

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

ȘCOALA DOCTORALĂ

**Facultatea de Inginerie Chimică și Protecția Mediului
„Cristofor Simionescu”**



TEHNICI NEURO-EVOLUTIVE CU APLICAȚII ÎN INGINERIE CHIMICA

REZUMATUL TEZEI DE DOCTORAT

Doctorand: ing. Costel ANTON

Conducător de doctorat: prof. univ. dr. ing. Silvia CURTEANU

IAȘI, 2025

Cuprins

Listă de prescurtări	4
Capitolul 1. Introducere	7
1.1. Obiectivele tezei.....	8
1.2. Structura tezei.....	9
Capitolul 2. Tehnici ale inteligenței artificiale utilizate în industria materialelor de construcții	12
2.1. Industria agregatelor.....	13
2.2. Industria cimentului.....	19
2.3. Industria materialelor de zidărie.....	23
2.4. Concluzii parțiale.....	31
Capitolul 3. Instrumente IA de modelare și optimizare utilizate în inginerie	32
3.1. Algoritmi de optimizare inspirați din comportamentul uman de învățare și cooperare.....	33
3.2. Algoritmi de optimizare inspirați din comportamentul competitiv uman.....	34
3.3. Algoritmi de optimizare inspirați din comportamentul virușilor.....	34
3.4. Concluzii parțiale.....	41
Capitolul 4. Procesul tehnologic. Baza de date și prelucrare statistică	42
4.1. Procesul tehnologic.....	42
4.2. Evaluarea impactului schimbărilor survenite în procesul de ardere în care se modifică mixul de fabricație.....	50
4.3. Baze de date și prelucrate statistic.....	53
4.3.1. Baza de date 1.....	53
4.3.2. Baza de date 2.....	56
4.4. Concluzii parțiale.....	59
Capitolul 5. Modelare cu rețele neuronale artificiale dezvoltate prin metoda încercărilor succesive	61
5.1. Utilizarea rețelelor neuronale pentru predicția noxelor de CO, NO și CH ₄ folosind baza de date 1.....	61
5.1.1. Rețele neuronale dezvoltate pentru predicția CO.....	63
5.1.2. Rețele neuronale dezvoltate pentru predicția NO.....	63
5.1.3. Rețele neuronale dezvoltate pentru predicția CH ₄	65
5.2. Utilizarea rețelelor neuronale pentru predicția noxelor de CO, NO și CH ₄ folosind baza de date 2.....	66
5.2.1. Rețele neuronale dezvoltate pentru predicția CO.....	67
5.2.2. Rețele neuronale dezvoltate pentru predicția CH ₄	69
5.2.3. Rețele neuronale dezvoltate pentru predicția NO.....	71
5.3. Concluzii parțiale.....	74

Capitolul 6. Optimizarea procesului de fabricație a cărămidilor	76
6.1. Impactul studiului prin simulare.....	76
6.2. Cadru experimental.....	77
6.3. Modelarea procesului de ardere folosind diverse modele de regresie.....	77
6.4. Optimizarea procesului de fabricare a cărămidilor.....	79
6.4.1. Optimizarea procesului folosind căutarea tip grilă.....	79
6.4.2. Optimizarea procesului folosind diferiți algoritmi inspirați din comportamentul uman și comportamentul virusilor.....	83
6.4.2.1. Minimizarea cantității de CO.....	83
6.4.2.2. Minimizarea cantității de CH ₄	86
6.4.3. Optimizarea hibrid-evolutivă aplicată modelării procesului de obținere a cărămidilor	92
6.4.3.1. Dezvoltarea modelului neuronal în varianta optimă.....	92
6.4.3.2. Optimizarea procesului de fabricare a cărămidilor.....	93
6.5. Concluzii parțiale.....	101
Capitolul 7. Modelarea și optimizarea procesului de fabricare a cărămidilor folosind programe Python	104
7.1. Structura programului Python pentru proiectarea modelelor neuronale.....	104
7.2. Parametri structurali și funcționali ai rețelelor neuronale.....	105
7.3. Metodologia de modelare și optimizare implementată în Python.....	107
7.4. Rezultate de modelare și optimizare pentru procesul de fabricare a cărămidilor.....	109
7.4.1. Strategia 1 de modelare și optimizare.....	109
7.4.2. Strategia 2 de modelare și optimizare.....	112
7.4.3. Strategia 3 de modelare și optimizare.....	118
7.5. Concluzii parțiale.....	125
Capitolul 8. Concluzii generale	126
8.1. Principalele concluzii rezultate din cercetările incluse în teză	126
8.2. Considerații practice.....	131
8.3. Aspecte originale.....	132
8.4. Direcții de continuare a cercetărilor.....	132
Activitate științifică	133
Bibliografie	135

INTRODUCERE

Domeniul inteligenței artificiale (IA) cunoaște o dezvoltare remarcabilă, datorată, în principal, diversității aplicațiilor sale. Tehnologiile IA s-au impus prin eficiența lor în modelarea și optimizarea proceselor chimice, cele mai utilizate fiind *rețelele neuronale artificiale* și *algoritmii inspirați din biologie*.

Rețelele neuronale reprezintă instrumente puternice de modelare, având capacitatea de a învăța relații complexe între diverse variabile. Datorită abilității lor de a aproxima orice funcție neliniară, continuă, acestea oferă soluții eficiente pentru modelarea sistemelor neliniare. Pe de altă parte, algoritmii de inspirație biologică, în special cei evolutivi, constituie metode eficiente de optimizare mono- și multi-obiectiv, bazate pe modele inspirate din comportamentul entităților biologice inteligente.

În ingineria reacțiilor chimice, numeroase procese și sisteme sunt insuficient cunoscute din punct de vedere fizico-chimic, ceea ce îngreunează sau face imposibilă dezvoltarea unor modele fenomenologice precise. În astfel de situații, *modelarea empirică*, bazată pe date experimentale, devine o alternativă viabilă. *Rețelele neuronale* funcționează conform principiului „cutiei negre”, operând pe baza relației dintre datele de intrare și cele de ieșire, principiu aplicabil și altor modele de regresie. Acest aspect le face utile în modelarea proceselor chimice complexe, evitând dificultățile asociate determinării și rezolvării sistemelor de ecuații diferențiale care descriu aceste procese.

O altă provocare majoră în asigurarea calității produselor chimice constă în absența măsurătorilor „on-line” pentru anumite variabile și în întârzierile semnificative introduse în proces de acțiunile de măsurare. În plus, *optimizarea proceselor chimice* este adesea de natură multi-obiectivă, necesitând satisfacerea simultană a mai multor criterii, deseori contradictorii. Această problemă poate fi abordată fie vectorial, prin tratarea obiectivelor ca fiind componente ale unei funcții vectoriale, fie scalar, prin combinarea lor ponderată (funcție de importanță) într-o funcție scalară.

Metodele tradiționale de optimizare bazate pe funcții diferențiabile prezintă limitări precum dependența de valorile inițiale, riscul de blocare în minime locale și influența tipului de proces analizat. În schimb, algoritmii de inteligență artificială au înregistrat progrese semnificative, fiind eficienți pentru o gamă variată de procese. Aceștia nu necesită valori inițiale, pot identifica optimul global chiar și în prezența optimelor locale și nu se bazează pe derivate ale funcției obiectiv.

Comparativ cu metodele clasice, tehnicile de optimizare bazate pe *algoritmi de inspirație biologică* sunt recomandate pentru procese care se desfășoară „on-line”, datorită robusteții lor considerabile. În plus, acești algoritmi pot fi adaptați diferitelor procese tehnologice, îmbunătățindu-se astfel performanțele în ceea ce privește convergența spre optimul global, viteza de căutare, reproductibilitatea și precizia rezultatelor.

1.1. Obiectivele tezei

Obiectivul principal al tezei este *simularea procesului de fabricare a cărămizilor* în scopul determinării compoziției amestecului de fabricație (cantitățile de rumeguș, coji de semințe de floarea soarelui, argilă, material uscat, materiale organice și cenușă), astfel încât cantitățile de gaze (metan, oxizi de carbon,

oxizi de azot) rezultate din ardere și evacuate din instalație să fie minime. Se precizează faptul că experimentele ce constituie baza de date sunt efectuate într-o instalație industrială cu o capacitate de 9000 bucăți/zi.

Simularea include:

✚ *analiza statistică* a datelor disponibile în scopul determinării dependențelor între mărimile de intrare considerate (componentele materiei prime) și ieșire reprezentate de cantitățile de gaze evacuate. În acest scop, s-a folosit programul *SigmaPlot* cu care au fost obținute informații relevante despre datele experimentale, condiție necesară pentru o modelare eficientă.

✚ *modelarea procesului* prin intermediul diverselor tehnici de regresie, incluzând rețele neuronale artificiale, k-Nearest Neighbor, K*, Support Vector Regression și Random Forest, cu un accent special pe dezvoltarea rețelelor neuronale în multiple configurații structurale și parametrice. Construcția modelelor neuronale a fost realizată utilizând abordări variate, incluzând metode iterative și aplicarea diferiților algoritmi de optimizare specifici inteligenței artificiale.

✚ *optimizarea procesului*, cu algoritmi inspirați din comportamentul uman (*Simple Human Learning Optimization Algorithm, Teaching-Learning Based Optimization Algorithm, Social Learning Optimization, Football Game Algorithm, Volleyball Premier League Algorithm, Imperialist Competitive Algorithm*) și al virusilor (*Viral System, Virulence Optimization Algorithm, Virus Colony Search* și *Virus Optimization Algorithm*) și cu metoda *grid search*, cu scopul determinării cantităților optime din mixul de fabricație care minimizează cantitățile de gaze evacuate. Optimizările s-au realizat în variantele *mono-* și *multi-*obiectiv, folosind diferite modele.

O abordare distinctă o reprezintă modelarea și optimizarea procesului folosind un program implementat în *PyTorch* - aplicație completă, ușor de utilizat.

Rezultatele de simulare au rolul efectuării de predicții referitoare la modificarea cantității de emisii de noxe din gazele de evacuare atunci când sunt introduse în mixul de producție diferite procente de materiale auxiliare, contribuind astfel la reducerea numărului de teste experimentale cu un impact economic semnificativ.

1.2. Structura tezei

Teza este organizată astfel încât fiecare capitol cuprinde o metodologie de modelare sau/și optimizare distinctă, ordonarea lor corespunzând creșterii complexității, în scopul îmbunătățirii performanțelor. Astfel, primele modele de regresie, cu un accent deosebit pe rețelele neuronale artificiale (RNA), sunt dezvoltate prin abordări iterative, urmând ca ulterior să fie aplicați algoritmi de optimizare pentru a obține forma optimă a acestora, atât din perspectiva structurii, cât și a funcționalității.

Teza este structurată în **8 capitole**: capitolul 1 reprezintă introducerea, capitolele 2 și 3 tratează fundamentele teoretice și realizările relevante, iar capitolele 4-8 prezintă contribuția principală a lucrării. Fiecare capitol include concluzii parțiale, iar ultimul capitol conține concluzii generale. Sunt anexate referințele bibliografice, o listă de abrevieri și publicațiile derivate din cercetările prezentate în teză.

Lucrarea conține o serie de tabele, scheme și reprezentări grafice care ilustrează sintetic principalele obiective abordate, modul de rezolvare a acestora, precum și principalele rezultate obținute.

Capitolul 1 este capitolul introductiv în care se prezintă principalele obiective, structura tezei și, pe scurt, conținutul fiecărui capitol. O reprezentare grafică inclusă în această secțiune reflectă edificator direcțiile de cercetare urmărite și metodologiile aplicate.

Capitolul 2 cuprinde o parte teoretică, respectiv o trecere în revistă a instrumentelor inteligenței artificiale aplicate în industria materialelor de construcții. Abordarea este structurată în funcție de tipurile de materiale, în principal agregate, ciment și cărămizi. Sunt prezentate aspectele vizate, metodologiile aplicate și principalele rezultate obținute. Paralel cu IA aplicat materialelor de construcții, sunt inserate elemente referitoare la tehnologia de fabricare a cărămizilor deoarece prezenta lucrare are drept contribuție importantă modificarea materiei prime prin inserarea diferitelor elemente (rumeguș, floarea soarelui). De aceea s-a considerat benefică compararea cu abordările din literatura de specialitate și din acest punct de vedere – mixul inițial de fabricație – nu numai cele referitoare la metodologiile și instrumentele IA de simulare.

Capitolul 3 descrie algoritmi de optimizare folosiți în teză și aplicațiile acestora găsite în literatură. Algoritmii fac parte din următoarele trei categorii: algoritmi inspirați din comportamentul uman de învățare și cooperare, algoritmi bazați pe comportamentul uman de competiție și algoritmi inspirați de comportamentul virușilor.

Capitolul 4 reprezintă începutul contribuției originale a tezei. Este prezentat detaliat procesul de fabricare a cărămizilor, cu descrierea fiecărei etape a fluxului tehnologic. O problemă importantă abordată este evaluarea impactului schimbărilor survenite în procesul de ardere în instalația de fabricare a cărămizilor în condițiile în care se modifică mixul de fabricație. Experimentele conduc la realizarea a două baze de date care, în urma prelucrărilor statistice sunt pregătite pentru modelarea procesului.

Capitolul 5 este destinat modelării cu rețele neuronale dezvoltate prin metoda încercărilor succesive. Au fost proiectate rețele neuronale cu structuri diferite și parametri diferiți, evaluându-se performanța lor prin erori procentuale, corelația și eroarea medie pătratică. Studiul a fost condus succesiv, cu modificări gradate, urmărindu-se îmbunătățirea performanțelor de modelare. Prin modelare neuronală, s-a urmărit stabilirea corelațiilor între principalele componente ale mixului de fabricație (coji de semințe de floarea soarelui, rumeguș, argilă, cenușă, materiale uscate și materiale organice) și cantitățile de gaze evacuate (metan, oxizi de carbon și de azot).

Capitolul 6 cuprinde proceduri de optimizare aplicate atât modelelor neuronale, cât și procesului de fabricare a cărămizilor. Se proiectează și alte modele de regresie față de rețelele neuronale, respectiv, k-Nearest Neighbor, Random Forest, Support Vector Regression și variante ale acestora. Un astfel de model este integrat într-o procedură de optimizare de tip *grid search* care determină cantitățile optime din componentele amestecului de fabricație care conduc la minimizarea volumelor de gaze evacuate. Este efectuată o optimizare multi-obiectiv, cu rezultate reprezentate de fronturi Pareto din care tehnologul poate alege soluția convenabilă care respectă diferite criterii impuse.

Se utilizează în continuare o serie de algoritmi de inspirație biologică mai puțin cunoscuți, a căror funcționare este inspirată din comportamentul uman și al virușilor (*Simple Human Learning Optimization*

Algorithm, Teaching-Learning Based Optimization Algorithm, Social Learning Optimization, Football Game Algorithm, Volleyball Premier League Algorithm, Imperialist Competitive Algorithm, Viral System, Virulence Optimization Algorithm, Virus Colony Search și Virus Optimization Algorithm). Aceștia funcționează într-o optimizare mono-obiectiv, cu model rețea neuronală, în care funcția obiectiv este reprezentată, pe rând, de cantitatea de metan, monoxid de carbon și, respectiv, oxid de azot.

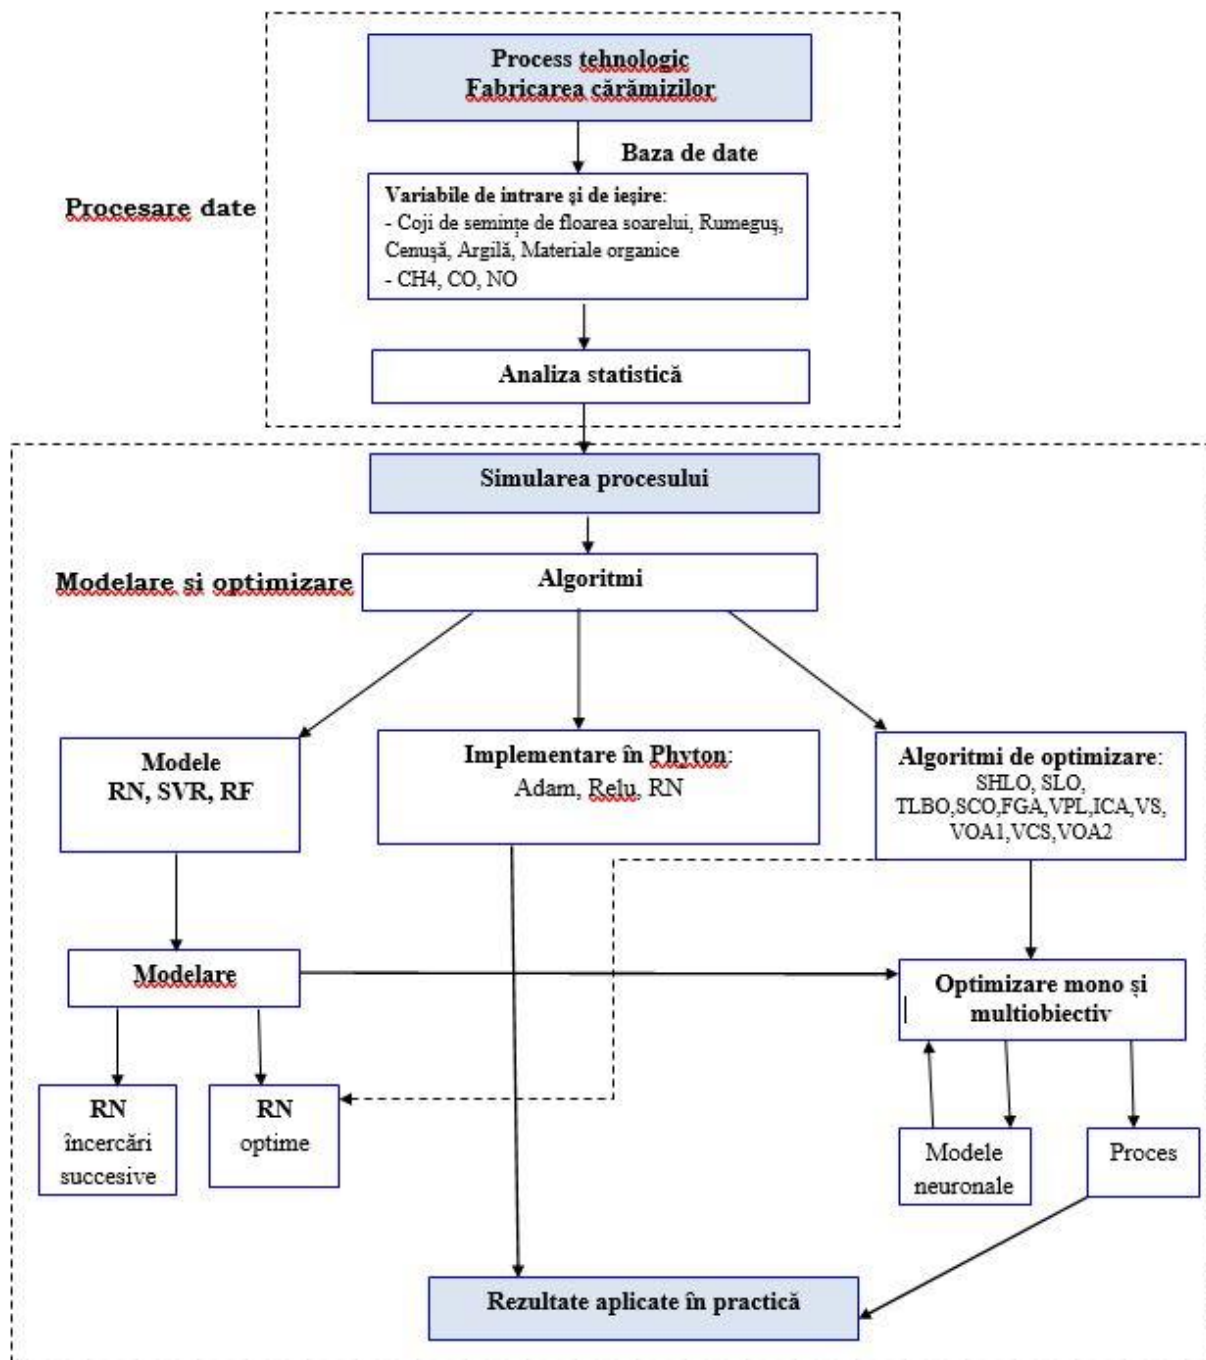


Figura 1.1. Principalele obiective abordate și rezolvate în teză

O altă direcție de cercetare a acestui capitol se referă la aplicarea unei tehnici neuro-evolutive de optimizare care presupune optimizarea modelului neuronal cu *algoritmului competitiv imperialist* (ICA) și optimizarea procesului cu un algoritm evolutiv, respectiv *Algoritmul Genetic de Sortare Nedominat-II*

(NSGA-II).

Capitolul 7 – modelarea și optimizarea procesului de fabricare a cărămizilor folosind programe dezvoltate în Python utilizând platforma *PyTorch*. Au fost proiectate prin încercări succesive diferite variante de rețele neuronale diferite structural și parametric. Cele mai bune modele au fost integrate în procedura de optimizare bazată pe algoritmul evolutiv NSGA. Fronturile Pareto rezultate din optimizarea multi-obiectiv oferă un domeniu extins și divers de rezultate de optimizare.

Capitolul 8, Concluzii generale, cuprinde trei secțiuni: principalele concluzii ale lucrării prezentate detaliat, considerații practice care se referă la directa aplicare în industrie a rezultatelor cercetărilor și direcții de continuare a cercetărilor.

Figura 1.1. prezintă grafic structura tezei, respectiv metodologia aplicată așa cum a fost descrisă mai sus, trecând în revistă fiecare capitol. În plus, este evidențiat fluxul de evoluție și legătură între tehnicile aplicate și rezultatele obținute.

CAPITOLUL 4

Procesul tehnologic. Baza de date și analiza statistică

4.1. Procesul tehnologic

Industria ceramicii brute este una din cele mai vechi industrii în care se obțin materiale de construcții (cărămizi, țigle, planșee ceramice etc.), transformând argila prin procese termice la temperaturi înalte (aproximativ 1000°C) în ceramică. În principiu, argila este o rocă sedimentară alcătuită dintr-un amestec de silicați, SiO_2 , și alumină, Al_2O_3 , în diverse proporții (Ogunro și colab., 2018).

Fiind o industrie energofagă (pentru a ajunge la temperaturile necesare transformărilor chimice sunt necesare cantități importante de gaz metan sau alte materiale combustibile precum păcură, cărbune), în ultimii ani, din nevoia de a fi competitivă economic, industria s-a orientat spre utilizarea diverselor materiale de natură organică (deșeuri ale industriei agricole – coji de semințe de floarea soarelui, de orez, de soia) care, prin aportul energetic adus, duc la diminuarea consumurilor de combustibili fosili și la reducerea costurilor de fabricație, menținând însă performanțele procesului (productivitatea) și calitatea produsului.

4.1.1. Fazele fluxului tehnologic

Principalele faze ale fluxului tehnologic de obținere a elementelor de construcții din argilă arsă sunt: *extragere argilă* → *preparare materii prime* → *fasonare* → *uscare* → *descărcare/așezare produse uscate* → *ardere* → *descărcare/paletizare produse arse* → *ambalare* → *depozitare* → *livrare*.

1. Extragerea argilei

Această etapă tehnologică presupune următoarele subetape: *derocare* (extragerea argilei brute din zăcămant) → *excavare* → *încărcare în mijloace de transport* → *transport auto* → *formare halde* (haldele sunt depozite intermediare de argilă în care, sub acțiunea apei și a microorganismelor aerobe și anaerobe, au loc procese de hidratare a structurilor minerale din componența argilelor) → *macerare* (proces fizice de

hidratare a structurilor minerale din compoziția argilelor) → *excavare argilă macerată* → *încărcare în mijloace de transport* → *transport auto* → *depozitare în punctul de alimentare*.

2. Preparare materii prime

Pentru fabricarea cărămizilor și a blocurilor ceramice, se pot utiliza amestecuri de argilă cu adaosuri de materiale neplastice cu rol de degresant: cenușă de termocentrală, rumeguș, coji de semințe de floarea soarelui, nisip, argilă deshidratată, praf de șamotă, perlit expandat, cărbune, cocs, tuf vulcanic, argile nisipoase cu un conținut ridicat de dioxid de siliciu și cu o plasticitate redusă, loess-uri, zgură granulată de furnal etc.

Operațiile de bază pentru prepararea-prelucrarea mixurilor de materiale constau în: • dozarea materiilor prime (argile) care se efectuează gravimetric, prin cântărire on line și transmiterea informațiilor către calculatorul de proces; • dozarea materialelor neplastice, cu rol de degresant, efectuată gravimetric prin cântărire on line și transmiterea informațiilor calculatorului de proces; • sfărâmarea bulgărilor de argilă; • mărunțirea fină a argilei; • umezirea mixului de material; • omogenizarea amestecului de materii prime și materiale neplastice; • omogenizarea umidității și structurii mixului de material; • îmbunătățirea aptitudinii de modelare-fasonare a mixului de material, realizată în silozuri intermediare de omogenizare în care au loc procese de detensionare mecanică și omogenizare a proprietăților mixului de fabricație.

3. Fasonarea

În aceasta etapă tehnologică, este importantă stabilirea dimensiunilor produsului verde. Produsul verde este cărămida proaspăt fasonată care înglobează, pe lângă mixul de materii prime implicate în obținerea produsului finit (cărămida/blocul ceramic), și apa de formare (apa adăugată în etapa de fasonare pentru a facilita modelarea cărămizii). Adăugarea de apă peste anumite limite, stabilite funcție de tipul de mix de fabricație și de tipul de argile implicate, poate conduce la inconstanța performanțelor dimensionale ale cărămizilor, dar și la costuri suplimentare cu faza de uscare sau chiar la rebutarea produsului după faza de uscare.

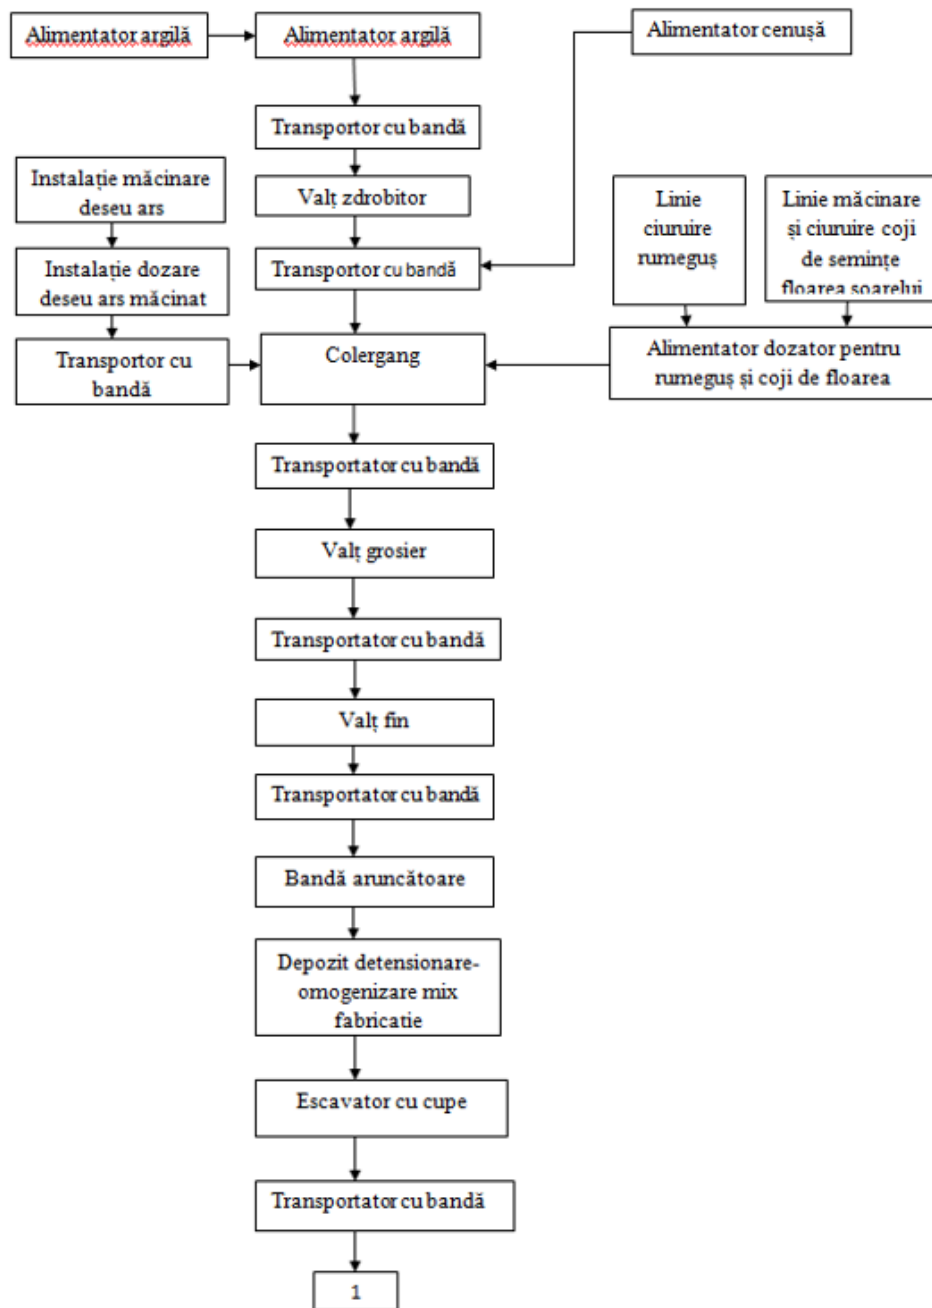
4. Uscarea

Uscarea este etapa tehnologică în care este îndepărtată, cu ajutorul căldurii, majoritatea apei legate fizic în structura argilelor și a materialelor ajutoare din componența cărămizilor fasonate. În majoritatea timpului, căldura necesară este obținută prin recircularea aerului cald care provine de la cuptor.

5. Arderea

“Arderea” reprezintă etapa tehnologică în care, prin aducerea la temperaturi superioare (în jurul temperaturii de 1000°C), are loc transformarea masei argiloase în ceramică. Această transformare este ireversibilă, dând naștere unui material cu proprietăți net diferite și superioare față de materialul inițial.

Figura 4.4. reprezintă schema bloc a fluxului tehnologic de obținere a cărămizilor.



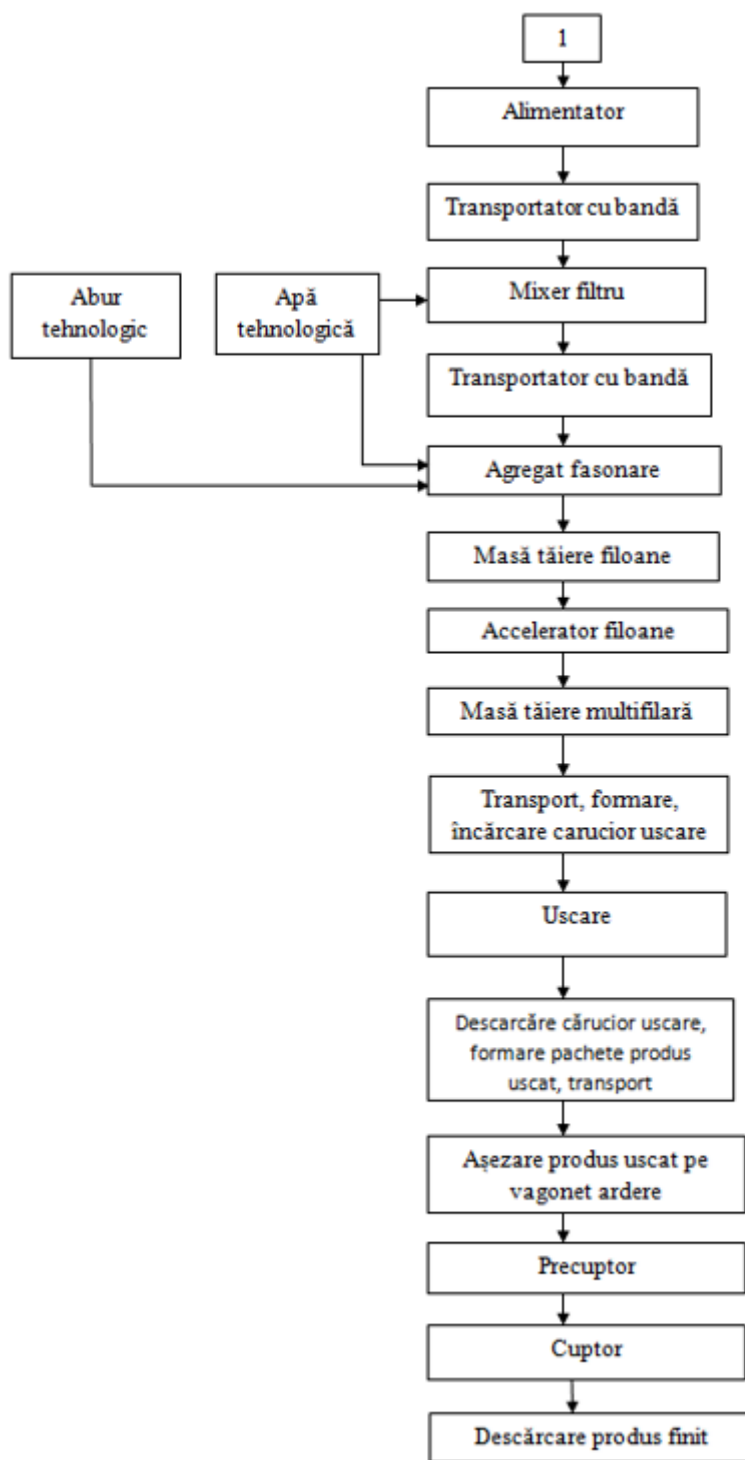


Figura 4.4. Schema bloc a fluxului tehnologic de obținere a cărămizilor

4.2. Evaluarea impactului schimbărilor survenite în procesul de ardere în care se modifică mixul de fabricație

S-a efectuat un studiu pe o instalație industrială, în condiții reale de lucru, în care s-au făcut determinări asupra gazelor exhaustate la coșul cuptorului, păstrând constanți parametrii de ardere (cantitate mix, setări parametri ardere – aport gaz metan, aer, presiuni, ritm etc.), cu scopul de a evalua influența

utilizării a două materii prime ajutătoare, respectiv rumeguș și coji de semințe de floarea soarelui, asupra consumului de oxigen din aerul adus în proces și impactul asupra produșilor de ardere.

S-a utilizat în procesul tehnologic același cuptor în care s-au încărcat mixturi diferite de material pe bază de siliciu. S-au luat în calcul diferite tipuri de produse, obținute prin adăugare la mixurile formate din argilă a unor procente diferite de rumeguș și coji de semințe de floarea soarelui, pentru care s-au calculat valorile medii de gaze evacuate la cos.

Determinările experimentale au fost efectuate folosind un analizor de gaze arse tip Testo 350, dotat cu celule de detectare și măsurare specifice gazelor de interes (CO , NO_x , C_xH_y , O_2), calibrate și etalonate metrologic. Pentru acuratețea rezultatelor, s-au efectuat mai multe serii de determinări pe durata a 15 minute, cu citiri din minut în minut, rezultatele luate în considerare fiind media aritmetică a celor 15 citiri.

Pentru a o analiză a impactului schimbărilor survenite la nivelul procesului de ardere, s-au analizat gazele exhaustate la coșul de fum al cuptorului. S-au păstrat toate caracteristicile tehnologice constante, cu excepția tipului de materie primă ajutătoare de natură organică. Comparând valorile medii de gaze exhaustate pentru diferite rețete, în urma procesului de ardere a două mixuri de materie primă care conțin aceleași procente de argilă, degresant și materie primă ajutătoare (rumeguș sau coji de semințe de floarea soarelui), se poate observa că, practic, la același tonaj orar, există același consum de oxigen din aerul adus în proces, dar impactul asupra produșilor de ardere este diferit.

Au fost analizate comparativ și cantitățile de gaze cu potențial energetic obținute în cazul celor două tipuri de mix de fabricație. În acest scop, s-au comparat, în condiții similare de proces, pentru diferite rețete, valorile medii obținute pentru gazele de interes energetic. Rezultatele sunt prezentate în figura 4.5, în care numerotarea produselor corespunde unor procente diferite de coji de semințe de floarea soarelui și de rumeguș. Diferențele dintre procentul de CO exhaustat în cazul celor două variante de mixuri de fabricație nu sunt semnificative. Cantități mai mari de CH_4 se obțin pentru produsele 2 și 4, atunci când se utilizează rumeguș, comparativ cu situația în care se utilizează în mixul de fabricație coji de semințe de floarea soarelui pentru același produs.




Figura 4.5. Variația concentrației gazelor cu potențial energetic

4.3. Baze de date și prelucrarea statistică

Pe baza măsurătorilor experimentale realizate pentru masa de produs uscat, numărul de bucăți/vagon, total tone/zi, cantitatea de argilă, cantitatea de cenușă, cantitatea de materii prime organice și valorile noxelor măsurate la coș, respectiv CO, NO și CH₄, s-au construit două baze de date ce conțin informații cu privire la **121, respectiv 100 șarje de cărămizi**, diferența constând nu numai în aceste numere, ci și în numărul variabilelor de intrare considerate în modelare.

Prelucrarea statistică a datelor experimentale avute la dispoziție s-a realizat cu programul specializat *SigmaPlot 11.00* care a permis colectarea de informații referitoare la valorile medii, deviația standard, eroarea standard a mediei, intervalul de încredere a mediei, amplitudinea, valoarea maximă, valoarea minimă, mediana, intervalul de distribuție a 25% dintre date, a 75% dintre date, evaluarea distribuției normale a datelor (testele Skewness și Kurtosis, testul Kolmogorov – Smirnov, testul Shapiro–Wilk), suma datelor și suma pătratelor datelor (tabelul 4.4).

Tabelul 4.4. Descrierea statistica a datelor experimentale pentru baza de date 2

Coloana	Nr. date	Date lipsă	Media	Dev. Std.	Eroarea Std. a mdiei	Intervalul de încredere a mediei	Intervalul de variație a datelor	Amplitudinea	Valoarea minimă	Mediana
Col 1	100	0	2.065	1.312	0.131	0.26	3.5	3.5	0	3
Col 2	100	0	0.94	1.525	0.152	0.303	3.5	3.5	0	0
Col 3	100	0	14.375	3.169	0.317	0.629	8.46	18.67	10.21	13.915
Col 4	100	0	606.654	92.772	9.277	18.408	408.027	729.677	321.65	639.345
Col 5	100	0	110.969	16.884	1.688	3.35	74.639	133.477	58.838	117.426
Col 6	100	0	22.171	3.964	0.396	0.787	17.165	28.932	11.768	23.326
Col 7	100	0	902.481	114.662	11.466	22.751	541.684	1199.34	657.656	902.867
Col 8	100	0	379.196	195.677	19.568	38.827	846.358	863.186	16.828	354.356
Col 9	100	0	111.714	20.841	2.084	4.135	94.762	161.882	67.121	109.793
Coloana	25%	75%	Skewness	Kurtosis	K-S Dist.	K-S Prob.	SWilk W	SWilk Prob	Suma datelor	Suma pătratelor
Col 1	0	3	-0.908	-1.078	0.35	<0.001	0.666	<0.001	206.5	596.75
Col 2	0	2.75	1.032	-0.913	0.451	<0.001	0.577	<0.001	94	318.5
Col 3	11.365	17.895	0.094	-1.689	0.237	<0.001	0.836	<0.001	1437.511	21658.74
Col 4	559.013	674.627	-1.285	1.074	0.172	<0.001	0.855	<0.001	60665.37	37654920
Col 5	102.459	123.036	-1.313	1.146	0.188	<0.001	0.852	<0.001	11096.91	1259636
Col 6	20.32	25.096	-0.619	-0.117	0.128	<0.001	0.943	<0.001	2217.098	50710.97
Col 7	822.641	972.871	0.211	-0.0654	0.0366	0.896	0.99	0.627	90248.06	82748729
Col 8	236.466	504.418	0.408	-0.46	0.0638	0.387	0.976	0.06	37919.57	18169592
Col 9	94.945	127.598	0.374	-0.44	0.0981	0.019	0.975	0.052	11171.36	1290992

Col 1 (CS,%); Col 2 (RU,%); Col 3 (DPM, kg); Col 4 (C, tone); Col 5 (A, tone); Col 6 (ORM, tone); Valori noxe măsurate la coș; Col 7 (CO mg/m³); Col 8 (CH₄ mg/Nm³); Col 9 (NO mg/m³)

Mediana are valori apropiate de valoarea medie, ceea ce indică o distribuție uniformă a datelor experimentale. Aceeași concluzie este furnizată și de analiza indicilor de aplatizare a curbei de variație a

datelor (Kurtosis) care are valori mici. Acestea indică o bună repartiție a datelor, respectiv faptul că sunt puține date care au valori mult diferite de medie.

Aplicându-se procedurile de comparație multiplă în perechi (metoda Dunn's), respectiv testul Kruskal – Wallis, s-au obținut informații despre dependența între variabile ceea ce reprezintă o etapă preliminară importantă în obținerea unor modele matematice credibile.

CAPITOLUL 5

Modelare cu rețele neuronale artificiale dezvoltate prin metoda încercărilor succesive

În prezentul studiu, s-au utilizat modelele neuronale pentru a analiza influența adăugării de materiale auxiliare în mixul de fabricație a cărămizilor asupra noxelor emise la coșul de fum al cuptorului. Într-o primă etapă, s-au dezvoltat modele prin metoda încercărilor succesive, folosind programul *NeuroSolutions*, un produs software specializat în acest scop.

Pentru a stabili topologia rețelelor neuronale care furnizează cele mai bune rezultate, s-au încercat mai multe rețele de tipul celor prezentate în figura 5.1, cu 4 intrări (masa de produs uscat, argilă, cenușă și materii organice – baza de date 1 care conține 121 șarje de cărămizi), unul sau două straturi, conținând 4...80 neuroni ascunși și o ieșire pentru predicția cantității de CO, NO și, respectiv, CH₄, ce rezultă în coșul de evacuare a gazelor.

Drept criterii de alegere a celei mai bune topologii de rețea s-au folosit eroarea pătratică medie (MSE), coeficientul de corelație (r^2) și eroarea procentuală E_p (%). Topologia rețelelor a fost codificată prin (m:n:p), în care m reprezintă numărul de neuroni din stratul de intrare, n - numărul de neuroni ascunși din stratul intermediar și p - numărul de neuroni din stratul de ieșire.

De exemplu, pentru predicția cantității de CO ce rezultă în coșul de evacuare a gazelor, s-au construit modelele neuronale care au topologiile și erorile MSE, r^2 și E_p prezentate în tabelul 5.1. În etapa de validare, conform figurii 5.2, aproximativ toate rezultatele se înscriu într-un interval de încredere de $\pm 22\%$.

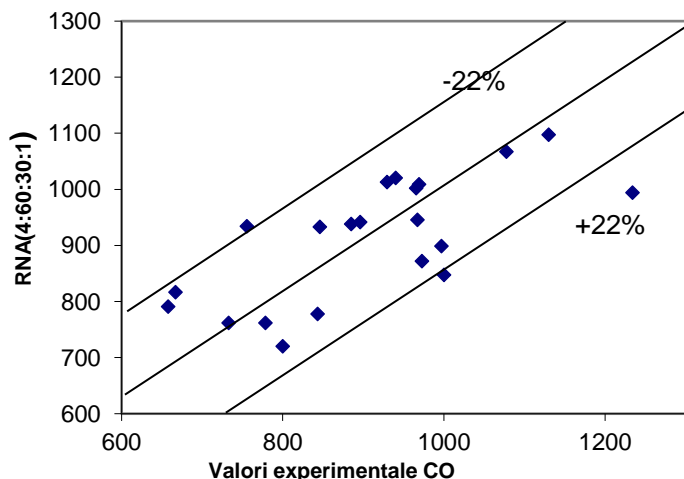


Figura 5.2. Compararea rezultatelor obținute în etapa de validare pentru predicția CO

Tabelul 5.1. Topologia diferitelor rețele neuronale cu propagare înainte construite pentru predicția monoxidului de carbon

Nr.	Topologie	MSE	r^2	$E_p(\%)$
1.	RNA(4:4:1)	0.0199	0.696	7.18
2.	RNA(4:8:1)	0.0181	0.728	6.58
3.	RNA(4:12:1)	0.0177	0.735	6.56
4.	RNA(4:16:1)	0.0175	0.739	6.50
5.	RNA(4:20:1)	0.0177	0.735	6.50
6.	RNA(4:40:1)	0.0165	0.757	6.11
7.	RNA(4:40:20:1)	0.0138	0.801	4.92
8.	RNA(4:60:30:1)	0.0123	0.825	4.76
9.	RNA(4:80:40:1)	0.0126	0.821	4.77

La fel s-a procedat pentru baza de date 2 care conține 100 șarje de cărămizi și care are 2 intrări suplimentare, respectiv cantitățile de semințe de floarea soarelui și rumeguș. Scopul modelărilor a fost corelarea cantităților gazelor exhaustate la coșul de ardere cu cele 6 mărimi de intrare, interesând astfel determinarea prin predicții a compoziției amestecului de fabricație care conține diferite adaosuri. S-a selectat ca exemplu modelarea neurală în care mărimea de ieșire a fost cantitatea de metan.

Numărul de epoci de antrenare a fost stabilit la 50000 (figura 5.7).

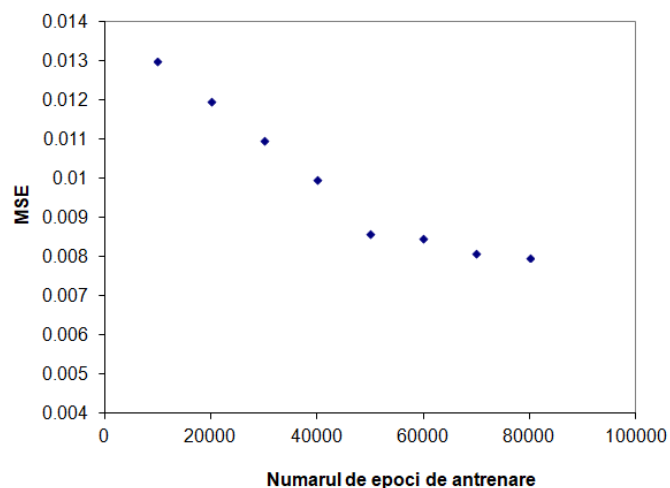


Figura 5.7. Evoluția erorii MSE cu creșterea numărului de epoci de antrenare în etapa de antrenare pentru CH_4

Modelele neuronale construite pentru a realiza predicția cantității de CH_4 rezultată în coșul de evacuare a gazelor și performanța acestora în etapa de antrenare sunt prezentate în tabelul 5.5. Rezultatele obținute indică faptul că cea mai bună performanță pentru CH_4 se obține cu modelul RNA(6:30:18:1). Valoarea erorii pătratice medii calculate pentru CH_4 este $\pm 43,8 \text{ mg/m}^3$ și este puțin mai mare decât cea obținută pentru CO.

Figura 5.8 compară valorile obținute cu modelul RNA(6:30:18:1) în etapa de validare cu cele experimentale și prezintă o abatere pătratică medie de $\pm 108,8 \text{ mg/m}^3$.

Tabelul 5.5. Topologia diferitelor RNA-uri de propagare înainte construite pentru predicția CH₄

Nr.	Topologia rețelei	MSE	r ²	E _p (%)	Timp(minute)
1.	RNA(6:6:1)	0.0173	0.946	18.28	2.02
2.	RNA(6:14:1)	0.0122	0.962	15.38	2.25
3.	RNA(6:20:1)	0.0106	0.967	12.16	2.42
4.	RNA(6:24:1)	0.0105	0.968	11.48	2.55
5.	RNA(6:30:1)	0.0093	0.971	10.44	3.05
6.	RNA(6:36:1)	0.0100	0.970	11.29	3.32
7.	RNA(6:30:12:1)	0.0091	0.972	9.81	3.33
8.	RNA(6:30:18:1)	0.0085	0.973	9.59	3.58
9.	RNA(6:30:24:1)	0.0095	0.971	10.25	3.64

MSE - eroarea pătratică medie, r² - coeficientul de corelare, E_p - eroarea procentuală

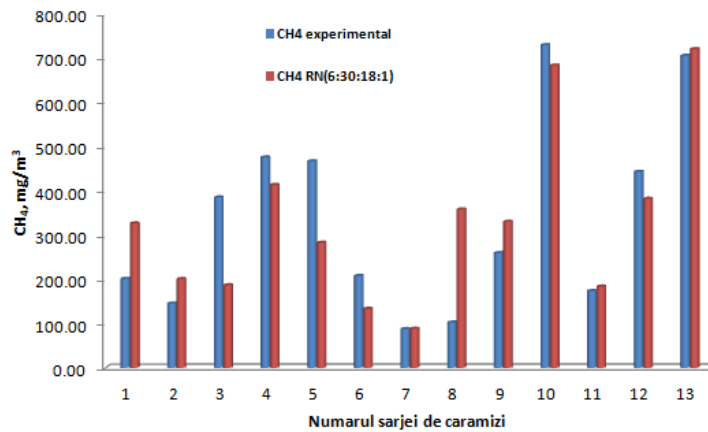


Figura 5.8. Valori experimentale pentru CH₄ în comparație cu cele obținute cu modelul RNA(6:30:18:1)

Modelele neuronale construite pentru a evalua impactul adăugării de materiale auxiliare (rumeguș și coji de semințe de floarea soarelui) asupra cantității de noxe evacuate din coșul cuptorului dintr-o fabrică industrială de cărămidă oferă posibilitatea efectuării de predicții care pot ajuta la reducerea numărului de loturi de testare, cu economii semnificative de timp și bani.

CAPITOLUL 6

Optimizarea procesului de fabricare a cărămidilor

Acest capitol prezintă modul în care metodele avansate de învățare automată, în special *rețelele neuronale* și *algoritmii de optimizare cu inspirație biologică* pot fi implicați pentru a realiza simularea procesului de fabricare a cărămidilor, oferind soluții pentru reducerea emisiilor nocive și menținând, în același timp, productivitatea instalației, dar și calitatea produsului (a cărămidii).

6.3. Modelarea procesului de ardere folosind diverse modele de regresie

Pe lângă rețele neuronale, au fost testate și alte modele de regresie, cum ar fi: *Nearest Neighbor* (NN) și *k-Nearest Neighbor* (kNN), *algoritmul K**, *Support Vector Regression* (SVR).

În modelare, s-a utilizat baza de date 1 în care intrările sunt în număr de patru, respectiv masa produsului uscat, cantitățile de argilă, cenușă și materiale organice), iar ieșirile sunt reprezentate de cele trei componente gazoase (CO, CH₄ și NO) care vor fi minimizate în procedura de optimizare. (Anton și colab., 2021).

Tabelul 6.1 prezintă rezultatele regresiei pentru fiecare din cele trei ieșiri (CO, NO and CH₄), aplicând diferiți algoritmi și combinații de valori ale parametrilor acestora. Se prezintă coeficientul de corelație (*r*), pentru care o valoare cât mai apropiată de 1 desemnează o potrivire foarte bună a datelor. Pentru fiecare variantă a algoritmului, sunt prezentate rezultatele pentru setul de antrenare și pentru validarea încrucișată (CV). Interesează o bună generalizare, ca urmare rezultatele CV sunt utilizate pentru a selecta modelele cele mai bune. Cele mai bune valori obținute pentru fiecare din cele trei ieșiri sunt evidențiate cu bold în tabel.

După cum se poate vedea, nu există un singur model cel mai bun pentru toate cele trei ieșiri. Totuși, k-Nearest Neighbor și Random Forest sunt algoritmi care par să promită soluționarea problemei. A doua variantă a kNN (k=10) este mai bună pentru CO, dar mult mai rea pentru NO față de kNN (k=6). Astfel, s-a selectat kNN (k=6, w=1/d) și Random Forest (1000 arbori) pentru a fi utilizați în procedura de optimizare, împreună cu o combinație de modele, câte una separată pentru fiecare ieșire.

Tabelul 6.1. Rezultatele obținute pentru fiecare model de regresie

Algoritm	Set de date	CO	NO	CH ₄
kNN (k=6, w=1/d)	Antrenare	0.9261	0.9251	0.9525
	Validare încrucișată	0.6315	0.5184	0.7203
kNN (k=10, w=1/d)	Antrenare	0.8127	0.7336	0.7790
	Validare încrucișată	0.6355	0.4666	0.7081
NN (k=1)	Antrenare	0.9978	0.9893	0.9875
	Validare încrucișată	0.4927	0.4371	0.6473
K* (gb=10)	Antrenare	0.9392	0.9456	0.9641
	Validare încrucișată	0.5954	0.4529	0.6449
K* (gb=20)	Antrenare	0.8945	0.8927	0.9359
	Validare încrucișată	0.6295	0.4608	0.6840
K* (gb=50)	Antrenare	0.7924	0.7540	0.8670
	Validare încrucișată	0.6061	0.4461	0.7197
SVR (C=10000, PUK)	Antrenare	0.7999	0.7812	0.8841
	Validare încrucișată	0.2349	0.1995	0.1880
	Antrenare	0.6443	0.3835	0.7736

SVR ($C=100$, poly $d=2$)	Validare încrucișată	0.5938	0.1619	0.7061
SVR ($C=100$, RBF)	Antrenare	0.6277	0.3061	0.6432
	Validare încrucișată	0.6037	0.2103	0.5999
Random Forest (100 trees)	Antrenare	0.9592	0.9418	0.9621
	Validare încrucișată	0.5994	0.4799	0.7120
Random Forest (1000 trees)	Antrenare	0.9613	0.9468	0.9612
	Validare încrucișată	0.6045	0.4878	0.7384

Rezultatele obținute prin CV pot fi considerate acceptabile, având în vedere faptul că experimentele au fost realizate în condiții industriale, ceea ce presupune valori semnificative pentru cantitățile de materiale, timp de efectuare și energia necesară. Cel mai bun rezultat, selectat pentru optimizare, este considerat cel furnizat de algoritmul Random Forest cu 1000 de arbori. De asemenea, rezultatele obținute sunt de reală utilitate pentru practica industrială datorită indicațiilor referitoare la compoziția materialului de fabricație (Anton și colab., 2021).

6.4. Optimizarea procesului de fabricare a cărămizilor

6.4.1. Optimizarea procesului folosind căutarea tip grilă

În a doua etapă, cel mai bun model identificat anterior este utilizat pentru optimizare în sensul identificării valorilor optime pentru variabilele de decizie, respectiv mărimile de intrare (masa produsului uscat, argilă, cenușă și materii prime organice) care conduc la valori minime ale ieșirilor (CO , NO și CH_4). O astfel de optimizare în care se realizează minimizarea simultană a mai multor mărimi presupune aplicarea unui algoritm specific *optimizării multiobiectiv*, iar în urma aplicării acestuia se obțin mai multe soluții dintre care inginerul tehnolog poate alege funcție de diverse criterii. În cazul de față, se folosesc cele mai bune modele de regresie obținute cu algoritmi kNN și Random Forest, iar pentru optimizare s-a ales o abordare bazată pe *căutarea tip grilă* – metodă adecvată atunci când dimensionalitatea problemei este redusă și când interesează calitatea soluției, mai degrabă decât viteza de rezolvare (Anton și colab., 2021).

Frontul Pareto obținut prin includerea în procedura de optimizare a modelului Random Forest (1000 arbori) este prezentat în figura 6.2.

Rezultatele obținute relevă faptul că nu s-au obținut soluții dominate, astfel încât se poate spune că toți parametrii de intrare considerați (masa produsului uscat, argilă, cenușă și materii organice) influențează semnificativ valorile parametrilor de ieșire (CO , NO și CH_4).

Tabelul 6.2 prezintă o serie de rezultate, selectate din zone diferite ale frontului Pareto.

Tabelul 6.3. conține compoziții optime pentru amestecul de fabricație calculat pe baza datelor din tabelul 6.2. În concordanță cu aceste rezultate, adăugarea în amestec a unei cantități de materiale organice în proporție de 3.4% până la 5.1% determină obținerea unui minim pentru cantitățile de noxe (CO , NO și CH_4). Utilizarea tehnicilor inteligenței artificiale pentru optimizarea compoziției

amestecului destinat fabricării cărămizilor la scară industrială aduce beneficii importante prin reducerea numărului de teste, ceea ce înseamnă economii de resurse (materiale, timp și bani). Includerea în amestec a diferitelor cantități de cenușă și materiale organice din resurse reutilizabile (coji de semințe și rumeguș) reduce consumul de gaz metan și amprenta de carbon în produsul finit.

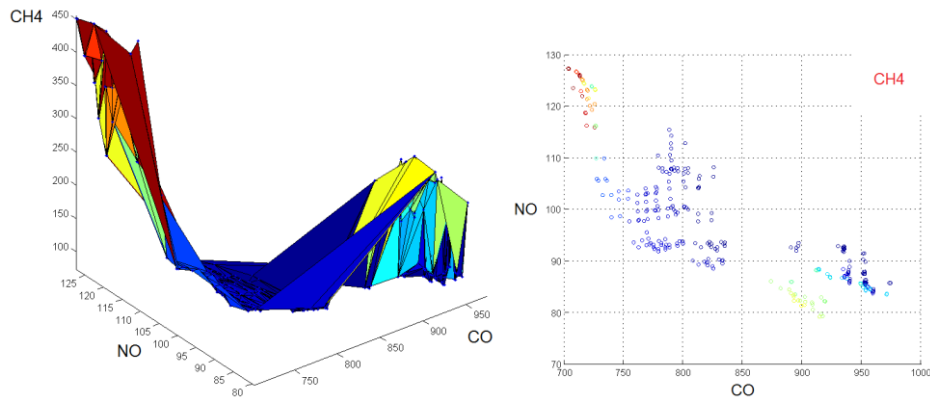


Figura 6.2. Frontul Pareto obținut prin modelare Random Forest și optimizare cu grid search

Tabelul 6.2. Rezultate selectate din zone diferite ale frontului Pareto în optimizarea multiobiectiv realizată cu *grid search*

Intrări				Ieșiri		
Masa de produs uscat, kg	Argilă, tone	Cenușă, tone	Materiale organice, tone	CO, mg/m ³	NO, mg/m ³	CH ₄ , mg/Nm ³
12.896	578.546	123.77	25.022	864.597	87.964	241.18
13.208	581.269	107.839	25.129	889.921	78.558	308.368
12.653	398.821	70.999	19.987	891.191	91.429	83.235
13.104	423.329	123.272	25.129	903.532	85.727	223.315
12.445	398.821	70.999	25.129	952.124	85.256	77.318
12.41	583.992	68.509	25.022	919.141	83.59	258.731
12.999	578.546	123.272	25.129	866.244	84.493	273.002
13.173	360.699	107.341	25.129	951.917	83.2	201.009
12.479	398.821	68.509	21.165	933.974	92.196	75.094
13.104	387.93	82.449	25.129	940.948	84.239	146.211

6.4.2. Optimizarea procesului folosind diferiți algoritmi inspirați din comportamentul uman și comportamentul virușilor

În această secțiune, sunt testați diferiți algoritmi de inspirație biologică (algoritmi de optimizare și modele neuronale) cu scopul determinării valorilor optime pentru cantitățile de produs uscat, argilă, cenușă, materiale organice, coji de semințe de floarea soarelui și rumeguș, astfel încât cantitățile de monoxid de carbon și metan eliminate pe coș să fie minime. Datele utilizate aparțin *bazei de date 2* (Anton și colab., 2022).

Au fost utilizați 10 algoritmi de optimizare mono-obiectiv, inspirați din comportamentul uman și comportamentul virușilor, respectiv: *Simple Human Learning Optimization Algorithm*, *Teaching-Learning*

Based Optimization Algorithm, Social Learning Optimization, Football Game Algorithm, Volleyball Premier League Algorithm, Imperialist Competitive Algorithm, Viral System, Virulence Optimization Algorithm, Virus Colony Search și Virus Optimization Algorithm.

Fiind vorba de *optimizare mono-obiectiv* au fost formulate două probleme ce folosesc aceleași 6 variabile de decizie, dar funcții obiectiv diferite, respectiv minimizarea cantității de CH₄ și a cantității de CO. Metodologia implementată pentru modelare (detalii în capitolul 5) și optimizare este prezentată în figura 6.4.

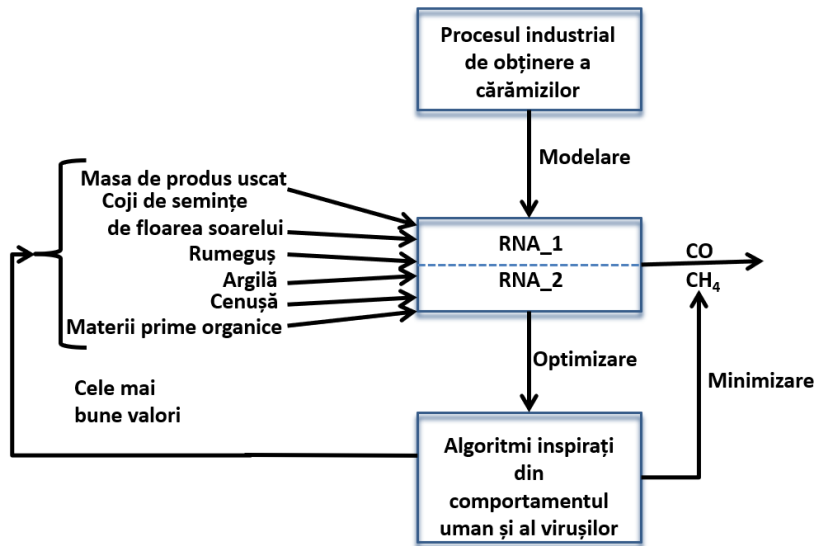


Figura 6.4. Metodologie de modelare și optimizare cu algoritmi inspirați din comportamentul uman și al virusurilor

6.4.2.1. Minimizarea cantității de CO

Rezultatele obținute referitoare la cantitatea de CO sunt prezentate în tabelul 6.4. În acest caz, modelul folosit a fost o rețea neuronală cu două straturi, RN(6:20:16:1), cu performanțele: MSE = 0.0578, $r^2 = 0.786$, $E_p = 5.79\%$. Pentru algoritmi Simple Human Learning Optimization, Teaching-Learning Based Optimization, Imperialist Competitive și Virus Colony Search, valorile pentru variabilele de decizie în minimizarea cantității de CO sunt: 0% semințe de floarea soarelui, 0.5% rumeguș, 729.677 tone argilă, 108 tone cenușă și 3.4 tone materiale organice.

Tabelul 6.4. Rezultate obținute cu algoritmi de inspirație biologică pentru minimizarea CO (mg/m³)

Algoritmi de optimizare	Cea mai bună soluție ([intrări] ⇒ ieșire)		Performanță (100 simulări)
Simple Human Learning Optimization Algorithm	[0.000, 0.523, 14.310, 729.676, 133.477, 8.564] ⇒ 627.567	Timp de rulare mediu: 169.9 Deviația standard pentru timpul de execuție: 33.783 Nr. mediu de evaluări: 100100 Deviația standard pentru nr. de evaluări: 0	Cea mai bună soluție: 627.567 Soluție medie: 627.567 Deviația standard pentru soluție: 0

Algoritmi de optimizare	Cea mai bună soluție ([intrări] ⇒ ieșire)	Performanță (100 simulări)	
Teaching-Learning Based Optimization Algorithm	[0.000, 0.529, 14.305, 729.677, 133.477, 8.547] ⇒ 627.567	Timp de rulare mediu: 723.3 Deviația standard pentru timpul de execuție: 3.466 Nr. mediu de evaluări: 200100 Deviația standard pentru nr. de evaluări: 0	Cea mai bună soluție: 627.567 Soluție medie: 627.567 Deviația standard pentru soluție: 0.002
Social Learning Optimization	[0.056, 0.565, 14.268, 375.746, 240.888, 1.403] ⇒ 627.567	Timp de rulare mediu: 70 Deviația standard pentru timpul de execuție: 11.747 Nr. mediu de evaluări: 16030 Deviația standard pentru nr. de evaluări: 0	Cea mai bună soluție: 627.567 Soluție medie: 627.567 Deviația standard pentru soluție: 0
Football Game Algorithm	[0.000, 0.472, 14.611, 729.677, 133.477, 10.382] ⇒ 627.567	Timp de rulare mediu: 55.3 Deviația standard pentru timpul de execuție: 13.252 Nr. mediu de evaluări: 10000 Deviația standard pentru nr. de evaluări: 0	Cea mai bună soluție: 627.567 Soluție medie: 627.568 Deviația standard pentru soluție: 0.001
Volleyball Premier League Algorithm	[0.578, 2.425, 13.460, 682.426, 86.488, 4.182] ⇒ 627.582	Timp de rulare mediu: 1492.3 Deviația standard pentru timpul de execuție: 13.077 Nr. mediu de evaluări: 333938 Deviația standard pentru nr. de evaluări: 1358.68	Cea mai bună soluție: 627.582 Soluție medie: 627.59 Deviația standard pentru soluție : 0.007
Imperialist Competitive Algorithm	[0.000, 0.529, 14.305, 729.677, 133.477, 8.547] ⇒ 627.567	Timp de rulare mediu: 305.7 Deviația standard pentru timpul de execuție: 147.901 Nr. mediu de evaluări: 79520 Deviația standard pentru nr. de evaluări: 39005.3	Cea mai bună soluție: 627.567 Soluție medie: 627.567 Deviația standard pentru soluție: 0.002
Viral System	[1.809, 0.268, 11.717, 723.748, 98.529, 5.989] ⇒ 627.583	Timp de rulare mediu: 6.7 Deviația standard pentru timpul de execuție: 4.562 Nr. mediu de evaluări: 175.1 Deviația standard pentru nr. de evaluări: 23.927	Cea mai bună soluție: 627.583 Soluție medie: 627.583 Deviația standard pentru soluție: 0
Virulence Optimization Algorithm	[3.673, 0.302, 12.475, 391.974, 183.682, 33.514] ⇒ 627.571	Timp de rulare mediu: 442.3 Deviația standard pentru timpul de execuție: 130.741 Nr. mediu de evaluări: 5662.5 Deviația standard pentru nr. de evaluări: 654.742	Cea mai bună soluție: 627.571 Soluție medie: 627.682 Deviația standard pentru soluție: 0.179
Virus Colony Search	[0.002, 0.595, 14.249, 729.497, 133.256, 8.370] ⇒ 627.567	Timp de rulare mediu: 0.9 Deviația standard pentru timpul de execuție: 2.7 Nr. mediu de evaluări: 33110 Deviația standard pentru nr. de evaluări: 17291.1	Cea mai bună soluție: 627.567 Soluție medie: 627.568 Deviația standard pentru soluție: 0.002
Virus Optimization Algorithm	[0.264, 0.494, 14.517, 715.361, 130.378, 11.070] ⇒ 627.567	Timp de rulare mediu: 0.1 Deviația standard pentru timpul de execuție: 0.03 Nr. mediu de evaluări: 6550.8 Deviația standard pentru nr. de evaluări: 802.434	Cea mai bună soluție: 627.567 Soluție medie: 627.578 Deviația standard pentru soluție: 0.008

Cele mai bune rezultate au fost obținute cu algoritmi Simple Human Learning Optimization, Taching-Learning Based Optimization și Imperialist Competitive. Un exemplu de astfel de rezultate (selectate să nu coincidă cu valorile lor extreme) este următorul: 1.9% coji de semințe de floarea soarelui, 0.8% rumeguș, 14.9 kg produse uscate, 510.8 tone argilă, 18.2 tone cenușă și 26.2 tone materiale organice.

Referitor la avantajele și dezavantajele algoritmilor de optimizare aplicați, trebuie subliniat faptul că un lucru important într-o astfel de abordare este specificul problemei (procesului). Acesta este și motivul pentru care au fost testați 10 algoritmi de optimizare, urmărind calitatea soluției și durata execuției. În plus, trebuie ținut cont și de accesibilitatea metodei. Dar, odată implementată, aceasta poate fi folosită cu ușurință chiar și de către utilizatorul nespecialist în programare datorită interfeței grafice. Încă un lucru important de menționat – adaptarea metodei la alte procese sau seturi de date se poate face cu ușurință.

Cele două probleme de optimizare rezolvate cu algoritmi inspirați din comportamentul virușilor arată că adăugarea de coji de semințe și de rumeguș în amestecul utilizat la fabricarea cărămizilor contribuie la creșterea cantităților de CO și CH₄ evacuate la coșul de ardere. Totuși, căldura generată în timpul arderii cojilor de semințe și a rumegușului înlocuiește căldura necesară procesului de fabricație, ceea ce înseamnă o reducere de consum energetic.

6.4.3. Optimizare hibrid-evolutivă aplicată modelării procesului de obținere a cărămizilor

Se abordează problema prin căutarea unui model de regresie care să reprezinte în mod adecvat relația dintre ingredientele de intrare și emisiile de ieșire în cadrul procesului de fabricare a cărămizilor. Modelul se bazează pe o rețea neuronală complet conectată ale cărei ponderi și hiperparametri sunt deduși printr-un optimizator personalizat. Având în vedere complexitatea procesului de bază, se propune un *optimizator hibrid de rețele neuronale* care combină avantajele unei *versiuni modificate a algoritmului competitiv imperialist* (ICA) (Atashpaz-Gargari și Lucas, 2007) și optimizarea bazată pe *gradient descent*. Metoda rezultată implică *deducerea arhitecturii și ponderilor optime ale rețelei neuronale* astfel încât modelul de regresie să descrie cel mai bine relația dintre intrările procesului de fabricare a cărămizilor și emisiile de gaze rezultate la coșul cuptorului. Acest model este utilizat în continuare pentru a *optimiza procesul*, astfel încât emisiile menționate mai sus să fie minimizate.

Obținerea modelului de regresie, bazat pe o rețea neuronală, implică parcurgerea a două etape esențiale: (1) reprezentarea rețelei în conformitate cu cerințele optimizatorului evolutiv și (2) optimizarea parametrilor modelului prin intermediul algoritmului evolutiv.

6.4.3.2. Optimizarea procesului de fabricare a cărămizilor

Se utilizează în continuare modelul dezvoltat anterior pentru a optimiza procesul de fabricare a cărămizilor, urmărind reducerea emisiilor de CO și CH₄. Se formulează astfel o problemă de *optimizare neconstrânsă cu dublu obiectiv*, în care scopul este de a determina seturi de valori pentru intrările în procesul de fabricație care au ca rezultat emisii minime de CO și CH₄ (adică procentele de rumeguș și coji de semințe și cantitățile de argilă, cenușă și materii prime organice). Se folosește modelul de regresie

reprezentat de cea mai bună rețea neuronală determinată anterior cu optimizatorul hibrid, aceasta reprezentând cel mai bine dependența ieșirilor de intrările sistemului.

În optimizarea procesului, se aplică Algoritmul Genetic de Sortare Nedominat-II (NSGA-II) pentru a căuta în spațiul parametrilor de intrare soluții nedominate, adică seturi de parametri de intrare care oferă cele mai bune compromisuri în ceea ce privește minimizarea ambelor ieșiri. Figura 6.7 prezintă frontul Pareto al problemei în spațiul 2D al celor două obiective de optimizare. Fiecare punct care formează granița din figura 6.7 reprezintă un compromis între reducerea la minimum a emisiilor de CO și CH₄. Deplasarea în ambele direcții pe acest front înseamnă că, pe măsură ce o ieșire are o valoare din ce în ce mai mică, cealaltă ieșire este din ce în ce mai mare ca valoare. În consecință, nu se ajunge la compromisuri mai bune în ceea ce privește minimizarea simultană a ambelor rezultate.




Figura 6.7. Reprezentarea frontului Pareto al problemei de optimizare care conține valorile de ieșire rezultate din soluții nedominate

Rezultatele obținute prin simulare sunt utile pentru practica industrială înlocuind experimente care consumă resurse semnificative de timp, energie și materiale.

CAPITOLUL 7

Modelarea și optimizarea procesului de fabricare a cărămizilor folosind programe Python

7.3. Metodologia de modelare și optimizare implementată în Python

În figura 7.2, este ilustrată tehnica neuro-evolutivă, rezultată din combinarea rețelelor neuronale cu un optimizator evolutiv, implementată în Python. Sunt evidențiate cele două etape:

1. proiectarea modelului neuronal
2. optimizarea procesului cu NSGA

Se dezvoltă diferite modele neuronale, se fac încercări pentru diferite configurații ale rețelelor neuronale și ale parametrilor funcționali ale acestora, apoi cel mai bun model se alege funcție de eroarea procentuală și coeficientul de corelație.

În procedura de optimizare se introduc diferite modele, dar obligatoriu dintre cele cu coeficient de corelație ridicat și se obțin ca rezultate valori optime ale variabilelor de decizie (masa de produs uscat, cantitățile de coji de semințe de floarea soarelui, rumeguș, argilă, cenușă și materii organice) care conduc la minimizarea simultană a cantităților de metan, monoxid de carbon și monoxid de azot (*optimizare multiobiectiv*).

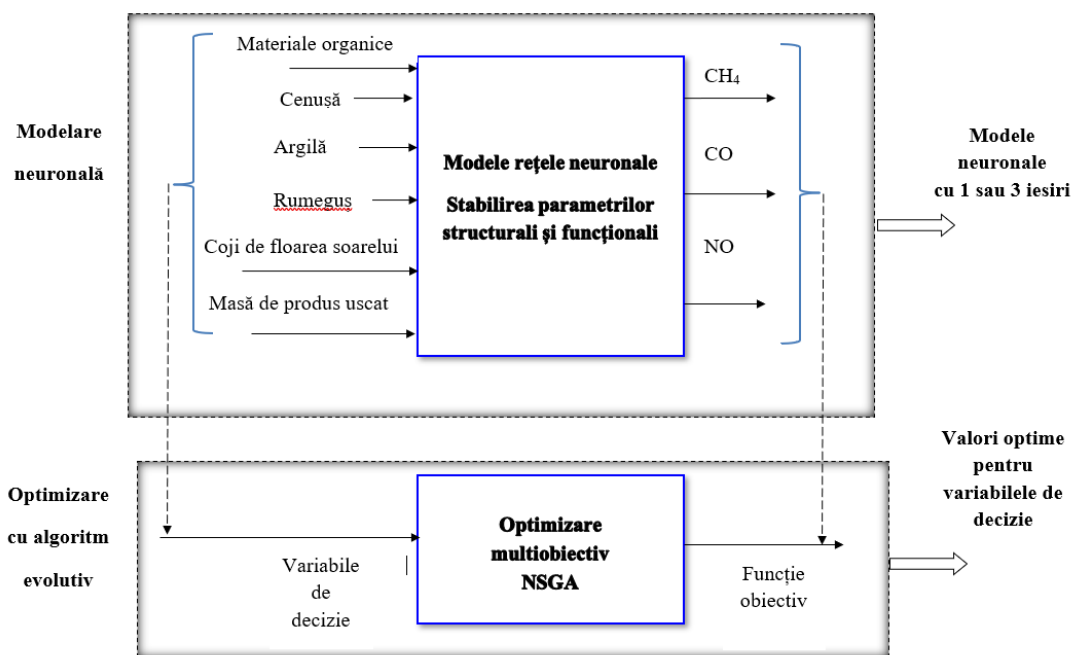


Figura 7.2. Tehnica neuro-evolutivă implementată în Python pentru modelare și optimizare

7.4. Rezultate de modelare și optimizare pentru procesul de fabricare a cărămizilor

Sunt abordate mai multe strategii de modelare și optimizare, modificările fiind efectuate funcție de rezultatele obținute. Astfel, sunt proiectate modele neuronale cu 5 sau 6 intrări, 3 sau o singură ieșire și număr diferit de straturi intermediare și neuroni ascunși. Doar modelele considerate bune sunt introduse în procedura de optimizare multi-obiectiv, considerându-se că doar în acest mod rezultatele sunt de încredere.

Rezultate de modelare sunt prezentate în tabelul 7.2, iar modelului 5:128:64:32:3 îi sunt atașate, ca exemple, reprezentările grafice 7.13. și 7.14.

Tabelul 7.2. Rețele neuronale proiectate în Python în cadrul strategiei 2

Arhitectură de rețea	E_p antrenare (%)	r antrenare	E_p testare	r testare (%)
5:128:64:3	16.63	0.821	16.06	0.655
5:128:64:32:3	13.99	0.830	19.02	0.720

Aceste modele, fiind considerate satisfăcătoare, au fost introduse în programul de optimizare multi-obiectiv, frontul Pareto pentru al doilea model din tabel fiind vizibil în figura 7.17.

Ca în orice situație specifică optimizării multi-obiectiv, inginerul tehnolog are la îndemână mai multe soluții, respectiv mai multe valori pentru variabilele de decizie reprezentate de cantitățile de materiale

necesare fabricării cărămizilor și pentru funcțiile obiectiv, respectiv cantitățile minime de gaze evacuate la coșul de ardere.

Un aspect important de menționat se referă la aplicarea acestor rezultate în practica industrială cu rezultate bune.




Figura 7.13. Date experimentale și predicții ale modelului 5:128:64:32:3 pentru monoxid de carbon




Figura 7.14. Date experimentale și predicții ale modelului 5:128:64:32:3 pentru metan




Figura 7.17. Frontul Pareto pentru optimizare cu modelul 5:128:64:32:3

CAPITOLUL 8

Concluzii generale

8.1. Principalele concluzii rezultate din cercetările incluse în teză

Conform structurii tezei, respectiv a metodologiilor aplicate și a rezultatelor obținute, această secțiune va fi organizată pe următoarele direcții:

- proces tehnologic și experimente efectuate
- baze de date
- procesarea datelor și prelucrări statistice
- modele empirice
- optimizarea modelelor și a procesului
- instrumente IA folosite și metodologii elaborate

✚ Procesul abordat – **fabricarea cărămizilor din materiale pe bază de argilă** – face parte din procesele energofage deoarece atingerea temperaturilor necesare transformărilor chimice presupun consumuri semnificative de combustibil. De aceea, în ultimii ani, a fost acordată atenție materialelor de natură organică (deșeuri ale industriei agricole – coji de semințe de floarea soarelui, de orez, de soia) care, prin aportul lor energetic, duc la diminuarea consumurilor de combustibili fosili și la reducerea costurilor de fabricație, menținând însă performanțele procesului (productivitate) și calitatea produsului.

Fluxul tehnologic al procesului include fazele: *extragere argilă, preparare materii prime, fasonare, uscare, descărcare/așezare produse uscate, ardere, descărcare/paletizare produse arse, ambalare, depozitare, livrare*. Din acest flux, interesează prepararea materiilor prime, respectiv componentele necesare și proporția acestora, precum și cantitățile de gaze evacuate (metan, oxizi de carbon și azot).

✚ S-a realizat un **studiu experimental** detaliat pentru evaluarea impactului modificării mixului de fabricație asupra procesului de ardere pentru care au fost considerați drept indicatori gazele exhaustate la coșul de fum al cuptorului. Analiza acestor gaze s-a realizat folosind un analizor de gaze arse tip Testo 350, dotat cu celule de detectare și măsurare specifice gazelor de interes (CO , NO_x , C_xH_y) calibrate și etalonate metrologic. Determinările experimentale au fost efectuate în condiții similare - aceeași masă în cuptor, aceeași viteză de ardere (ritm), aceeași curbă de ardere și același loc de prelevare.

S-a constatat că rețeta care conține rumeguș are tendința de a genera în gazele exhaustate o cantitate mai mare de gaze cu potențial energetic, dar, din punct de vedere al protecției mediului, aceste produse au un potențial mai mare de a genera emisii de poluanți. Inginerii de proces au misiunea de a găsi prin șarje test sau prin simulare (așa cum s-a procedat în această lucrare) mixul de materii prime care să conducă la menținerea și îmbunătățirea performanțelor produselor, pe aceeași instalație, respectând aceleași curbe de ardere, în condiții economice avantajoase. De asemenea, trebuie să reducă cantitatea de gaze poluante degajate. Deși în cazul rețetelor ce utilizează coji de semințe de floarea soarelui se degajă o cantitate mai mică de gaze cu

potențial energetic, este de preferat utilizarea acestora deoarece cantitatea de oxizi de azot exhaustați la coșul de fum al cuptorului este mai mică.

✚ S-au constituit **două baze de date** pe baza măsurătorilor experimentale realizate într-o fabrică de cărămizi ce produce 9000 de piese/zi. Prima bază de date a inclus informații cu privire la masa de produs uscat utilizat, cantitatea de argilă, cantitatea de cenușă, cantitatea de materii prime organice și valorile noxelor măsurate la coș, respectiv CO, NO și CH₄, pentru 121 șarje de cărămizi. Cea de a doua bază de date a fost obținută pe baza testelor experimentale realizate pe aceeași instalație industrială pentru obținerea cărămizilor și a inclus în plus informații cu privire la mixul de fabricație care a fost modificat prin introducerea de coji de semințe de floarea soarelui și rumeguș, în proporții cuprinse între 0 și 3.5%. Pentru această bază de date, s-au considerat informații despre compoziția procentuală masică a cojilor de semințe de floarea soarelui și a rumegușului, masa produsului uscat, cantitatea de argilă, cantitatea de cenușă, cantitatea de materii prime organice și cantitățile de CO, CH₄ și NO evacuate în coșul cuptorului în procesul de fabricație a 100 loturi de cărămizi.

✚ **Prelucrările statistice** au furnizat informații cu privire la: valorile medii, deviația standard, eroarea standard a mediei, intervalul de încredere a mediei, amplitudinea, valoarea maximă, valoarea minimă, mediana, intervalul de distribuție a 25% dintre date, a 75% dintre date, distribuția normale a datelor (testele Skewness și Kurtosis, testul Kolmogorov – Smirnov, testul Shapiro–Wilk), suma datelor și suma pătratelor ce reprezintă abaterea de la valoarea medie. Se constată valori mai mici pentru *deviația standard* pentru masa de produs uscat și cantitatea de materii prime organice, ceea ce indică o împrăștiere mai mică a acestor date experimentale. *Amplitudinea*, respectiv diferența dintre valoarea maximă și cea minimă, care indică plaja de valori în care se întinde distribuția datelor experimentale, are valori cuprinse între 8 și 963. *Mediana*, parametrul statistic ce reprezintă mijlocul seriei de date, dacă aceasta este organizată în sens crescător sau descrescător, are valori apropiate de valoarea medie, ceea ce indică o distribuție uniformă a datelor experimentale. *Indicii de aplatizare a curbei de variație* a datelor analizate (Kurtosis) au valori mici, ceea ce reprezintă o bună repartiție a datelor, respectiv faptul că sunt puține date care au valori mult diferite de medie. *Testele de normalitate Kolmogorov–Smirnov și Shapiro–Wilk* indică o distribuție normală a valorilor noxelor măsurate la coș, evidențiind suprapunerea cu distribuția Gaussiană.

✚ Pentru **modelarea procesului abordat** s-au utilizat bazele de date amintite mai sus, selectându-se ca mărimi de intrare cantitățile de coji de semințe de floarea soarelui, rumeguș, argilă, cenușă, materiale uscate și materiale organice, iar ca variabile de ieșire, volumele de metan, oxid de carbon și oxid de azot.

S-au realizat *modelări* care diferă prin:

- tipul de model dezvoltat;
- numărul variabilelor de intrare și ieșire folosite;
- baza de date utilizată;
- parametrii structurali și funcționali ai modelelor;

- metoda prin care au fost proiectate modelele.

1. Prima variantă de modelare s-a realizat prin metoda încercărilor succesive, proiectând *rețele neuronale* cu 4 intrări (argilă, cenușă, masa de produs uscat și masa de produse organice) și o ieșire, respectiv CH₄, CO și NO (succesiv). Drept criterii de alegere a celei mai bune topologii de rețea s-au folosit eroarea pătratică medie (MSE), coeficientul de corelație (r) și eroarea procentuală E_p (%). Folosind baza de date 1, cele mai bune rețele neuronale, cu performanțele lor sunt prezentate în tabelul 8.1.

Tabelul 8.1. Cele mai bune rețele neuronale în varianta 1 de modelare, baza de date 1

Ieșire	Topologie	MSE	r^2	E_p (%)
CO	RN(4:60:30:1)	0.0123	0.825	4.76
NO	RN(4:40:20:1)	0.0082	0.895	5.88
CH ₄	RN(4:60:30:1)	0.0070	0.902	33.63

S-a procedat la fel pentru baza de date 2, considerându-se în acest caz 6 intrări, deci adăugând cantitățile de coji de semințe de floarea soarelui și de rumeguș. Tabelul 8.2 conține cele mai bune modele neuronale cu performanțele lor.

Dat fiind faptul că experimentele au fost efectuate la scară industrială, performanțele asociate modelelor neuronale sunt considerate foarte bune. De remarcat că nu s-au putut obține modele bune cu 3 ieșiri (modelarea simultană a celor trei gaze evacuate funcție de compoziția amestecului inițial).

Tabelul 8.2. Cele mai bune rețele neuronale în varianta 1 de modelare, baza de date 2

Ieșire	Topologie	MSE	r^2	E_p (%)
CO	RN(6:20:16:1)	0.0128	0.959	2.19
NO	RN(6:18:6:1)	0.01195	0.0733	0.9626
CH ₄	RN(6:30:18:1)	0.0085	0.973	9.59

Posibilitatea de a realiza predicții pentru cantitățile de CH₄, NO_x și CO (gaze cu potențial energetic și gaze cu caracter poluant) în gazele exhaustate permite ca în procesul decizional să se ia hotărârea de a investi în re tehnologizarea instalației sau de a schimba unele limite de operare, astfel încât performanțele procesului și a produselor să rămână în zona de confort, iar costurile să fie îmbunătățite.

2. Pe lângă rețele neuronale, au fost testate și alte modele de regresie, cum ar fi: *Nearest Neighbor* (NN) și *k- Nearest Neighbor* (kNN), *algoritmul K**, *Support Vector Regression* (SVR), *Random Forerst* (RF). Acești algoritmi au fost testați în diferite variante, respectiv cu diferiți parametri. Cel mai bun rezultat a fost obținut cu *Random Forest* (tabelul 8.3).

Rezultatele obținute cu modelele de regresie menționate, la fel ca și cele tip rețea neuronală, pot fi considerate acceptabile, având în vedere faptul că experimentele au fost realizate în condiții industriale, ceea ce presupune valori semnificative pentru cantitățile de materiale, timp de efectuare și energia necesară.

Tabelul 8.3. Modelare cu Random Forest

Random Forest (1000 trees)	Antrenare	0.9613	0.9468	0.9612
	Validare încrucișată	0.6045	0.4878	0.7384

3. A treia variantă de modelare se bazează pe un program Python creat prin utilizarea platformei *PyTorch*. Modelele dezvoltate au avut 6 sau 5 intrări (s-a scos argila considerându-se că are influență mică asupra cantității gazelor evacuate), iar ieșirile au fost 1 sau 3. Această tehnică de modelare se remarcă, pe lângă metodologia diferită, prin faptul că s-au putut obține modele satisfăcătoare cu 3 ieșiri, deci o singură rețea neuronală reușește să redea dependența celor trei ieșiri de variabilele de intrare considerate (compoziția materiei prime). Pentru cazurile abordate, cele mai bune modele neuronale sunt date în tabelul 8.4.

Tabelul 8.4. Modele – varianta3, Python-Pytorch

Ieșiri	Arhitectură de rețea	E_p antrenare (%)	r antrenare	E_p testare	r testare (%)
CH ₄ , CO, NO	6:128:64:32:3	26.72	0.646	20.64	0.588
CH ₄ , CO, NO	5:128:64:32:3	13.99	0.830	19.02	0.720
CO	5:128:64:32:1	6.44	0.741	8.54	0.798
CH ₄	5:128:64:32:1	7.25	0.860	8.11	0.897
NO	5:128:64:32:1	14.63	0.548	16.52	0.598

4. Dezvoltarea unui model neuronal în variantă optimă: modelul se bazează pe o rețea neuronală complet conectată ale cărei ponderi și hiperparametri sunt deduși printr-un optimizator personalizat. Având în vedere complexitatea procesului de bază, se propune un *optimizator hibrid de rețele neuronale* care folosește avantajele unei *versiuni modificate a algoritmului competitiv imperialist* (ICA). Metoda rezultată implică *deducerea arhitecturii și ponderilor optime ale rețelei neuronale* astfel încât modelul de regresie să descrie cel mai bine relația dintre intrările procesului de fabricare a cărămizilor și emisiile de gaze rezultate la coșul cuptorului. Modelul cu cea mai bună performanță a avut corelația 0.929.

✚ Cele mai bune modele, au fost integrate în **proceduri de optimizare mono- sau multi-obiectiv**. Optimizarea presupune identificarea valorilor optime pentru variabilele de decizie, respectiv mărimile de intrare (masa produsului uscat, argilă, cenușă și materii prime organice) care conduc la valori minime ale ieșirilor (CO, NO și CH₄).

Pentru optimizarea multiobiectiv s-a aplicat o *căutare tip grilă* – metodă adecvată atunci când dimensionalitatea problemei este redusă și când interesează calitatea soluției, mai degrabă decât viteza de rezolvare – care furnizează un set cuprinzător de soluții (fronturile Pareto).

În optimizarea mono-obiectiv, s-au formulat probleme separate pentru minimizarea fiecăruia dintre cele trei gaze evacuate, folosindu-se algoritmi de inteligență artificială mai puțin cunoscuți (inpirați din comportamentul uman, individual sau de grup, și din comportamentul virusilor): Au fost utilizați 10 algoritmi de optimizare mono-obiectiv, inspirați din comportamentul uman și comportamentul virusilor, respectiv: *Simple Human Learning Optimization Algorithm*, *Teaching-Learning Based Optimization Algorithm*, *Social Learning Optimization*, *Football Game Algorithm*, *Volleyball Premier League Algorithm*, *Imperialist Competitive Algorithm*, *Viral System*, *Virulence Optimization Algorithm*, *Virus Colony Search* și *Virus Optimization Algorithm*.

Exemple de rezultate de optimizare sunt prezentate în secțiunea următoare a acestui capitol.

✚ Instrumente IA și metodologii:

- *Sigma Plot* pentru analiză statistică
- *NeuroSolutions* pentru modelare neuronală
- *Weka* pentru modele de regresie
- *Python-Pytorch* pentru modelare și optimizare

✚ Comparativ cu **abordările din literatură**, se subliniază următoarele aspecte:

- *rețeta de fabricare a cărămidilor* care stă la baza cercetării originale nu a mai fost utilizată până acum;
- *bazele de date* sunt rezultatul unor investigații proprii realizate la nivel industrial (față de majoritatea abordărilor descrise care utilizează date din literatură):
- *metodologiile de simulare* sunt originale, furnizând rezultate bune a căror utilitate a fost demonstrată prin imediata aplicare în practica industrială.

8.2. Considerații practice

O realizare importantă a acestei teze este utilizarea în practica industrială a rezultatelor obținute ceea ce contribuie la reducerea numărului de teste (încercări), deoarece, prin optimizare, se obține rețeta amestecului inițial care conduce la volume minime ale gazelor evacuate. Cu atât mai mult în optimizarea multi-obiectiv în care se obțin numeroase soluții, inginerul tehnolog poate alege din frontul Pareto soluțiile convenabile care respectă criteriile impuse. Tabelul 8.5 prezintă câteva exemple.

Tabelul 8.5. Rezultate de optimizare selectate din domeniul Pareto

Coji de semințe (%)	Rumeguș (%)	Materiale uscate (kg)	Cenusa (tone)	Materiale organice, (tone)	CO (mg/m ³)	CH ₄ (mg/Nm ³)	NO _x (mg/mc)
2.282	0.077	10.009	113.601	29.99	755.055	75.279	0.005
2.065	0	10.193	108.996	29.774	672.723	88.854	4.044
2.363	0.011	10.124	113.601	29.972	751.283	75.986	0.003
2.235	0	10.182	108.996	29.615	685.046	78.749	3.354

Criteriile avute în vedere la selecția rețetelor de mix de fabricație din tabelul 8.5 sunt următoarele:

- Păstrarea instalației existente fără investiții sau modificări.
- Simplitatea, fiind mai ușor de adăugat un singur component (coji de semințe), decât două componente (coji de semințe și rumeguș).
- Păstrarea productivității pe lanțul tehnologic (alimentare-preparare-fasonare-uscare).
- Aceleași proprietăți ale produsului finit (dimensiuni, rezistență la compresiune).
- Minimum de gaze cu potențial energetic evacuate la coșul de fum (CO și CH₄).

8.3. Aspecte originale ale tezei

O primă mențiune se referă la faptul că sunt foarte puține abordări în literatură care aplică instrumentele inteligenței artificiale în procesul de fabricare a cărămizilor.

În teză se pot evidenția următoarele elemente de originalitate:

- experimente originale, în număr semnificativ, realizate la scară industrială;
- modelări cu specific propriu în ceea ce privește variabilele considerate;
- metodologii proprii de modelare și optimizare;
- aplicarea în industrie a rezultatelor de modelare și optimizare.

ACTIVITATE ȘTIINȚIFICĂ

Lucrări științifice publicate în reviste internaționale cotate ISI

1. **Anton C.**, Curteanu S. (corresponding author), Lisa C., Leon F. (2021). Machine learning methods applied for modeling the proces of obtaining bricks using silicon-based materials. *Materials*, 14(23), 7232. <https://doi.org/10.3390/ma14237232>. (FI 3,1 – Q1, 5 citări).
2. **Anton C.**, Leon F., Gavrilesu M., Dragoi E-N., Floria S-A, Curteanu S., Lisa C. (2022). Obtaining Bricks Using Silicon-Based Materials: Experiments, Modeling and Optimization with Artificial Intelligence Tools. *Mathematics*, 10(11), 1891. <https://doi.org/10.3390/math10111891>. (FI 2,3 – Q1, 4 citări).

Lucrări științifice în curs de publicare în reviste internaționale cotate ISI:

1. **Anton, C.**, Leon, F., Curteanu S. (corresponding author) „Modelling and optimization of the process of obtaining bricks using biologically inspired algorithms” (în curs de publicare). *Environmental Engineering and Management Journal* (FI 0.9 – Q4).

Lucrări științifice publicate în reviste indexate BDI:

1. **Anton C.**, Curteanu S. (2022). Assessment of the impact of changes in the combustion process in a brick-making plant which the manufacturing mix changes. *BULETINUL INSTITUTULUI POLITEHNIC DIN IAȘI*, 68(72), 43-50.

Lucrări științifice publicate în volumele conferințelor internaționale:

1. Gavrilescu M., Floria S-A, Leon F., Curteanu S., **Anton C.** (2023). A Hybrid-Evolutionary Optimizer for Modelling the Process of Obtaining Bricks, Proceedings of the 17th International Conference on Machine Intelligence and Soft Computing Technologies (ICMISCT 2023), Stockholm, Sweden, July 2023, baza de date EBSCO.
2. Floria S-A., Gavrilescu M., Leon F., Curteanu S., **Anton C.**, Neuroevolution based on adaptive ensembles of biologically inspired optimization algorithms applied for modelling a chemical engineering process, Proceedings of the 17th International Conference on Computational Engineering and Applications (ICCEA 2023) Istanbul, Turkey, October 2023 International Conference – 2023-ICCEA, 16-17 Octobre, 2023, Istanbul, Turcia.
3. **Anton C.**, Lisa C., Curteanu S. (2022) Modeling of brick obtaining proces with artificial neural networks. In: Conferința tehnico-științifică a studenților, masteranzilor și doctoranzilor, 29-31 martie 2022, Chișinău. Chișinău, Republica Moldova: Tehnica-UTM, 2022, Vol.1, pp. 168-171. ISBN 978-9975-45-828-3.

Brevete de invenție:

1. Curteanu S., Leon F., Gavrilescu M., Floria S-A., **Anton C.**, Lisa C., Utilizarea unor algoritmi de inspirație biologică la minimizarea noxelor în procesul de obținere a cărămizilor Înregistrat la ORDA, Registrul de opere, nr. 4670/20.11.2023.
2. Curteanu S., Leon F., Gavrilescu M., Floria S-A., **Anton C.**, Lisa C. Modelarea procesului de fabricație a cărămizilor folosind ansambluri de metode evolutive de inspirație biologică și socială. Înregistrat la ORDA, Registrul de opere, nr. 4805/29.11.2023.

Participări la conferințe internaționale:

1. **Anton C.**, Lisa C., Leon F., Gavrilescu M., Floria S., Curteanu S. (2023). Minimizing NO_x emission in a brick manufacturing process, comunicare orală la 12th International Conference on Environmental Engineering and Management, 13-16 September 2023, Iași, România

2. **Anton C.**, Lisa C., Curteanu S. (2022). Modeling of brick obtaining proces with artificial neural networks. Comunicare orală la Conferința tehnico-științifică a studenților, masteranzilor și doctoranzilor, 29-31 martie 2022, Chișinău. Republica Moldova.
3. **Anton C.**, Curteanu S., Leon F. (2021). A neuro-evolutive method applied for optimizing the process for obtaining bricks using silicon based materials, comunicare orală la Conference of the TUIASI Doctoral School, May 19th-21th, 2021, Iasi, Romania.

Premii:

1. **Anton C. Premiul I** la Conferința tehnico-științifică a studenților, masteranzilor și doctoranzilor, 29-31 martie 2022, Chișinău (1st DEGREE CERTIFICAT Tehnical University of Moldova) pentru prezentarea lucrării Modeling of brick obtaining proces with artificial neural networks.

Bibliografie selectivă

1. Abdellatief, M., Elemam, W. E., Alanazi, H., & Tahwia, A. M. (2023). Production and optimization of sustainable cement brick incorporating clay brick wastes using response surface method. *Ceramics International*, 49(6), 9395–9411. <https://doi.org/10.1016/j.ceram.int.2022.11.144>
2. Ahmad, A.; Farooq, F.; Ostrowski, K.A.; Śliwa-Wieczorek, K.; Czarnecki, S. (2021). Application of Novel Machine Learning Techniques for Predicting the Surface Chloride Concentration in Concrete Containing Waste Material. *Materials*, 14, 2297. <https://doi.org/10.3390/ma14092297>
3. Ahmadi, M., Kheyroddin, A., Dalvand, A., Kioumars, M., (2020). New empirical approach for determining nominal shear capacity of steel fiber reinforced concrete beams. *Construction and Building Materials* 234, 117293. <https://doi.org/10.1016/j.conbuildmat.2019.117293>
4. Ahmed, H. U., Mohammed, A. A., & Mohammed, A. (2022). Soft computing models to predict the compressive strength of GGBS/FA-geopolymer concrete. *PLoS one*, 17(5), e0265846. <https://doi.org/10.1371/journal.pone.0265846>
5. Alekseev, K., Mymrin, V., Avanci, M. A., Klitzke, W., Magalhães, W. L. E., Silva, P. R., Catai, R. E., Silva, D. A., & Ferraz, F. A. (2019). Environmentally clean construction materials from hazardous bauxite waste red mud and spent foundry sand. *Construction and Building Materials*, 229, 116860. <https://doi.org/10.1016/j.conbuildmat.2019.116860>
6. Ali, A., Yazdani, M., Ghanbari, S., Akbarzadeh, H., Jafari, A., & Farrokh, H. (2021). Artificial neural network model to predict the compressive strength of eco-friendly geopolymer concrete incorporating silica fume and natural zeolite. *Journal of Cleaner Production*, 279, 123697. <https://doi.org/10.1016/j.jclepro.2020.123697>
7. Altun, O., (2018). Energy and cement quality optimization of a cement grinding circuit. *Adv. Powder* 29, 1713–1723. <https://doi.org/10.1016/j.apm.2018.04.006>
8. Anton, C., Curteanu, S., Lisa, C., Leon, F. (2021). Machine learning methods applied for modeling the process of obtaining bricks using silicon-based materials. In: *Materials*, 14, pp. 7232. <https://doi.org/10.3390/ma14237232>
9. Anton, C., Leon, F., Gavrilăscu, M., Drăgoi, E.-N., Floria, S.-A., Curteanu, S. and Lisa, C., (2022^a), Obtaining Bricks Using Silicon-Based Materials: Experiments, Modeling and Optimization with Artificial Intelligence Tools, *Mathematics*, vol. 10, no. 11, pp. 1891. <https://doi.org/10.3390/math10111891>
10. Anton, C., Lisa, C., Curteanu, S., (2022^b), Application of artificial neural networks to the modeling of industrial processes, *Technical Scientific Conference of Undergraduate, Master, PhD students Technical University of Moldova, Chisinau, 29-31 March 2022^b, Vol. I, 168-171*, ISBN 978-9975-45-829-0
11. Arora, S., Singh, B., Bhardwaj, B. (2019). Strength performance of recycled aggregate concretes containing mineral admixtures and their performance prediction through various modeling techniques. *Journal of Building Engineering*, 24, 100741 <https://doi.org/10.1016/j.jobbe.2019.100741>
12. Ashrafan, A., Taheri Amiri, M. J., Rezaie-Balf, M., Ozbakkaloglu, T., & Lotf-Omran, O. (2018). Prediction of compressive strength and ultrasonic pulse velocity of fiber reinforced concrete incorporating nano silica using heuristic regression methods. *Construction and Building Materials*, 190, 479–494. <https://doi.org/10.1016/j.conbuildmat.2018.09.047>
13. Ávalos-Rendón, T. L., Chelala, E. A. P., Mendoza Escobedo, C. J., Figueroa, I. A., Lara, V. H., & Palacios-Romero, L. M. (2018). Synthesis of belite cements at low temperature from silica fume and natural commercial zeolite. *Materials Science and Engineering B: Solid-State Materials for Advanced Technology*, 229, 79–85. <https://doi.org/10.1016/j.mseb.2017.12.020>
14. Aziminezhad, M., Mahdikhani, M., & Memarpour, M. M. (2018). RSM-based modeling and optimization of self-consolidating mortar to predict acceptable ranges of rheological properties. *Construction and Building Materials*, 189, 1200–1213. <https://doi.org/10.1016/j.conbuildmat.2018.09.019>
15. Basetti, V., Rangarajan, S. S., Shiva, C. K., Pulluri, H., Kumar, R., Collins, R. E., & Senjyu, T. (2021). Economic Emission Load Dispatch Problem with Valve-Point Loading Using a Novel Quasi-Optimizational-Based Political Optimizer. *Electronics*, 10(21), 2596. <https://doi.org/10.3390/electronics10212596>
16. Behnood, A., & Golafshani, E. M. (2018). Predicting the compressive strength of silica fume concrete using hybrid artificial neural network with multi-objective grey wolves. *Journal of Cleaner Production*, 202, 54–64. <https://doi.org/10.1016/j.jclepro.2018.08.065>

17. Behnood, A., Golafshani, E.M., (2020). Machine learning study of the mechanical properties of concretes containing waste foundry sand. *Construction and Building Materials* 243, 118152. <https://doi.org/10.1016/j.conbuildmat.2020.118152>
18. Belmajdoub, F.; Abderafi, S., (2018). Specific Electricity Consumption optimization of Raw Grinding Workshop in a Moroccan Cement Plant. In *Proceedings of the 2018 6th International Renewable and Sustainable Energy Conference (IRSEC)*, Rabat, Morocco, 5–8 December 2018; pp. 1–6
19. Bhardwaj, B., & Kumar, P. (2019). Comparative study of geopolymer and alkali activated slag concrete comprising waste foundry sand. *Construction and Building Materials*, 209, 555–565. <https://doi.org/10.1016/j.conbuildmat.2019.03.107>
20. Biswas, R., Bardhan, A., Samui, P., Rai, B., Nayak, S., Armaghani, D.J., (2021). Efficient soft computing techniques for the prediction of compressive strength of geopolymer concrete. *Computers and Concrete* 28 (2), 221–232. <https://doi.org/10.12989/cac.2021.28.2.221>
21. Bouzidi, M. A., Bouzidi, N., Eliche Quesada, D. (2024). Prediction of mechanical and physical properties of spent bleaching earth based fred bricks: an experimental study using RSM and ANN. *Asian Journal of Civil Engineering*, 25,5811–5833. <https://doi.org/10.1007/s42107-024-01148-z>
22. Bouzidi, M. A., Bouzidi, N., & Tahakourt, A. (2018). Valorization of Iron Ore Benefciation Rejects from the Iron Deposit of Boukhadra (Algeria) in the Fabrication of Ordinary Portland Cement. In *Thermo-Mechanics Applications and Engineering Technology*. https://doi.org/10.1007/978-3-319-70957-4_3
23. Cao, J., Yan, Z., Xu, X., He, G., Huang, S., (2016). Optimal power flow calculation in AC/DC hybrid power system based on adaptive simplified human learning optimization algorithm. *J. Mod. Power Syst. Clean Energy* 4, 690–701. <https://doi.org/10.1007/s40565-016-0227-2>
24. Cha, Y.J., Choi, W., Büyükoztürk, O. (2017). Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering* 32 (5), 361–378. <https://doi.org/10.1111/mice.12263>
25. Chandra, S.S., Kumar, R., Arjunasamy, A. *et al.* (2025). Predicting the compressive strength of polymer-infused bricks: A machine learning approach with SHAP interpretability. *Sci Rep* 15, 8090. <https://doi.org/10.1038/s41598-025-89606-9>
26. Cheng, MY., Prayogo, D. (2017). A novel fuzzy adaptive teaching–learning-based optimization (FATLBO) for solving structural optimization problems. *Engineering with Computers* 33, 55–69. <https://doi.org/10.1007/s00366-016-0456-z>
27. Coppio, G. J. L., Geimba, M., Lima, D., Lencioni, J. W., Cividanes, L. S., Dyer, P. P. O. L., & Silva, S. A. (2019). Surface electrical resistivity and compressive strength of concrete with the use of waste foundry sand as aggregate. *Construction and Building Materials*, 212, 514–521. <https://doi.org/10.1016/j.conbuildmat.2019.03.297>
28. Cultrone, G. (2022). The use of Mount Etna volcanic ash in the production of bricks with good physical-mechanical performance: Converting a problematic waste product into a resource for the construction industry. *Ceramics International*,48(4),5724–5736. <https://doi.org/10.1016/j.ceramint.2021.11.119>
29. Dabiri, H., Kioumarsi, M., Kheyroddin, A., Kandiri, A., Sartipi, F., (2022). Compressive strength of concrete with recycled aggregate; a machine learning-based evaluation. *Cleaner Materials* 3, 100044. <https://doi.org/10.1016/j.clema.2022.100044>
30. Dao, D. V., Ly, H.-B., Trinh, S. H., Le, T.-T., & Pham, B. T. (2019). Artificial Intelligence Approaches for Prediction of Compressive Strength of Geopolymer Concrete. *Materials*, 12(6), 983. <https://doi.org/10.3390/ma12060983>
31. Das, S. P., & Padhy, S. (2018). A novel hybrid model using teaching–learning-based optimization and a support vector machine for commodity futures index forecasting. *International Journal of Machine Learning and Cybernetics*, 9(1), 97–111. <https://doi.org/10.1007/s13042-015-0359-0>
32. de la Casa, J. A., & Castro, E. (2018). Fuel savings and carbon dioxide emission reduction in a fred clay bricks production plant using olive oil wastes: A simulation study. *Journal of Cleaner Production*, 185, 230–238. <https://doi.org/10.1016/j.jclepro.2018.03.010>
33. Deng Z., Liu B., Ye B., Xiang P. (2020). Mechanical behavior and constitutive relationship of the three types of recycled coarse aggregate concrete based on standard classification. *J Mater Cycles Waste Manag* 22(1):30–45. <https://doi.org/10.1007/ s10163-019-00922-5>
34. Deng, F., He, Y., Zhou, S., Yu, Y., Cheng, H., Wu, X. (2018). Compressive strength prediction of recycled concrete based on deep learning. *Construction and Building Materials* 175, 562–569. <https://doi.org/10.1016/j.conbuildmat.2018.04.169>

35. DigitalDefynd, (2025). 10 ways AI is being used by the Cement Industry, <https://digitaldefynd.com/IQ/ai-in-cement-industry/>
36. Djunaidi, A.V., Juwono, C. P. (2018). Football game algorithm implementation on the capacitated vehicle routing problems, *International Journal of Computing Algorithm*, 07(1), 45-53.
37. Doğan-Sağlamtimur. N., Bilgil, A., Szechyńska-Hebda, M., Parzych, S, Hebda, M.(2021). Eco-Friendly Fired Brick Produced from Industrial Ash and Natural Clay: A Study of Waste Reuse. In: *Materials*,14, 877. <https://doi.org/10.3390/ma14040877>
38. Eil, A., Li, J., Baral, P., Saikawa, E. (2020). Dirty stacks, high stakes. *Dirty Stacks High Stakes*. <https://doi.org/10.1596/33727>
39. Emamian, S.A., Eskandari-Naddaf, H., (2020). Genetic programming based formulation for compressive and flexural strength of cement mortar containing nano and micro silica after freeze and thaw cycles. *Construction and Building Materials* 241, 118027. <https://doi.org/10.1016/j.conbuildmat.2020.118027>
40. Erdogmus, E., Harja, M., Gencel, O., Sutcu, M., Yaras, A. (2021), New construction materials synthesized from water treatment sludge and fired clay brick wastes. *J. Build. Eng.*, 42, 102471. <https://doi.org/10.1016/j.jobe.2021.102471>
41. Fadakar, E. and Ebrahimi, M. (2016). A new metaheuristic football game inspired algorithm. *2016 1st Conference on Swarm Intelligence and Evolutionary Computation (CSIEC)*, 6-11.
42. Ferdous, W., Manalo, A., Siddique, R., Mendis, P., Zhuge, Y., Wong, H.S., Lokuge, W., Aravinthan, T., Schubel, P. (2021). Recycling of landfill wastes (tyres, plastics and glass) in construction—a review on global waste generation, performance, application and future opportunities, *Resour. Conserv Recycl* 173, 105745. <https://doi.org/10.1016/j.resconrec.2021.105745>
43. Floria, S.-A., Gavrilesco, M., Leon, F., & Curteanu, S. (2022). Ensembles of Biologically Inspired Optimization Algorithms for Training Multilayer Perceptron Neural Networks. *Applied Sciences*, 12(19), 9997. <https://doi.org/10.3390/app12199997>
44. Floria S-A., Gavrilesco M., Leon F., Curteanu S., Anton C., Neuroevolution based on adaptive ensembles of biologically inspired optimization algorithms applied for modelling a chemical engineering process, *Proceedings of the 17th International Conference on Computational Engineering and Applications (ICCEA 2023) Istanbul, Turkey, October 2023 International Conference – 2023- ICCEA, 16-17 Octobre, 2023, Istanbul, Turcia.*
45. Gavrilesco, M., Floria, S.-A., Leon, F., & Curteanu, S. (2022). A Hybrid Competitive Evolutionary Neural Network Optimization Algorithm for a Regression Problem in Chemical Engineering. *Mathematics*, 10(19), 3581. <https://doi.org/10.3390/math10193581>
46. Gencel, O.; Munir, M.J.; Kazmi, S.M.S. ; Sutcu, M. ; Erdogmus, E. ; Velasco, P.M.; Quesada, D.E. (2021). Recycling industrial slags in production of fired clay bricks for sustainable manufacturing, *Ceram. Int* 47, 30425–30438. <https://doi.org/10.1016/j.ceramint.2021.07.222>
47. Gencel, O., Kazmi, S.M.S., Munir, M.J., Sutcu, M., Erdogmus, E., Yaras, A. (2021) Feasibility of using clay-free bricks manufactured from water treatment sludge, glass, and marble wastes: an exploratory study, *Constr. Build. Mater.* 298, 123843. <https://doi.org/10.1016/j.conbuildmat.2021.123843>
48. Gnewuch, M. and Hebbinghaus N., (2021). Discrepancy bounds for a class of negatively dependent random points including Latin hypercube samples, *Ann. Appl. Probab.*, 31,1944–1965 <https://doi.org/10.1214/20-AAP1638>
49. Goel G., Kalamdhat A.S., Agrawal A. (2018). Parameter optimisation for producing fired bricks using organic solid wastes, *Journal of Cleaner Production.*,205,836-844. <https://doi.org/10.1016/j.jclepro.2018.09.116>
50. Golafshani, E.M., Behnood, A., (2019). Estimating the optimal mix design of silica fume concrete using biogeography-based programming. *Cement and Concrete Composites* 96, 95–105. <https://doi.org/10.1016/j.cemconcomp.2018.11.005>
51. Golafshani, E.M., Behnood, A., Arashpour, M.,(2020). Predicting the compressive strength of normal and High-Performance Concretes using ANN and ANFIS hybridized with Grey Wolf Optimizer. *Construction and Building Materials* 232, 117266.
52. Golafshani, E.M.,behnood, A., Hosseinikebria, S.S. Arashpour, M.(2021) Novel metaheuristic-based type-2 fuzzy inference system for predicting the compressive strength of recycled aggregate concrete. *Journal of Cleaner Production* 320, 128771. <https://doi.org/10.1016/j.jclepro.2021.128771>
53. Grzeszczyk, S., Kupka, T., Kalamarz, A., Sudol, A., Jurowski, K., Makieieva, N., Oleksowicz, K., Wrzalik, R. (2022). Characterization of eggshell as limestone replacement and its influence on properties of modified cement. *Construction and Building Materials* 319, 126006. <https://doi.org/10.1016/j.conbuildmat.2021.126006>

54. Habibi, A., Mohammad, A., & Mahdikhani, M. (2021a). RSM-based optimized mix design of recycled aggregate concrete containing supplementary cementitious materials based on waste generation and global warming potential. *Resources, Conservation & Recycling*. <https://doi.org/10.1016/j.resconrec.2021.105420>
55. Habibi, A., Mohammad, A., Mahdikhani, M., & Bamshad, O. (2021b). RSM-based evaluation of mechanical and durability properties of recycled aggregate concrete containing GGBFS and silica fume. *Construction and Building Materials*, 270, 121431. <https://doi.org/10.1016/j.conbuildmat.2020.121431>
56. Hameed, A., Haider U., Qazi, A.A., Abbas, S. (2018). Effect of Waste Glass on Properties of Burnt Clay Bricks. In: *Pak. J. Engg. Appl. Sci.*,22, 56–63
57. Han, S., Li, H., Li, M., & Rose, T. (2019). A Deep Learning Based Method for the Non-Destructive Measuring of Rock Strength through Hammering Sound. *Applied Sciences*, 9(17), 3484. <https://doi.org/10.3390/app9173484>
58. Harja, M., Gencil, O., Sari, A., Sutcu, M., Erdogmus, E., Hekimoglu, G. (2022). Production and characterization of natural clay-free green building brick materials using water treatment sludge and oak wood ash. *Arch. Civ. Mech. Eng.*, 22, 79. <https://doi.org/10.1007/s43452-022-00400-0>
59. Hasan, M.R., Siddika, A., Akanda, M.P.A., Islam, M.R. (2021). Effects of waste glass addition on brick's physical and mechanical properties, *Innov. Infrastruct. Solut.* 6, 1–13.
60. Hong, E., Yeneneh, A.M., Sen, T.K., Ang, H.M., Kayaalp, A., (2018). ANFIS based Modelling of dewatering performance and polymer dose optimization in a wastewater treatment plant. *Journal of Environmental Chemical Engineering* 6 (2), 1957–1968. <https://doi.org/10.1016/j.jece.2018.02.041>
61. Hossain S.S., Mathur L., Majhi M.R., Roy P.K. (2019). Manufacturing of green building brick: recycling of waste for construction purpose. *J Mater Cycles Waste Manag* 21(2), 281–292. <https://doi.org/10.1007/s10163-018-0788>
62. Hosseini, S.J.A.-D., Mohammadreza. M., Hossein. S., Sima, A. (2018). Optimal placement of distributed generators with regard to reliability assessment using virus colony search algorithm. *International Journal of Renewable Energy Research*. 8. 714-723
63. Hung, T.V., Viet, V.Q., Van Thuat, D. (2019). A deep learning-based procedure for estimation of ultimate load carrying of steel trusses using advanced analysis. *Journal of Science and Technology in Civil Engineering (STCE)-HUCE* 13 (3), 113–123. [https://doi.org/10.31814/stce.nuce2019-13\(3\)-11](https://doi.org/10.31814/stce.nuce2019-13(3)-11)
64. Ibrahim J. E. F.M., Tihiti, M., Gömze, L. A. (2021). Environmentally-friendly ceramic bricks made from zeolite-poor rock and sawdust. *Construction and Building Materials*, 297,123715. <https://doi.org/10.1016/j.conbuildmat.2021.123715>
65. Jaderyan, M., Khotanlou, H. (2016). Virulence Optimization Algorithm, *Applied Soft Computing*, Volume 43, 596-618. <https://doi.org/10.1016/j.asoc.2016.02.038>
66. Jalal, M., Arabali, P., Grasley, Z., Bullard, J. W., & Jalal, H. (2020). Behavior assessment, regression analysis and support vector machine (SVM) modeling of waste tire rubberized concrete. *Journal of Cleaner Production*, 273, 122960. <https://doi.org/10.1016/j.jclepro.2020.122960>
67. Jannat, N., Hussien, A., Abdullah, B. & Cotgrave, A.(2020). Application of agro and non-agro waste materials for unfired earth blocks construction: A review. *Constr. Build. Mater.*254, 119346. <https://doi.org/10.1016/j.conbuildmat.2020.119346>
68. Joyklad, P., Hussain, Q. (2019). Axial compressive response of grouted cement–clay interlocking hollow brick walls, *Asian J. Civ. Eng.* 20, 733–744. <https://doi.org/10.1007/s42107-019-00140-2>
69. Kankal, M. & Uzlu, E. (2017). Neural network approach with teaching-learning-based optimization for modeling and forecasting long-term electric energy demand in Turkey. *NEURAL COMPUTING & APPLICATIONS* , 28 737-747. <https://doi.org/10.1007/s00521-016-2409-2>
70. Kashyap D., Das S., Kalita P. (2021), Exploring the efficiency and pollutant emission of a dual fuel CI engine using biodiesel and producer gas: An optimization approach using response surface methodology, *Science of the Total Environment* 773, 145633 <https://doi.org/10.1016/j.scitotenv.2021.145633>
71. Kaveh, A. (2024). Applications of Artificial Neural Networks and Machine Learning in Civil Engineering. *Studies in Computational Intelligence*, 1168, Springer
72. Khademi, F., Jamal, S.M., Deshpande, N., Londhe, S. (2016). Predicting strength of recycled aggregate concrete using artificial neural network, adaptive neuro-fuzzy inference system and multiple linear regression. *International Journal of Sustainable Built Environment* 5 (2), 355–369. <https://doi.org/10.1016/j.ijlsbe.2016.09.003>
73. Khokhar S.A. , Khan, A., Siddique, A., Khushnood, R. A. Malik, U.J. (2023). A predictive mimicker for mechanical properties of eco-efficient and sustainable bricks incorporating waste glass using machine learning. *Case Studies in Construction Materials*, Volume 19, e02424. <https://doi.org/10.1016/j.cscm.2023.e02424>

74. Kifi, Z., Absa, M., & Musyafa, A. (2017). Prediction of mechanical properties of light weight brick composition using artificial neural network on autoclaved aerated concrete. *Asian Journal of Applied Sciences*, 05(03), 556–565. <https://www.ajouronline.com/index.php/AJAS/article/view/4754>
75. Kilic G., Sungur B., Topaloglu B., Ozcan H. (2018). Experimental analysis on the performance and emissions of diesel/ butanol/biodiesel blended fuels in a flame tube boiler. *Applied Thermal Engineering* 130, 195–202. <https://doi.org/10.1016/j.applthermaleng.2017.11.006>
76. Kiziloz, H. E., Deniz, A., Dokeroglu, T., & Cosar, A. (2018). Novel multiobjective TLBO algorithms for the feature subset selection problem. *Neurocomputing*, 306, 94-107. <https://doi.org/10.1016/j.neucom.2018.04.020>
77. Koçer, M., Oztürk, M., Arslan, M.H., (2019). Determination of moment, shear and ductility capacities of spiral columns using an artificial neural network. *Journal of Building Engineering* 26, 100878. <https://doi.org/10.1016/j.jobe.2019.100878>
78. Kumar, M., Mittal, M. L., Soni, G., & Joshi, D. (2018). A hybrid TLBO-TS algorithm for integrated selection and scheduling of projects. *Computers & Industrial Engineering*, 119, 121-130. <https://doi.org/10.1016/j.cie.2018.03.029>
79. Kumar, Y., Dahiya, N., Malik S., Khatri S. (2019). A New Variant of Teaching Learning Based Optimization Algorithm for Global Optimization Problems. *Informatica* 43(1). <https://doi.org/10.31449/inf.v43i1.1636>
80. Kumari ,P.,Paruthi,S., Alyaseen, A., Khan,A. H., Jijja,A. (2024). Predictive performance assessment of recycled coarse aggregate concrete using artificial intelligence: A review, <https://doi.org/10.1016/j.clema.2024.100263>
81. Kurmus H., Mohajerani A. (2021). Energy savings, thermal conductivity, micro and macro structural analysis of fired clay bricks incorporating cigarette butts. *Construction and Building Materials* 283. <https://doi.org/10.1016/j.conbuildmat.2021.122755>
82. Kurmus, H., Mohajerani, A. (2020). Recycling of Cigarette Butts in Fired Clay Bricks: A New Laboratory Investigation. In: *Materials*, 13, 790. <https://doi.org/10.3390/ma13030790>
83. Li, M.D., Zhao, H., Weng, X.W., Han, T. (2016). A novel nature-inspired algorithm for optimization: Virus colony search. *Adv. Eng. Softw.*, 92,65–88. <https://doi.org/10.1016/j.advengsoft.2015.11.004>
84. Liang, Y. -C.and Cuevas Juarez, J. R. (2016). Harmony search and virus optimization algorithm for multi-objective combined economic energy dispatching problems. *2016 IEEE Congress on Evolutionary Computation (CEC)*, Vancouver, BC, Canada, 3947-3954.
85. Limami, H., Guettioui, D., Dahi, O., Mehdi, E., Boustani, E., Manssouri, I., El, A., & Khaldoun, A. (2023). Machine learning forecasting of thermal, mechanical and physicochemical properties of unfred clay bricks with plastic waste additives. *Materials Today: Proceedings*.72(7),3509-3513. <https://doi.org/10.1016/j.matpr.2022.08.218>
86. Lin, C.-J., Wu, N.-J., (2021). An ANN model for predicting the compressive strength of concrete. *Applied Sciences* 11 (9), 3798. <https://doi.org/10.3390/app11093798>
87. Lisa, G., Wilson, D.A., Curteanu, S., Lisa, C., Piuleac, C.G., Bulacovschi, V. (2011). Ferrocene derivatives thermostability prediction using neural networks and genetic algorithms, *Thermochim. Acta*, 521, 26-36.
88. Liu, Z.-Z., Chu, D.-H., Song, C., Xue, X., Lu, B.-Y. (2016). Social learning optimization (SLO) algorithm paradigm and its application in QoS-aware cloud service composition, *Information Sciences*, 326, 315-333. <https://doi.org/10.1016/j.ins.2015.08.004>.
89. Loh, S. K., Cheong, K. Y., & Salimon, J. (2017). Surface-active physicochemical characteristics of spent bleaching earth on soil-plant interaction and water-nutrient uptake: A review. *Applied Clay Science*, 140, 59–65. <https://doi.org/10.1016/j.clay.2017.01.024>
90. Lu, C., Li, X., Gao, L., Liao, W., Yi, J. (2017). An effective multi-objective discrete virus optimization algorithm for flexible job-shop scheduling problem with controllable processing times. *Computers and Industrial Engineering*104(C),156-174. <https://doi.org/10.1016/j.cie.2016.12.020>.
91. Mahdinia, S., Eskandari-Naddaf, H., Shadnia, R. (2019). Effect of cement strength class on the prediction of compressive strength of cement mortar using GEP method. *Construction and Building Materials* 198, 27–41. <https://doi.org/10.1016/j.conbuildmat.2018.11.265>
92. Malkanthi S.N., Wickramasinghe W.G.S., Perera A.A.D.A.J. (2021). Use of construction waste to modify soil grading for compressed stabilized earth blocks (CSEB) production. *Case Stud Constr Mater* 15:e00717. <https://doi.org/10.1016/j.cscm.2021.e00717>

93. Marín-garcía, D., Bienvenido-huertas, D., Carretero-ayuso, M. J., & Della, S. (2023). Automation in construction deep learning model for automated detection of eforescence and its possible treatment in images of brick facades. *Automation in Construction*. <https://doi.org/10.1016/j.autcon.2022.104658>
94. Mirmozaffari, M., Shadkam, E., Khalili, S.M., Kabirifar, K., Yazdani, R., Asgari Gashteroodkhani, T., (2021). A novel artificial intelligent approach: comparison of machine learning tools and algorithms based on optimization DEA malmquist productivity index for eco-efficiency evaluation. *International Journal of Energy Sector Management* 15 (3), 523–550. <https://doi.org/10.1108/IJESM-02-2020-0003>
95. Moghdani, R., & Salimifard, K. (2018). Volleyball Premier League Algorithm. *Applied Soft Computing Journal*, 64, 161-185. <https://doi.org/10.1016/j.asoc.2017.11.043>
96. Moghdani, R., Elaziz, M. A., Mohammadi, D., & Neggaz, N. (2021). An improved volleyball premier league algorithm based on sine cosine algorithm for global optimization problem. *Engineering with Computers*, 37(4), 2633-2662. <https://doi.org/10.1007/s00366-020-00962-8>
97. Moghdani, R., Salimifard, K., (2017). Volleyball Premier League Algorithm, *Applied Soft Computing Journal* <https://doi.org/10.1016/j.asoc.2017.11.043>
98. Moghdani, R., Salimifard, K., Demir, E., & Benyettou, A. (2020). Multi-Objective Volleyball Premier League algorithm. *Knowledge-Based Systems*, 196,105781. <https://doi.org/10.1016/j.knsys.2020.105781>
99. Munoz, P., Letelier, V., Munoz, L., Gencel, O., Sutcu, M., Vasic, M. (2023). Assessing technological properties and environmental impact of fired bricks made by partially adding bottom ash from an industrial approach, *Constr. Build. Mater.* 396, 132338. <https://doi.org/10.1016/j.conbuildmat.2023.132338>
100. Naderpour, H., Eidgahee, D.R., Fakharian, P., Rafiean, A.H., Kalantari, S.M., (2020). A new proposed approach for moment capacity estimation of ferrocement members using Group Method of Data Handling. *Engineering Science and Technology, an International Journal* 23 (2), 382–391. <https://doi.org/10.1016/j.jestech.2019.05.013>
101. Nagajothi, S., Elavenil, S., (2020). Influence of aluminosilicate for the prediction of mechanical properties of geopolymer concrete–artificial neural network. *Silicon* 12, 1011–1021. <https://doi.org/10.1007/s12633-019-00203-8>
102. Nakkeeran G., Krishnaraj L., Shakor P., Alaneme G.U., Otu O.N. (2024). Mechanical properties optimization and cost analysis of agricultural waste as an alternative in brick production. *Sci Rep.*14(1),24075. <https://doi.org/10.1038/s41598-024-74970-9>.
103. Nakkeeran, G., Krishnaraj, L., Shakor, P., Alaneme, G.U., Out, O. N.. (2024). Mechanical properties optimization and cost analysis of agricultural waste as an alternative in brick production. *Scientific Reports* 14, 24075. <https://doi.org/10.1038/s41598-024-74970-9>
104. Nguyen, T.T., Dinh, K., (2020). An artificial intelligence approach for concrete hardened property estimation. *Journal of Science and Technology in Civil Engineering (STCE)- HUCE* 14 (2), 40–52. [https://doi.org/10.31814/stce.nuce2020-14\(2\)-04](https://doi.org/10.31814/stce.nuce2020-14(2)-04)
105. Nguyen, T.T., Pham Duy, H., Pham Thanh, T., Vu, H.H., (2020). Compressive strength evaluation of fiber-reinforced high-strength self-compacting concrete with artificial intelligence. *Advances in Civil Engineering* 2020, 1–12. <https://doi.org/10.1155/2020/3012139>
106. Nicolas, M. F., Vlasova, M., Aguilar, P. A. M., Kakazey, M., Cano, M. M. C., Matus, R. A., & Puig, T. P. (2020). Development of an energy-saving technology for sintering of bricks from highsiliceous clay by the plastic molding method. *Construction and Building Materials*, 242, 118142. <https://doi.org/10.1016/j.conbuilddmat.2020.118142>
107. Ogunro, A. S., Apeh, F. I., Nwannenna, O. C. and Ibadode, O. (2018). Recycling Of Waste Glass As Aggregate For Clay Used In Ceramic Tile Production, *American Journal of Engineering* 7(8), 272-278.
108. Oguntola, O.; Boakye, K.; Simske, S. (2024). Towards Leveraging Artificial Intelligence for Sustainable Cement Manufacturing: A Systematic Review of AI Applications in Electrical Energy Consumption Optimization. *Sustainability* 2024, 16, 4798. <https://doi.org/10.3390/su16114798>.
109. Parejo Guzmán, M., Navarrete Rubia, B., Mora Peris, P., Alfalla-Luque, R. (2022). Methodological development for the optimisation of electricity cost in cement factories: The use of artificial intelligence in process variables. *Electr. Eng.* 2022, 104, 1681–1696. <https://doi.org/10.1007/s00202-021-01409-z>
110. Patel, R., Yadav, N. (2024). Prediction of mechanical properties of bricks manufactured with recycled soil using artificial neural network. *Innov. Infrastruct. Solut.* 9, 334. <https://doi.org/10.1007/s41062-024-01640-0>

111. Patel, S. J., Toshniwal, A., & Kheraj, V. (2017). A novel teaching-learning based optimization approach for design of broad-band anti-reflection coatings. *Swarm and evolutionary computation*, 34, 68-74. <https://doi.org/10.1016/j.swevo.2016.12.003>
112. Phonphuak, N., Kanyakam, S., Chindaprasirt, P. (2016). Utilization of waste glass to enhance physical–mechanical properties of fired clay brick, *J. Clean. Prod.* 112 (4), 3057–3062. <https://doi.org/10.1016/j.jclepro.2015.10.084>
113. Prasad, K., Gorai, A.K., Goyal, P., (2016). Development of ANFIS models for air quality forecasting and input optimization for reducing the computational cost and time. *Atmospheric Environment* 128, 246–262. <https://doi.org/10.1016/j.atmosenv.2016.01.007>
114. Prusty, J. K., Patro, S. K. & Basarkar, S. S.(2016). Concrete using agro-waste as fine aggregate for sustainable built environment – A review. *Int. J. Sustain. Built Environ.*5, 312–333. <https://doi.org/10.1016/j.ijse.2016.06.003>
115. Rehman, M. U., Ahmad, M., & Rashid, K. (2020). Influence of fluxing oxides from waste on the production and physico-mechanical properties of fired clay brick: A review. *Journal of Building Engineering*. <https://doi.org/10.1016/j.jobe.2019.100965>
116. Sahoo, A. J., & Kumar, Y. (2019). A chaotic teaching learning based optimization algorithm for clustering problems. *Informatica* 43 (2019) 65–75. <https://doi.org/10.31449/inf.v43i1.1636>
117. Salimbahrami, S.R., Shakeri, R. (2021). Experimental investigation and comparative machine-learning prediction of compressive strength of recycled aggregate concrete. *Soft Comput* 25, 919–932. <https://doi.org/10.1007/s00500-021-05571-1>
118. Sani, R. Nzihou, A. (2017) Production of clay ceramics using agricultural wastes: Study of properties, energy savings and environmental indicators. *Appl. Clay Sci.*, 146, 106–114. <https://doi.org/10.1016/j.clay.2017.05.032>
119. Sarween Akhtar, U., Moniruz Zaman, M., Islam, M.S., Nigar, F., Hossain, M.K. (2017). Effect of different types of glasses as fluxing agent on the sintering temperature of bricks, *Trans. Indian Ceram. Soc.* 76,128–132. <https://doi.org/10.1080/0371750X.2016.1278402>
120. Shaban, W. M., Yang, J., Elbaz, K., Xie, J., Li, L. (2021). Fuzzy-metaheuristic ensembles for predicting the compressive strength of brick aggregate concrete. *Resour. Conserv. Recycl.* 169, 105443. <https://doi.org/10.1016/j.resconrec.2021.105443>
121. Shahinzadeh, H., Gharehpetian, G.B., Moazzami, M., Moradi, J., & Hosseini, S.H. (2017). Unit commitment in smart grids with wind farms using virus colony search algorithm and considering adopted bidding strategy. *2017 Smart Grid Conference (SGC)*, 1-9. <https://doi.org/10.1109/SGC.2017.8308892>.
122. Shahmansouri, A.A., Bengar, H.A., Ghanbari, S. (2020). Compressive strength prediction of eco-efficient GGBS-based geopolymer concrete using GEP method. *Journal of Building Engineering* 31, 101326. <https://doi.org/10.1016/j.jobe.2020.101326>
123. Shahmansouri, A.A., Bengar, H.A., Jahani, E. (2019). Predicting compressive strength and electrical resistivity of eco-friendly concrete containing natural zeolite via GEP algorithm. *Construction and Building Materials* 229, 116883. <https://doi.org/10.1016/j.conbuildmat.2019.116883>
124. Shahmansouri, A.A., Yazdani, M., Ghanbari, S., Bengar, H.A., Jafari, A., Ghatte, H.F., (2021). Artificial neural network model to predict the compressive strength of ecofriendly geopolymer concrete incorporating silica fume and natural zeolite. *Journal of Cleaner Production* 279, 123697. <https://doi.org/10.1016/j.jclepro.2020.123697>
125. Shahnewaz, M., Rteil, A., Alam, M.S., (2020). Shear strength of reinforced concrete deep beams–A review with improved model by genetic algorithm and reliability analysis. In: *Structures*. Elsevier, pp. 494–508. <https://doi.org/10.1016/j.istruc.2019.09.006>
126. Khokhar, S. A., Khan, A., Siddique, A., Khushnood, R. A., Malik, U. J. (2023). A predictive mimicker for mechanical properties of eco-efficient and sustainable bricks incorporating waste glass using machine learning, *Case Studies in Construction Materials*, 19, e02424. <https://doi.org/10.1016/j.cscm.2023.e02424>.
127. Slimanou, H., Eliche-Quesada, D., Kherbache, S., Bouzidi, N., & Tahakourt, A. K. (2020). Harbor Dredged Sediment as raw material in fired clay brick production: Characterization and properties. *Journal of Building Engineering*. <https://doi.org/10.1016/j.jobe.2019.101085>

128. Sonebi, M., Cevik, A., Grünewald, S., & Walraven, J. (2016). Modelling the fresh properties of self-compacting concrete using support vector machine approach. *Construction and Building Materials*, 106, 55–64. <https://doi.org/10.1016/j.conbuildmat.2015.12.035>
129. Suescum-Morales, D., Salas-Morera, L., Jiménez, J.R., García-Hernández, L. (2021). A Novel Artificial Neural Network to Predict Compressive Strength of Recycled Aggregate Concrete. *Appl. Sci.* 11, 11077. <https://doi.org/10.3390/app112211077>
130. Sutcu, M., Ozturk, S., Yalamac, E., & Gencel, O. (2016). Effect of olive mill waste addition on the properties of porous fired clay bricks using Taguchi method. *Journal of Environmental Management*, 181, 185–192. <https://doi.org/10.1016/j.jenvman.2016.06.023>
131. Tafese, W. Z., & Sistonen, E. (2017). Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions. *Automation in Construction*, 77, 1–14. <https://doi.org/10.1016/j.autcon.2017.01.016>
132. Thomas, J., Thaickavil, N.N., Wilson, P., (2018). Strength and durability of concrete containing recycled concrete aggregates. *Journal of Building Engineering* 19, 349–365. <https://doi.org/10.1016/j.jobe.2018.05.007>
133. Tong, R., Sui, T., Feng, L., Lin, L. (2023). The digitization work of cement plant in China. *Cem. Concr. Res.* 173, 107266. <https://doi.org/10.1016/j.cemconres.2023.107266>
134. Tong, Z., Huo, J., & Wang, Z. (2020). High-throughput design of fiber reinforced cement-based composites using deep learning. *Cement and Concrete Composites*. <https://doi.org/10.1016/j.cemconcomp.2020.103716>
135. Tung, P.T., Hung, P.T. (2020). Predicting fire resistance ratings of timber structures using artificial neural networks. *Journal of Science and Technology in Civil Engineering (STCE)-HUCE* 14 (2), 28–39. [https://doi.org/10.31814/stce.nuce2020-14\(2\)-03](https://doi.org/10.31814/stce.nuce2020-14(2)-03)
136. Ullah, S., Qureshi, M.I., Joyklad, P., Suparp S., Hussain, Q., Chaiyasarn, K., Yooprasertchai, E. (2022). Effect of partial replacement of E-waste as a fine aggregate on compressive behavior of concrete specimens having different geometry with and without CFRP confinement, *J. Build. Eng.* 50, 104151. <https://doi.org/10.1016/j.jobe.2022.104151>
137. Utomo, D. P., Perdana, B. W., Pamungkas, A., Syaiin, M., Adhitya, R. Y., Munadhif, I., Endrasmono, J., Soeprijanto, A., Soelistijono, R.T. (2017). CLC (Cellular Lightweight Concrete) Brick Making Process using Neural Network and Extreme Learning Method Based on Microcontroller and Visual Studio. *International Symposium on Electronics and Smart Devices*, 79-84. <https://doi.org/10.1109/ISESD.2017.8253309>
138. Van Quan Tran, Viet Quoc Dang, Lanh Si Ho (2022). Evaluating compressive strength of concrete made with recycled concrete aggregates using machine learning approach, *Construction and Building Materials*, 323, 126578. <https://doi.org/10.1016/j.conbuildmat.2022.126578>.
139. Vasić, M. V., Pezo, L. L., & Radojević, Z. (2020). Optimization of adobe clay bricks based on the raw material properties (mathematical analysis). *Construction and Building Materials*. <https://doi.org/10.1016/j.conbuildmat.2020.118342>
140. Vinothkumar, A., Kalaivani, M., Easwaran, P., (2019). Development of fly ash GGBS based self compacting geopolymer concrete: A review. *International Research Journal of Multidisciplinary Technovation* 1 (6), 373–377. <https://doi.org/10.34256/irjmtcon49>
141. Vishnupriyan, M., & Annadurai, R. (2023). A study on the macroproperties of PCB fiber-reinforced concrete from recycled electronic waste and validation of results using RSM and ANN. *Asian Journal of Civil Engineering*, 24(6), 1667–1680. <https://doi.org/10.1007/s42107-023-00595-4>
142. Wang, Q., Ahmad, W., Ahmad, A., Aslam, F., Mohamed, A. and Vatin, N. (2022). Application of Soft Computing Techniques to Predict the Strength of Geopolymer Composites. *Polymers* 14(6), 1074,. <https://doi.org/10.3390/polym14061074>
143. Yaswanth, K., Revathy, J., Gajalakshmi, P., (2022). Soft computing techniques for the prediction and analysis of compressive strength of alkali-activated Alumino-silicate based strain-hardening Geopolymer composites. *Silicon* 1–24. <https://doi.org/10.1007/s12633-021-00988-7>
144. Ye, X.-Y.; Liu, Z.-W.; Chi, M.; Ge, M.-F.; Xi, Z. (2023). Demand Response optimization of Cement Manufacturing Industry Based on Reinforcement Learning Algorithm. In *Proceedings of the 2022 IEEE International Conference on Cyborg and Bionic Systems (CBS)*, Wuhan, China,. 402–406.
145. Yeddula, B.S.R., Karthiyaini, S. (2020). Experimental investigations and GEP modelling of compressive strength of ferrosialate based geopolymer mortars. *Construction and Building Materials* 236, 117602. <https://doi.org/10.1016/j.conbuildmat.2019.117602>

146. Yin, S., Hussain, Q., Joyklad, P., Chaimahawan, P., Rattanapitikon, W., Limkatanyu, S., Pimanmas, A. (2021). Strengthening effect of natural fiber reinforced polymer composites (NFRP) on concrete, *Case Stud. Constr. Mater.* 15, e00653. <https://doi.org/10.1016/j.cscm.2021.e00653>
147. Zawrah, M. F., Gado, R. A., Feltin, N., Ducourtieux, S., & Devoille, L. (2016). Recycling and utilization assessment of waste fired clay bricks (Grog) with granulated blast-furnace slag for geopolymer production. *Process Safety and Environmental Protection*, 103, 237–251. <https://doi.org/10.1016/j.psep.2016.08.001>
148. Zhai, Z., Jia, G., & Wang, K. (2018). A Novel Teaching-Learning-Based Optimization with Error Correction and Cauchy Distribution for Path Planning of Unmanned Air Vehicle. *Computational intelligence and neuroscience*, 2018, 5671709. <https://doi.org/10.1155/2018/5671709>
149. Zhai, Z., Jia, G., Wang, K. and Powers, D.M. (2018). A Novel Teaching-Learning-Based Optimization with Error Correction and Cauchy Distribution for Path Planning of Unmanned Air Vehicle. *Intell. Neuroscience* 2018. <https://doi.org/10.1155/2018/5671709>
150. Zhang, Z., Nielsen, M.K., Hørsholt, S., Muralidharan, G., Jørgensen, J.B. (2021). Digitalization, control and optimization for cement plants. In *Computer Aided Chemical Engineering* 50, 1319–1324. <https://doi.org/10.1016/B978-0-323-88506-5.50203-5>
151. Zhu, Y., Yang, C., Chen, X., Zhou, J.; Zhao, J.(2022). Identification-based real-time optimization and its application to power plants. *Control Eng. Pract.* 123, 105160.
152. Zulkifli, D.S.; Absa, M.; Musyafa, A. (2017). Prediction of Mechanical Properties of Light Weight Brick Composition Using Artificial Neural Network on Autoclaved Aerated Concrete. (2017). *Asian Journal of Applied Sciences*, 5(3). <https://www.ajouronline.com/index.php/AJAS/article/view/4754>