legată de calitatea informației euristice utilizate pentru a ghida mișcarea furnicilor. În cazul în care această informație este slabă sau inexactă, explorarea spațiului de soluții devine aproape aleatorie, ducând la o convergență mai lentă și rezultate mai slabe [32].

Ca și în cazul PSO și ACO, dezavantajele principale ale algoritmului CSA sunt: sensibilitatea la setarea parametrilor, convergența prematură și dificultățile întâmpinate în probleme de dimensiuni mari. Un dezavantaj specific CSA constă în faptul că mecanismul de urmărire și furt între ciori poate conduce la o concentrare excesivă asupra soluțiilor deja urmărite [28]. Aceasta reduce diversitatea populației și limitează capacitatea algoritmului de a explora eficient întreg spațiul soluțiilor, mai ales în cazul problemelor complexe.

CAPITOLUL 3
DESCRIEREA MECANISMELOR FUNCȚIONALE ALE ALGORITMILOR GA ȘI NSGA-II

3.1 DESCRIEREA MECANISMULUI FUNCȚIONAL ALGORITMULUI GENETIC

Pentru implementarea unui Algoritm Genetic (GA) este necesară definirea următoarelor elemente:

a) dimensiunea populației și metoda de inițializare a indivizilor;
b) funcția fitness utilizată pentru evaluarea indivizilor;
c) criteriile de oprire ale algoritmului;
d) mecanismul de selecție;
e) mecanismul de încrucișare și modul de aplicare;
f) mecanismul de mutație și parametri asociați.

a) Dimensiunea și modul de inițializare al populației

Populația este un ansamblu de vectori n-dimensionali, fiecare vector reprezentând o soluție potențială la problema de optimizare [8]. Acest vector este numit individ sau cromozom și este compus dintr-o secvență de gene.

Inițializarea populației se realizează, de regulă, aleatoriu, generând indivizi cu valori ale genelor distribuite uniform în limitele definite ale spațiului de căutare [42]. Potrivit literaturii de specialitate, uneori se introduc în populația inițială indivizi construiți pe baza unor cunoștințe euristice sau soluții deja cunoscute (inițializare ghidată), în timp ce restul indivizilor sunt generați aleatoriu. Această combinație îmbină avantajul explorării unor regiuni noi din spațiul soluțiilor cu cel al exploatării zonelor deja identificate ca fiind promițătoare [53] [54].

Dimensiunea populației reprezintă numărul total de indivizi ce formează populația inițială. Alegere acestei dimensiuni este o problemă sensibilă, deoarece de acest parametru depinde eficiența și performanța algoritmului GA. Dimensiunea populației trebuie aleasă astfel încât să existe un echilibru optim între diversitatea soluțiilor explorate și eficiența procesului de căutare [55]. Potrivit

literaturii de specialitate, valorile uzuale pentru dimensiunea populației variază între 10 și 160 de cromozomi, în funcție de complexitatea problemei și resursele disponibile [56].

b) Funcția fitness

Funcția fitness este un criteriu de evaluare al gradului de adaptare al fiecărui individ din populație la problema specifică. Această funcție are la bază principiul selecției naturale, conform căruia indivizii cei mai adaptați au șanse mai mari de supraviețuire și reproducere [57] [58]. Cunoscută și sub denumirea de funcție obiectiv, aceasta are rolul de a evalua calitatea fiecărui cromozom în raport cu scopul optimizării, ghidând astfel procesul de selecție în cadrul GA.

c) Criteriile de oprire

Rolul unui criteriu de oprire este stabili momentul în care execuția Algoritmului Genetic trebuie întreruptă, astfel încât soluția curentă obținută să fie cât mai apropiată de soluția optimă. Principalele criterii utilizate pentru oprirea rulării GA sunt:

- atingerea unui număr maxim de generații;
- atingerea limitei maxime de timp de rulare. Algoritmul rulează pentru o perioadă de timp predefinită [59];
- obținerea unei valori apropiate de cea așteptată [60]. Indivizii concurează între ei pentru a găsi soluția optimă, dar numai aceia cu cele mai bune rezultate sunt selectați și trec în generația următoare. Funcția fitness f_i a cromozomilor selectați este comparată cu valoarea așteptată f_d. Procesul se repetă până când eroarea scade sub un prag impus. Altfel spus, dacă $|f_i - f_d| \leq \varepsilon$, atunci algoritmul se oprește;
- convergența prematură. Se referă la întreruperea execuției algoritmului înainte ca acesta să atingă o soluție optimă globală, de obicei din cauza unei convergențe rapide către un optim local.

d) Mecanismul de selecție

Acest operator nu generează direct soluții noi, însă, pe baza valorii funcției fitness a fiecărui individ, stabilește cromozomii care vor fi selectați pentru împerechere și reproducere (selecția părinților), influențează numărul de descendenți pe care îi poate produce fiecare cromozom ales, precum și indivizii care vor fi păstrați în generația următoare în cadrul procesului de selecție a

urmașilor sau a supraviețuitorilor [61]. Există mai multe mecanisme tradiționale de selecție a indivizilor, aplicate în funcție de natura problemei și obiectivele optimizării, precum:

- selecția proporțională cu funcția fitness (selecția de tip ruletă);
- selecția pe baza rangurilor;
- selecția de tip turneu;
- selecția prin trunchiere;
- elitismul.

e) Mecanismul de încrucișare (Crossover) și modul de aplicare

Se aleg aleatoriu doi cromozomi-părinți cărora le sunt interschimbate genele pentru a genera unul sau doi descendenți, în funcție de implementarea algoritmului. Acești descendenți moștenesc informația genetică de la ambii părinți și îi înlocuiesc pe aceștia în cadrul noii populații. Interschimbarea genelor se realizează prin introducerea unuia sau mai multor puncte de separare a informației (*cross points*) în interiorul cromozomilor [62].

În funcție de tipul de reprezentare a indivizilor, încrucișarea se poate realiza în diferite moduri, fiecare fiind adaptat specificului reprezentării:

1. Reprentarea binară și cea întreagă;

- Cu unul sau multe puncte de încrucișare (single-point, two-point sau multi-point crossover);
- Uniformă (Uniform crossover);

2. Reprezentare reală;

- Discretă (Discrete recombination);
- Intermediară sau aritmetică (Arithmetic crossover): Aritmetică singulară, Aritmetică simplă, Aritmetică completă;
- Geometrică (Geometric crossover);
- Încrucişare amestecată (Blend crossover (BLX-α));
- Încrucişare binară simulată (SBX – Simulated Binary Crossover);

3. Reprezentare prin permutări

- Încrucişare prin ordonare (Order Crossover – OX);
- Încrucişare transformată parţial (Partially Mapped Crossover – PMX);
- Încrucişare ciclică (Cycle Crossover – CX);
- Încrucişare bazată pe legături (muchii) (Edge Recombination Crossover – ERX) [40].

f) Mecanismul de mutație și parametri asociați

Mutația are loc după procesul de încrucișare și are rolul de a introduce material genetic nou în populație, cu scopul de a încuraja diversitatea populației. Aceasta constă în modificarea aleatorie a uneia sau mai multor gene dintr-un cromozom. Probabilitatea ca o genă să fie modificată în cadrul unui cromozom se numește *probabilitate de mutație* (*mutation probability*).

În funcție de reprezentarea indivizilor, mutația se împarte în următoarele categorii [40]:

1. Reprezentare binară;

- Mutația bit-flipping;

2. Reprezentare întreagă;

- Random resetting;
- Creep mutation;

3. Reprezentare reală;

- Mutație uniformă;
- Mutație neuniformă (mutație Gaussiană, Cauchy sau Laplace);

4. Reprezentare cu permutări;

- Mutație prin inserție;
- Mutație prin interschimbare;
- Mutație prin inversare;
- Mutație prin amestec;
- Mutație K-opt.

3.2 DESCRIEREA MECANISMULUI FUNCȚIONAL ALGORITMULUI GENETIC DE SORTARE NEDOMINANT

Algoritmul Genetic de Sortare Nedominant II (NSGA – II) este asemănător cu Algoritmul Genetic (GA), însă diferă prin modul de selecție al părinților, deoarece NSGA - II utilizează sortarea nedominată și sortarea pe baza distanței de aglomerare. Pașii necesari dezvoltării unui model NSGA-II sunt:

1. stabilirea parametrilor de intrare precum dimensiunea populației, numărul de generații, probabilitatea de mutație, probabilitatea de încrucișare [63]; se generează o populație inițială aleatoriu de dimensiune *N*, ținând cont de intervalele impuse variabilelor de decizie ale problemei de optimizare (limitele spațiului de căutare) și se calculează valorile funcției fitness pentru fiecare cromozom [64]. Selecția urmărește construirea unui set de soluții cât mai

aproape de frontul Pareto optim. Acest front reprezintă *"un set de soluții nedominate, acestea fiind alese ca optime dacă niciun obiectiv nu poate fi îmbunătățit fără a sacrifica cel puțin un alt obiectiv*" [65].

2. crearea descendenților din părinți prin aplicarea selecției de tip turnir binar, unde compararea indivizilor se face pe baza rangului nedominant și a distanței de aglomerare, urmată de aplicarea operatorilor de încrucișare și mutație specifici Algoritmului Genetic și obținerea unei populații combinate de dimensiune *2N* [66];
3. sortarea populației combinate utilizând principiul nedominanței și distanța de aglomerare în vederea obținerii unei noi populații;

Pe baza **principiului sortării nedominante** sunt produse mai multe fronturi Pareto astfel:

- fiecare individ este comparat cu ceilalți indivizi din populația combinată în funcție de valoarea funcției fitness și sunt identificate toate soluțiile nedominante ținând cont de principiul dominanței care afirmă: "*Se spune că o soluție x domină cealaltă soluție y dacă soluția x nu este mai rea decât y în toate obiectivele și soluția x este strict mai bună decât y în cel puțin un obiectiv.*" [63];
- toate aceste soluții nedominante sunt asignate primului front;
- restul indivizilor din populația combinată rămași neatribuiți primului front sunt comparați în vederea asignării lor la următorul front Pareto; procesul se repetă până când toți indivizii sunt atribuiți unui front nedominant [67] [68];

Doar o parte din indivizii aparținând primelor fronturi dominante vor trece în generația următoare. Cei mai buni N indivizi cu diversitate mai mare sunt selectați folosind sortarea nedominată și distanța de aglomerare, în timp ce restul indivizilor sunt eliminați [69].

Distanța de aglomerare reprezintă un criteriu de selecție a indivizilor ce aparțin aceluiași front nedominant pe baza distanței Euclidiene dintre indivizii vecini din spațiul de căutare [70]. Aceasta este folosită pentru păstrarea diversității în cadrul aceluiași front. Astfel, indivizii mai „izolați" în spațiul obiectivelor au prioritate la selecție față de cei foarte apropiați.

Indivizii ce vor face parte din noua populație sunt selectați astfel: dacă mărimea primului front este mai mică decât *N*, toți indivizii din acest front vor fi aleși pentru a face parte din noua generație; restul indivizilor, adică diferența dintre mărimea *N* a populației și numărul de indivizi aparținând primului front nedominant, sunt aleși din următoarele fronturi nedominate menținând aceeași regulă. Doar o parte din indivizii ultimului front sunt selectați pentru a face parte din

generația următoare și anume soluțiile cu o distanță de aglomerare mai mare [71]. Algoritmul rulează de la pasul 2 până când se îndeplinește criteriul de oprire prestabilit. Acest proces complex este rezumat în figura 3.1.

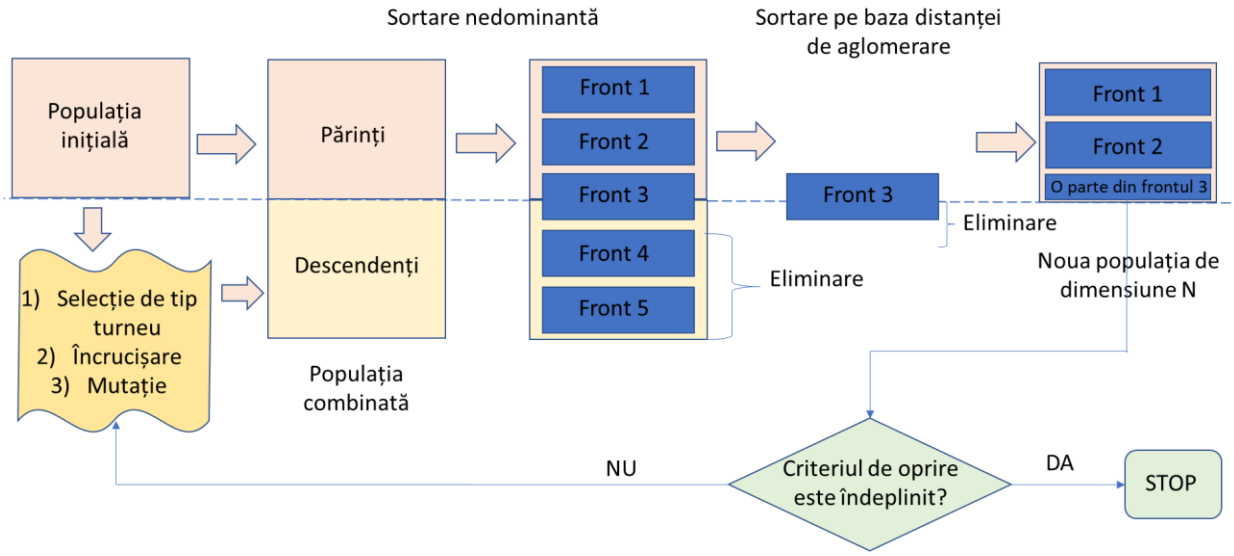


Fig. 3.1. Algoritmul Genetic de Sortare Nedominant II

CAPITOLUL 4
STUDIU DE CAZ – OPTIMIZAREA NECESARULUI DE ENERGIE PENTRU ÎNCĂLZIRE ȘI RĂCIRE

4.1 STUDIU DE CAZ 1 – Optimizarea fluxului termic unitar utilizând GA

Datorită performanței sale ridicate, Algoritmul Genetic este utilizat în cadrul acestui studiu de caz în vederea determinării grosimilor și conductivităților termice optime care să conducă la minimizarea fluxului termin unitar printr-un perete exterior sudic izolat cu polistiren expandat, prin placa peste sol izolată cu polistiren extrudat și prin plafonul izolat cu vată minerală. Astfel, sunt implementați trei GA similari, unul pentru fiecare tip de construcție.

4.1.1 Definirea problemei de optimizare și prezentarea algoritmului utilizat

Algoritmul GA alege grosimile și conductivitățile termice optime ale polistirenului expandat polistirenului extrudat sau vatei minerale în vederea obținerii fluxurilor termice unitare minime.

Din motive de simplificare a calculelor, se consideră că peretele nu are uși și ferestre și este realizat din materiale de construcție prezentate în figura 4.1. Rezistența termică totală a peretelui neizolat este egală cu 1,383 ($m^2 \cdot K$)/W.

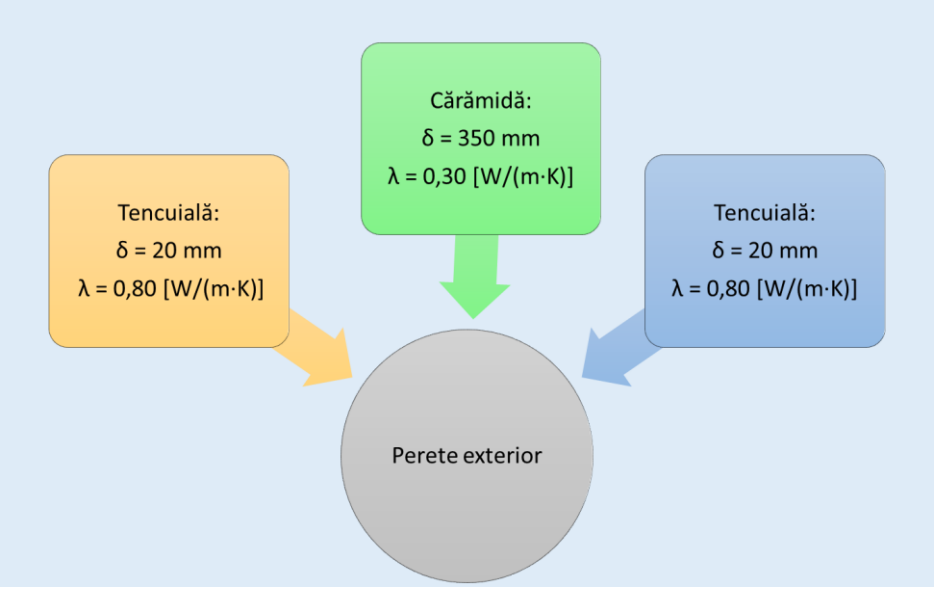


Figura 4.1. Structura peretelui exterior

Structura plăcii peste sol este prezentată în figura 4.2. Rezistența termică totală a plăcii peste sol neizolate este 2,062 (m^2·K)/W.

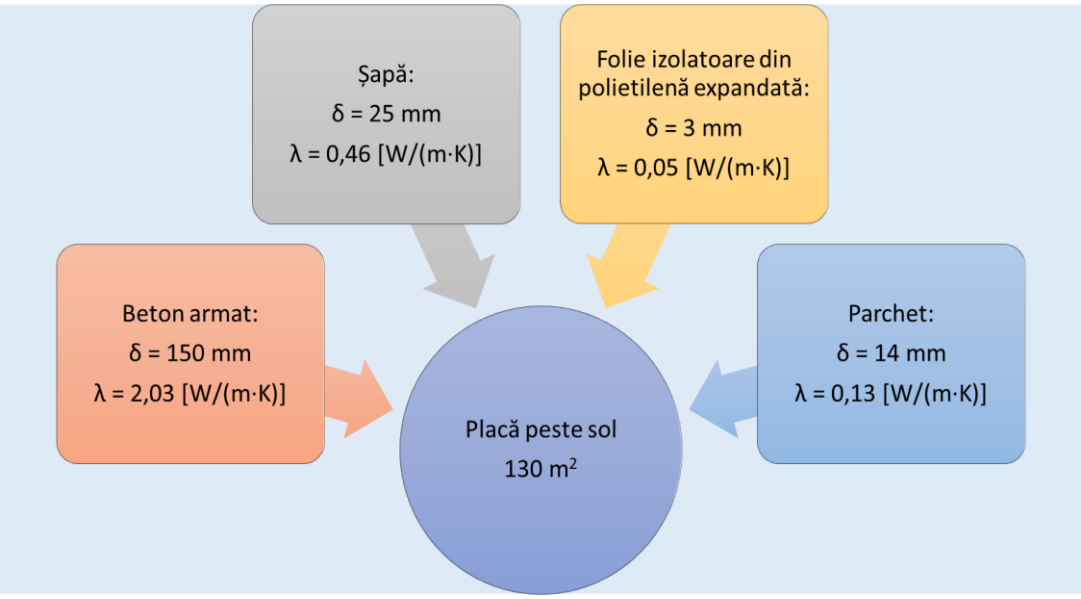


Figura 4.2. Structura plăcii peste sol

Materialele de construcție ale plafonului pot fi vizualizate de asemenea în figura 4.3. Rezistența termică totală a acestuia în cazul în care este neizolat are valoarea de 0,367 (m^2·K)/W.

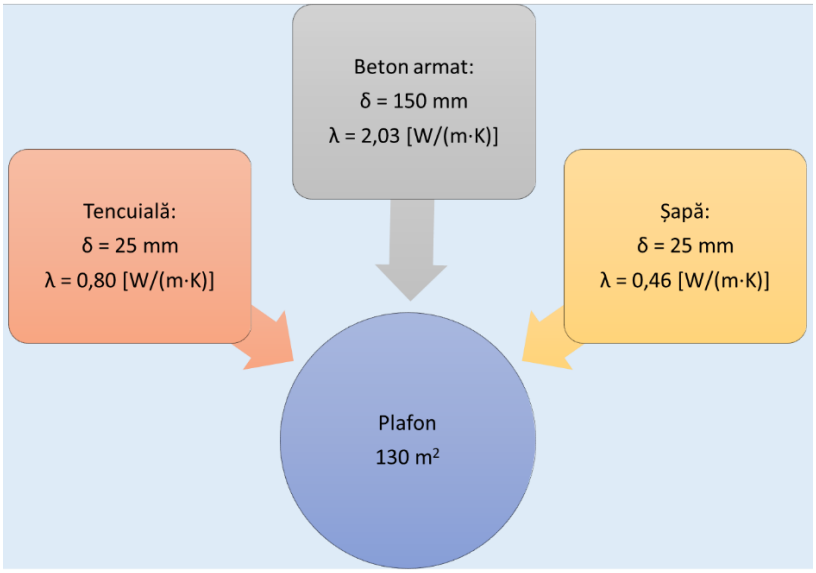


Figura 4.3. Structura plafonului

Pentru a calcula cele trei fluxuri termice optime, se utilizează valorile coeficienților de convecție termică prezentate în tabelul 4.1. Aceste valori sunt preluate din Metodologia MC001

[72] și din *Normativul privind calculul termotehnic al elementelor de construcție în contact cu solul* [73]. În acest tabel este descrisă de asemenea conductivitatea termică a solului la diferite adâncimi conform aceluiași normativ. Conform literaturii de specialitate, temperatura interioară este considerată θ_{in} = 20˚C, cea exterioară θ_{ext} = - *15˚C,* iar temperatura la suprafața solului se consideră θ_{sol} = 10˚C [73] [74] [75].

Tabel 4.1. Parametrii utilizați în calculul fluxurilor termice unitare

Parametru	Valoare	Unitate de măsură
α_{1in}	8	W/(m^2·K)
α_{1ext}	24	W/(m^2·K)
α_2	6	W/(m^2·K)
α_{3in}	8	W/(m^2·K)
α_{3ext}	12	W/(m^2·K)
λ_{1p}	2	W/(m·K)
δ_{1p}	1,2	m
λ_{2p}	4	W/(m·K)
δ_{2p}	4	m

Un prim pas în cadrul algoritmului este definirea variabilelor și stabilirea limitelor spațiului de căutare. Acestea sunt prezentate în figura 4.4

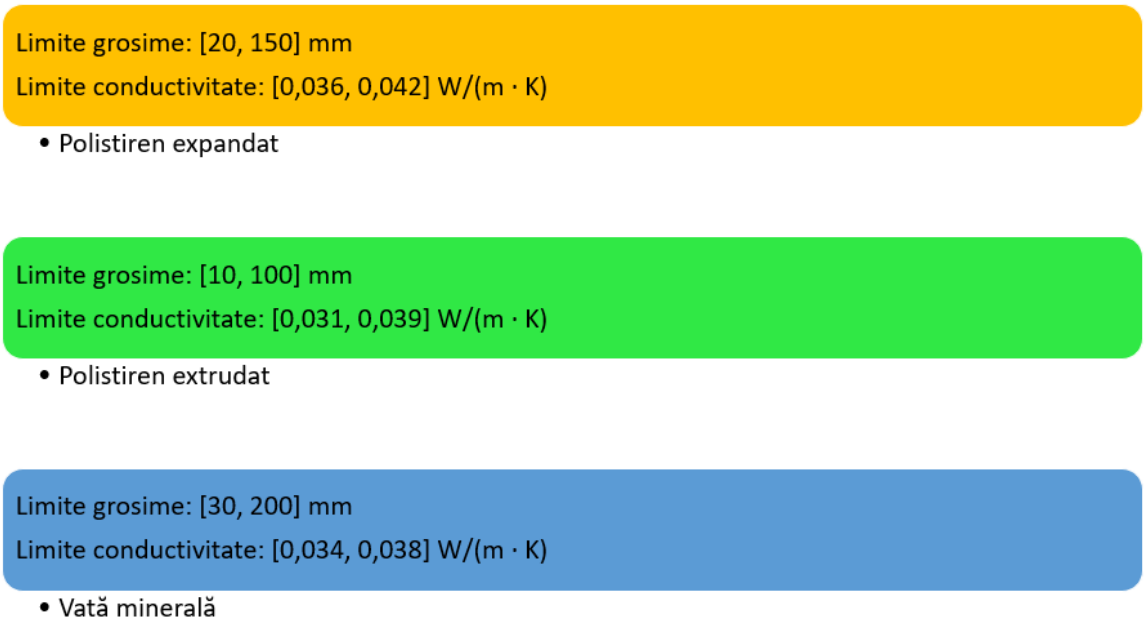


Figura 4.4. Limitele grosimilor și conductivităților termice ale materialelor de izolație termică

Indivizii sunt codificați prin numere reale. Dimensiunea populației, adică numărul total de indivizi ce formează populația inițială, este setată la 30. Populația inițială este generată utilizând valori aleatoare uniform distribuite între limitele prestabilite ale fiecărui parametru, prin intermediul funcției *numpy.random.uniform*. Algoritmul se oprește după un număr fix de 80 de iterații, ceea ce constituie condiția de finalizare a procesului evolutiv. Selecția indivizilor pentru generarea noii populații se realizează utilizând *Selecția prin trunchiere*. Metoda de încrucișare utilizată este *încrucișarea amestecată*. Descendenții sunt generați ca și combinații liniare ale părinților. Algoritmul GA folosește o rată de încrucișare de 100%, ceea ce înseamnă că toți indivizii selectați participă la procesul de încrucișare, generând noi descendenți. Algoritmul implementat utilizează *mutația neuniformă*. Probabilitatea de mutație este setată la 1%.

4.1.2 Rezultate

Prin acest studiu de caz se demonstrează faptul că GA poate fi utilizat cu succes în identificarea materialelor de izolație termică potrivite, în vederea obținerii unui flux termic unitar minim printr-un perete. În figura 4.5 se observă rezultatul rulării algoritmului pentru determinarea fluxului termic optim prin peretele izolat, pentru un număr maxim de iterații egal cu 80.

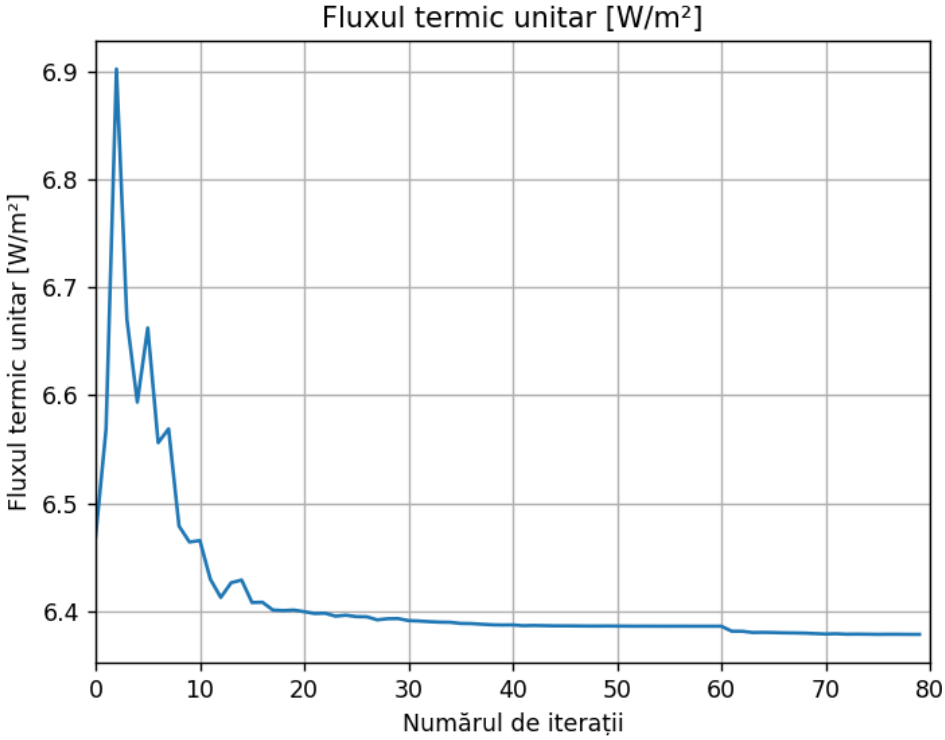


Figura 4.5. Fluxul termic unitar optim prin peretele izolat termic

Polistirenul expandat care îndeplinește condiția de obținere a unui flux termic unitar cât mai mic, este acela cu conductivitate de 0,0365 W/(m·K) și grosime de 149,9 mm. Fluxul termic unitar optim are valoarea 6,378 W/m^2.

În figura 4.6 se poate observa că fluxul termic unitar optim prin placa peste sol izolată termic are valoarea de 1,961 W/m^2. Acesta se obține prin utilizarea polistirenului extrudat cu conductivitatea termică de 0,031 W/(m·K) și o grosime de 94,115 mm.

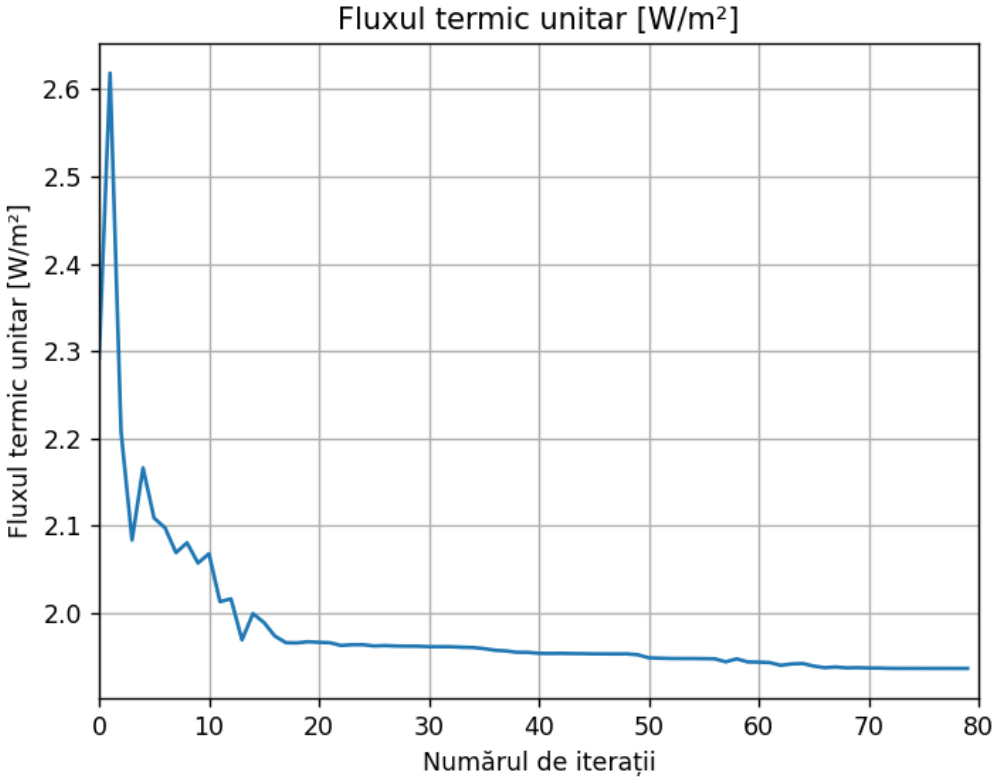


Figura 4.6. Fluxul termic unitar optim prin placa peste sol izolată termic

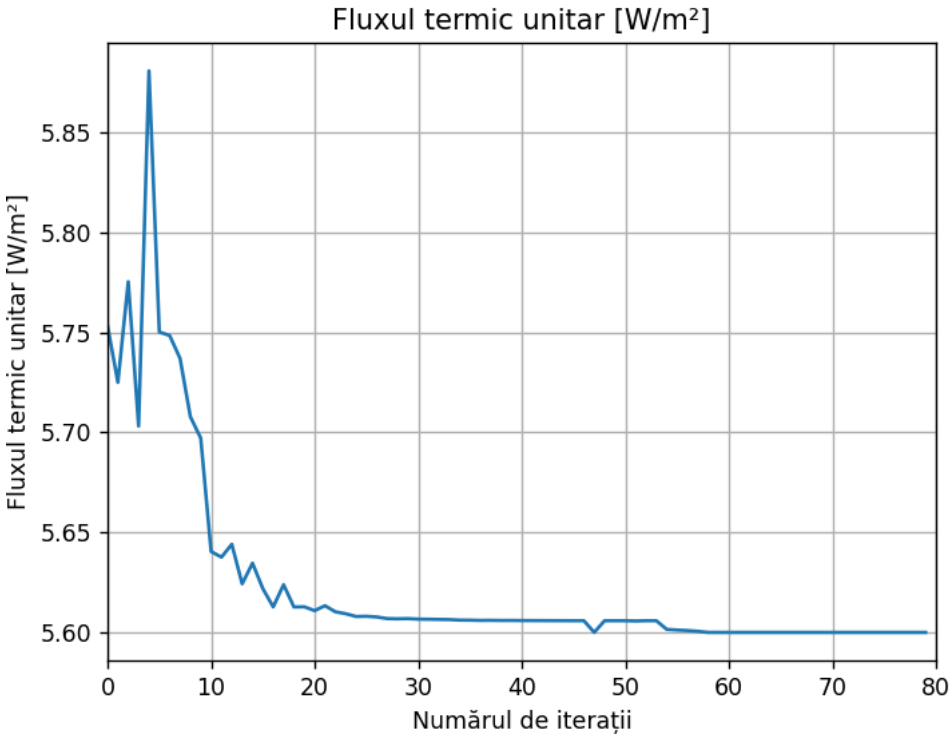


Figura 4.7. Fluxul termic unitar optim prin plafon

Figura 4.7 ilustrează rezultatul obținut în urma rulării algoritmului pentru determinarea fluxului termic optim prin plafonul izolat, considerând un număr maxim de 80 de iterații. Vata minerală care conduce la obținerea celui mai redus flux termic unitar are conductivitatea termică de 0,034 W/(m·K) și grosimea de 199,98 mm. În aceste condiții, fluxul termic unitar optim atinge valoarea de 5,599 W/m².

4.2 STUDIU DE CAZ 2 – Optimizarea energiei necesare pentru încălzire utilizând NSGA – II

Datorită performanței sale ridicate, Algoritmul Genetic de Sortare Nedominant II (NSGA II) este utilizat în cadrul acestui studiu de caz în vederea identificării configurației optime a anvelopei termice a unei clădiri rezidențiale care asigură necesarul minim de energie pentru încălzire, luând în considerare și restricțiile de preț obținute printr-un studiu de piață specific. Acest algoritm este implementat utilizând libraria Pymoo (Optimizare Multiobiectiv în Python) și este aplicat în cazul clădirii studiate ai cărei pereți exteriori, placă peste sol și plafon se izolează cu polistiren expandat, polistiren extrudat și vată minerală, iar ferestre și ușile se înlocuite cu elemente cu caracteristici termice superioare prezentate în subcapitolul 4.2.2. Astfel, modelul NSGA-II este creat cu scopul

de a găsi soluția optimă într-un spațiu de căutare considerat a fi compus din grosimi și conductivități termice ale materialelor de izolație și proprietăți termice ale ușilor și ferestrelor.

4.2.1 Descrierea anvelopei clădirii neizolate termic

În cadrul acestui studiu de caz se analizează o clădire rezidențială unifamilială ipotetică situată în București, România. Temperatura exterioară medie lunară pentru această zonă este considerată conform Standardului SR4839 [75]. Temperatura solului este preluată din software-ul RETScreen V9.0. Valorile intensităților medii lunare ale radiației solare totale pentru zona București sunt prezentate de asemenea în tabelul 4.2 și sunt în conformitate cu Metodologia MC001 [78].

Tabel 4.2. Date climatice, zona București

Luna	Intensitatea medie lunară a radiației solare, SE [W/m^2]	Temperaturi exterioare medii lunare [°C]	Temperatura la suprafața solului [°C]
Ianuarie	59,3	-1,4	-2,2
Februarie	87,3	0,1	0,0
Martie	91,4	5,1	5,5
Aprilie	91,6	11,1	12,0
Mai	86,0	16,8	18,3
Iunie	92,8	20,7	23,1
Iulie	89,9	22,6	26,0
August	123,8	21,8	25,6
Septembrie	119,1	16,5	19,5
Octombrie	104,1	10,5	12,2
Noiembrie	57,4	4,5	5,2
Decembrie	53,0	-0,3	-0,7

* Valorile medii lunare ale radiației solare sunt determinate ca media zilnică (pe 24 de ore) a iradianței globale incidente pe o suprafață orizontală, calculată ulterior pe întreaga lună.

Conform standardului SR1907-2, temperatura interioară convențională de calcul pentru camere de locuit și holuri este de 20°C în perioada de încălzire [76].

În conformitate cu standardul SR 4839, durata convențională a sezonului de încălzire calculată pentru o temperatură interioară convențională de 20°C și pentru o temperatură exterioară medie de 12°C pentru zona București este de 189 zile [75]. Înmulțind această valoare cu 24 ore, se consideră că sezonul de încălzire durează 4536 ore pe an, astfel: 744 ore în lunile ianuarie, martie, octombrie și decembrie, 720 ore în noiembrie, 672 ore în februarie și 168 ore în aprilie.

Necesarul de energie pentru încălzire înainte de izolarea termică a pereților, plăcii peste sol și plafonului a fost de 385,128 kWh/m^2/an. Pentru a reduce această valoare, peretele exterior se izolează cu polistiren expandat, placa peste sol cu polistiren extrudat și plafonul cu vată minerală. De asemenea, ușa și ferestrele sunt înlocuite cu elemente cu performanțe termoizolante superioare, conform caracteristicilor prezentate în subcapitolul 4.2.2. Materialele de construcție utilizate pentru pereții exteriori, placă peste sol și plafon în cazul clădirii neizolate sunt descrise în figurile 4.1, 4.2 și 4.3.

4.2.2 Definirea problemei de optimizare

Variabilele utilizate în cadrul modelării sunt: conductivitățile termice și grosimile polistirenului expandat, polistirenului extrudat, vatei minerale în cazul pereților, plăcii peste sol și plafonului, coeficienții globali de schimb de căldură și coeficienții de transmisie a energiei solare totale în cazul ferestrelor, precum și coeficienții globali de schimb de căldură în cazul ușilor.

Numărul de variabile de decizie este *n_var* = 9, iar numărul de obiective este *n_obj* = 1. Problema de optimizare are un singur obiectiv, acela de a minimiza valorile funcției obiectiv care reprezintă necesarul de energie pentru încălzire. Această problemă este implementată utilizând relația:

$$min\, Q_{\text{încălzire }k}\left(\delta_{izol1}, \lambda_{izol1,}\delta_{izol2}, \lambda_{izol2,}\delta_{izol3}, \lambda_{izol3,}K_{s1}, g, K_{s2}\right) = \sum_k h_k \cdot \quad (4.1)$$

$$\left[\Delta T_k \cdot H_V + q_{1k}(\delta_{izol1}, \lambda_{izol1}) \cdot (A_1 + A_2 + A_3 + A_4) + q_{2k}\left(\lambda_{izol2,}\delta_{izol2}\right) \cdot A_5 + q_{3k}\left(\lambda_{izol3,}\delta_{izol3}\right) \cdot A_6 + q_{4k}(g, K_{s1}) \cdot A_7 + q_{5k}(K_{s2}) \cdot A_8\right] \text{ [kWh/an]}$$

unde k = ianuarie, februarie, martie, aprilie, octombrie, noiembrie, decembrie; $Q_{încălzire}$ = necesar de energie pentru încălzire [kWh/an]; h_k = durata sezonului de încălzire [h]; H_V = coeficient de pierderi de căldură prin ventilare [W/K]; ΔT_k = diferența de temperatură în sezonul de încălzire [ºC]; δ_{izol1}, δ_{izol2}, δ_{izol3} = grosimile polistirenului expandat, extrudat și vatei minerale [mm]; λ_{izol1}, λ_{izol2}, λ_{izol3} = conductivitățile termice ale polistirenului expandat, extrudat și vatei minerale [W/(m·K)]; K_{s1}, K_{s2} = coeficienții globali de schimb de căldură în cazul ușilor și ferestrelor; [W/(m^2·K)]; g = coeficienții de transmisie a energiei solare totale [−]; A_1, A_2, A_3, A_4, A_5, A_6, A_7, A_8 = ariile elementelor de construcție (perete vestic, estic, nordic, suprafața nevitrată a peretelui sudic, placă peste sol, plafon, ferestre și uși) [m^2]; q_{1k} (δ_{izol1}, λ_{izol1}), q_{2k} (δ_{izol2}, λ_{izol2}), q_{3k} (δ_{izol3}, λ_{izol3}), q_{4k} (g, K_{s1}), q_{5k} (K_{s2}) = fluxurile termice unitare prin pereți, placă peste sol, plafon, ferestre și uși [W/m^2].

Scopul optimizării este acela de a găsi soluțiile optime care satisfac toate constrângerile asociate cu funcția obiectiv [76]. Astfel, în Pymoo este necesar să se formuleze constrângerile ca inegalități mai mici sau egale cu zero. În cadrul modelării, aceste constrângeri sunt aplicate sub forma unor restricții privind prețul. În consecință, a fost realizat un studiu de piață și astfel au fost obținute de pe website-urile diferiților producători/comercianți de materiale de construcție mai multe combinații de prețuri pentru fiecare configurație optimă (constând în diferite perechi de proprietăți termice). Prin urmare, $P_i\ (\delta_{izoli},\ \lambda_{izoli})$ reprezintă prețul materialelor de izolație pentru diferite combinații de tip grosime (δ_{izoli}) și conductivitate termică (λ_{izoli}). Similar, $P_4(g,\ K_{s1})$ reprezintă prețul ferestrelor, în timp ce $P_5(K_{s2})$ conține prețul diferitelor tipuri de uși. Aceste valori sunt utilizate pentru a obține o medie a prețurilor pentru fiecare configurație (constând în diferite perechi de proprietăți termice), rezultând următoarele valori: 42,41 RON/m^2 – pentru polistiren expandat, 78,91 RON/m^2 – pentru polistiren extrudat și 91,09 RON/m^2 – pentru vată mineral. În cazul ferestrelor și ușilor, aceste prețuri sunt setate la 1500 RON/fereastră și 6574,63 RON/ușă. În consecință, cele cinci ecuații aferente constrângerilor de preț, al căror număr este notat cu *n_constr* = 5, sunt definite astfel:

$$P_1(\delta_{izol1}, \lambda_{izol1}) - 42{,}41 \ \leq 0\ [\mathrm{RON/m^2}] \tag{4.2}$$

$$P_2(\delta_{izol2}, \lambda_{izol2}) - 78{,}91 \ \leq 0\ [\mathrm{RON/m^2}] \tag{4.3}$$

$$P_3(\delta_{izol3}, \lambda_{izol3}) - 91{,}09 \ \leq 0\ [\mathrm{RON/m^2}] \tag{4.4}$$

$$P_4(g, K_{s1}) - 1500 \ \leq 0\ [\mathrm{RON}] \tag{4.5}$$

$$P_5(K_{s2}) - 6574{,}63 \ \leq 0\ [\mathrm{RON}] \tag{4.6}$$

Limita inferioară (x_l) și limita superioară (x_u) în cazul variabilelor sunt:

$$20 \leq \delta_{izol1} \ \leq 150\ [\mathrm{mm}] \tag{4.7}$$

$$0{,}036 \leq \lambda_{izol1} \ \leq 0{,}042\ [\mathrm{W/(m \cdot K)}] \tag{4.8}$$

$$10 \leq \delta_{izol2} \ \leq 100\ [\mathrm{mm}] \tag{4.9}$$

$$0{,}031 \leq \lambda_{izol2} \ \leq 0{,}039\ [\mathrm{W/(m \cdot K)}] \tag{4.10}$$

$$30 \leq \delta_{izol3} \leq 200 \text{ [mm]} \quad (4.11)$$

$$0{,}034 \leq \lambda_{izol3} \leq 0{,}038 \text{ [W/(m} \cdot \text{K)]} \quad (4.12)$$

$$0{,}4 \leq g \leq 0{,}85 \text{ [}-\text{]} \quad (4.13)$$

$$0{,}6 \leq K_{s1} \leq 5{,}4 \text{ [W/(m}^2 \cdot \text{K)]} \quad (4.14)$$

$$0{,}7 \leq K_{s2} \leq 2{,}47 \text{ [W/(m}^2 \cdot \text{K)]} \quad (4.15)$$

Clădirea studiată are un singur etaj și o suprafață utilă de 130 m^2. Ariile elementelor de construcție sunt: $A_1 = A_2 = 15{,}6$ [m^2]; $A_3 = 48{,}0$ [m^2]; $A_4 = 35{,}4$ [m^2]; $A_5 = A_6 = 130{,}0$ [m^2]; $A_7 = 10{,}8$ [m^2], $A_8 = 1{,}8$ [m^2]. Dimensiunile liniare ale clădirii sunt prezentate în figura 4.8.

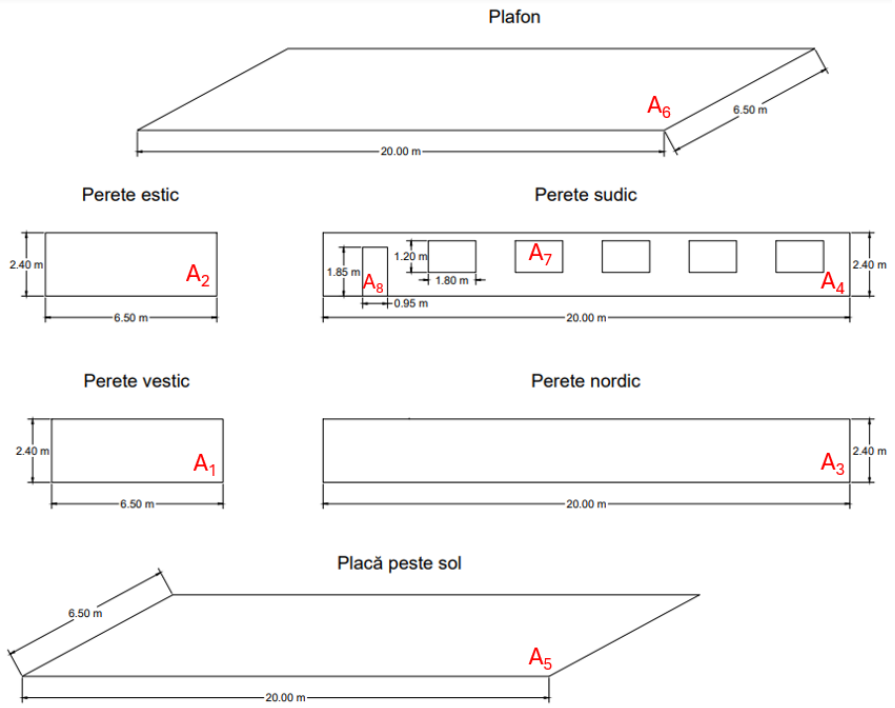


Figura 4.8. Dimensiunile liniare ale clădirii studiate [77]

Coeficientul de pierderi de căldură prin ventilare, H_V, este determinat utilizând relația 4.20:

$$H_V = \frac{\rho_a c_a n_a V}{3{,}6} \left[\frac{W}{K}\right] \quad (4.16)$$

unde ρ_a = densitatea aerului; c_a = căldura specifică a aerului; n_a = media numărului de schimburi de aer; V = volumul încălzit. Acești parametrii sunt considerați: $\rho_a = 1{,}2$ [kg/m^3]; $c_a = 1{,}005$ [kJ/(kg·K)]; $V = 312$ [m^3]; $n_a = 0{,}6$ [h^{-1}] [78]. În vederea stabilirii numărului mediu de

schimburi de aer se consideră că clădirea este moderat adăpostită și are o clasă de permeabilitate medie.

Pentru determinarea fluxurilor termice unitare se aplică legea lui Fourier pentru fiecare dintre componentele clădirii: pereți (relația 4.17), placă peste sol (relația 4.18) și plafon (relația 4.19). Fluxurile termice unitare q_{4k} (g, K_{s1}) și q_{5k} (K_{s2}) pentru ferestre și uși sunt determinate utilizând relațiile 4.20 și 4.21.

$$q_{1k}(\delta_{izol1}, \lambda_{izol1}) = \frac{\theta_{in} - \theta_{ext\,k}}{\frac{1}{\alpha_{1in}} + \frac{\delta_1}{\lambda_1} + \frac{\delta_2}{\lambda_2} + \frac{\delta_3}{\lambda_3} + \frac{\delta_{izol1}}{\lambda_{izol1}} + \frac{1}{\alpha_{1ext}}} \left[\frac{\mathrm{W}}{\mathrm{m}^2}\right] \tag{4.17}$$

$$q_{2k}(\delta_{izol2}, \lambda_{izol2}) = \frac{\theta_{in} - \theta_{sol\,k}}{\frac{1}{\alpha_2} + \frac{\delta_1}{\lambda_1} + \frac{\delta_2}{\lambda_2} + \frac{\delta_3}{\lambda_3} + \frac{\delta_4}{\lambda_4} + \frac{\delta_{izol2}}{\lambda_{izol2}} + \frac{\delta_{1p}}{\lambda_{1p}} + \frac{\delta_{2p}}{\lambda_{2p}}} \left[\frac{\mathrm{W}}{\mathrm{m}^2}\right] \tag{4.18}$$

$$q_{3k}(\delta_{izol3}, \lambda_{izol3}) = \frac{\theta_{in} - \theta_{ext\,k}}{\frac{1}{\alpha_{3in}} + \frac{\delta_1}{\lambda_1} + \frac{\delta_2}{\lambda_2} + \frac{\delta_3}{\lambda_3} + \frac{\delta_{izol3}}{\lambda_{izol3}} + \frac{1}{\alpha_{3ext}}} \left[\frac{\mathrm{W}}{\mathrm{m}^2}\right] \tag{4.19}$$

$$q_{4k}(g, K_{s1}) = K_{s1} \cdot (\theta_{in} - \theta_{ext\,k}) + G_k \cdot \mathrm{g} \left[\frac{\mathrm{W}}{\mathrm{m}^2}\right] \tag{4.20}$$

$$q_{5k}(K_{s2}) = K_{s2} \cdot (\theta_{in} - \theta_{ext\,k}) \left[\frac{\mathrm{W}}{\mathrm{m}^2}\right] \tag{4.21}$$

unde θ_{in} = temperatura interioară convențională de calcul în perioada de încălzire [ºC]; $\theta_{ext\,k}$ = temperatura exterioară medie lunară în perioada de încălzire prezentată în tabelul 4.2 [ºC]; $\theta_{sol\,k}$ = temperatura solului prezentată în tabelul 4.2 [°C]; α_{1in}, α_{1ext}, α_2, α_{3in}, α_{3ext} = coeficienți de convecție termică [W/(m^2·K)]; δ_1, δ_2, δ_3, δ_4 = grosimile materialelor de construcție în cazul pereților exterior, plăcii peste sol sau plafonului prezentate în figurile 4.1, 4.2 și 4.3 [mm]; λ_1, λ_2, λ_3, λ_4 = conductivitățile termice ale materialelor de construcție în cazul pereților exteriori, plăcii peste sol sau plafonului prezentate în figurile 4.1, 4.2 și 4.3 [W/(m·K)]; δ_{izol1}, δ_{izol2}, δ_{izol3} = grosimile polistirenului expandat, polistirenului extrudat și vatei minerale [mm]; λ_{izol1}, λ_{izol2}, λ_{izol3} = conductivitățile termice ale polistirenului expandat, polistirenului extrudat și vatei minerale [W/(m·K)]; δ_{1p}, δ_{2p} = adâncimea solului [mm]; λ_{1p}, λ_{2p} = conductivitățile termice ale solului [W/(m·K)]; K_{s1}, K_{s2} = coeficienții globali de schimb de căldură [W/(m^2·K)]; g = coeficienții de transmisie a energiei solare totale [-]; G_k = intensitatea medie lunară a radiației solare prezentată în tabelul 4.2 [W/m^2].

Pentru a calcula $q_{1k}\,(\delta_{izol1},\,\lambda_{izol1})$, $q_{2k}\,(\delta_{izol2},\,\lambda_{izol2})$ și $q_{3k}\,(\delta_{izol3},\,\lambda_{izol3})$, coeficienții de convecție și conductivitatea termică a solului sunt considerate conform tabelului 4.1.

În cadrul modelării sunt considerate mai multe tipuri de geamuri precum geam simplu, geam termoizolant alcătuit din două foi de sticlă float separate printr-un strat compact de aer, geam termoizolant cu o sticlă float și o sticlă cu emisivitatea joasă (low – E) separate fie prin aer, fie prin Argon; geamul termoizolant Patru anotimpuri (4S) format dintr-o foaie de sticlă float și o sticlă 4S separate prin Argon, etc. Sunt studiate de asemenea mai multe tipuri de uși precum: uși de lemn masiv, din metal, din fibre lemnoase cu densitate medie (MDF), din Clorura de polivinil (PVC) și uși din Clorură de polivinil neplastifiată (PVC-U).

4.2.3 Prezentarea algoritmului utilizat

Eșantionarea (*Sampling)* este utilizată pentru a crea populația inițială. În statistică eșantionarea reprezintă selecția unui subset de indivizi dintr-o populație statistică (denumit eșantion) pentru a estima caracteristicile întregii populații. Populația inițială s-a considerat a fi formată din 40 de indivizi. Algoritmul NSGA – II utilizat generează 10 descendenți în fiecare generație. Indivizii sunt sortați în funcție de fronturile Pareto.

Criteriul de oprire al NSGA – II este atins la un număr maxim de 200 de generații. Acest parametru a fost stabilit prin metoda încercărilor succesive, fiind testate mai multe valori. Rezultatele au arătat că valoarea de 200 este adecvată pentru obținerea unui front Pareto optim, cu soluții distribuite aproximativ uniform [64].

În cazul încrucișării, este utilizată *Încrucișarea Binară Simulată* (*Simulated Binary Crossover (SBX))* cu o probabilitate de distribuție egală cu 0,9. Descendenții sunt generați utilizând relația 3.5 prezentată în cadrul subcapitolului 3.1 la pagina 57.

În cazul mutației, este utilizată *Mutația Polinomială* (*Polynomial Mutation*) cu o probabilitate de mutație egală cu 0,111 și un index de distribuție egal cu 20 (η=20).

Tabel 4.3. Valorile coeficienților globali de schimb de căldură

Element		Grosime [mm]	Conductivitate termică [W/(m·K)]	Valorile R, clădire neizolată [(m²·K)/W]	*Valorile K_s, clădire neizolată [W/(m²·K)/]	Valorile R, clădire izolată [(m²·K)/W]	*Valorile K_s, clădire izolată [W/(m²·K)]
Perete exterior	Tencuială	20	0,80	0,025	0,723	0,025	0,249
	Cărămidă	350	0,30	1,166		1,166	
	Tencuială	20	0,80	0,025		0,025	
	Polistiren expandat	100	0,038	–		2,632	
	Beton armat	150	2,03	0,074	0,485	0,074	0,189

Placă peste sol	Șapă	25	0,46	0,054		0,054	
	Folie izolatoare din polietilenă	3	0,05	0,06		0,06	
	Parchet	14	0,13	0,107		0,107	
	Polistiren extrudat	100	0,031	–		3,226	
Plafon	Tencuială	25	0,80	0,031	2,718	0,031	0,178
	Beton armat	150	2,03	0,074		0,074	
	Șapă	25	0,46	0,054		0,054	
	Vată minerală	200	0,038	–		5,263	

*Valorile *Ks* în cazul pereților, plăcii peste sol și plafonului au fost obținute considerând transferul termic prin conducție și convecție și rezistența termică a solului.

În tabelul 4.3 sunt prezentate caracteristicile tehnice ale materialelor de izolație termică rezultate ca fiind optime. Soluția optimă este atinsă atunci când se folosește geam termoizolant tripan cu două foi de sticlă de tip 4S și o foaie de sticlă de tip float, cu spațiul dintre ele umplut cu Argon. Aceste geamuri au un coeficient global de schimb de căldură de 0,6 W/(m^2·K) și coeficientul de transmisie a energiei solare totale de 0,4. În cazul ușilor, NSGA -II a ales uși din stejar stratificat acoperite cu oțel inoxidabil, cu un coeficient global de schimb de căldură de 0,7 W/(m^2·K). În tabelul 4.3 este realizată de asemenea o comparație între coeficienții globali de schimb de căldură în cazul clădirii neizolate și în cazul clădirii izolate termic.

Figura 4.9 arată îmbunătățirile valorilor necesarului de energie pentru încălzire în timpul rulării NSGA – II.

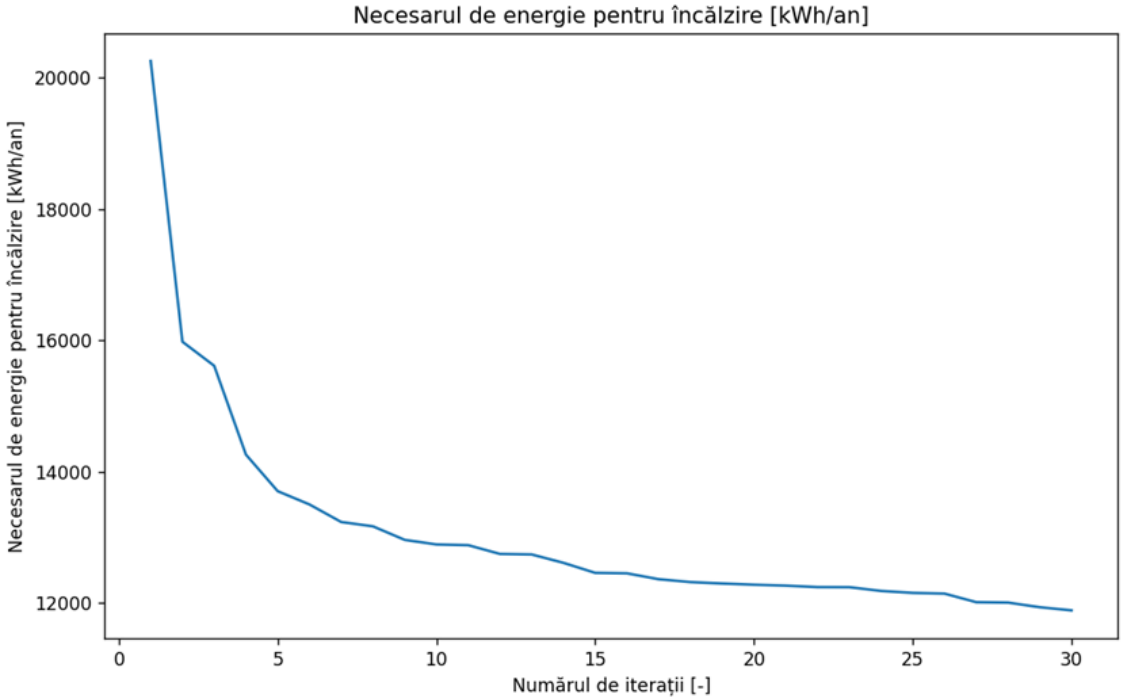


Figura 4.9. Necesarul de energie pentru încălzire [kWh/an]

Se observă că valoarea optimă a necesarului de energie pentru încălzire în cazul clădirii izolate termic este de 12486,16 kWh/an. Raportată la suprafața utilă a locuinței, această valoare este egală cu 96,05 kWh/m^2/an. Prin utilizarea polistirenului expandat, a polistirenului extrudat și a vatei minerale cu caracteristicile termice prezentate în tabelul 4.3 și prin utilizarea ferestrelor termoizolante tripan cu valoarea K_{s1} de 0.6 W/(m^2·K) și a ușilor cu un coeficient global de schimb de căldură de 0,7 W/(m^2·K), valoarea necesarului de energie pentru încălzire este redusă cu aproximativ 75% comparativ cu valoarea obținută în cazul clădirii neizolate termic.

4.3 STUDIU DE CAZ 3 – Optimizarea simultană a energiei necesare pentru încălzire și răcire utilizând NSGA – II

Un Algoritm Genetic de Sortare Nedominant II dezvoltat utilizând librăria Pymoo caută soluțiile optime în vederea minimizării simultane a necesarelor de energie pentru încălzie și răcire. Algoritmul este aplicat în cazul aceleași clădirii izolate termic prezentată anterior, cu scopul de a identifica automat cele mai bune materiale de izolație și elemente de contrucție, ținând cont totodată și de anumite restricțiile de preț. Date suplimentare necesare definirii problemei multiple de optimizare față de cele prezentate în subcapitolul 4.2 sunt: temperatura interioară convențională de calcul în sezonul de răcire și durata perioadei de răcire. În cadrul modelării se utilizează o temperatură interioară convențională de calcul de 25°C pe perioada de răcire [79]. În cadrul modelării se consideră o temperatură de echilibru de 17,1°C, iar durata sezonului de răcire este formată din: 360 ore în luna mai, 720 ore în luna iunie, 744 ore în iulie și august și 192 ore în luna septembrie.

Necesarul de energie pentru răcire înainte de izolarea termică a clădirii este de 73,855 kWh/m^2/an. Proprietățile termice ale materialelor de construcție sunt cele utilizate în cadrul celui de-al doilea studiu de caz.

Spre deosebire de problema anterioară de optimizare, *n_obj* = 2 (numărul de obiective). Sunt definite două funcții obiectiv cu cinci ecuații aferente constrângerilor legate de preț. Prima funcție obiectiv, minimizarea funcției necesarului de energie pentru încălzire, este definită utilizând relația 4.1 prezentată anterior. A doua funcție obiectiv, minimizarea funcției necesarului de energie pentru răcire, este definită prin relația 4.22. Cele cinci constrângeri legate de preț, limita inferioară (x_l) și limita superioară (x_u) în cazul variabilelor sunt cele definite în cadrul celui de-al doilea studiu de caz prin relațiile 4.2 – 4.15.

$$min\, Q_{răcire\ m}\left(\delta_{izol1}, \lambda_{izol1,}\delta_{izol2}, \lambda_{izol2,}\delta_{izol3}, \lambda_{izol3,}K_{s1}, g, K_{s2}\right) = \sum_m h_m \cdot \left[\Delta T_m \cdot H_V + q_{1m}(\delta_{izol1}, \lambda_{izol1}) \cdot (A_1 + A_2 + A_3 + A_4) + q_{2m}\left(\lambda_{izol2,}\delta_{izol2}\right) \cdot A_5 + q_{3m}\left(\lambda_{izol3,}\delta_{izol3}\right) \cdot A_6 + q_{4m}(g, K_{s1}) \cdot A_7 + q_{5m}(K_{s2}) \cdot A_8\right] \quad [\text{kWh/an}] \tag{4.22}$$

unde m = mai, iunie, iulie, august, septembrie; $Q_{răcire}$ = necesar de energie pentru răcire [kWh/an]; h_m = durata sezonului de răcire [h]; H_V = coeficient de pierderi de căldură prin ventilare [W/K]; ΔT_m = diferența de temperatură în perioada de răcire [ºC]; δ_{izol1}, δ_{izol2}, δ_{izol3} = grosimile polistirenului expandat, extrudat și vatei minerale [mm]; λ_{izol1}, λ_{izol2}, λ_{izol3} = conductivitățile termice ale polistirenului expandat, extrudat și vatei minerale [W/(m·K)]; K_{s1}, K_{s2} = coeficienții globali de schimb de căldură în cazul ușilor și ferestrelor; [W/(m^2·K)]; g = coeficienții de transmisie a energiei solare totale [–]; A_1, A_2, A_3, A_4, A_5, A_6, A_7, A_8 = ariile elementelor de construcție (perete vestic, estic, nordic, suprafața nevitrată a peretelui sudic, placă peste sol, plafon, ferestre și uși) [m^2]; q_{1k} (δ_{izol1}, λ_{izol1}), q_{2k} (δ_{izol2}, λ_{izol2}), q_{3k} (δ_{izol3}, λ_{izol3}), q_{4k} (g, K_{s1}), q_{5k} (K_{s2}) = fluxurile termice unitare prin pereți, placă peste sol, plafon, ferestre și uși [W/m^2].

Rezultatul NSGA – II arată că un necesar minim de energie pentru încălzire și un necesar minim de energie pentru răcire pot fi obținute simultan luând în considerare și restricțiile de preț, dacă se utilizează:

- polistiren expandat cu o conductivitate de 0,038 W/(m·K) și o grosime de 100 mm;
- polistiren extrudat cu o conductivitate termică de 0,031 W/(m·K) și o grosime de 100 mm;
- vată minerală cu o conductivitate de 0,038 W/(m·K) și o grosime de 200 mm;
- geam termoizolant tripan cu două foi de sticlă de tip 4S și o foaie de sticlă de tip float, cu spațiul dintre ele umplut cu Argon cu un coeficient global de schimb de căldură de 0,6 W/(m^2·K) și coeficientul de transmisie a energiei solare totale de 0,4;
- uși din stejar stratificat acoperite cu oțel inoxidabil, cu un coeficient global de schimb de căldură de 0,7 W/(m^2· K).

În figurile 4.10 și 4.11 este reprezentată variația necesarului de energie pentru încălzire și a necesarului de energie pentru răcire în timpul rulării NSGA – II, reprezentându-se grafic numai iterațiile unde aceste necesare au o valoare mai mică decât valorile obținute la iterațiile precedente. Se observă că valorile optime ale necesarelor de energie sunt egale cu 12486,16 kWh/an, respectiv 2802,28 kWh/an. Consumul specific de energie pentru încălzire optim este de 96,05 kWh/m^2/an, iar cel pentru răcire are valoarea de 21,56 kWh/m^2/an.

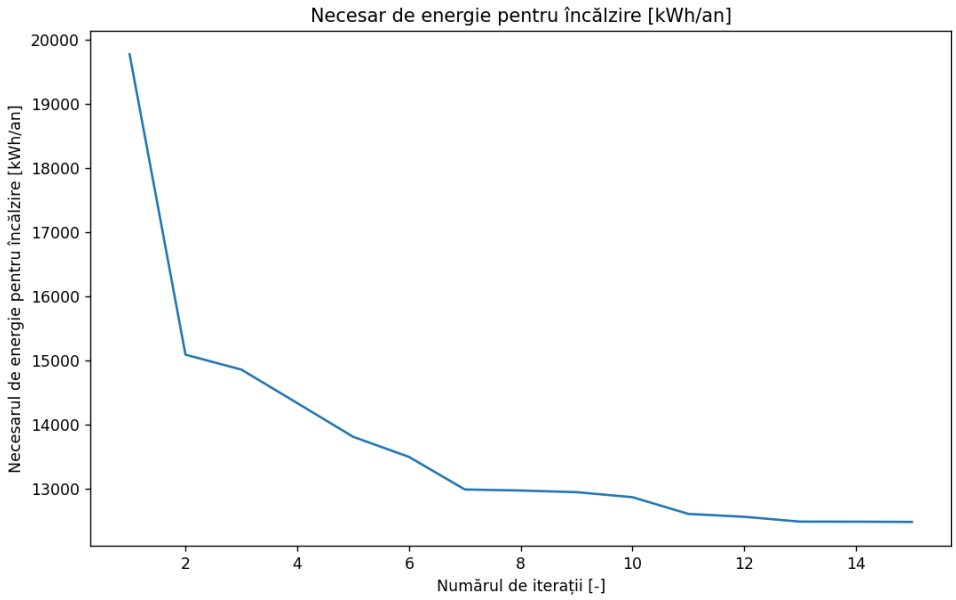


Figura 4.10. Variația necesarului de energie pentru încălzire [kWh/an]

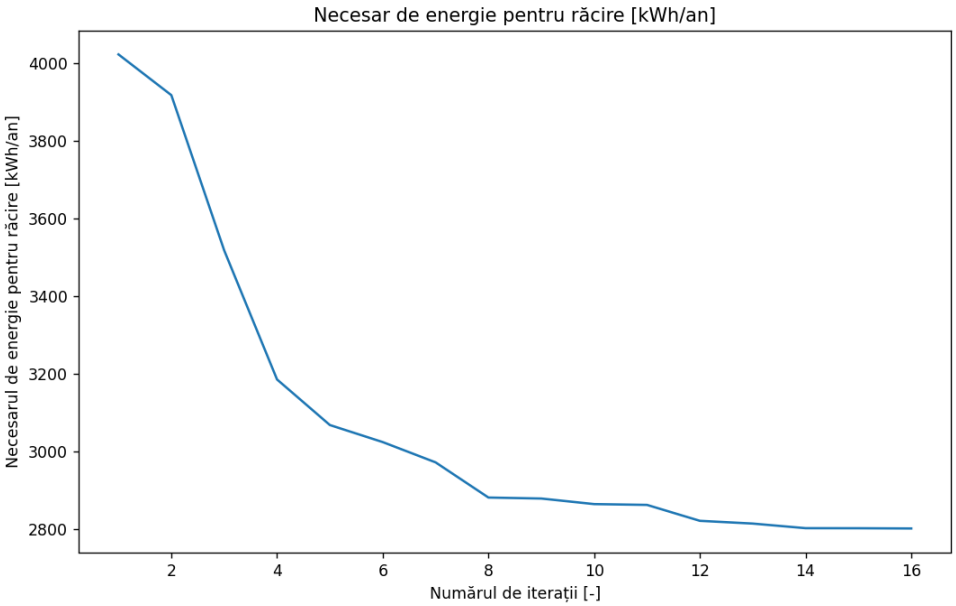


Figura 4.11. Variația necesarului de energie pentru răcire [kWh/an]

Necesarele de energie pentru încălzire și răcire astfel determinate țin cont de aceleași pierderi și aporturi de căldură menționate în cadrul celui de-al doilea studiu de caz. Valorile necesarului de energie pentru încălzire și a necesarului de energie pentru răcire sunt reduse cu aproximativ 75%, respectiv 71% (comparativ cu valorile acestor necesare de energie obținute în cazul clădirii neizolate termic) prin izolarea clădirii și prin înlocuirea ferestrelor și ușilor cu elementele de tâmplărie cu caracteristici tehnice superioare prezentate în acest capitol.

CAPITOLUL 5
PREZENTAREA SISTEMULUI HIBRID UTILIZAT PENTRU ACOPERIREA NECESARULUI DE ENERGIE TERMICĂ

În continuare este prezentat un studiu complex privind integrarea pompelor de căldură în procesul de reabilitare energetică a clădirilor rezidențiale existente. Acest studiu presupune alegerea sistemelor energetice optime în vederea acoperirii necesarului de energie pentru încălzire și pentru prepararea apei calde de consum, după cum urmează:

- alegerea pompelor de căldură de tip aer – apă adecvate criteriilor tehnice și economice stabilite în cadrul subcapitolului 5.2; aceste pompe sunt comparate în Python V3.11;
- verificarea aplicabilității practice a rezultatelor modelului matematic din Python, cu ajutorul software-ului GeoT*SOL;
- alegerea unui sistem hibrid format din pompa de căldură, panouri solare termice și panouri fotovoltaice, punându-se accent pe importanța utilizării acestuia din punct de vedere al reducerii dependenței de combustibilii fosili în clădirile rezidențiale din România.

5.1 DETERMINAREA NECESARULUI DE ENERGIE PENTRU PREPARAREA APEI CALDE DE CONSUM

Necesarul de energie pentru prepararea apei calde de consum (Q_{acm}) este calculat utilizând relațiile (5.1) – (5.5) [72].

$$Q_{acm} = Q_{ac} + Q_{ac,c}\ [\text{kWh/an}] \tag{5.1}$$

$$Q_{ac} = \sum_{i=1}^{n} \rho \cdot c_{apă} \cdot V_{ac} \cdot (\theta_{ac} - \theta_{ar})\ [\text{kWh/an}] \tag{5.2}$$

$$V_{ac} = \frac{a \cdot N_u}{1000}\ [\text{m}^3] \tag{5.3}$$

$$Q_{ac,c} = \sum \rho \cdot c_{apă} \cdot V_{ac,c} \cdot \left(\theta_{ac,c} - \theta_{ar}\right)\ [\text{kWh/an}] \tag{5.4}$$

$$V_{ac,c} = V_{ac} \cdot f_1 \cdot f_2 - V_{ac}\ [\text{m}^3] \tag{5.5}$$

unde Q_{ac} = consumul de energie datorat furnizării la consumator a apei calde [kWh/an]; $Q_{ac,c}$ = pierderea de căldură datorată furnizării la consumator a apei calde la temperatură diferită de temperatura nominală de calcul [kWh/an]; ρ = 983,2 [kg/m^3] = densitatea apei la temperatura de 60°C; $c_{apă}$ = 4,183 [kJ/(kg·K)] = căldura specifică a apei la aceeași temperatură ; V_{ac} = volumul

necesar de apă caldă de consum pe perioada considerată [m^3]; $V_{ac,c}$ = volumul corespunzător pierderilor și risipei de apă caldă pe perioada considerată [m^3]; θ_{ac} = 60 ºC = temperatura apei calde de consum [ºC]; θ_{ar} = 10 ºC = temperatura medie a apei reci care intră în sistemul de preparare a apei calde [ºC]; $\theta_{ac,c}$ = 50 ºC = temperatura de furnizare a apei calde la punctul de consum [˚C]; i = 1, n reprezintă indice de calcul pentru categoriile de consumatori [–]; a = 50 [l/persoană/zi] = necesarul specific de apă caldă de consum pentru o persoană în clădiri de locuit multifamiliale; N_u = 6 [–] = număr de persoane; f_1 = 1,3 [–] = coeficient ce depinde de tipul instalației la care este racordat punctul de consum; f_2 = 1,1 [–] = coeficient ce depinde de starea tehnică a armăturilor la care are loc consumul de apă caldă [72].

Astfel, necesarul de energie pentru prepararea apei calde de consum (Q_{acm}) este: $Q_{acm} = Q_{ac} + Q_{ac,c} = 3238{,}77 + 1114{,}14 = 4352{,}91 \left[\frac{\text{kWh}}{\text{an}}\right]$.

5.2 ALEGEREA POMPELOR DE CĂLDURĂ OPTIME CU AJUTORUL MODELULUI MATEMATIC IMPLEMENTAT ÎN PYTHON

Baza de date utilizată în vederea alegerii pompelor de căldură de tip aer-apă conforme cu criteriile tehnice și economice stabilite este creată utilizând software-ul RETScreen Expert V9.0. Un total de 150 modele de pompe de căldură de la 16 producători diferiți sunt comparate în Python V3.11, ținând cont de criteriile de mai jos.

5.2.1 Prima modelare în care primează criteriul financiar

În cadrul acestei modelări se stabilește un preț maxim ce poate fi alocat pompelor de căldură, iar pompele de căldură care se încadrează în acest preț sunt comparate din punct de vedere al coeficientului de performanță (COP), al sarcinii termice a condensatorului și al numărului de pompe necesar asigurării necesarului de energie pentru încălzire și pentru prepararea apei calde de consum:

- Criteriul 1: $Preț_{pompe} \leq$ 20200 RON și N_{pompe} = 1

unde 20200 RON reprezintă prețul maxim ce poate fi alocat pompelor de căldură. Prețul pompelor de căldură este obținut printr-un studiu de piață.

$$N_{pompe} = \frac{Q_{ctotal}}{Q_{cpompă}} \ [-] \tag{5.6}$$

$$Q_{ctotal} = \frac{Q_{\text{încălzire}} + Q_{acm}}{h_{pompă}} \text{ [kW]} \quad (5.7)$$

unde N_{pompe} = numărul de pompe de căldură selectate pentru a acoperi cea mai mare parte a necesarului de energie pentru încălzire și pentru prepararea apei calde de consum în cazul clădirii studiate [–]; $Q_{cpompă}$ = sarcina termică a condensatorului în cazul fiecărei pompe de căldură studiate [kW]; Q_{ctotal} = 8,42 [kW] reprezintă sarcina termică necesară pentru încălzire și pentru prepararea apei calde de consum în cazul modelării realizate; $Q_{încălzire}$ = necesarul de energie pentru încălzire [kWh/an] (relația 4.1); Q_{acm} = necesarul de energie pentru prepararea apei calde de consum [kWh/an] (relația 5.1); $h_{pompă}$ = 2000 [h/an] reprezintă numărul de ore de funcționare ale pompei de căldură.

Pompele de căldură alese după aplicarea primului criteriu sunt prezentate în tabelul 5.1.

Tabel 5.1. Pompele de căldură alese conform criteriului 1

Producător		Fedders	Luxaire	Shandong
Model		H30BA1	BUA-030	LAWHRPA08
$Q_{cpompă}$	[kW]	8,78	8,47	9,60
$Q_{0pompă}$	[kW]	4,50	5,65	6,40
$P_{pompă}$	[kW]	4,28	2,82	3,20
COP	[–]	2,05	3,00	3,00
$Pret_{pompe}$	[RON]	20158	20040	20000

- Criteriul 2: $COP \geq 3$

$$COP = \frac{|Q_{cpompă}|}{P_{pompă}} = \frac{|Q_{cpompă}|}{|Q_{Cpompă}| - Q_{0pompă}} \text{ [–]} \quad (5.8)$$

unde COP = coeficient de performanță [–]; $Q_{opompă}$ = puterea termică a vaporizatorului [kW]; $P_{pompă}$ = puterea consumată pentru antrenarea compresorului în cazul fiecărei pompe studiate [kW].

Coeficientul de performanță al pompei de căldură depinde de mai mulți factori, dintre care cei mai relevanți sunt temperatura agentului termic la consumator, dimensionarea corectă a sistemului, pierderile de presiune în circuitele de agent termic și eficiența componentelor auxiliare, cum ar fi pompele de circulație sau ventilatoarele. În cazul pompelor de tip aer-apă, performanța acestora depinde de umiditatea și de temperatura aerului exterior, care constituie sursa de căldură [80]. La temperaturi exterioare ridicate, diferența dintre sursa de căldură și agentul termic scade, reducând efortul compresorului și crescând COP-ul. În condiții de temperaturi scăzute, diferența de

temperatură crește, ceea ce determină un consum mai mare de energie și, implicit, o scădere a COP-ului [81]. Alte aspecte care influențează COP-ul includ calitatea instalării, izolarea termică a conductelor și caracteristicile termice ale clădirii în care este integrată pompa de căldură [82].

În cadrul acestei modelări s-a optat pentru un echipament cu COP mai mare sau egal cu 3, luând în considerare specificațiile producătorilor. Această valoare reprezintă un compromis optim între eficiența energetică și costul investițional. Acest echipament asigură în condiții tipice de operare menținerea unei performanțe energetice ridicate pe întreaga durată a sezonului rece, precum și o operare stabilă și fiabilă în intervalul de temperaturi anticipate.

Conform modelării, pompele de căldură selectate în urma criteriului 1 care îndeplinesc și cel de-al doilea criteriu sunt: pompa de căldură de la producătorul Luxaire, model BUA-030 și cea de la Shandong, model LAWHRPA08. Caracteristicile acestor pompe de căldură sunt prezentate în tabelul 5.1.

- Criteriul 3: $8{,}42 \leq Q_{cpompă} \leq 9$

Pompa de căldură de la Luxaire, prezentată în tabelul 5.1 satisface și cea de-al treilea criteriu. Conform primei modelări, aceasta este pompa de căldură optimă atât din punct de vedere tehnic cât și din punct de vedere financiar.

5.2.2 Cea de-a doua modelare în care primează criteriile tehnice

În cadrul acestei modelări pompele de căldură sunt comparate pe baza caracteristicilor tehnice prezentate la modelarea 1 și apoi se verifică dacă pompele selectate respectă limita maximă de preț impusă.

- Criteriul 1: $N_{pompe} = 1$ și $COP \geq 3$

După aplicarea acestui criteriu, algoritmul selectează un număr de 16 pompe de căldură.

- Criteriul 2: $8{,}42 \leq Q_{cpompă} \leq 9$

Rezultatul modelării arată că pompele de căldură de tip aer – apă cu specificațiile prezentate în figura 5.2 trebuie să fie instalate pentru a asigura sarcina termică de 9 kW necesară pentru încălzire și pentru prepararea apei calde în perioada de încălzire în cazul clădirii studiate, conform criteriilor tehnice.

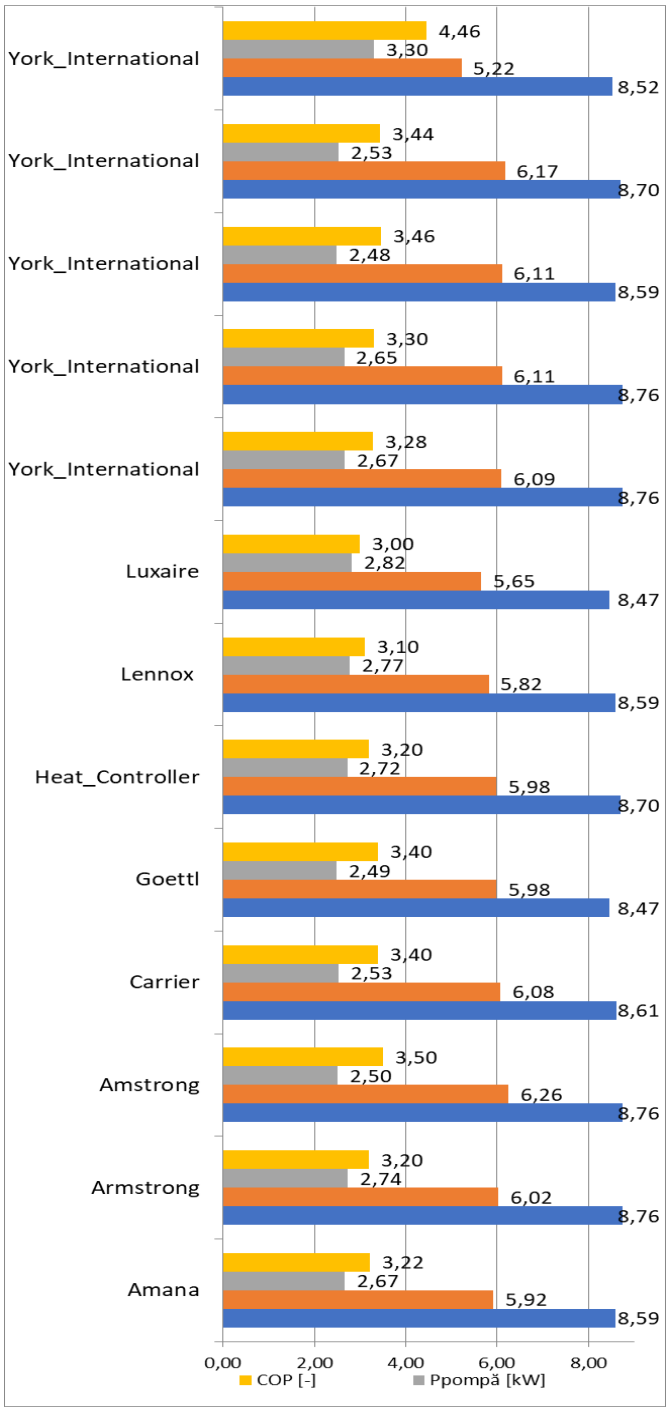


Figura 5.1. Pompele de căldură alese în cadrul modelăriii în conformitate cu caracteristicile tehnice

Cel de-al treilea criteriu aplicat este cel financiar. După aplicarea acestuia, pompa de căldură rămasă este o pompă produsă de Luxaire, model BUA-030, cu o sarcină termică a condensatorului de 8,42 kW, cu o putere termică a vaporizatorului de 5,65 kW și un COP egal cu 3.

Conform celor două modele matematice implementate în Python, această pompa de căldură este cea care îndeplinește cel mai bine criteriile tehnice și financiare impuse.

5.3 VERIFICAREA APLICABILITĂȚII PRACTICE A REZULTATELOR MODELULUI MATEMATIC

În cadrul acestui subcapitol se verifică aplicabilitatea practică a rezultatelor modelului matematic din Python, cu ajutorul software-ului GeoT*SOL. Acesta este un software licențiat, dezvoltat de compania Valentin Software, destinat modelării dinamice a pompelor de căldură cu sursă termică aerul, apa sau solul, inclusiv a sistemelor hibride formate din atât din pompe de căldură, cât și din panouri solare și/sau panouri fotovoltaice [83]. GeoT*SOL utilizează propria sa hartă climatică, MeteoSyn, derivată din baza de date Meteonorm 8.2 [84].

După selectarea zonei climaterice, se alege tipul de pompă de căldură utilizat. Astfel, din baza de date a software-ului se selectează o pompă de căldură cu sursă termică aerul. Următorul pas în cadrul acestei simulări este introducerea datelor precum suprafața utilă a clădirii studiate și necesarul de energie pentru încălzire. Acesta a fost determinat în cadrul subcapitolului 4.2.4 și este egal cu 12486,16 kWh/an. Alte date de intrare definite sunt temperatura interioară și temperatura exterioară convențională de calcul. Conform literaturii de specialitate, temperatura interioară este considerată a fi egală cu 20˚C iar cea exterioară cu - 15˚C [72].

În vederea simulării necesarului de energie pentru prepararea apei calde de consum, se consideră că o persoană consumă 50 [l//zi] de apă caldă [72]. De asemenea, se presupune că în această clădire locuiesc șase persoane.

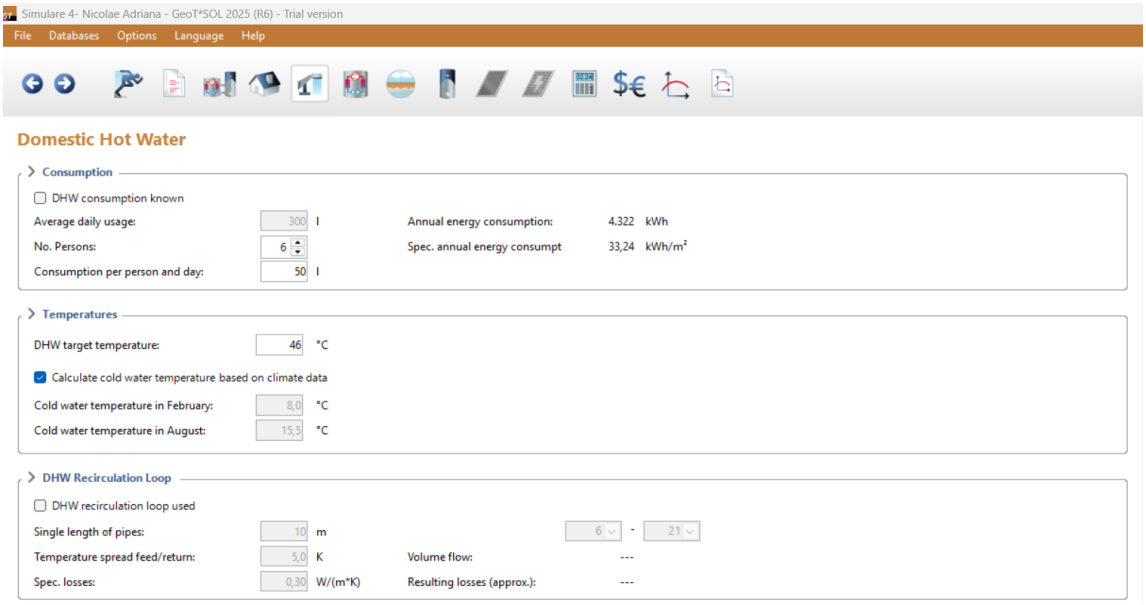


Figura 5.2. Necesarul de energie pentru prepararea apei calde de consum în simularea GeoT*SOL

În figura 5.2 se poate observa ca necesarul de energie astfel determinat are o valoare apropiată de necesarul de energie determinat cu modelul matematic prezentat în Metodologia MC001 (relația 5.1) [72]. Diferența dintre cele două valori este de 30,91 kWh/an.

Următorul pas în cadrul simulării este alegerea caracteristicilor tehnice ale pompei de căldură din baza de date a software-ului GeoT*SOL. Se dorește ca aceste caracteristici să fie similare cu cele ale pompei de căldura aleasă cu ajutorul modelului matematic dezvoltat în Pyton (subcapitolul 5.2.3). Astfel se alege o pompă Schuco International KG, model HPSol11, cu COP = 3,1 și o putere nominală de 8,8 kW. Conform rezultatelor simulării, Factor de performanță sezonier (SPF) al pompei de căldură de tip aer- apă simulată are valoarea 2,73. Valoarea obținută este relativ mică pentru standardele actuale, unde SPF mai mare sau egal cu 3 este considerat acceptabil, iar sisteme performante ajung la SPF egal cu 4. În figura 5.3 sunt prezentate rezultatele simulării dinamice realizate în software-ul GeoT*SOL. Conform acestora, pompa de căldură aleasă produce 16921 kW pe perioada sezonului de încălzire și acoperă în totalitate necesarul de energie termică. Energia termică generată este preponderent utilizată pentru încălzirea spațiului (75%). Energie electrică consumată de pompa de căldură are valoarea 6189 kWh/sezon.

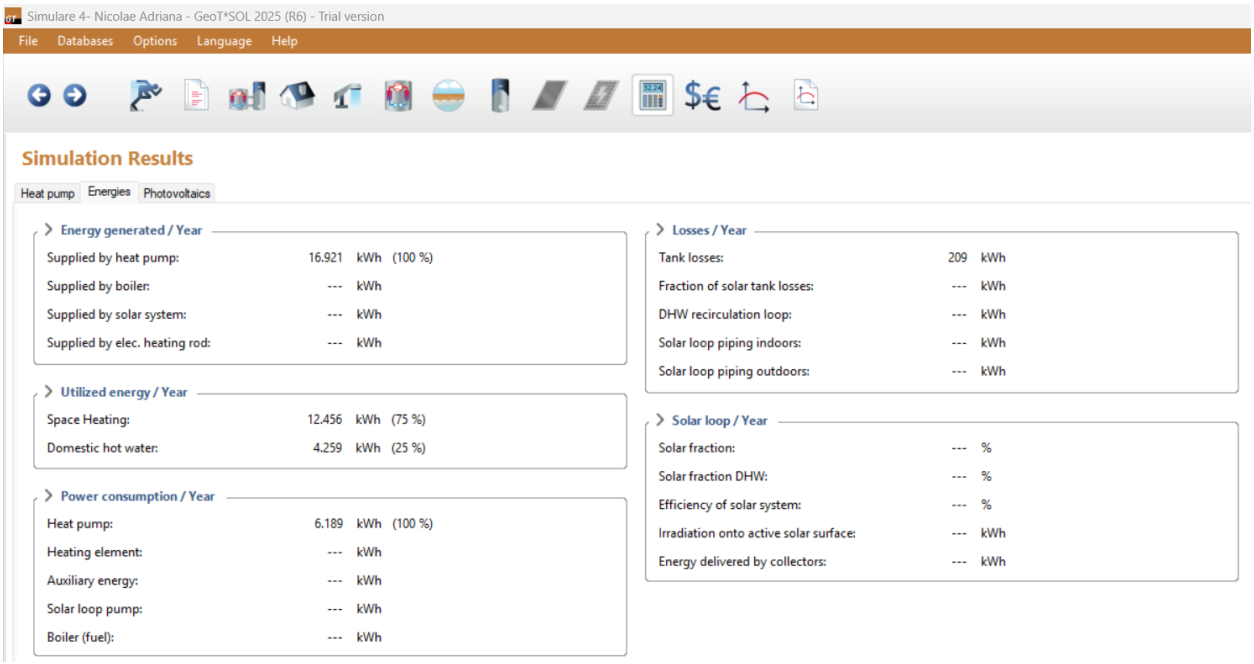


Figura 5.3. Energie termică generată cu ajutorul pompei de căldură

Rezultatele acestei simulări dinamice evidențiază aplicabilitatea practică a rezultatelor modelului matematic din Python, deoarece pompa de căldură determinată cu acest model are

capacitatea de a acoperi întregul necesar de energie termică, nefiind supradimensionată. Acest sistem poate fi însă îmbunătățit, deoarece are SPF relativ mic, ceea ce se traduce printr-un randament global al instalației mai slab și costuri de exploatare mai mari.

5.4 SIMULAREA UNUI SISTEM HIBRID FORMAT DIN POMPĂ DE CĂLDURĂ, PANOURI SOLARE TERMICE ȘI PANOURI FOTOVOLTAICE

În vederea îmbunătățirii randamentului global al sistemului simulat anterior, în cadrul software-ului GeoT*SOL se simulează un sistem hibrid format din pompa de căldură, panouri solare termice și panouri fotovoltaice. În cadrul acestei analize se consideră că sistemul este alcătuit din 5 panouri solare termice alese de la producătorul Schulte GmbH, model SFK 2300, cu o suprafață totală de 10,61 m^2 și 20 de panouri fotovoltaice cu o suprafață totală de 32,6 m^2. Aceste panouri pot fi vizualizate în figura 5.4.

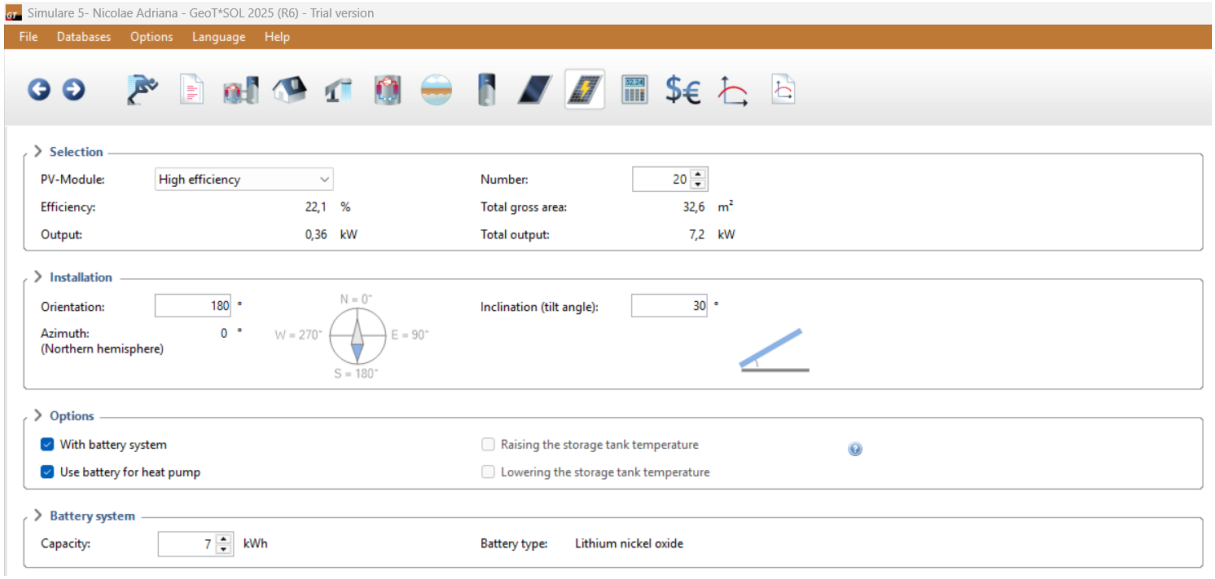


Figura 5.4. Panourile fotovoltaice utilizate în cadrul simulării

Rezultatele simulării arată o îmbunătățire semnificativă a valorii factorului SPF al sistemului, acesta având valoarea 3,59. În figura 5.5 sunt prezentate de asemenea rezultatele simulării dinamice pe partea de energie. În această figură se poate observa cantitatea de energie termică produsă de fiecare dintre elementele sistemului. De exemplu pompa de căldură asigură acum 79% din necesarul de energie termică pe perioada sezonului de încălzire (13420 kWh), iar panourile solare termice acoperă restul necesarului de 21% (3462 kWh). Cel mai mare consum de energie

electrică îl au pompele de căldură. Acesta este de 4594 kWh în sezonul de încălzire. Consumul panourilor solare termice este estimat la 110 kWh în același sezon.

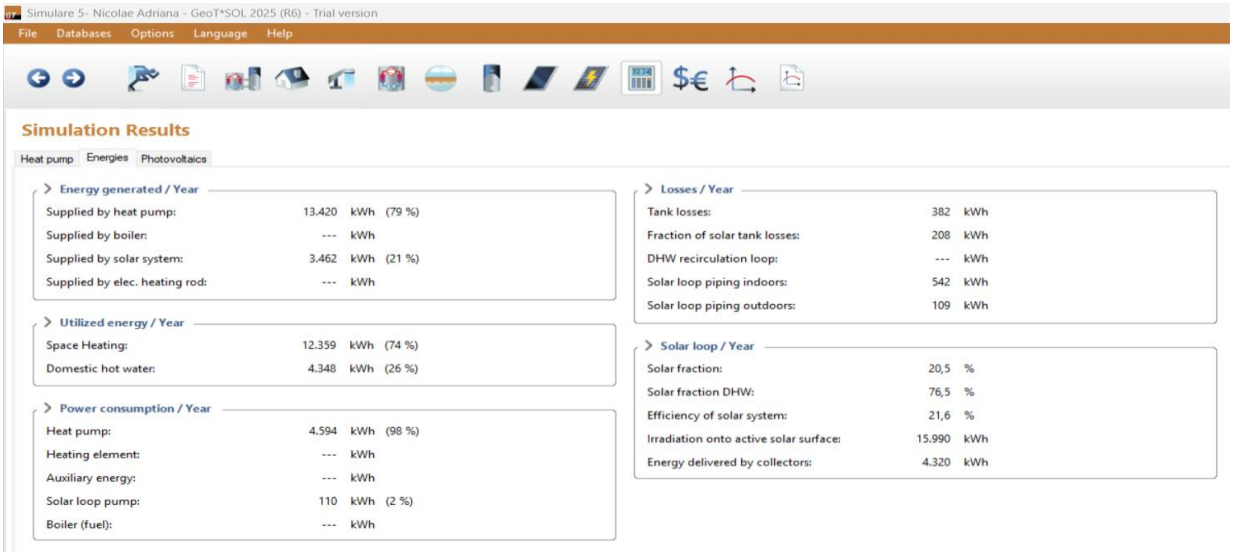


Figura 5.5. Energia termică generată cu ajutorul sistemului hibrid

De asemenea, panourile fotovoltaice instalate produc 10291 kWh, dintre care 51,5% sunt utilizați pentru consumul propriu al sistemului și 49,9% reprezintă surplus de energie electrică și este injectat în rețea. Acest lucru are un impact pozitiv în ceea ce privește economiile realizate cu facturile de energie electrică.

În concluzie, pe lângă avantajul financiar (diminuarea valorii facturii la energia electrică), sistemul hibrid utilizat subliniază importanța trecerii de la sisteme energetice bazate pe combustibili fosili puri la alternative hibride ecologice, aliniindu-ne în acest fel obiectivelor naționale asumate, chiar dacă există limitări tehnologice (de exemplu spațiul necesar pentru instalare) și constrângeri financiare (costurile inițiale mari).

COCLUZII

Acest capitol sintetizează principalele rezultate obținute în cadrul tezei de doctorat, evidențiind contribuțiile originale ale autorului și direcțiile de cercetare ce rezultă din studiul efectuat până în prezent. Lucrarea este structurată în cinci capitole, fiecare abordând un subiect de interes în domeniul eficienței energetice a clădirilor.

CONCLUZII GENERALE

CAPITOLUL 1 examinează în detaliu modul în care clădirile influențează consumul de energie, luând în considerare atât perspectivele la nivel european, cât și situația națională. În plus, sunt prezentate argumentele care au stat la baza elaborării tezei de doctorat, printr-o evaluare aprofundată a consumului energetic în sectorul clădirilor. Din statisticile prezentate, cel mai important aspect este acela că sectorul clădirilor este a doilea sector dominant din punct de vedere al distribuției consumului final de energie în UE, după sectorul transporturilor. Cea mai mare parte a consumului energetic din sectorul clădirilor în Uniunea Europeană este asociată încălzirii spațiilor (62,5%), urmată de încălzirea apei (15,1%). Gazul natural este cel care furnizează aproape o treime din energie utilizată în clădiri (29,5%), urmat de electricitate (25,9%) și de sursele regenerabile (23,5%). Restul consumului este acoperit de produsele petroliere (10,3%), căldura rezultată prin ardere (8,5%) și cărbune (2,2%). Mai mult, sectorul clădirilor este responsabil în prezent pentru o pondere majoră a emisiilor de dioxid de carbon de aproximativ 26% din totalul emisiilor de acest tip din sectorul energetic, 8% reprezentând emisii directe și 18% fiind emisii indirecte rezultate din producerea energiei electrice și termice utilizate în clădiri. Aceste statistici subliniază necesitatea adoptării unor acțiuni prompte menite să reducă impactul energetic al clădirilor asupra consumului de energie și asupra emisiilor GHG din întreaga UE. Din acest motiv, cercetările se concentrează continuu pe dezvoltarea și aplicarea unor noi metode de îmbunătățire a eficienței energetice a clădirilor existente.

CAPITOLUL 2 prezintă o cercetare amplă privind aplicațiile a șapte algoritmi de optimizare în sectorul clădirilor, în literatura de specialitate. Cel mai important aspect în cadrul acestui capitol este comparația amplă între aceștia, cu menționarea principalelor avantaje și dezavantaje. Comparativ cu ACO, care este specializat în probleme combinatoriale, GA oferă o aplicabilitate mai largă, fiind capabil să gestioneze probleme cu reprezentări complexe și variabile mixte. Comparativ cu CSA și MRFO, GA are o capacitate excelentă de explorare. Algoritmul PSO poate rezolva probleme complexe de optimizare cu o eficiență ridicată, fiind ideal pentru probleme

continue de optimizare și în special pentru probleme de dimensiuni mari. Acest algoritm este cunoscut pentru simplitatea și ușurința sa de implementare, are o acuratețe de predicție ridicată și are un timp de convergență mai scurt decât GA. Performanțele PSO nu sunt foarte sensibile la dimensiunea populației, fiind suficient ca numărul de particule să nu fie prea mic. În plus, mecanismul prin care PSO actualizează viteza și poziția particulelor îi conferă o capacitate ridicată de a evita blocarea prematură în minime locale. Studiile arată că ACO converge mai repede către soluția optimă comparativ cu algoritmul PSO. Performanța CSA este mai mare decât performanța algoritmilor PSO și GA, algoritmul CSA având o eficiență ridicată în problemele de optimizare. Acest algoritm este ușor de implementat și este mai fezabil decât GA sau PSO. Viteza de convergență a algoritmului CSA către soluția optimă este de 2 până la 7 ori mare decât viteza de convergență a algoritmilor ACO și PSO.

CAPITOLUL 3 descrie mecanismele funcționale a doi dintre acești algoritmi și anume Algoritmul Genetic simplu și Algoritmul Genetic de Sortare Nedominant II. Sunt prezentate metodele de selecție, încrucișare și mutație aplicabile în cazul acestor algoritmi. Algoritmul NSGA – II este asemănător cu Algoritmul Genetic (GA), însă diferă prin modul de selecție al părinților, deoarece NSGA - II utilizează sortarea nedominată și sortarea pe baza distanței de aglomerare. Distanța de aglomerare reprezintă un criteriu de selecție a indivizilor ce aparțin aceluiași front nedominant pe baza distanței Euclidiene dintre indivizii vecini din spațiul de căutare. Aceasta este folosită pentru păstrarea diversității în cadrul aceluiași front.

CAPITOLUL 4 prezintă trei studii de caz, fiecare descriind câte un model de optimizare ce poate fi aplicat în analiza strategiilor de optimizare energetică a consumului de energie din clădiri. Primul studiul de caz presupune optimizarea fluxului termic unitar transmis prin peretele izolat termic, prin placa peste sol sau prin plafonul izolat, utilizând un Algoritm Genetic simplu. Polistirenul expandat care îndeplinește condiția de obținere a unui flux termic unitar cât mai mic, este acela cu conductivitate de 0,0365 W/(m·K) și grosime de 149,9 mm. Fluxul termic unitar optim transmis prin perete are valoarea 6,378 W/m2. Fluxul termic unitar optim prin placa peste sol izolată termic are valoarea de 1,961 W/m². Acesta se obține prin utilizarea polistirenului extrudat cu conductivitatea termică de 0,031 W/(m·K) și o grosime de 94,115 mm. Vata minerală care conduce la obținerea celui mai redus flux termic unitar are conductivitatea termică de 0,034 W/(m·K) și grosimea de 199,98 mm. În aceste condiții, fluxul termic unitar optim atinge valoarea de 5,599 W/m².

Al doilea studiu de caz propune o metodă de a identifica configurația optimă a anvelopei termice a unei clădiri rezidențiale ce va asigura necesarul minim de energie pentru încălzire, luând în considerare și restricțiile de preț obținute printr-un studiu de piață specific. Prin utilizarea polistirenului expandat, a polistirenului extrudat și a vatei minerale cu caracteristicile termice superioare prezentate în cadrul acestui capitol și prin utilizarea ferestrelor termoizolante tripan cu valoarea Ks1 de 0.6 W/(m2·K) și a ușilor cu un coeficient global de schimb de căldură de 0,7 W/(m2·K), valoarea necesarului de energie pentru încălzire este redusă cu aproximativ 75% comparativ cu valoarea obținută în cazul clădirii neizolate termic.

Cel de-al treilea studiu de caz analizează o problemă multiplă de optimizare: minimizarea simultană a energiei necesare pentru încălzirea și răcirea habitatului interior, ținând cont de anumite restricții de preț. Valorile optime ale necesarelor de energie sunt egale cu 12486,16 kWh/an, respectiv 2802,28 kWh/an. Consumul specific de energie pentru încălzire optim este de 96,05 kWh/m2/an, iar cel pentru răcire are valoarea de 21,56 kWh/m2/an. Valorile necesarului de energie pentru încălzire și a necesarului de energie pentru răcire sunt reduse cu aproximativ 75%, respectiv 71% (comparativ cu valorile acestor necesare de energie obținute în cazul clădirii neizolate termic) prin izolarea clădirii și prin înlocuirea ferestrelor și ușilor cu elementele de tâmplărie cu caracteristici tehnice superioare prezentate în acest capitol.

CAPITOLUL 5 este împărțit în patru subcapitole. În primul subcapitol este calculat necesarul de energie pentru prepararea apei calde de consum.

În cadrul celui de-al doilea subcapitol este prezentat modelul matematic implementat în Python în vederea alegerii pompelor de căldură de tip aer – apă adecvate criteriilor tehnice și economice stabilite. Pompa de căldură astfel aleasă este o pompă produsă de Luxaire, model BUA-030, cu o sarcină termică a condensatorului de 8,42 kW, cu o putere termică a vaporizatorului de 5,65 kW și un COP egal cu 3.

În cadrul celui de-al treilea subcapitol este analizată aplicabilitatea practică a rezultatelor modelului matematic din Python, prin intermediul simulării dinamice realizate cu software-ul GeoT*SOL. Rezultatele obținute confirmă că pompa de căldură determinată cu acest model are capacitatea de a acoperi integral necesarul de energie termică, nefiind supradimensionată. Totuși, sistemul prezintă un potențial de optimizare, deoarece coeficientul SPF obținut este relativ redus, ceea ce implică un randament global scăzut al instalației și, implicit, costuri de exploatare mai ridicate.

În vederea îmbunătățirii randamentului global al sistemului simulat anterior, în cadrul software-ului GeoT*SOL se simulează un sistem hibrid format din pompa de căldură, panouri solare termice și panouri fotovoltaice. În cadrul acestei analize se consideră că sistemul este alcătuit din 5 panouri solare termice cu o suprafață totală de 10,61 m^2 și din 20 de panouri fotovoltaice cu o suprafață totală de 32,6 m^2. Conform rezultatelor simulării, panourile fotovoltaice instalate produc 10291 kWh, dintre care 51,5% sunt utilizați pentru consumul propriu al sistemului și 49,9% reprezintă surplus de energie electrică și este injectat în rețea. Acest lucru are un impact pozitiv în ceea ce privește economiile realizate cu facturile de energie electrică.

În concluzie, pe lângă avantajul financiar (diminuarea valorii facturii la energia electrică), sistemul hibrid utilizat subliniază importanța trecerii de la sisteme energetice bazate pe combustibili fosili puri la alternative hibride ecologice, aliniindu-ne în acest fel obiectivelor naționale asumate, chiar dacă există limitări tehnologice (de exemplu spațiul necesar pentru instalare) și constrângeri financiare (costurile inițiale mari).

CONTRIBUȚII ORIGINALE

Teza de doctorat își are punctul de plecare în construirea unei baze teoretice menite să susțină demersurile de îmbunătățire a eficienței energetice în sectorul clădirilor. În acest cadru, autorul a întreprins o cercetare complexă asupra modului în care clădirile influențează consumul de energie la nivel național și european, urmată de un amplu studiu privind aplicațiile practice a șapte algoritmi de optimizare în sectorul clădirilor. Doi dintre acești algoritmi, Algoritmul Genetic simplu și Algoritmul Genetic de Sortare Nedominant II sunt prezentați în detaliu, descriindu-se întregul lor mecanism funcțional. Fiecare dintre capitole oferă fundamente conceptuale necesare pentru înțelegerea și justificarea metodelor aplicate în analizele realizate.

Autorul a gândit şi dezvoltat trei Algoritmi Genetici simpli de optimizare a fluxului termic unitar transmis prin peretele izolat termic, prin placa peste sol sau prin plafonul izolat.

De asemenea, au fost dezvoltați alți doi Algoritmi Genetici de Sortare Nedominanți II, unul în vederea optimizării necesarului de energie pentru încălzire, celălalt în vederea minimizării simultane a energiei necesare pentru încălzirea și răcirea habitatului interior, în ambele cazuri luând în considerare și restricțiile de preț obținute printr-un studiu de piață specific. Acești algoritmi au scopul de a găsi soluția optimă într-un spațiu de căutare considerat a fi compus din grosimi și conductivități termice ale materialelor de izolație și/sau proprietăți termice ale ușilor și ferestrelor.

Rezultatele obținute sunt încurajatoare privind aplicabilitatea lor practică atât din punct de vedere eficiență energetică, cât și din punct de vedere economic.

O altă contribuție importantă a prezentei teze de doctorat constă în dezvoltarea unui cadru integrat pentru evaluarea și optimizarea pompelor de căldură în contextul reabilitării energetice a clădirilor rezidențiale existente. Autorul a propus un model matematic dezvoltat în Python, capabil să selecteze echipamentele optime din punct de vedere tehnic și economic pentru acoperirea necesarului de energie atât pentru încălzire, cât și pentru prepararea apei calde de consum pe perioada sezonului rece. Noutatea constă în validarea practică a rezultatelor acestui model matematic prin intermediul unei simulări dinamice realizate cu ajutorul software-ului GeoT*SOL. De asemenea, în vederea îmbunătățirii randamentului global al acestui sistem, s-a realizat o simulare dinamică a unui sistem hibrid format din această pompă de căldură, cinci panouri solare termice și douăzeci de panouri fotovoltaice. Această abordare reprezintă o contribuție originală, oferind un instrument util pentru proiectarea și optimizarea sistemelor eficiente energetic în clădirile rezidențiale.

PERSPECTIVE DE CERCETARE

Teza de doctorat își propune să integreze aspectele esențiale legate de aplicarea algoritmilor evolutivi în procesul de optimizare a consumului de energie și de creștere a eficienței energetice în clădiri. Autorul a construit un cadru teoretic și practic, care poate constitui o bază solidă pentru dezvoltări și analize ulterioare.

Ca principală direcție de cercetare, autorul propune validarea Algoritmului Genetic de Sortare Nedominant II pe o gamă largă de clădiri, pentru a verifica capacitatea acestuia de a selecta optim soluțiile energetice în contexte variate. În absența unui set complet de date de validare, consumul de energie pentru încălzire estimat de algoritm poate fi comparat cu valorile indicate în Certificatul de Performanță Energetică al clădirii, oferind astfel un criteriu relevant pentru evaluarea corectitudinii și acurateței modelului.

O altă direcție de cercetare constă în alternarea diferitelor proprietățile termice ale materialelor constructive ale pereților, plăcii peste sol și plafonului pentru a reflecta variațiile capacității termice a elementelor de construcție, deoarece aceasta determină modul în care clădirea stochează și eliberează căldură, influențând atât confortul termic, cât și consumul de energie pentru încălzire. Utilizarea unor materiale cu caracteristici constructive diferite permite altfel simularea precisă a comportamentului energetic al clădirii.

O altă perspectivă de cercetare vizează simularea necesarului de energie pentru încălzire și/sau răcire luând în considerare nu numai pierderile de căldură prin infiltrații și transferul de căldură prin transmisie între spațiul încălzit și mediul exterior, ci și inerția termică, aporturile termice provenite de la radiația solară și degajările de căldură interne de la echipamente și locuitori.

Se propune de asemenea dezvoltarea unei baze de date complexe care să includă diferite materiale de izolație termică. Utilizarea, pe lângă materialele tradiționale de izolație menționate în cadrul tezei, a unor soluții moderne cu caracteristici tehnice superioare, care pot contribui la creșterea eficienței energetice a clădirilor.

Un alt punct de interes ar fi îmbunătățirea modelului matematic de selecție al pompelor de căldură, astfel încât acestea să fie capabil să acopere iarna necesarul de energie pentru încălzire și prepararea apei calde de consum și vara, energia termică necesară pentru răcirea spațiului și pentru asigurarea apei calde necesare.

BIBLIOGRAFIE

[1] „Directiva (UE) 2024/1275 a Parlamentului European și a Consiliului din 24 aprilie 2024 privind performanța energetică a clădirilor (reformare),” 2024.

[2] „Eurostat - Departamentul Comisiei Europene responsabil de publicarea unor statistici compatibile pentru tot teritoriul,” Disponibil la: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_statistics_-_an_overview#Final_energy_consumption. [Accesat 7 iulie 2025].

[3] „Agenția Internațională de Energie,” Disponibil la: https://www.iea.org/energy-system/buildings. [Accesat 17 iulie 2025].

[4] Building Performance Institute Europe, „EU Buildings Climate Tracker 3rd edition,” 27 November 2024. Disponibil la: https://www.bpie.eu/publication/eu-buildings-climate-tracker-3rd-edition/. [Accesat 17 iulie 2025].

[5] Building Performance Institute Europe (BPIE), „Europe’s buildings under the microscope. A country-by-country review of the energy performance of buildings,” 2011.

[6] I. Baran, L. Dumitrescu, R. A. Pescaru, „Thermal Rehabilitation Technology and the Nearly Zero-Energy Buildings. Romanian Representative Education Buildings-Case Study,” *Procedia Technology,* vol. 22, pp. 358-364, 2016.

[7] Ministerul Energiei, „Strategia energetică a României 2025-2035, cu perspectiva anului 2050,” 2025. Disponibil la: https://energie.gov.ro/strategiei-energetice-a-romaniei-2025-2035-cu-perspectiva-anului-2050/. [Accesat 21 iulie 2025].

[8] J. H. Holland, „Adaptation in Natural and Artificial Systems,” *University of Michigan Press,* 1975.

[9] S. N. Al-Saadi, K. S. Al-Jabri, „Optimization of envelope design for housing in hot climates using a genetic algorithm (GA) computational approach,” *Journal of Building Engineering,* vol. 32, 2020.

[10] L. Xia, Z. Ma, G. Kokogiannakis, Z. Wang, S. Wang, „A model-based design optimization strategy for ground source heat pump systems with integrated photovoltaic thermal collectors,” *Applied Energy,* vol. 214, pp. 178-190, 2018.

[11] M. Ferrara, A. Rolfo, F. Prunotto, E. Fabrizio, „EDeSSOpt – Energy Demand and Supply Simultaneous Optimization for cost-optimized design: Application to a multi-family building,” *Applied Energy,* vol. 236, pp. 1231-1248, 2019.

[12] F. Ascione, N. Bianco, R. F. De Masi, C. De Stasio, G. M. Mauro, G. P. Vanoli, „Multi-objective optimization of the renewable energy mix for a building,” *Applied Thermal Engineering,* vol. 101, pp. 612-621, 2016.

[13] H. Zhang, R. Chen, F. Wang, H. Wang, Y. Wang, „Multi-objective Optimization for Operational Parameters of A Micro-turbine CCHP System Based on Genetic Algorithm,” *Procedia Engineering,* vol. 205, p. 1807–1814, 2017.

[14] F. Ascione, N. Bianco, R. F. De Masi, G. M. Mauro, G. P. Vanoli, „Resilience of robust cost-optimal energy retrofit of buildings to global warming: A multi-stage, multi-objective approach," *Energy and Buildings,* vol. 153, pp. 150-167, 2017.

[15] A. Ciardiello, F. Rosso, J. Dell Olmo, V. Ciancio, M. Ferrero, F. Salata, „Multi- objective approach to the optimization of shape and envelope in building energy design," *Applied Energy,* vol. 280, 2020.

[16] C. Wu, H. Pan, Z. Luo, C. Liu, H. Huang, „Multi-objective optimization of residential building energy consumption, daylighting, and thermal comfort based on BO-XGBoost-NSGA-II," *Building and Environment,* vol. 254, 2024.

[17] A. Narayanan, M. Moore, „Quantum-inspired genetic algorithms," în *Proceedings of the IEEE International Conference on Evolutionary Computation*, 1996.

[18] B. Lia, P. Hu, N. Zhu, F. Lei, Lu Xing, „Performance analysis and optimization of a CCHP-GSHP coupling system based on quantum genetic algorithm," *Sustainable Cities and Society,* vol. 46, 2019.

[19] Y. Wang, C. Wei, „Design optimization of office building envelope based on quantum genetic algorithm for energy conservation," *Journal of Building Engineering,* vol. 35, 2021.

[20] R. C. Eberhart, Y. Shi, „Particle Swarm Optimization: Developments, Applications and Resources," în *Proceedings of the 2001 Congress on Evolutionary Computation*, 2001.

[21] A. P. Engelbrecht, Fundamentals of Computational Swarm Intelligence, Wiley, 2005.

[22] N. Delgarm, B. Sajadi, F. Kowsary, S. Delgarm, „Multi-objective optimization of the building energy performance: A simulation-based approach by means of particle swarm optimization (PSO)," *Applied Energy,* vol. 170, pp. 293-303, 2016.

[23] J. Kim, T. Hong, J. Jeong, C. Koo, K. Jeong, „An optimization model for selecting the optimal green systems by considering the thermal comfort and energy consumption," *Applied Energy,* vol. 169, pp. 682-695, 2016.

[24] Y. Gao, S. Li, X. Fu, W. Dong, B. Lu, Z. Li., „Energy management and demand response with intelligent learning for multi-thermal-zone buildings," *Energy,* vol. 210, 2020.

[25] H. Awad, K.M. E. Salim, M. Gül, „Multi-objective design of grid-tied solar photovoltaics for commercial flat rooftops using particle swarm optimization algorithm," *Journal of Building Engineering,* vol. 28, 2020.

[26] T.V. Dixit, A. Yadav, S. Gupta, „Annual optimum tilt angle prediction of solar collector using PSO estimator," *Materials Science and Engineering,* 2017.

[27] C. Mokhtara, B. Negrou, N. Settou, B. Settou, M. M. Samy, „Design optimization of off-grid Hybrid Renewable Energy Systems considering the effects of building energy performance and climate change: Case study of Algeria," *Energy,* vol. 219, 2021.

[28] A. Askarzadeh, „A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm," *Computers & Structures,* vol. 169, pp. 1-12, 2016.

[29] M. Gharibi, A. Askarzadeh, „Technical and economical bi-objective design of a grid-connected photovoltaic/diesel generator/fuel cell energy system," *Sustainable Cities and Society,* vol. 50, 2019.

[30] A. Ghaffari, A. Askarzadeh, „Design optimization of a hybrid system subject to reliability level and renewable energy penetration," *Energy,* vol. 193, 2020.

[31] Y. Ke, J. Xie, S. Pouraminic, „Utilization of an improved crow search algorithm to solve building energy optimization problems: Cases of Australia," *Journal of Building Engineering,* vol. 38, 2021.

[32] M. Dorigo, T. Stützle, Ant Colony Optimization, MIT Press, 2004.

[33] K. Bamdad, M. E. Cholette, L. Guan, J. Bell, „Ant colony algorithm for building energy optimisation problems andcomparison with benchmark algorithms," *Energy and Buildings,* vol. 154, p. 404–414, 2017.

[34] K. Bamdad, M. E. Cholette, S. Omrani, J. Bell, „Building energy optimisation under uncertainty using ACOMV algorithm," *Energy and Buildings,* vol. 167, p. 322–333, 2018.

[35] K. Bamdad, M. E. Cholette, S. Omrani, J. Bell, „Future energy-optimised buildings - Addressing the impact of climate change on buildings," *Energy and Buildings,* vol. 231, 2021.

[36] J. Feng, X. Luo, M. Gao, A. Abbas, Yi-Peng Xu, „Minimization of energy consumption by building shape optimization using an improved Manta-Ray Foraging Optimization algorithm," *Energy Reports,* vol. 7, pp. 1068-1078, 2021.

[37] P. M. Fernandez, I. V. Sanchís, V. Yepes, R. I. Franco, „A review of modelling and optimisation methods applied to railways energy consumption," *Journal of Cleaner Production,* vol. 222, 2019.

[38] E. H. Houssein, A. G. Gad, K. Hussain, P. N. Suganthan, „Major Advances in Particle Swarm Optimization: Theory, Analysis, and Application," *Swarm and Evolutionary Computation,* vol. 63, 2021.

[39] Florin Leon, Syntheses of Artificial Intelligence / Sinteze de inteligenta artificiala, Iasi: Tehnopress, 2020.

[40] L. Dioşan, *Inteligenta artificiala. Rezolvarea problemelor de căutare. Strategii de căutare informată locală. Algoritmi Evolutivi. Universitatea Babes-Bolyai. Facultatea de Matematică şi Informatică,* 2013.

[41] D.E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, 1989.

[42] M. Mitchell, An Introduction to Genetic Algorithms, MIT Press, 1998.

[43] D. Whitley, „A Genetic Algorithm Tutorial," *Statistics and Computing,* vol. 4(2), p. 65–85, 1994.

[44] D. Chauhan, Shivani, P. N. Suganthan, „Learning Strategies in Particle Swarm Optimizer: A Critical Review and Performance Analysis," *Neural and Evolutionary Computing; Artificial Intelligence,* 2025.

[45] J. Fang, W. Liu, L. Chen, S. Lauria, A. Miron, X. Liu, „A Survey of Algorithms, Applications and Trends for Particle Swarm Optimization," *International Journal of Network Dynamics and Intelligence,* vol. 2(1), p. 24–50, 2023.

[46] B.Y. Qu, P.N. Suganthan, S. Das, „A distance-based locally informed particle swarm model for multimodal optimization," *EEE Transactions on Evolutionary Computation,* vol. 17, p. 387–402, 2012.

[47] M.R. Bonyadi, Z. Michalewicz, „Particle Swarm Optimization for Single Objective Continuous Space Problems: A Review," *Evolutionary Computation,* vol. 25, pp. 1-54, 2017.

[48] M. S. Innocente, J. Sienz, „Coefficients' Settings in Particle Swarm Optimization: Insight and Guidelines," *Neural and Evolutionary Computing; Optimization and Control,* 2021.

[49] Q. Li, S. Y. Liu, X. S. Yang, „Influence of Initialization on the Performance of Metaheuristic Optimizers," *Applied Soft Computing,* vol. 91, 2020.

[50] X. Li, K. Mao, F. Lin, X. Zhang, „Particle swarm optimization with state-based adaptive velocity limit strategy," *Neural and Evolutionary Computing; Artificial Intelligence,* 2023.

[51] M.N. Ab Wahab, S. Nefti-Meziani, A. Atyabi, „A Comprehensive Review of Swarm Optimization Algorithms," *PLOS ONE,* 2015.

[52] V. K. Ojha, A. Abraham, V. Snasel, „ACO for Continuous Function Optimization: A Performance Analysis," în *14th International Conference on Intelligent Systems Design and Applications (ISDA)*, 2014.

[53] A. E. Eiben; J. E. Smith, Introduction to Evolutionary Computing. Second edition, Springer, 2015.

[54] R. L. Haupt, S. E. Haupt, Practical Genetic Algorithms. Second edition, Wiley-Interscience, 2004.

[55] A. Hassanat, K. Almohammadi, E. Alkafaween, E. Abunawas, A. Hammouri, V. B. S. Prasath, „Choosing Mutation and Crossover Ratios for Genetic Algorithms—A Review with a New Dynamic Approach," *Information,* vol. 10(12), p. 390, 2019.

[56] M. Dianati, I. Song, M. Treiber, „An Introduction to Genetic Algorithms and Evolution Strategies," University of Waterloo, Ontario, Canada, Technical Report, 2002.

[57] B. Căruțașiu, „Contributions to the development of gray–box mathematical model used for analyzing high energy efficiency buildings," Universitatea Națională de Știință și Tehnologie Politehnica, Facultatea de Energetică, Departamentul de Producere și Utilizare a Energiei, București, 2015.

[58] H. Kour, P. Sharma, P. Abrol, „Analysis of Fitness Function in Genetic Algorithms," *International Journal of Scientific and Technical Advancements,* vol. 1, nr. 3, pp. 87-89, 2015.

[59] M. Wang, „Description and Application of Genetic Algorithm," Thesis for the Master of Science Degree in Mathematical Modeling and Simulation, 2012.

[60] D. Bhandari, C. A. Murthy, K. P. Sankar, „Variance as a Stopping Criterion for Genetic Algorithms with Elitist Model," *Fundamenta Informaticae,* pp. 145-164, 2012.

[61] A. Shukla, H.M Pandey, D. Mehrotra, „Comparative review of selection techniques in genetic algorithm," în *International Conference on Futuristic Trends on Computational Analysis and Knowledge Management*, Noida, India, 2015.

[62] G. Jones, „Genetic and Evolutionary Algorithms," *Encyclopedia of Computational Chemistry,* 1998.

[63] A. Khan, A. R, Baig, „Multi-Objective Feature Subset Selection using Non-dominated Sorting Genetic Algorithm," *JART 2015,* vol. 13(1), p. 145–159.

[64] R. Fortună (Popa), *Aplicații ale Algoritmilor Evolutivi în Optimizarea Proceselor din Ingineria Chimică,* Școala Doctorală a Facultății de Inginerie Chimică și Protecţia Mediului, Universitatea Tehnică "Gheorghe Asachi" din Iași, 2011.

[65] J. R. Manne, „Multiobjective Optimization in Water and Environmental Systems Management- MODE Approach," *In Handbook of Research on Advanced Computational Techniques for Simulation-Based Engineering,* 2016.

[66] M. W, Mkaouer, M. Kessentini, „Model Transformation Using Multiobjective Optimization," *Advances in Computers,* vol. 92, pp. 161-202, 2014.

[67] I. Halim, A. Adhitya, R. Srinivasan , „Multi-objective Optimization for Integrated Water Network Synthesis," *11th International Symposium on Process Systems Engineering. In Computer Aided Chemical Engineering.,* vol. 31, pp. 1432-1436, 2012.

[68] S. Jiang, S. Yang , „Convergence Versus Diversity in Multiobjective Optimization," *Lecture Notes in Computer Science,* pp. 984-993, 2016.

[69] X. S. Yang, „Multi-Objective Optimization," *In Nature-Inspired Optimization Algorithms,* pp. 197-211, 2014.

[70] C. Xiangxiang, Y. Xinjie, „Improved Crowding Distance for NSGA-II," *Computer Science, Neural and Evolutionary Computing,* 2018.

[71] L. Junhui, C. Xindu, „An Improved NSGA-II Algorithm Based on Crowding Distance Elimination Strategy," *International Journal of Computational Intelligence Systems,* vol. 12(2), pp. 53-518, 2019.

[72] *Metodologie de calcul al performanței energetice a clădirilor. Partea a IV-a. Breviar de calcul al performanței energetice a clădirilor și apartamentelor. Indicativ MC001/4,* 2009.

[73] *Normativ privind calculul termotehnic al elementelor de construcție în contact cu solul, Indicativ C107/5,* București, România, 2005.

[74] *Standard SR1907-2, Instalații de încălzire. Necesarul de căldură de calcul. Temperaturi interioare convenționale de calcul. Asociația de Standardizare din România,* București, 2014.

[75] *Standard SR4839. Instalații de încălzire. Numărul anual de grade-zile,* 2014.

[76] E. T. Bailey, L. Caldas , „Operative generative design using non-dominated sorting genetic algorithm II (NSGA-II)," *Automation in Construction,* vol. 155, 2023.

[77] A. E. Nicolae, H Necula, B. M. Căruțașiu, „Optimizing the Building Refurbishment Process Using Improved Evolutionary Algorithms," *EnergieS,* vol. 7(9), 2014.

[78] *Normativ privind calculul termotehnic al elementelor de construcție ale clădirilor, Indicativ C107/3,* București, România, 2005.

[79] *Normativ pentru proiectarea, executarea şi exploatarea instalaţiilor de ventilare şi climatizare, Indicativ I5,* București, România, 2022.

[80] T. Koopman, T. Zhu, W. Rohlfs, „Performance evaluation of air-source heat pump based on a pressure drop embedded model,” *Energy Reports,* 2024.

[81] L. Sun, Z. Hu, M. Mae, T. Imaizumi, „A predictive COP model for air source heat pumps under extreme heat conditions using no experimental data,” *Energy and Buildings,* vol. 339, 2025.

[82] A. Nyers, J. Nyers, „Enhancing the Energy Efficiency—COP of the Heat Pump Heating System by Energy Optimization and a Case Study,” *Energies,* 2023.

[83] „GeoT*SOL®—Exploiting the Earth’s Sustainable Energy Supply Planning Programs from Valentin Software,” Disponibil la: https://solsta.co/uploads/product/4a960ac291a543828795731231fb56a0/datasheet-geot-sol.pdf. [Accesat 2025 Mai 20].

[84] H. N. M. B. Căruțașiu, „Assessing the Impact of Air-Source Heat Pumps in a Residential Building’s Retrofit Process,” *Buildings,* vol. 14(12), 2024.