



**MINISTERUL EDUCAȚIEI ȘI CERCETĂRII**  
**Universitatea Națională de Știință și**  
**Tehnologie POLITEHNICA București**  
**Școala Doctorală de**  
**Inginerie Industrială și Robotică**

**Iulian-Constantin COROPEȚCHI**

# **REZUMAT AL TEZEI DE DOCTORAT**

**Optimizarea bazată pe  
inteligență artificială pentru  
realizarea de structuri  
topologice de configurație  
specială**

***Conducător științific,***

***Prof.univ.dr.ing. Dan Mihai CONSTANTINESCU***

## COMISIA DE DOCTORAT

Președinte	Prof.univ.dr.ing. Diana POPESCU	Universitatea Națională de Știință și Tehnologie POLITEHNICA București
Conducător științific	Prof.univ.dr.ing. Dan Mihai CONSTANTINESCU	
Referent	Acad. Dorel BANABIC	Universitatea Tehnică din Cluj-Napoca
Referent	Prof.univ.dr.ing. Arian-Marius PASCU	Univeristatea „Lucian Blaga” din Sibiu
Referent	Conf.univ.dr.ing. Florin BACIU	Universitatea Națională de Știință și Tehnologie POLITEHNICA București

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## CUPRINS

CUPRINS .....	1
INTRODUCERE .....	2
CAPITOLUL 1 – STADIUL ACTUAL AL PROIECTĂRII STRUCTURILOR TOPOLOGICE DE CONFIGURAȚIE SPECIALĂ .....	5
CAPITOLUL 2 – ANALIZA PROCEDEELOR ȘI A ALGORITMIILOR DE OPTIMIZARE STRUCTURALĂ .....	8
CAPITOLUL 3 – ANALIZA COMPARATIVĂ A METODELOR DE CĂUTARE DIRECTĂ ÎN REZOLVAREA PROBLEMELOR DE OPTIMIZARE STRUCTURALĂ ....	11
CAPITOLUL 4 – METODE DE ÎNVĂȚARE AUTOMATĂ PENTRU OPTIMIZAREA STRUCTURALĂ .....	17
CAPITOLUL 5 – CERCETĂRI EXPERIMENTALE ASUPRA STRUCTURILOR COMPOZITE AUXETICE PERIODICE OPTIMIZATE .....	24
CAPITOLUL 6 – METODOLOGIE DE UTILIZARE A PROCEDURILOR DE OPTIMIZARE .....	24
CAPITOLUL 7 - CONCLUZII FINALE .....	29
7.1 Concluzii generale .....	29
7.2 Contribuții personale.....	33
7.3 Direcții pentru cercetări viitoare .....	34
BIBLIOGRAFIE .....	35

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## INTRODUCERE

### *Motivația alegerii temei de cercetare*

Studiul proceselor de optimizare în proiectarea structurală este din ce în ce mai necesar datorită cererii tot mai mari de materiale și structuri ușoare, eficiente și multifuncționale. Abordările tradiționale de proiectare prin încercări sau pur analitice sunt adesea limitate în a surprinde întregul potențial al structurilor complexe, în special atunci când se lucrează cu geometrii non-intuitive, cum ar fi materialele auxetice sau mecanismele deformabile. Optimizarea oferă o modalitate sistematică de a explora spații vaste de proiectare, de a identifica soluții inovatoare și de a echilibra obiective concurente, cum ar fi rigiditatea, rezistența, reducerea greutateii sau caracteristicile de deformare. În contextul provocărilor ingineresti moderne, unde eficiența și performanța materialelor trebuie să meargă mână în mână cu sustenabilitatea și rentabilitatea, optimizarea nu mai este un lux, ci o necesitate.

În același timp, motivația studierii proceselor de optimizare provine și din progresele înregistrate în fabricația aditivă și metodele bazate pe inteligență artificială. Noile tehnologii de fabricație permit realizarea unor geometrii complexe și arhitecturi multi-materiale care anterior erau imposibil de produs, în timp ce metodele de învățare automată oferă instrumente puternice pentru a gestiona complexitatea unor astfel de probleme. Prin integrarea cadrelor de optimizare cu validarea experimentală, cercetătorii pot reduce decalajul dintre modelele teoretice și aplicațiile practice, asigurându-se că soluțiile propuse sunt atât fezabile, cât și eficiente. În cele din urmă, motivația pentru a studia acest proces de optimizare constă în potențialul său de a permite proiectarea de metamateriale mecanice de generație următoare și structuri cu proprietăți personalizate, deschizând noi posibilități în industria aerospațială, auto, dispozitive biomedicale și nu numai.

### *Actualitatea și importanța cercetării doctorale*

Relevanța acestei cercetări constă în faptul că metodologiile tradiționale de proiectare sunt adesea insuficiente pentru a gestiona structuri extrem de complexe, neintuitive, cum ar fi structurile celulare [1], structurile spinoidale [2] sau mecanismele deformabile [3]. Aceste structuri de configurație specială nu pot fi întotdeauna proiectate prin metode convenționale, ceea ce face ca instrumentele de optimizare să fie indispensabile pentru identificarea soluțiilor eficiente. Prin formularea sistematică a problemei și aplicarea tehnicilor avansate de optimizare, această cercetare contribuie la o înțelegere mai profundă a modului de proiectare a structurilor cu proprietăți personalizate care altfel ar rămâne neexplorate.

Un alt aspect important este faptul că optimizarea structurală abordează o problemă des întâlnită: echilibrarea obiectivelor conflictuale, cum ar fi minimizarea greutateii, maximizarea rigidității sau permiterea unor deformări mari fără a compromite rezistența. În multe domenii chiar și mici îmbunătățiri ale eficienței materialelor sau ale performanțelor mecanice se traduc în beneficii tehnologice și economice semnificative. Prin urmare, această cercetare oferă atât contribuții teoretice în domeniul optimizării, cât și relevanță practică în rezolvarea problemelor de proiectare din lumea reală.

Legătura cu fabricația aditivă (AM) consolidează și mai mult importanța cercetării. Tehnologiile AM permit fabricarea unor structuri extrem de complexe care anterior erau imposibil de produs folosind metodele tradiționale de fabricație. Această legătură dintre

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

optimizare și AM asigură că proiectele teoretice pot fi realizate fizic. Mai mult, cercetarea abordează constrângerile de fabricație, asigurându-se că soluțiile optimizate nu sunt doar teoretic optime, ci și fezabile în medii de producție.

O contribuție cheie a acestei lucrări constă în integrarea mai multor materiale în cadrul de optimizare. Spre deosebire de structurile cu un singur material, configurațiile multi-material oferă un spațiu de proiectare mai bogat. De exemplu, combinarea materialelor rigide și flexibile într-o structură optimizată poate produce un comportament auxetic. Acest lucru face ca cercetarea să fie deosebit de relevantă pentru dezvoltarea metamaterialelor mecanice, care au aplicații variind de la absorbția energiei de impact la proiectarea implanturilor medicale.

La fel de importantă este validarea experimentală a structurilor optimizate. Deși simulările pot oferi informații valoroase, acestea sunt adesea limitate de ipoteze simplificatoare. Prin testarea materialelor de bază și a structurilor optimizate în condiții de laborator, această cercetare asigură că proprietățile prezise sunt realizabile în practică. Utilizarea unor instrumente experimentale avansate, cum ar fi corelarea digitală a imaginilor (DIC), sporește și mai mult fiabilitatea rezultatelor și consolidează încrederea în cadrul de optimizare.

În cele din urmă, cercetarea contribuie la dezvoltarea pe termen lung a strategiilor de proiectare a structurilor speciale. Prin combinarea algoritmilor de optimizare, a abordărilor de învățare automată și a validării experimentale, aceasta stabilește un cadru care poate evolua pe măsură ce apar noi tehnologii și instrumente de calcul. Această perspectivă asigură că relevanța cercetării se extinde dincolo de rezultatele sale imediate, servind drept fundament pentru studii viitoare în optimizarea structurală și proiectarea metamaterialelor.

### *Scopul și obiectivele cercetării doctorale*

Principalul scop al acestei lucrări este să dezvolte o metodologie de optimizare bazată pe inteligență artificială ce poate fi adaptată ușor pentru diverse probleme pentru a determina noi configurații geometrice ale structurilor de configurație specială.

Pentru a îndeplini scopul propus se urmăresc următoarele obiective principale:

1. Analiza literaturii de specialitate în privința structurilor topologice de configurație specială precum grinzile cu zăbrele, microstructurile celulare, structurile spinoidale și mecanismele deformabile precum și a tehnologiilor de fabricație aditivă ce permit realizarea acestor structuri speciale și a materialelor compatibile.
2. Studiarea tipurilor de algoritmi utilizați în optimizarea structurală în trei mari categorii: algoritmi bazați pe gradient, algoritmi de căutare directă și algoritmi de inteligență artificială.
3. Realizarea unui studiu comparativ asupra performanțelor unor algoritmi de căutare directă în rezolvarea unei probleme de optimizare a unei structuri repetitive compozite.
4. Studiarea și implementarea unor metode de inteligență artificială ce pot fi utilizate în predicția proprietăților mecanice a unor structuri sau în descoperirea unor noi tipuri de configurații în funcție de necesitățile definite.
5. Fabricarea unor structuri optimizate cu ajutorul tehnologiilor de fabricație aditivă.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

6. Testarea experimentală a structurilor fabricate prin diverse metode standardizate în scopul validării procesului de optimizare.

### *Organizarea tezei de doctorat*

Teza de doctorat este structurată pe 7 capitole la care se adaugă referințele bibliografice.

Capitolul 1 prezintă un studiu al literaturii de specialitate realizat asupra tipurilor de structuri de configurație specială precum grinzile cu zăbrele, structurile celulare, structurile spinoidale și mecanismele deformabile. Sunt studiate ultimele cercetări privind modurile de proiectare cât și de verificare numerică și experimentală a acestor structuri. În a doua parte a capitolului sunt analizate cele șapte tehnologii de fabricație aditivă ce pot fi utilizate pentru realizarea structurilor de configurație specială.

În capitolul 2 este realizată o analiză asupra tipurilor de optimizare structurală existente precum și a metodelor de reglare a proceselor de optimizare. Sunt studiați principalii algoritmi de rezolvare a problemelor de optimizare împărțiți în algoritmi bazați pe gradient, algoritmi de căutare directă și algoritmi de inteligență artificială.

În capitolul 3 se realizează o analiză comparativă a metodelor de căutare directă în rezolvarea unei probleme de optimizare a unei structuri repetitive compozite în scopul determinării soluției cu modulele de elasticitate maximizate după cele două direcții ortogonale. Modul de implementare al algoritmilor în limbajul de programare Python este descris și este prezentat întregul flux de lucru cu pachetul PyAnsys ce permite utilizarea integrată a programului de analiză cu elemente finite direct în formularea matematică a algoritmilor. Cei patru algoritmi de optimizare studiați *greedy*, SA, GA și PSO sunt evaluați după diferite metrici în funcție de efortul de calcul necesar și de calitatea soluției furnizate.

Capitolul 4 prezintă două metode de inteligență artificială ce pot fi utilizate în rezolvarea problemelor de optimizare structurală: o rețea neuronală de convoluție (CNN) și un autocodificator variațional (VAE). Sunt analizate modurile de construcție a rețelelor precum principalii parametri ce stau la baza acestora cât și modul de antrenarea și validare ale acestora. Rețeaua de convoluție este antrenată pentru a realiza predicția unor proprietăți mecanice ale structurilor, iar abilitățile generative ale autocodificatorului variațional sunt exploatate.

Cercetări experimentale asupra unui studiu de caz sunt realizate în capitolul 5. Structuri optimizate de algoritmi dezvoltați la capitolele anterioare sunt realizate prin tehnologii de fabricație aditivă după care sunt realizate diferite teste pentru determinarea proprietăților mecanice ale materialelor folosite. Rezultatele obținute experimental sunt comparate cu rezultatele numerice pentru a valida procesul de optimizare.

În capitolul 6 este prezentat un demers sintetizat și structurat de utilizare a metodologiei de optimizare dezvoltate. Sunt prezentate principalele etape pe care utilizatorul trebuie să le parcurgă de la definirea problemei de optimizare, la alegerea algoritmilor, antrenare și validare numerică și experimentală a soluțiilor.

În capitolul 7 sunt prezentate concluziile generale, contribuțiile personale și direcțiile viitoare de cercetare.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## **CAPITOLUL 1 – STADIUL ACTUAL AL PROIECTĂRII STRUCTURILOR TOPOLOGICE DE CONFIGURAȚIE SPECIALĂ**

Spre deosebire de structurile clasice, care sunt proiectate în mod uzual cu materiale omogene și geometrii convenționale pentru a prelua sarcinile și a îndeplini funcții mecanice de bază, structurile topologice de configurație specială precum grinzile cu zăbrele, microstructurile celulare, structurile spinoidale, mecanismele deformabile sau altele, exploatează geometria la nivel micro sau mezo pentru a îndeplini proprietăți unice și de multe ori contraintuitive. Aceste materiale sau structuri arhitecturate pot prezenta valori negative ale coeficientului lui Poisson, rigiditate programabilă, geometrii deformabile, capacitate sporită de absorbție a energiei precum și alte proprietăți mecanice. Proprietățile acestora nu reies doar din proprietățile materialelor de bază, dar și din configurația geometrică pe care o prezintă, permițând utilizatorilor să fabrice astfel de structuri care să prezinte un răspuns specific aplicațiilor.

Structurile cu zăbrele sunt compuse din elemente drepte conectate la noduri, formând unități triunghiulare care transportă eficient încărcările prin forțe axiale. Utilizate în mod tradițional în poduri, turnuri și structuri, zăbrelele oferă raporturi ridicate rezistență-greutate. În aplicațiile avansate, arhitecturile de tip zăbrele sunt miniaturizate în materiale *lattice*, unde geometria lor poate fi optimizată pentru a obține proprietăți specifice de rigiditate, rezistență sau absorbție a energiei [4]. Un exemplu de structură cu zăbrele optimizată este prezentat în Fig. 1-1 (a).

Structurile celulare constau din celule repetitive, adesea în aranjamente asemănătoare spumei, cu celule deschise sau închise. Aceste arhitecturi pot reduce semnificativ greutatea, menținând în același timp integritatea structurală, ceea ce le face ideale pentru componente ușoare. Geometria celulelor - hexagonală, octet sau aleatorie - poate fi optimizată pentru a influența performanța termică, acustică și mecanică. Structurile celulare sunt utilizate pe scară largă în ambalaje, panouri aerospațiale și straturi de absorbție a energiei [5], [6]. Un exemplu de structură celulară este prezentat în Fig. 1-1 (b).

Structurile spinodale sunt geometrii continue, inspirate de fenomenele de separare a fazelor din procesele metalurgice. Acestea prezintă zone netede, interconectate și sunt adesea generate computațional folosind simulări de descompunere spinodală. Aceste structuri oferă raporturi suprafață-volum ridicate, ceea ce le face potrivite pentru filtrare, implanturi biomedicale și materiale multifuncționale care necesită proprietăți cuplate precum rigiditatea și permeabilitatea [7]. Un exemplu de structură spinoidală este prezentat în Fig. 1-1 (c).

Mecanismele deformabile realizează mișcarea de mecanism prin deformarea elastică a structurii lor, în loc să utilizeze articulații sau balamale discrete. Acest lucru permite geometrii monolitice mai simple, cu un număr redus de piese și o întreținere redusă. Aceste mecanisme sunt utilizate pe scară largă în ingineria de precizie, dispozitivele biomedicale și robotica

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

ușoară. Performanța lor este foarte sensibilă la geometrie și la selecția materialelor, ceea ce face ca optimizarea computațională să fie esențială pentru proiectarea lor [3]. Un exemplu de mecanism deformabil plan obținut prin optimizare este prezentat în Fig. 1-1 (d).




Fig. 1-1 Exemple de structuri optimizate: (a) grindă cu zăbrele [8]; (b) structură celulară TPMS [9]; (c) structură spinoidală optimizată pentru a imita structura unui os [7]; (d) mecanisme deformabile de tip clește obținut prin optimizare [8]

La fel de important pentru această evoluție a fost dezvoltarea tehnologiilor de fabricație, în special a fabricației aditive. Multe dintre aceste structuri arhitecturate prezintă geometrii complexe, extrem de detaliate, care sunt impracticabile sau imposibil de fabricat folosind metode tradiționale. Fabricația aditivă permite construcția strat cu strat a unor forme interne complexe, cu un grad ridicat de libertate atât în geometrie, cât și în compoziția materialului. Tehnici precum extrudarea de material, foto-polimerizarea sau fuziunea de pulberi au deschis calea către realizarea fizică a structurilor proiectate computațional la scări multiple - de la rețele macro-arhitecturate la modele celulare sau spinodale la scară micro. Această sinergie dintre proiectare și fabricație nu numai că a permis producerea unor structuri anterior teoretice, dar a accelerat și inovația în domenii precum biomecanica, industria aerospațială și apărarea.

În acest capitol, am explorat domeniul emergent al structurilor topologice cu configurație specială, concentrându-ne pe geometria, funcția, fabricarea și testarea acestora.



UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

Aceste structuri avansate, oferă un comportament mecanic unic, greu de atins prin structuri clasice. Topologiile lor personalizate permit performanțe îmbunătățite, cum ar fi raporturi ridicate rezistență-greutate, comportament auxetic, deformare controlată sau absorbție de energie, ceea ce le face vitale în industria aerospațială, dispozitive biomedicale și sisteme structurale ușoare.

Evoluția acestor structuri a fost strâns legată de progresele în fabricația aditivă (AM). Cele șapte procese AM standard definite de ISO/ASTM 52900:2021 [10] - extrudarea materialelor, fotopolimerizarea, fuziunea în pat de pulbere, pulverizarea de material, pulverizarea de liant, depunerea de energie directă și laminarea foilor - au deschis fiecare oportunități specifice pentru fabricarea structurilor complexe, funcționale sau multi-material. Aceste tehnologii ocolesc constrângerile geometrice tradiționale, permițând producerea de forme extrem de complexe cerute de materialele arhitecturate moderne.

La fel de important este rolul selecției materialelor în AM. Polimerii, metalele și ceramica sunt acum adaptate în mod curent la diferite procese de fabricație aditivă (AM), fiecare oferind avantaje mecanice, termice sau chimice specifice. De exemplu, termoplasticele precum PLA și TPU sunt utilizate pe scară largă în AM pe bază de extrudare, în timp ce metalele precum Ti-6Al-4V sunt cruciale pentru fuziunea în pat de pulbere și depunerea de energie directă. AM pe bază de ceramică, deși mai dificilă, câștigă teren în aplicațiile medicale și în aplicații ce presupun temperaturi ridicate. Combinația dintre designul structural și proprietățile materialelor este esențială pentru reglarea performanței structurilor cu configurație specială.

În cele din urmă, capitolul a analizat metodologiile de testare experimentală necesare pentru validarea și caracterizarea acestor structuri. Tehnicile variază de la testarea mecanică clasică (teste de tracțiune, compresie și încovoiere) până la corelarea avansată a imaginilor digitale (DIC) și analiza la oboseală sau la încărcare ciclică. Aceste metode asigură că topologiile noi nu numai că îndeplinesc așteptările teoretice, dar funcționează și în mod fiabil în condiții practice de încărcare.

În concluzie, convergența dintre proiectarea structurală, materialele avansate, procesele de fabricație aditivă de ultimă generație și testarea experimentală robustă a creat o nouă paradigmă de proiectare. Aceste structuri cu configurație specială oferă soluții promițătoare pentru provocările ingineresti viitoare, în special atunci când sunt optimizate prin metode computaționale și validate prin cercetări experimentale. Dezvoltarea continuă în acest domeniu va duce probabil la sisteme de materiale și mai adaptive, multifuncționale și inteligente, adaptate pentru aplicații din lumea reală.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## CAPITOLUL 2 – ANALIZA PROCEDEELOR ȘI A ALGORITMILOR DE OPTIMIZARE STRUCTURALĂ

Optimizarea structurală este utilizată în ingineria mecanică de mulți ani, de exemplu pentru a minimiza masa de material folosit și energia totală de deformare a structurilor, menținându-și în același timp rezistența mecanică [8]. Aceasta include optimizarea dimensională, optimizarea de formă și optimizarea topologică și duce la generarea unor geometrii mai complexe pentru structurile utilizate în domeniu, geometrii care nu pot fi realizate întotdeauna cu procedeele clasice de fabricație.

Optimizarea structurală are rolul de a crește performanțele (definite de utilizator) unei structuri mecanice cu ajutorul unei formulări matematice. Aceasta poate fi optimizare dimensională, optimizare de formă sau optimizare topologică. Optimizarea structurală poate face referire la optimizarea topologică clasică, la optimizarea compozitelor, la optimizarea mecanismelor deformabile, la optimizarea microstructurilor celulare sau la combinații din cele menționate.

Conform [11], orice proces de proiectare structurală cuprinde trei stadii. Primul stadiu este unul *conceptual* în care sistemul structural și forma lui brută sunt alese. În cadrul acestui stadiu se face apel la experiența și judecata proiectantului într-un mod calitativ și nu are o bază algoritmică, fiind foarte dificil de automatizat. Cel de-al doilea stadiu, *proiectarea preliminară*, presupune stabilirea formei și a geometriei definitive. Ultimul stadiu, *proiectarea detaliată*, presupune modificarea locală și detaliată a geometriei structurii. Procesele de optimizare structurală, pot fi aplicate începând cu cel de-al doilea stadiu sau, în unele cazuri, în al treilea stadiu.

O problemă de optimizare cu constrângeri se scrie din punct de vedere matematic sub următoarea formă:

$$\begin{aligned} \min_{x \in \mathbb{R}^n} f(x) \\ \text{supus la: } Cx \leq d, g(x) \leq 0, l \leq x \leq u, Ax = b, h(x) = 0 \end{aligned} \quad (2-1)$$

unde  $l, u \in \mathbb{R}^n$ ,  $d \in \mathbb{R}^{m1}$ ,  $b \in \mathbb{R}^{p1}$ ,  $C \in \mathbb{R}^{m1 \times n}$ ,  $A \in \mathbb{R}^{p1 \times n}$ , iar  $g(x): \mathbb{R}^n \rightarrow \mathbb{R}^{m2}$ ,  $h(x): \mathbb{R}^n \rightarrow \mathbb{R}^{p2}$  sunt funcții multidimensionale (vectori de funcții), reprezentând constrângerile neliniare de inegalitate și respectiv, de egalitate iar  $x$  reprezintă variabila de optimizare.

Acest capitol a explorat abordările fundamentale și avansate ale optimizării structurale, cu accent deosebit pe cele trei metode clasice - optimizarea dimensională, optimizarea de formă și optimizarea topologică - și strategiile lor de calcul. Fiecare dintre aceste niveluri de optimizare joacă un rol distinct în procesul de proiectare. Optimizarea dimensională, ca abordare de bază, se ocupă de ajustarea dimensiunilor sau grosimilor secțiunii transversale în cadrul unor machete predefinite pentru a obține eficiență și reducerea greutateii. Optimizarea formei avansează acest lucru prin rafinarea limitelor externe ale structurilor, îmbunătățind performanța fără a altera topologia acesteia. În cele din urmă, optimizarea topologică reprezintă

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

cea mai generală și puternică strategie, permițând descoperirea unor modele de materiale și forme structurale complet noi, care sunt adesea contraintuitive și imposibil de atins prin abordările tradiționale de proiectare.

O metodă centrală în optimizarea topologiei este tehnica SIMP. Această abordare s-a dovedit extrem de eficientă pentru reducerea discrepantei dintre formulările de optimizare continuă și modelele discrete. Cu toate acestea, SIMP și metodele aferente bazate pe densitate nu sunt lipsite de provocări. Instabilitățile numerice, cum ar fi modelele de tip tablă de șah, dependența de finețea discretizării și apariția unor soluții non-fizice, complică adesea procesul de optimizare. Pentru a aborda aceste probleme, au fost implementate tehnici de filtrare și strategii de regularizare, în timp ce modelarea evoluției interfeței a apărut ca o alternativă promițătoare, oferind un cadru matematic consistent pentru a controla limitele structurale și a asigura tranziții line între fazele materialelor. Împreună, aceste dezvoltări evidențiază importanța nu doar a formulării problemelor de optimizare, ci și a asigurării robusteții, fiabilității și aplicabilității acestora în contexte practice de inginerie. Influența implementării unor tehnici de regularizare asupra soluției optime poate fi observată în Fig. 2-1.




Fig. 2-1 Problema tablei de șah demonstrată pe o structură rectangulară supusă la o încărcare biaxială și modelată cu elemente Q4. a) modelul problemei, b) soluția obținută fără aplicarea constrângerilor pentru eliminarea tablei de șah, c) soluția obținută cu aplicarea constrângerilor [8]

Dincolo de formularea problemelor, un aspect crucial al optimizării structurale constă în algoritmi utilizați pentru rezolvarea problemei. Acest capitol a analizat trei categorii majore: metode bazate pe gradient, metode de căutare directă și abordări bazate pe inteligență artificială. Tehnicile bazate pe gradient rămân cele mai utilizate în optimizarea structurală datorită eficienței și fundamentului matematic solid, în special pentru problemele în care informațiile derivate sunt disponibile și precise. Cu toate acestea, dependența lor de funcții obiectiv diferențiabile le limitează aplicabilitatea în probleme de optimizare extrem de neliniare sau discrete.

În schimb, metodele de căutare directă - cum ar fi algoritmul *greedy*, algoritmi genetici sau roi de particule - nu necesită informații derivate, ceea ce le face atractive pentru probleme neliniare, în care funcția obiectiv nu este derivabilă sau pentru rezultate obținute prin metode experimentale. Robuștețea lor este adesea compensată de costul de calcul, în

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

special în spațiile de căutare de dimensiuni ridicate, dar rămân un instrument important în aplicațiile în care gradientii fie nu sunt disponibili, fie sunt nesiguri.

În cele din urmă, ascensiunea inteligenței artificiale a deschis noi frontiere în optimizarea structurală. Metodele bazate pe rețelele neuronale au demonstrat capacitatea de a explora spații de proiectare vaste și complexe, de a capta comportamente neliniare și de a se integra perfect cu datele de simulare. Metodele bazate pe inteligență artificială oferă, de asemenea, potențial în optimizarea bazată pe date, unde modelele de învățare automată aproximează performanțele, reducând drastic costul de calcul. Cu toate acestea, rămân provocări în ceea ce privește fiabilitatea convergenței, interpretabilitatea și integrarea cu constrângerile bazate pe fenomene fizice. Combinarea inteligenței artificiale cu cadrele de optimizare tradiționale, în special abordările hibride, este o direcție promițătoare pentru cercetările viitoare.

Luate împreună, discuția despre metode, instabilități numerice și algoritmi de calcul ilustrează natura interconectată a optimizării structurale. Aplicarea lor cu succes nu este doar o chestiune de alegere a unui algoritm, ci mai degrabă de echilibrare a rigurozității matematice, a eficienței computaționale și a viabilității fizice. Dezvoltarea continuă a metodelor de filtrare și regularizare, combinată cu progresele în optimizarea bazată pe inteligență artificială, sugerează că viitorul optimizării structurale va implica din ce în ce mai mult strategii hibride - integrând rigurozitatea bazată pe gradienti, robustețea căutării directe și adaptabilitatea învățării automate.

Dintr-o perspectivă mai largă, optimizarea structurală reprezintă mai mult decât un exercițiu computațional; este o filozofie de proiectare care remodelează ingineria modernă. Capacitatea de a identifica sistematic configurațiile optime permite inginerilor să reducă consumul de materiale și să descopere concepte structurale noi. Aceste progrese au un impact deosebit atunci când sunt combinate cu metode moderne de fabricație, cum ar fi fabricația aditivă, care pot aduce topologii optimizate în realitatea fizică fără limitările fabricației tradiționale. Ca atare, optimizarea structurală nu este doar un instrument teoretic puternic, ci și un factor practic care permite inovația în domeniul aerospațial, auto, biomedical, al ingineriei civile precum și în alte domenii.

În concluzie, evoluția optimizării structurale a progresat de la ajustările clasice ale dimensiunilor la proiectarea avansată a topologiei, susținută de algoritmi sofisticati și modele numerice. Provocări precum utilizarea configurațiilor în tablă de șah, dependența de finețea discretizării și instabilitatea soluției au stimulat dezvoltarea de filtre și formulări de modelare a evoluției interfeței, consolidând fiabilitatea procesului de optimizare. Între timp, extinderea tehnicilor de calcul disponibile a îmbogățit setul de instrumente disponibil atât cercetătorilor, cât și inginerilor implicați în producție. Privind în perspectivă, integrarea acestor metode diverse, împreună cu simulări de înaltă fidelitate și tehnologii avansate de fabricație, va continua să împingă limitele proiectării structurale, conducând către structuri cu adevărat optimizate, multifuncționale și adaptive, capabile să abordeze provocările ingineresti ale viitorului.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

### **CAPITOLUL 3 – ANALIZA COMPARATIVĂ A METODELOR DE CĂUTARE DIRECTĂ ÎN REZOLVAREA PROBLEMELOR DE OPTIMIZARE STRUCTURALĂ**

Acest capitol se concentrează pe analiza metodelor de căutare directă aplicate problemelor de optimizare structurală. Aceste abordări sunt apreciate pentru simplitatea, versatilitatea și aplicabilitatea lor largă, în special în cazurile în care informațiile despre gradient nu sunt disponibile sau sunt nesigure. Spre deosebire de metodele bazate pe gradient, tehnicile de căutare directă nu necesită derivate explicite ale funcției obiectiv. În schimb, ele explorează sistematic spațiul de proiectare prin secvențe de soluții eșantionate, ceea ce le face deosebit de potrivite pentru problemele cu funcții obiectiv nediferențiabile, discontinue sau costisitoare din punct de vedere computațional.

Scopul acestui capitol este de a evalua și compara diferiți algoritmi de căutare directă în ceea ce privește eficiența lor în rezolvarea problemelor de optimizare structurală. Pentru fiecare metodă, discuția evidențiază principalele avantaje, limitări și considerații practice pentru a înțelege mai bine contextele în care fiecare abordare este cea mai eficientă. Metodele de căutare directă examinate includ: căutarea prin forță brută (*brute force*), algoritmi *greedy*, algoritmi *simulated annealing* (SA), algoritmi genetici (GA) și optimizarea de tip roi de particule (PSO).

Pentru a compara și evalua metodele de căutare directă se definește o problemă de optimizare a unui material compozit. Problema aleasă, este inspirată din [12] cu anumite modificări. Pentru început, s-a considerat un domeniu bi-dimensional periodic (Fig. 3-1 (a)) format din două materiale diferite, pentru care se cunosc modulele de elasticitate  $E_1$ , respectiv  $E_2$  și coeficienții contracției transversale  $\nu_1$ , respectiv  $\nu_2$ . În domeniul dat, proporțiile celor două materiale sunt egale. Obiectivul propus pentru această problemă de optimizare este de a determina care este distribuția optimă din cele două materiale în domeniul dat care asigură proprietăți efective maxime și egale între ele ale modulelor de elasticitate în cele două direcții ortogonale ale domeniului.

Analizând domeniul dat, se identifică o celulă reprezentativă conform celei prezentate în Fig. 3-1 (b) care, din motive de simetrie, se poate analiza doar pe un sfert de celulă – Fig. 3-1 (c). Acest sfert de celulă, de dimensiuni generale  $a \times b$ , pentru problema de față  $a = b = 1$  mm, se poate analiza folosind condiții la limită (rezemări și încărcări) adecvate (Fig. 3-1 (d)) și o discretizare cu numai 16 elemente finite patrulate egale. Pentru a simula comportamentul acestui sfert de celulă în domeniul periodic, se aplică condiția de simetrie în deplasări după axa  $Ox$  pe latura  $x=0$ , respectiv condiția de simetrie în deplasări după axa  $Oy$  pe latura  $y=0$ . În același timp se aplică cuplaj în deplasări după axa  $Ox$  pe latura  $x=a$ , respectiv cuplaj în deplasări după axa  $Oy$  pe latura  $y=b$ . Aceste condiții la limită impuse sfertului de celulă reprezentativă echivalează cu realizarea calculului pe întreg domeniul periodic.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

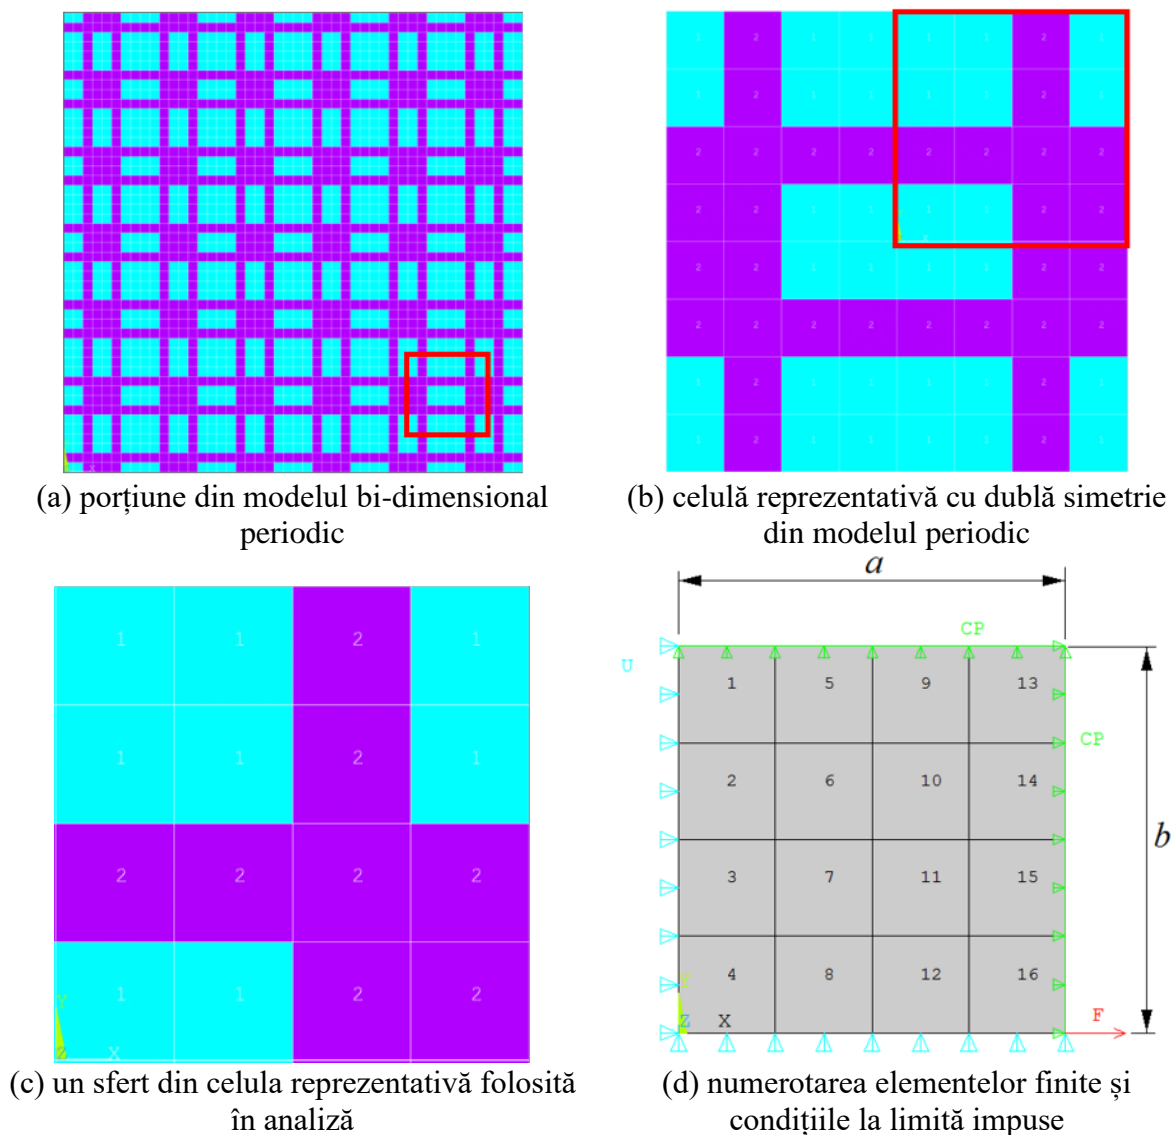


Fig. 3-1 Descrierea domeniului bi-dimensional periodic format din 2 materiale cu proprietăți diferite ce apar în proporții egale în domeniu

Pentru problema de față un parametru de interes al celulei reprezentative este modulul de elasticitate efectiv care se poate defini prin relația (3-1)

$$E_{eff} = \frac{\bar{\sigma}}{\bar{\varepsilon}} = \frac{\frac{1}{V} \sum_{i=1}^{NE} V_i \sigma_i}{\frac{1}{V} \sum_{i=1}^{NE} V_i \varepsilon_i} \quad (3-1)$$

unde:

- $E_{eff}$  este modulul de elasticitate efectiv (mediat);
- $\bar{\sigma}$  este tensiunea mediată pe întreg domeniul de calcul;
- $\bar{\varepsilon}$  este deformația specifică mediată pe întreg domeniul de calcul;
- $V$  este volumul întregului domeniu de calcul;

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

- $NE$  este numărul de elemente din domeniul de calcul;
- $V_i$  este volumul elementului  $i$ ;
- $\sigma_i$  este tensiunea medie în elementul finit  $i$  (componenta reprezentativă după X sau Y);
- $\varepsilon_i$  este deformația specifică medie în elementul finit  $i$  (componenta reprezentativă după X sau Y);

Un studiu de convergență a fost realizat, de unde putem observa că pentru o soluție care are foarte multe elemente conetate în tablă de șah, finețea discretizării are un rol foarte important. Pe măsură ce numărul de elemente folosite pentru discretizare unui domeniu de material crește, valoare modulului de elasticitate scade, dar și comportamentul soluției la rotirea axelor se modifică drastic. Cea mai accentuată modificare se poate observa în cazul coeficientului lui Poisson, când figura devine antisimetrică odată cu creșterea numărului de elemente în discretizarea unui domeniu. În acest sens, s-a aplicat o dicretizare cu 9 elemente finite în fiecare domeniu de material.

Analizând spațiul soluțiilor prezentat în Fig. 3-2 se consideră cele patru soluții prezentate în dreapta figurii ca fiind soluțiile optime pentru evaluarea performanțelor algoritmilor. Primele două soluții au aceeași valoare a funcției obiectiv egală cu 4,065855 și ele reprezintă aceeași soluție rotită cu  $90^\circ$ . Deși această soluție nu prezintă module de elasticitate egale pe cele două direcții, eroarea relativă între acestea este sub 0,2 % și este considerată optimă. Următoarele două soluții au valori ale funcției obiectiv egale cu 4,027104, respectiv 4,022015 și prezintă o eroare relativă față de prima soluție mai mică decât 1,1 %.

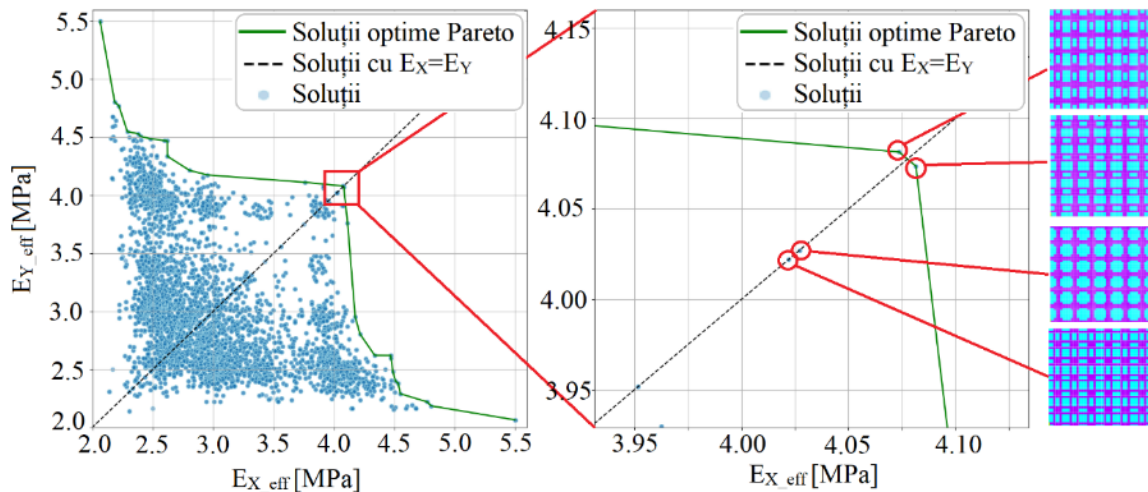


Fig. 3-2 Distribuția tuturor soluțiilor discretizate cu 9 elemente finite pe domeniu și prezentare celor patru soluții considerate optime pentru evaluarea performanțelor algoritmilor de căutare directă

Modul în care algoritmi converg în timp poate fi observat în mod evident în Fig. 3-3, unde se prezintă funcțiile de distribuție de probabilitate ale timpului de calcul. Deoarece timpul de calcul efectiv, măsurat în secunde, este influențat de performanțele sistemului de calcul utilizat, acesta este exprimat aici prin numărul de evaluări ale funcției obiectiv. Analiza statistică din Fig. 3-3 ilustrează atât calitativ, cât și cantitativ performanțele algoritmilor, cu 100 de rulări pentru problema 4x4 pentru fiecare dintre aceștia.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------




Fig. 3-3 Densitatea de probabilitate a numărului de evaluări ale celor 4 algoritmi pentru problema 4x4

Analizând Fig. 3-3 putem spune că pentru problema 4x4, algoritmul PSO prezintă cea mai bună formă a PDF cu o simetrie clară și un grad de „vârfuire” accentuat ceea ce indică probabilități mari ca algoritmul să determine optimul global în jurul valorii medii a numărului de evaluări ale funcției obiectiv. În mod similar, putem trage aceeași concluzie despre algoritmul *greedy* care se situează pe locul doi din punctul de vedere al formei PDF. În ceea ce privește GA, se poate observa că forma PDF prezintă asimetrie accentuată și un grad scăzut de „vârfuire” fapt ce indică o probabilitate mai mică ca un algoritm genetic să ajungă la optimul global cu un număr de evaluări ale funcției obiectiv apropiat de medie. Densitatea probabilității pentru GA este mult mai împrăștiată decât a celor doi algoritmi analizați anterior. Pentru SA, se poate observa că acesta prezintă o simetrie clară dar gradul de aplatizare este similar cu GA. Probabilitatea ca algoritmul să găsească optimul global pentru un număr de evaluări ale funcției obiectiv în jurul mediei este similară cu probabilitatea algoritmului GA dar mai mare în jurul valorii medii.

În ceea ce privește problema 6x6, întrucât din cauza numărului foarte mare de soluții este imposibilă realizarea *brute force* și determinarea optimului global, s-au realizat câte 5 rulări cu algoritmi *greedy*, GA și PSO. Motivul pentru care nu s-a implementat și SA pentru problema 6x6 este dat de structura acestuia similară cu a algoritmului *greedy*, practic o înlănțuire de algoritmi *greedy*.

Pentru a realiza o comparație directă între algoritmi se impune prezentarea evoluției funcției obiectiv față de numărul de evaluări ale funcției deoarece fiecare algoritm evaluează un număr diferit de soluții la fiecare iterație. Pentru problema 6x6 algoritmul *greedy* evaluează 324 de soluții pe iterație, GA evaluează 180 de soluții pe iterație, iar PSO evaluează 30 de soluții pe iterație. Evoluție funcției obiectiv pentru primele 10.000 de soluții evaluate este prezentată în Fig. 3-4.






Fig. 3-4 Evoluția funcției obiectiv în funcție de numărul de evaluări necesare pentru cei trei algoritmi – Greedy, GA și PSO – primele 10.000 de soluții evaluate

Putem observa în Fig. 3-4 că pentru primele 1.000 de evaluări ale funcției obiectiv, cei trei algoritmi au rezultate comparabile în ceea ce privește valoarea funcției obiectiv. Algoritmul *greedy* este singurul care are o îmbunătățire a funcției obiectiv la fiecare iterație și cel care atinge cea mai mare valoare a funcției egală cu 3,822149. În același timp, din cele 5 rulări, 2 ajung la soluții cu rezultatele cele mai slabe dintre cei trei algoritmi. Se poate observa că rulările pentru GA și PSO ajung în jurul aceleiași valori, cu o valoare îmbunătățită pentru PSO și cu mai puține evaluări ale funcției obiectiv.

Întrucât algoritmi *greedy* și PSO au prezentat cele mai bune performanțe, o abordare hibrid PSO+*greedy* a fost realizată. Fig. 3-5 prezintă valoarea medie a funcției obiectiv în funcție de numărul mediu de evaluări necesare pentru a atinge respectiva valoare pentru cele 5 rulări pentru fiecare dintre cei patru algoritmi prezentați. Graficul ne indică efortul de calcul și performanțele atinse de unde putem concluziona că algoritmul *greedy* prezintă cel mai mic efort de calcul dar cu o valoare medie mai mică a funcției obiectiv. Cea mai bună valoare medie a funcției obiectiv o are algoritmul hibrid dar efortul de calcul este mai mare. În același timp, GA cade pe ultimul loc în ceea ce privește valoarea funcției obiectiv dar și efortul de calcul depus.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------




Fig. 3-5 Valoarea medie a funcției obiectiv funcție de numarul mediu de evaluări

Acest studiu comparativ oferă informații valoroase asupra performanței a patru algoritmi de optimizare - *greedy*, SA, GA și PSO, precum și o abordare hibridă PSO-*greedy*. Algoritmii au fost evaluați pe baza diferitelor metrice, cum ar fi viteza de convergență, calitatea soluției, eficiența de calcul și robustețea.

Analiza arată că fiecare algoritm prezintă puncte forte și puncte slabe distincte, în funcție de caracteristicile și cerințele problemei de optimizare. Algoritmul *greedy*, deși simplu, demonstrează performanță competitivă în ceea ce privește viteza de convergență, dar poate suferi de soluții suboptimale. Pentru problema de dimensiuni reduse 4x4, toți algoritmii ating maximul global cunoscut însă efortul de calcul este diferit. Pentru problema de dimensiuni mai mari 6x6, în lipsa informației maximului global putem observa că GA este mult mai susceptibil la blocaje în minime locale față de ceilalți algoritmi.

Abordarea hibridă PSO-*greedy*, care combină punctele forte ale ambilor algoritmi, arată rezultate promițătoare în ceea ce privește echilibrarea explorării și exploatării, ceea ce duce la îmbunătățirea calității soluției și a vitezei de convergență în comparație cu algoritmii individuali. În general, alegerea celui mai potrivit algoritm de optimizare depinde de diverși factori, cum ar fi complexitatea problemei, resursele de calcul și obiectivele de optimizare.

Cercetările privind comparația algoritmilor de căutare directă au fost publicate în [13], iar aceleași metode au fost testate pentru optimizarea configurațiilor auxetice pentru alte tipuri de configurații geometrice [14].

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## CAPITOLUL 4 – METODE DE ÎNVĂȚARE AUTOMATĂ PENTRU OPTIMIZAREA STRUCTURALĂ

Acest capitol analizează metode bazate pe învățarea automată (ML) în rezolvarea problemelor de optimizare structurală, metode care oferă flexibilitate, adaptabilitate și eficiență pentru o gamă largă de probleme. Spre deosebire de metodele tradiționale bazate pe gradient, tehnicile de ML pot învăța relații complexe și pot identifica modele în datele analizate, fără a necesita cunoașterea explicită a gradientului funcției obiectiv. Aceste tehnici explorează spațiul de optimizare prin intermediul algoritmilor de învățare, care îmbunătățesc continuu estimările bazate pe feedback, fiind astfel potrivite pentru probleme cu spații foarte mari de căutare.

Problema aleasă pentru testarea metodelor de ML este similară cu problema descrisă în Capitolul 3 cu câteva diferențe. Se consideră același domeniu bi-dimensional periodic format din două materiale diferite cu aceleași valori pentru coeficienții lui Poisson  $\nu_1=0,4$ , respectiv  $\nu_2=0,2$ , dar cu valori diferite pentru modulele de elasticitate ale materialelor,  $E_1=1$  MPa, respectiv  $E_2=100$  MPa). În domeniul dat, nu se impun restricții în ceea ce privește proporțiile celor două materiale astfel încât spațiul de căutare să fie cât mai puțin restricționat. Obiectivul propus pentru această problemă de optimizare este de a determina care este distribuția optimă a celor două materiale în domeniu astfel încât să se asigure valori efective minime ale coeficienților lui Poisson în cele două direcții ortogonale ale domeniului.

Condițiile la limită impuse pentru cazurile de încărcare utilizate sunt la fel ca la problema anterioară. Ținând cont de studiul asupra dependenței de finețea discretizării prezentat în Capitolul 3, se impune eliminarea soluțiilor ce prezintă elemente conectate în tablă de șah din spațiul de căutare deoarece s-a demonstrat că acestea introduc erori semnificative în calcule odată cu creșterea gradului de discretizare. Astfel, s-a păstrat discretizarea cu un singur element finit pe domeniu de material, dar s-au eliminat soluțiile conectate în tablă de șah. În cazul de față, din analiza soluțiilor obținute prin *brute force*, putem observa că avem un număr de 23.858 de soluții ce nu conțin elemente în tablă de șah, reprezentând aproximativ 36,4% din totalul de 65.536 de soluții. Reprezentarea grafică a acestor soluții se poate regăsi în Fig. 4-1.

Dacă analizăm Fig. 4-1, se poate observa că în colțul din stânga jos, găsim soluțiile cu valoare negativă a coeficientului lui Poisson într-un număr de 34 de configurații, dintre care 5 independente, reprezentând sub 0,15% din întreg spațiul de soluții. Motivul pentru care în figură nu se observă 34 de puncte este dat de suprapunerea unor soluții cu altele în ceea ce privește valoarea celor doi coeficienți. Cele 5 soluții independente în formă periodică cu valoare negativă pentru coeficientul lui Poisson sunt prezentate în Fig. 4-2.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------




Fig. 4-1 Distribuția tuturor soluțiilor ce nu prezintă elemente în tablă de șah în funcție de valoarea coeficienților lui Poisson – configurația 4x4




Fig. 4-2 Reprezentarea periodică a soluțiilor cu valoare negativă a coeficientului lui Poisson pentru modelul 4x4

Au fost implementate două modele de ML, o rețea neuronală de convoluție (CNN) pentru predicția valorii coeficientului lui Poisson în funcție de distribuția de material și un autocodificator variațional (VAE) cu abilitatea de a comprima spațiul de soluții într-un spațiu latent și de a reconstrui datele.

Modelul CNN s-a dovedit a fi un model robust, cu o valoare foarte scăzută în ceea ce privește eroarea de predicție. Acest lucru implică faptul că antrenarea a fost realizată cu un set de date suficient de mare, reprezentând doar o fracțiune de 0,0006% din întreg spațiul de soluții, iar parametrii din procesul de antrenare au fost bine setați. În final, obținem un model, care poate prezice cu o precizie ridicată proprietățile mecanice ale unei configurații, fără să realizeze calcule complexe asemănătoare analizei cu elemente finite. Folosind acest model, putem aplica metode de căutare directă studiate anterior pentru a determina soluția optimă din spațiul de soluții.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

Din cercetările anterioare, s-a stabilit că algoritmul *greedy* a prezentat o performanță ridicată în rezolvarea acestor probleme. În acest sens, a fost aplicat algoritmul împreună cu rețeaua neuronală de convoluție antrenată pentru modelul 6x6. În Fig. 4-3 se prezintă valoarea prezisă de rețeaua neuronală a coeficienților lui Poisson față de valoarea reală verificată cu analiza cu elemente finite pentru 20 de soluții auxetice determinate de algoritm. Pentru a crește performanțele algoritmului *greedy*, la fiecare iterație acesta a verificat toate configurațiile obținute prin modificarea unui element din domeniu dar și toate configurațiile obținute prin modificarea a două elemente. La fiecare iterație, algoritmul a evaluat maxim 1.296 de soluții, eliminând soluțiile ce prezintă elemente conectate în tablă de șah deoarece a fost stabilit apriori eliminarea acestora din cauza erorilor.

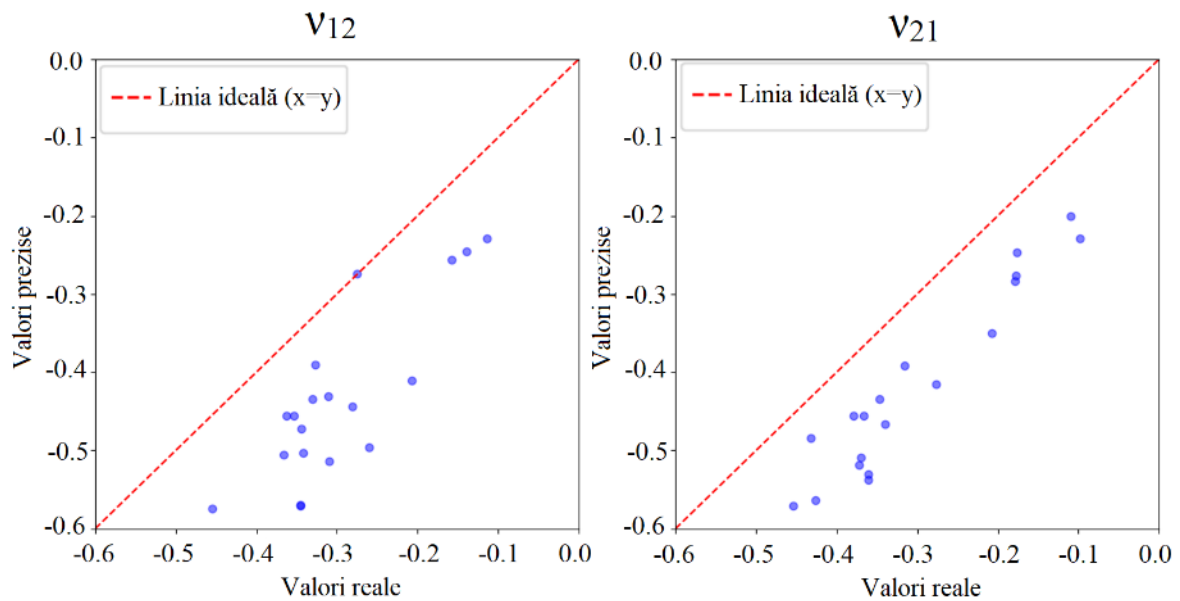


Fig. 4-3 Valori prezise față de valori reale ale coeficienților lui Poisson pentru soluții auxetice determinate cu *greedy* pentru modelul 6x6

Putem observa că valoarea prezisă este mult mai mică decât valoarea reală determinată prin analiză cu elemente finite, eroarea putând ajunge până la 133%. Acest lucru poate fi explicat prin faptul că, în setul de date de antrenare format din 280.000 de soluții, doar aproximativ 1.500 de soluții sunt auxetice, aproximativ 0,53%, prezentând valori negative pentru coeficientul lui Poisson cu cea mai mică valoare întâlnită egală cu -0,371. Astfel, deși rețeaua a învățat să prezică valoarea coeficientului lui Poisson pentru soluții alese aleator, aceasta prezintă o eroare mai mare pentru extremele spațiului de soluții. În același timp, deși valoarea reală diferă cu mult de valoarea prezisă, soluțiile determinate sunt în continuare auxetice iar ordinea coeficienților preziși corespunde cu ordinea coeficienților reali. În Fig. 4-4 se prezintă cele mai bune 9 soluții determinate de algoritm în reprezentarea periodică a structurii.



UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------



Fig. 4-4 Cele mai bune nouă soluții determinate de algoritmul greedy aplicat împreună cu rețeaua neuronală de convoluție pentru modelul 6x6

Putem observa în figura prezentată anterior că toate soluțiile prezintă un element comun, și anume prezența unui dreptunghi de material moale care alternează în orientare în lungul direcției X (orizontală) sau Y (verticală) în structura periodică. Soluția cu cele mai mici valori pentru coeficientul lui Poisson este soluția din Fig. 4-5 (a) cu valori egale ale coeficientului lui Poisson după cele două direcții ortogonale de  $-0,4543$ . Analizând literatura de specialitate, putem observa că această soluție este foarte similară cu celula tetra-anti-chiral care este prezentată în Fig. 4-5 (d). În Fig. 4-5 se prezintă celula reprezentativă pentru cea mai bună soluție obținută (a), câmpul de deplasări pentru solicitarea axială în lungul axei X (b), respectiv în lungul axei Y (c), precum și tensiunile echivalente în celula reprezentativă pentru solicitarea axială în lungul axei X (e), respectiv în lungul axei Y (f). Câmpul de deplasări, respectiv

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

tensiunile echivalente au fost obținute prin analiza cu elemente finite folosind cazurile de încărcare prezentate anterior și anume tracțiune după axa X, respectiv tracțiune după axa Y.

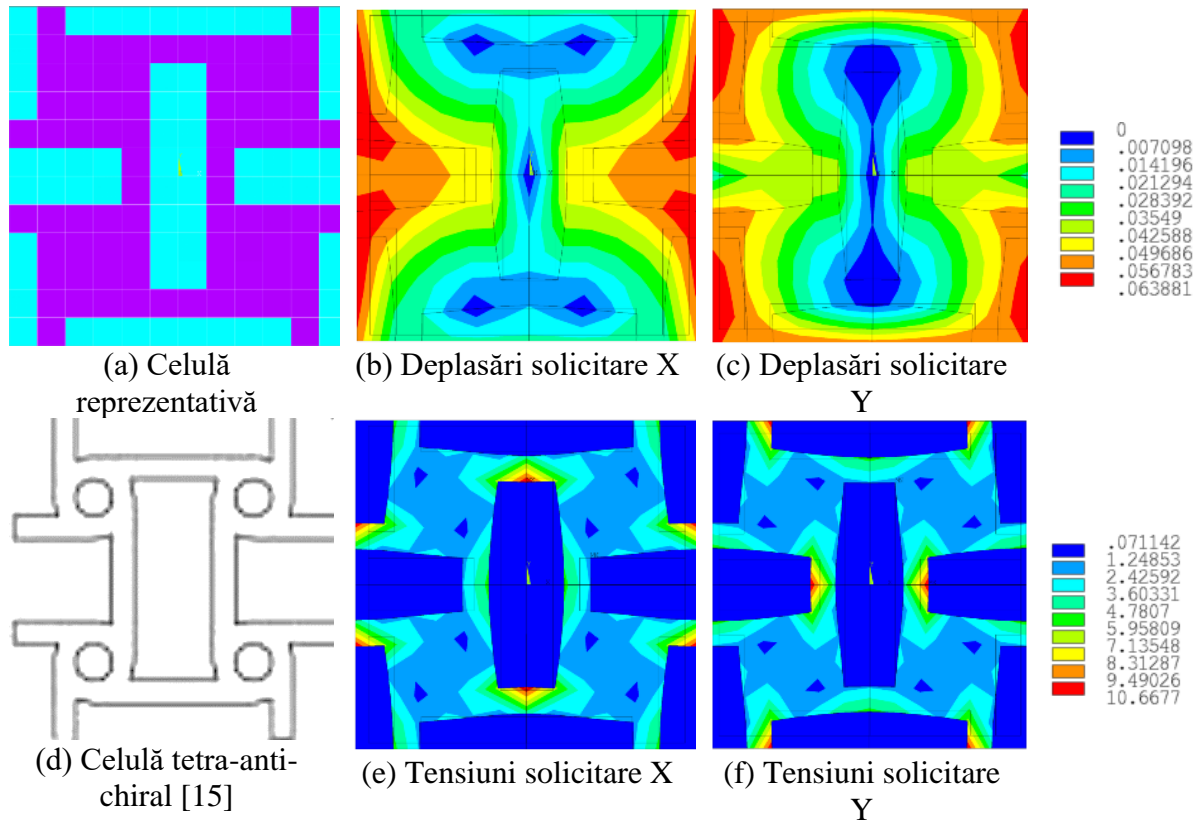


Fig. 4-5 Soluția determinată cu cea mai mică valoare a coeficientului lui Poisson, câmpul de deplasări și tensiuni pentru cele două cazuri de încărcare și asemănarea cu celula tetra-anti-chiral

În ceea ce privește modelul VAE, datele prezentate anterior sugerează că modelul a fost antrenat cu succes, iar acesta poate comprima variabilele de intrare într-un spațiu latent după care poate realiza reconstrucția datelor cu precizie ridicată. Următorul pas în dezvoltarea acestui model este realizarea unei legături între performanțele unei anumite soluții, în cazul de față între valorile coeficienților lui Poisson și spațiul latent determinat de rețeau VAE. În acest caz, se poate reduce cu succes dimensiunea unei probleme de la 36 de variabile binare care reprezintă configurația unei soluții la 12 variabile latente eșantionate dintr-o distribuție normală generată de encoderul modelului. O corespondență bine realizată între valoarea funcției obiectiv și variabilele latente facilitează rezolvarea problemei de optimizare. În afară de acest avantaj pe care îl poate reprezenta modelul VAE, acesta are și proprietăți generative și poate genera structuri noi cu performanțe superioare ce nu au fost „văzute” anterior de model. Un exemplu de aplicare cu succes a unui model VAE în rezolvarea unei astfel de probleme este prezentat în [16].

Cu modelul VAE antrenat pe setul de date cu soluții auxiliare, s-a realizat procesul de optimizare bayesiană în spațiul latent. Procedul de optimizare bayesiană se bazează pe selectarea celor mai bune locuri din spațiul latent pentru a realiza căutarea folosind probabilități și informații cunoscute apriori. Spre deosebire de metodele de căutare stocastică, optimizarea

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

bayesiană construiește un model pentru a prezice cât de promițătoare este o anumită regiune, face presupuneri privind date de intrare similare ce dau date de ieșire similare, iar modelul se actualizează automat cu fiecare punct testat. În Fig. 4-6 se prezintă cele mai bune 5 soluții determinate prin procedeul de optimizare bayesiană în spațiul latent.




Fig. 4-6 Cele mai bune 5 soluții determinate prin optimizare bayesiană în spațiul latent al VAE pentru modelul 6x6

Se poate observa că valorile minime obținute cu ajutorul optimizării bayesiene în spațiul latent al VAE nu sunt mai mici decât cele obținute cu ajutorul algoritmului *greedy* și a modelului CNN. Modelul inițial utilizat reușește să determin structuri cu valori mai mici ale coeficientului lui Poisson. Cu toate acestea, se dovedește că și optimizarea bayesiană poate determina structuri auxetice.

Pe lângă optimizarea în spațiul latent, un model VAE antrenat poate fi utilizat și pentru proprietățile sale generative. De exemplu, acesta poate identifica familii de soluții ce prezintă caracteristici asemănătoare și pot fi testate în privința proprietăților similare. Un alt mod de a utiliza proprietățile generative ale VAE este de a realiza o interpolare în spațiul latent între două soluții cunoscute. Întrucât spațiul latent este bine organizat, soluții învecinate prezintă caracteristici asemănătoare, motiv pentru care se poate interpola între două vectori latenți, iar rezultatele prezintă modul în care se face trecerea de la o soluție la alta navigând prin spațiul de soluții. Un astfel de exemplu este prezentat în Fig. 4-7 unde se observă structurile pentru fiecare pas de interpolare (a) și variația coeficienților lui Poisson (pe direcția X cu albastru și pe direcția Y cu portocaliu) corespondent cu fiecare configurație din spațiul de interpolare (b). Utilizatorul poate folosi această proprietate generativă pentru a determina soluții noi care au proprietăți combinate. De exemplu, dacă cunoaștem o structură auxetică și o structură cu valoare ridicată a modulului de elasticitate transversal, prin interpolare între acestea două se pot determina structuri care combină cele două proprietăți menționate.



UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

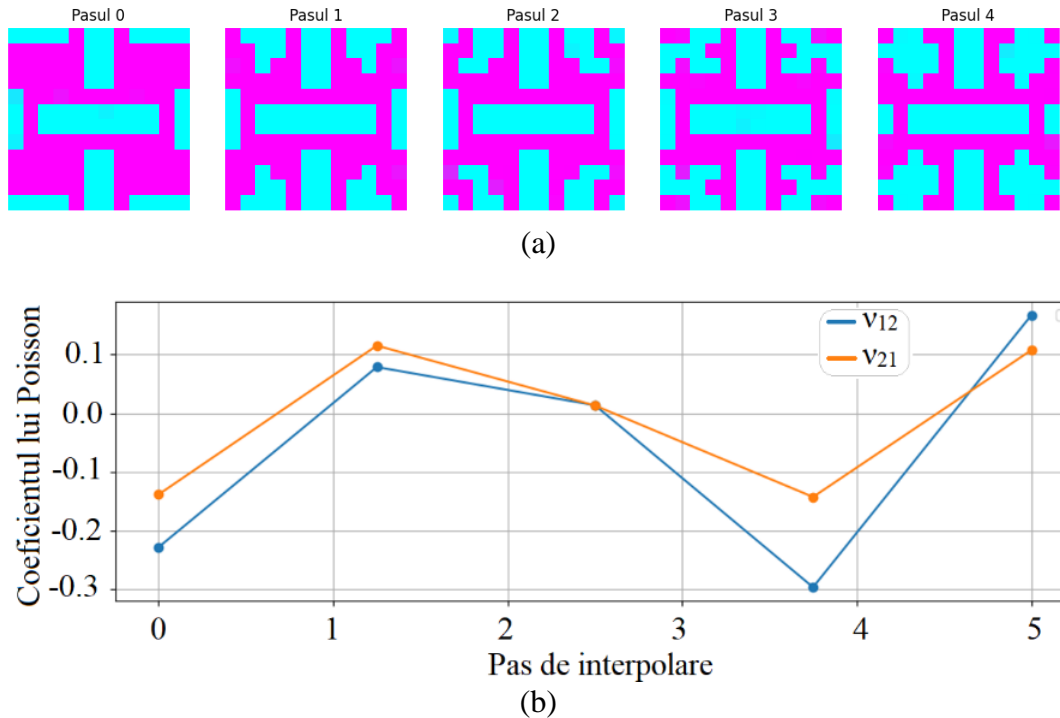


Fig. 4-7 Interpolare în spațiul latent între două soluții: (a) configurațiile obținute în pași de interpolare; (b) variația coeficienților lui Poisson pentru pași de interpolare;

Acest capitol prezintă modele de rezolvare a problemelor de optimizare bazate pe tehnici de inteligență artificială pentru materiale compozite cu elemente de volum reprezentative ce vizează identificarea metamaterialelor cu comportare auxetică. Metodologia combină tehnicile de căutare directă, cu modele avansate de învățare în scopul determinării eficiente a soluțiilor optime.

Aplicarea CNN pentru predicția proprietăților mecanice a volumelor reprezentative s-a dovedit a fi foarte eficientă. Prin antrenarea rețelei cu un set de date format din configurații ale volumelor reprezentative și valorile coeficienților lui Poisson reprezentând doar 0,006% din întreg spațiul de soluții, aceasta a reușit să estimeze cu precizie proprietățile mecanice ale configurațiilor. Eroarea de predicție scăzută a rețelei neuronale de convoluție evidențiază potențialul modelelor de învățare automată în abordarea provocărilor legate de simulările costisitoare din punct de vedere computațional.

Soluția optimă determinată de agloritmul greedy combinat cu rețeaua neuronală de convoluție antrenată prezintă o similitudine ridicată cu celulele cunoscute din literatura de specialitate sub denumirea de tetra-anti-chiral. Această asemănare demonstrează validitatea și capacitatea modelului de optimizare de a naviga cu succes în spațiul de soluții. În același timp, apariția unei astfel de structuri evidențiază faptul că modelul rețelei neuronale de convoluție „a învățat” și folosește în mod eficient principiile mecanice care stau la baza comportamentului auxetic. Apariția soluției similare cu celula tetra-anti-chiral indică faptul că aceste soluții nu sunt doar solide din punct de vedere teoretic, dar, în plus, apar în mod natural din procese de optimizare bazate pe date, validând suplimentar relevanța lor în domeniul metamaterialelor. Cercetările privind utilizarea CNN+*greedy* pentru optimizarea unor astfel de structuri au fost publicate în [17].

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## **CAPITOLUL 5 – CERCETĂRI EXPERIMENTALE ASUPRA STRUCTURILOR COMPOZITE AUXETICE PERIODICE OPTIMIZATE**

Structurile auxetice, caracterizate printr-o valoare negativă a coeficientului lui Poisson, prezintă proprietatea neobișnuită de a se extinde lateral atunci când sunt întinse și de a se contracta atunci când sunt comprimate. Acest comportament are ca rezultat proprietăți mecanice avantajoase, cum ar fi absorbția ridicată a energiei, rezistența sporită la forfecare și performanța superioară la impact, ceea ce le face atractive pentru utilizarea în echipamente de protecție [18], implanturi biomedicale [19], componente aerospațiale [20] și metamateriale mecanice [21].

Scopul acestui capitol este să se verifice experimental dacă configurațiile auxetice determinate anterior, optimizate utilizând un cadru de optimizare CNN-*greedy*, fabricate prin tipărire cu două materiale prezintă într-adevăr un comportament auxetic. Configurațiile testate sunt structuri repetitive cu volumele reprezentative similare cu geometriile tetra anti-chirale compuse dintr-un material dur (Ultimaker PETG) și un elastomer moale (BASF TPU85), distribuția materialelor fiind determinată de algoritmul de optimizare.

În prima etapă a studiului experimental, au fost determinate proprietățile mecanice ale materialelor de bază. Epruvetele din PETG fabricate conform standardului ASTM D638 au fost testate cu ajutorul unei mașini universale de testare INSTRON și cu un extensometru care a furnizat măsurători precise ale deformației specifice. Acest lucru a permis determinarea a modulului de elasticitate și a tensiunii maxime de tracțiune. Rezultatele obținute experimental au confirmat proprietățile mecanice definite în fișele tehnice ale materialului cu erori de sub 3%. TPU85, fiind un elastomer foarte deformabil, a fost testat cu ajutorul unei mașini de testare Zwick, iar datele referitoare la deformare au fost captate prin DIC întrucât extensometrul cu clips nu a putut fi montat pe epruvete. Pentru modulul de elasticitate al materialului TPU85 s-a obținut o eroare de 10% însă pentru rezistența la rupere eroare prezentată este de 250% deoarece a fost utilizată curba convențională și nu curba reală a materialului. Pentru ambele materiale, coeficientul Poisson a fost evaluat prin DIC, folosind trei metode diferite (1) analiza deformării de-a lungul unei linii verticale centrale în comparație cu trei linii orizontale din domeniul de analiză, (2) medierea deformațiilor specifice pe întreaga regiune de analiză și (3) urmărirea deplasării punctelor de colț ale domeniului dreptunghiular de analiză DIC. Toate cele trei metode au indicat aproximativ aceleași valori ale coeficientului lui Poisson pentru epruvetele realizate omogen din materialele de bază.

Pentru configurațiile auxetice, DIC a fost instrumentul principal utilizat (Fig. 5-2) pentru a măsura câmpurile de deformații și pentru a calcula coeficientul lui Poisson.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------




Fig. 5-2 Imagine din timpul analizei DIC - configurație auxetică

Din metodele utilizate la epruvetele materialelor de bază, doar metoda 3 a prezentat rezultate promițătoare, celelalte două metode fiind greu de implementat, cu erori ridicate. În acest sens, a fost aplicată o metodologie prezentată în literatura de specialitate prin care a fost determinat coeficientul lui Poisson prin 12 variante diferite. Aceste abordări au permis atât validarea încrucișată, cât și creșterea încrederii în valorile măsurate, în ciuda complexității ridicate a analizei structurilor repetitive din mai multe materiale.

Două configurații optimizate (prezentate în Fig. 5-1) au fost selectate pentru testare: configurația A cu 55% materiale tare și configurația B cu 41%. Pentru fiecare configurație au fost realizate câte patru epruvete. Au fost aplicate formulele menționate pentru a determina valoarea coeficientului lui Poisson, iar rezultatele medii au fost comparate cu rezultatele obținute prin simulările numerice în ipoteza de stare plană de tensiune, respectiv stare plană de deformare. Rezultatele au fost convingătoare: trei din cele patru probe pentru fiecare configurație au prezentat un coeficient Poisson negativ, confirmând natura auxetică a acestor structuri. Configurația A a arătat în mod constant o concordanță puternică cu rezultatele simulate, prezentând o gamă de valori negative ale raportului Poisson între -0,25 și -0,74. Configurația B, deși a prezentat tendințe auxetice, a arătat mai puțină consecvență, cu rapoarte Poisson între -0,07 și -0,24 și o abatere mai mare față de rezultatele obținute prin simulare numerică.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------




Fig. 5-1 Structuri auxetice optimizate cu ajutorul CNN și a algoritmului *greedy*; (A) 55,56% material tare; (B) 41,66% material tare

Erorile mai mari ale configurației B pot fi atribuite mai multor factori. În primul rând, procentul mai mare de material moale a făcut probabil ca structura să fie mai sensibilă la inconsecvențe în procesul de imprimare. TPU85 și PETG au proprietăți termice semnificativ diferite, iar procesul de fabricare prin depunere de material topit introduce potențiale provocări la interfața materialului. A fost observată o aderență scăzută între cele două materiale în cadrul unui test de tracțiune considerat eșuat. În același timp, s-a observat că anumite probe au prezentat culori diferite ale materialelor de bază, semn ce poate semnifica amestecul celor două materiale în timpul procesului de imprimare și introducerea de erori prin rigidizarea suplimentară a părților moi. În plus, echipamentul de imprimare nu a avut precizia necesară pentru a asigura o repetabilitate ridicată, în special pentru imprimarea mai multor materiale.

Din punct de vedere al analizei DIC, configurațiile auxetice au prezentat mai multe provocări. Procesul de vopsire al epruvetelor a fost îngreunat de diferențe de nivel dintre zonele cu materiale diferite, suprafața epruvetei nefiind perfect plană. Din cauza deformațiilor mari locale ale zonelor cu material moale, multe puncte de urmărire au fost pierdute în timpul testului, făcând dificilă reconstrucția câmpului de deformații în unele regiuni. Cu toate acestea, prin selectarea atentă a zonelor de referință și a metodelor de analiză, au fost obținute rezultate semnificative.

În concluzie, cercetările experimentale susțin ipoteza că aceste configurații de structuri repetitive cu două materiale optimizate de algoritmul CNN-*greedy* pot prezenta într-adevăr un comportament auxetic. Rezultatele au validat performanța prezisă a configurației A cu o precizie ridicată și au oferit o confirmare parțială pentru configurația B. Aceasta oferă o bază promițătoare pentru explorarea în continuare a strategiilor de proiectare pentru metamaterialele mecanice.

Cu toate acestea, studiul evidențiază, de asemenea, mai multe limitări. Dependența de imprimare precisă a materialelor și de aderența interfacială rămâne un obstacol major în calea fabricării repetabile și de calitate a structurilor auxetice multi-materiale. În plus, analiza DIC, deși a prezentat rezultate promițătoare, necesită prelucrarea inițială a suprafețelor epruvetelor formate din două materiale având o configurație auxetică.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## CAPITOLUL 6 – METODOLOGIE DE UTILIZARE A PROCEDURILOR DE OPTIMIZARE

Metodologia de utilizare a procedurilor de optimizare prezentată în acest capitol prezintă un flux de lucru sistematic care ghidează întregul proces, de la definirea problemei până la validarea soluției. Metodologia începe cu o definire clară a problemei de optimizare, abordând ce se optimizează, sub ce constrângeri și în ce scop. Prin definirea condițiilor limită, a cazurilor de încărcare și a formulării matematice a funcției obiectiv, această etapă asigură că procesul de optimizare este bine definit atât din punct de vedere teoretic, cât și în relevanța practică. Metodologia de aplicare a cadrului de optimizare este reprezentată schematizat în Fig. 6-1.

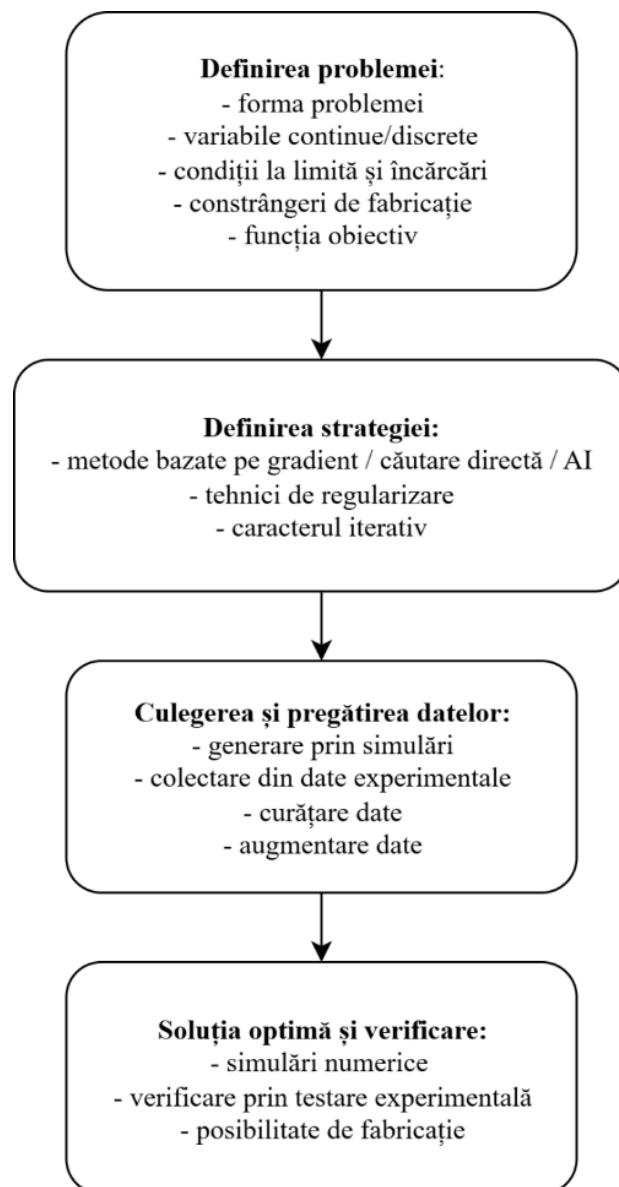


Fig. 6-1 Schematizarea metodologiei de utilizare a procedurilor de optimizare

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

Strategia de optimizare definește modul în care este abordată și rezolvată problema, selectând algoritmi adecvați din tehnici bazate pe gradienti, metode de căutare directă sau abordări de tip AI. Etapa ulterioară subliniază importanța colectării și pregătirii datelor, în special atunci când se utilizează modele de ML, asigurându-se că seturile de date de intrare sunt atât reprezentative, cât și structurate pentru a surprinde complexitatea problemei. Odată ce datele sunt disponibile, procesul de obținere a soluției optime poate fi implementat, timp în care este monitorizată convergența și eficiența computațională.

Etapa finală de verificare și validare a soluției evidențiază faptul că optimizarea nu se termină cu un rezultat numeric. Verificarea prin simulări, teste experimentale, analize de sensibilitate și comparații cu literatura de specialitate asigură că soluția propusă este robustă, fezabilă și aliniată cu aplicațiile practice. În același timp, recunoașterea limitărilor - cum ar fi posibilitatea unor optime locale sau a constrângerilor de fabricație - menține procesul ancorat în realitate. Luate împreună, aceste etape ale fluxului de lucru oferă o metodologie coerentă pentru optimizarea structurală, menținând un echilibru între formularea teoretică și aplicabilitatea practică, stabilind un cadru versatil care poate fi adaptat la diverse probleme.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## CAPITOLUL 7 - CONCLUZII FINALE

### 7.1 Concluzii generale

În cadrul tezei de doctorat se prezintă o metodologie de optimizare a unor structuri periodice compozite utilizând metode de căutare directă și metode bazate pe AI. Cadrul de optimizare este versatil și poate fi modificat și aplicat altor tipuri de probleme de optimizare structurală. În final, sunt realizate cercetări experimentale asupra unor structuri compozite auxetice optimizate cu cadrul dezvoltat anterior, ca studiu de caz. Pe baza celor prezentate, se pot extrage următoarele concluzii generale:

- Pentru implementarea algoritmilor s-a utilizat pachetul PyAnsys care a demonstrat o versatilitate ridicată. Acesta creează un cadru facil de dezvoltare între limbajul de programare Python ce permite realizarea rutinelor de calcul și a algoritmilor matematici pentru optimizare și programul ANSYS ce permite analiza cu elemente finite a soluțiilor găsite de algoritmi de optimizare. Pachetul PyAnsys permite lucrul în buclă închisă fără să fie nevoie de utilizarea mai multor programe în același timp.
- În definirea problemei de optimizare, au fost analizate o serie de puncte importante printre care putem menționa:
  - Formularea matematică a funcției obiectiv are o importanță deosebită asupra procesului de optimizare. În primul rând, funcția obiectiv trebuie să asigure transpunerea în termeni matematici a scopului final al procesului de optimizare. În al doilea rând, formularea matematică trebuie să fie simplă și clară astfel încât să poată fi determinată ușor în procesul iterativ al optimizării.
  - Pentru structurile periodice se recomandă ca analiza să se facă pe un volum reprezentativ și să se utilizeze condiții periodice. În cazul problemei definite în teză, datorită condițiilor de dublă simetrie a volumului reprezentativ, analiza s-a putut face pe un sfer de celulă reducând considerabil timpul de calcul pentru o singură soluție.
  - Tehnicile de regularizare pot influența decisiv soluția optimă. Un studiu de convergență a fost realizat asupra structurilor compozite unde a fost demonstrat că elementele dispuse în tablă de șah introduc erori mari de calcul. S-a arătat că pentru o creștere a fineții discretizării într-un domeniu de material din celula reprezentativă, soluția optimă diferă pentru aceeași formularea a funcției obiectiv. Implementarea unor tehnici de regularizare precum funcții specializate de eliminare a soluțiilor conectate în tablă de șah a fost implementată ulterior cu succes demonstrând necesitatea acestora.
  - Utilizare variabilelor de optimizare discrete sau continue schimbă nuanța procesului. În problema descrisă în teza de doctorat au fost utilizate variabile discrete și s-a arătat că pentru dimensiuni mici ale volumului reprezentativ se poate determina optimul printr-o abordare *brute force*. Totodată, s-a arătat că numărul total de soluții crește considerabil pentru o creștere relativ mică a dimensiunii volumului reprezentativ de la 4x4 la 6x6. Limitările impuse de hardware fac ca abordarea *brute force* să poată fi utilizată doar pentru probleme restrânse. În situația unor probleme cu variabile de optimizare continue, numărul total de soluții este infinit, iar o astfel de abordare nu poate fi utilizată.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

- O analiză comparativă a patru algoritmi de căutare directă a fost realizată pentru determinarea structurilor definite anterior cu module de elasticitate maximizate după cele două direcții ortogonale de unde au fost trase următoarele concluzii:
  - Algoritmul *greedy* prezintă o implementare ușoară și oferă rezultate promițătoare. În același timp, soluția optimă determinată de acesta depinde de punctul de plecare. Pentru configurația 4x4 acesta a prezentat o rată de succes de 86% cu o medie de 227,2 evaluări ale funcției obiectiv.
  - Algoritmul SA, deși a prezentat performanțe ridicate în alte studii, nu a ieșit în evidență în clasamentul realizat. La modul în care a fost definit algoritmul, acesta este o înlănțuire de algoritmi *greedy* cu scopul de a elimina dezavantajul dependenței de punctul de start. Pentru configurația 4x4 acesta a prezentat o rată de succes de 100% dar cu o medie de 1.868,16 evaluări ale funcției obiectiv, adică un efort de calcul de 8 ori mai mare decât a algoritmului *greedy*.
  - Din categoria algoritmilor evolutivi, GA și PSO au fost aplicați pentru configurația 4x4, iar rezultatele au fost promițătoare. GA a prezentat o rată de succes de 100% cu o medie de evaluări a funcției obiectiv de 578, iar PSO a prezentat o rată de succes de 100% cu o medie de evaluări a funcției obiectiv de 179,5.
  - După scalarea problemei la configurația 6x6, GA s-a dovedit inefficient pentru rezolvarea acestui tip de problemă cu cel mai mare efort de calcul necesar și cea mai mică valoare obținută pentru funcția obiectiv.
  - Dintre algoritmii testați la configurația 4x4, PSO a prezentat cel mai bun echilibru între efortul de calcul și valoarea medie a funcției obiectiv obținută pentru configurația 6x6.
  - O abordarea hibridă PSO+*greedy* a fost implementată, oferind cele mai bune performanțe în ceea ce privește efortul de calcul și valoarea funcției obiectiv. Abordarea hibridă a atins o medie a funcției obiectiv de 3,7511, o îmbunătățire cu aproximativ 4% față de algoritmul PSO, pentru o medie a numărului de soluții evaluate egală cu 4.555,2 adică o îmbunătățire cu aproximativ 20% a efortului de calcul.
- În vederea implementării metodelor bazate pe AI pentru rezolvarea problemelor de optimizare structurală, o bază de date este necesară. Au fost prezentate principalele considerente de care trebuie ținut cont pentru construcția bazei de date, de la consecvență în stocarea datelor și normalizarea datelor, fie că vorbim de generarea a datelor sau de colectare a datelor. Procesele de augmentare a datelor, care multiplică baza de date pentru antrenare a prezentat o importanță deosebită în facilitarea procesului de antrenare.
- Pentru rezolvarea unei probleme de optimizare a distribuției de material al unui material compozit în scopul obținerii configurațiilor cu valori negative ale coeficientului lui Poisson, au fost testate două metode bazate pe AI, o metodă în care s-a utilizat o rețea neuronală de convoluție pentru predicția valorii coeficientului lui Poisson a unei anumite configurații împreună cu un algoritm *greedy* pentru determinarea optimului și o metodă cu un autocodificator variațional. Din construcția celor două metode au fost trase următoarele concluzii:
  - Pentru CNN, o analiză privind numărul de straturi și structura acestora a fost realizată. Atât pentru configurația 4x4, cât și pentru configurația 6x6 au fost dezvoltate rețele cu 9 straturi cu intercalări între straturile de grupare maximă și



UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

convoluție. Construcția s-a dovedit a fi robustă pentru ambele configurații și a permis transferul de învățare de la configurația 4x4 la configurația 8x8. S-a dovedit că augmentarea setului de date de antrenare a redus semnificativ eroarea de validare a rețelei la finalul etapei de antrenare, iar transferul de învățare a influențat valoarea inițială a erorii prezentând potențial de a reduce numărul necesare de epoci de antrenare.

- Pentru VAE, construcția encoderului a presupus un strat de intrare, trei straturi de convoluție cu 16, 32, respectiv 64 de filtre după care un strat de aplatizare și densificare. Modul de construcție al decoderului este similar cu cel al encoderului, doar cu ordinea straturilor inversate. O analiză a fost realizată asupra influenței numărului de variabile latente asupra erorii de reconstrucție, de unde a reieșit un optim de 12 variabile. În același timp, s-a demonstrat că numărul crescut de variabile latente a crescut și eroarea KL. În acest sens a fost abordată o strategie de antrenare cu aplicarea ponderii  $\beta$  în evaluarea erorii KL, fapt care a dus la îmbunătățirea semnificativa a erorii totale la finalul procesului de antrenare.
- Performanțele metodelor bazate pe AI au fost verificate prin diferite metrice:
  - Pentru CNN, valoarea erorii de validare în configurația 4x4 a ajuns la 0,00008 pentru o antrenare cu 90% din totalul de soluții, iar în configurația 6x6 la 0,004 pentru o antrenare cu 0,0003% din totalul de soluții. Valoare prezisă de rețea a fost comparată cu valoarea reală obținută prin analiză cu elemente finite pentru coeficientului lui Poisson în ambele configurații, 4x4, respectiv 6x6, de unde s-a observat o precizie ridicată în predicția valorii coeficientului lui Poisson pentru o anumită configurație de material.
  - Pentru VAE, diagrama de perechi a variabilelor latente a prezentat o distribuție normală pentru toate cele 12 variabile, semn că antrenarea s-a realizat în conformitate cu cerințele unui autocodificator variațional. Spațiului de variabile latente i-au fost aplicate tehnici de reducere a dimensionalității astfel încât au putut fi identificate cinci grupuri de soluții cu similarități în construcție. Deși valoarea erorii totale a rămas în jurul valorii de 30, aceasta a fost comparabilă cu alte modele relizate în literatură
- Rețeaua CNN în configurație 6x6 antrenată a permis construcția unui cadru de optimizare împreună cu un algoritm *greedy* care a oferit o varietate de soluții cu valori negative ale coeficientului lui Poisson. Soluția optimă descoperită a înregistrat o valoare coeficientului lui Poisson de -0,4543 pentru ambele direcții ortogonale. Cadrul de optimizare CNN-*greedy* s-a dovedit a fi foarte eficient, combinând puterea de predicție a coeficientului lui Poisson cu un minim efort de calcul al rețelei CNN, împreună cu abilitatea algoritmului *greedy* de a naviga ușor în spațiul de soluții pentru a determina optimul.
- Autocodificatorul variațional antrenat a fost folosit împreună cu un cadru de optimizare bayesiană în spațiul latent. Acest cadru nu a descoperit soluții la fel de performante ca și cadrul CNN-*greedy*, minimul înregistrat pentru coeficientul lui Poisson fiind de -0,3379 pentru una din direcții. Chiar dacă soluțiile obținute nu au avut aceleași performanțe, VAE a prezentat abilități generative ce pot fi exploatate în alte condiții precum clasificarea soluțiilor în familii sau interpolarea în spațiul latent între două soluții pentru descoperirea configurațiilor cu similarități în construcție între cele două.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

- Cecetări experimentale asupra unui studiu de caz privind configurații obținute prin optimizare a structurilor compozite auxetice au fost realizate, de unde s-au tras următoarele concluzii:
  - În prima etapă experimentală, au fost determinate proprietățile mecanice ale materialelor de bază. Specimenele de PETG au fost testate la tracțiune (ASTM D638) pe o mașină INSTRON cu un extensometru, obținând valori ale modulului de elasticitate și tensiunii la rupere în limita a 3% față de valorile din fișa tehnică. Materialul TPU85, testat tot la tracțiune pe o mașină Zwick cu DIC datorită deformabilității sale ridicate, a prezentat o eroare de 10% în valoarea obținută pentru modulul de elasticitate și o eroare mai mare, de 250%, pentru valoarea rezistenței la rupere, cauzată, se pare, de utilizarea curbei convenționale în locul celei reale. Coeficientul lui Poisson pentru ambele materiale a fost evaluat cu ajutorul DIC folosind trei metode, toate oferind rezultate consistente.
  - Pentru configurațiile auxetice, testele la tracțiune au arătat faptul că forța de adeziune între aceste două materiale este foarte mică, fapt ce a dus la delaminarea prematură în timpul testului de tracțiune. Rezultatele au fost inconsistente pentru testele de tracțiune, iar studiul literaturii de specialitate asupra forțelor de adeziune interfacială a materialelor plastice fabricate cu ajutorul tehnologiei FDM a arătat că problema este una complexă și dificil de rezolvat.
  - DIC a fost principalul instrument pentru măsurarea deformațiilor și evaluarea coeficientului lui Poisson pentru testele de compresie realizate asupra configurațiilor auxetice optimizate. Dintre metodele utilizate, doar urmărirea deformării colțurilor unui domeniu ales s-a dovedit fiabilă, în timp ce celelalte au prezentat erori mari. A fost adoptată o metodologie din literatura de specialitate, aplicând 12 variante de calcul pentru a permite validarea încrucișată și pentru a crește încrederea, în ciuda complexității analizei structurilor periodice multi-materiale.
  - Au fost testate două configurații optimizate: configurația A (55% material rigid) și configurația B (41% material rigid). Au fost analizate câte patru mostre din fiecare configurație, iar valorile medii obținute pentru coeficientul lui Poisson au fost comparate cu simulările numerice sub ipoteza stării plane de tensiune, respectiv pentru starea plană de deformare. Rezultatele au confirmat comportamentul auxetic la trei din patru mostre pentru fiecare caz. Configurația A s-a aliniat îndeaproape cu simulările (−0,25 până la −0,74), în timp ce configurația B a prezentat o deviație mai mare (−0,07 până la −0,24).
  - Erorile mai mari din configurația B au fost atribuite conținutului mai mare de material moale, ceea ce o face mai sensibilă la calitatea imprimării. Problemele au fost cauzate de aderența slabă PETG-TPU, defectele interfaciale și dovezile observate ale amestecării parțiale a materialelor, care au rigidizat regiunile moi. Precizia imprimării a fost, de asemenea, insuficientă pentru o reproductibilitate fiabilă a mai multor materiale, contribuind în continuare la variabilitatea obținută.
  - Analiza DIC a probelor auxetice s-a confruntat cu provocări precum suprafețe neuniforme între fazele dure și cele moi și pierderi de date în regiunile TPU extrem de deformabile. Cu toate acestea, prin definirea atentă a zonelor și metodelor de referință, s-au obținut câmpuri de deformare semnificative, validând fezabilitatea utilizării DIC pentru structuri atât de complexe.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

- Experimentele au confirmat că aceste configurații optimizate cu ajutorul cadrului CNN-*greedy* pot prezenta un comportament auxetic. Configurația A a validat substanțial predicțiile, în timp ce configurația B a oferit o confirmare parțială. Cu toate acestea, au fost observate și limitări, inclusiv dificultăți în imprimarea precisă multi-material, aderență interfacială slabă și necesitatea unei pregătiri atente a specimenului în analiza DIC.

## 7.2 Contribuții personale

O serie de contribuții personale au fost aduse metodelor de optimizare a structurilor de configurație specială precum și metodelor experimentale precum:

- Realizarea unui cadru de lucru cu pachetul PyAnsys pentru dezvoltarea algoritmilor de optimizare în limbajul de programare Python concomitent cu apelarea programului de analiză cu elemente finite ANSYS (Subcapitolul 3.3.1).
- Realizarea unei analize comparative a performanțelor în rezolvarea problemelor de optimizare structurală a patru algoritmi de căutare directă: *greedy*, SA, GA și PSO (Subcapitolul 3.3.2.).
- Dezvoltarea algoritmilor de optimizare astfel încât să permită modificarea ușoară a parametrilor pentru scalarea la dimensiuni mai mari ale problemelor. (Subcapitolul 3.3.3).
- Dezvoltarea și antrenarea unei rețele neuronale de convoluție care să prezică cu o eroare mică proprietățile de material ale structurilor de configurație specială (Subcapitolele 4.3.2., 4.3.3. și 4.3.4.).
- Dezvoltarea și antrenarea unui autocodificator variațional care să codifice având 12 variabile latente cu o distribuție normală spațiul de soluții și să permită reconstrucția lor cu o precizie ridicată (Subcapitolele 4.3.2., 4.3.3. și 4.3.4.).
- Realizarea unui cadru de optimizare CNN-*greedy* care să utilizeze puterea de predicție a rețelei neuronale de convoluție și abilitatea algoritmului *greedy* de a naviga spațiul de soluții în scopul determinării soluțiilor optime pentru probleme de dimensiuni ridicate (Subcapitolul 4.4.).
- Reglarea parametrilor echipamentelor de imprimare prin tehnologie FDM pentru a realiza tipărirea multi-material într-un mod eficient (Subcapitolul 5.2.).
- Dezvoltarea, verificarea și validarea a trei metode de determinare a coeficientului lui Poisson pentru epruvete omogene utilizând echipamentul DIC de corelare digitală a imaginilor (Subcapitolul 5.3.2.).
- Dezvoltarea unei proceduri de determinare a coeficientului lui Poisson utilizând DIC pentru structuri compozite periodice cu ajutorul unor linii de control ce trec prin puncte predefinite în structură, realizând o mediere a deformațiilor specifice pe întreaga lungime a liniilor de control (Subcapitolul 5.4.2.).
- Sintetizarea și structurarea etapelor procedurii de optimizare a structurilor de configurație specială într-o metodologie de utilizare, în vederea aplicării facile de către alți utilizatori pentru diverse probleme (Capitolul 6).

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

### 7.3 Direcții pentru cercetări viitoare

- Extinderea cadrului de optimizare pentru a putea realiza optimizarea structurilor repetitive tridimensionale cu diferite funcții obiectiv astfel încât să se extindă biblioteca structurilor de materiale arhitecturate.
- Lărgirea cadrului de optimizare pentru a include trei sau mai multe materiale ce ar putea deschide posibilități de proiectare mult mai bogate. S-ar putea combina o fază rigidă, o fază extrem de deformabilă pentru absorbția energiei și o fază intermediară pentru reglarea rigidității locale sau îmbunătățirea forței de adeziune între materiale.
- Implementarea altor metode de inteligență artificială pentru optimizarea structurilor. Exploatarea metodelor generative pentru descoperirea altor structuri cu proprietăți și geometrii inedite.
- Realizarea unei aplicații integrate care să îi faciliteze utilizatorului definirea problemei de optimizare a structurilor de configurație specială, setarea funcției obiectiv, alegerea algoritmului de optimizare, generarea setului de date pentru antrenare în situația unei abordări bazate pe AI, antrenarea și căutarea soluțiilor optime.
- Rafinarea proceselor de fabricație aditivă multi-material pentru îmbunătățirea repetabilității și a forțelor de adeziune interfacială între materiale. Verificarea altor metode hibride de fabricație (imprimare unuei faze de material și turnarea sau injecția celeilalte faze) a structurilor multi-material cu geometrie complexă.
- Îmbunătățirea procedurilor de verificare a proprietăților mecanice ale structurilor optimizate utilizând alte sisteme complexe precum scanare cu raze X sau computer tomograf pentru a verifica comportamentul structurilor în interiorul volumului de lucru.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

## BIBLIOGRAFIE

- [1] C. Pan, Y. Han, and J. Lu, “Design and Optimization of Lattice Structures: A Review,” *Appl. Sci.*, vol. 10, no. 18, p. 6374, 2020, doi: 10.3390/app10186374.
- [2] L. Zheng, S. Kumar, and D. M. Kochmann, “Data-driven topology optimization of spinodoid metamaterials with seamlessly tunable anisotropy,” *Comput. Methods Appl. Mech. Eng.*, vol. 383, p. 113894, 2021, doi: 10.1016/j.cma.2021.113894.
- [3] B. Zhu, X. Zhang, H. Zhang, J. Liang, H. Zang, H. Li and R. Wang., “Design of compliant mechanisms using continuum topology optimization: A review,” *Mech. Mach. Theory*, vol. 143, 103622, 2020, doi: 10.1016/j.mechmachtheory.2019.103622.
- [4] R. M. Gorguluarslan and Y. Yamaner, “Self-supporting robust lattice optimization for material extrusion additive manufacturing,” *Compos. Struct.*, vol. 371, no. April, p. 119470, 2025, doi: 10.1016/j.compstruct.2025.119470.
- [5] H. Yan, W. T. Wu, Z. Zhao, and F. Feng, “Review and comparison of turbulent convective heat transfer in state-of-the-art 3D truss periodic cellular structures,” *Appl. Therm. Eng.*, vol. 235, no. August, p. 121450, 2023, doi: 10.1016/j.applthermaleng.2023.121450.
- [6] S. Song, C. Xiong, and J. Yin, “Mechanical performance of reinforced hybrid periodic-multicell thin-walled structures in sandwich applications: A review,” *Thin-Walled Struct.*, vol. 208, no. December 2024, p. 112832, 2025, doi: 10.1016/j.tws.2024.112832.
- [7] S. Kumar, S. Tan, L. Zheng, and D. M. Kochmann, “Inverse-designed spinodoid metamaterials,” *npj Comput. Mater.*, vol. 6, no. 1, pp. 1–10, 2020, doi: 10.1038/s41524-020-0341-6.
- [8] M. P. Bendsøe and O. Sigmund, *Topology Optimization. Theory, Methods, and Applications*. Springer-Verlag Berlin Heidelberg, 2004.
- [9] D. W. Abueidda, M. Elhebeary, C. S. (Andrew) Shiang, S. Pang, R. K. Abu Al-Rub, and I. M. Jasiuk, “Mechanical properties of 3D printed polymeric Gyroid cellular structures: Experimental and finite element study,” *Mater. Des.*, vol. 165, p. 107597, 2019, doi: 10.1016/j.matdes.2019.107597.
- [10] “ISO/ASTM 52900:2021 Additive manufacturing — General principles — Fundamentals and vocabulary,” 2021.
- [11] B. Hassani and E. Hinton, *Homogenization and Structural Topology Optimization.*, Springer London, 1999.
- [12] G. X. Gu, L. Dimas, Z. Qin, and M. J. Buehler, “Optimization of Composite Fracture Properties: Method, Validation, and Applications,” *J. Appl. Mech. Trans. ASME*, vol. 83, no. 7, pp. 1–7, 2016, doi: 10.1115/1.4033381.
- [13] I. C. Coropețchi, D. M. Constantinescu, A. Vasile, Șt Sorohan, and D. A. Apostol, “Comparative analysis of direct search methods for material design optimization,” *Proc. Inst. Mech. Eng. Part L J. Mater. Des. Appl.*, vol. 239, no. 4, pp. 642–660, 2025, doi: 10.1177/14644207241294056.
- [14] I. C. Coropețchi, D. M. Constantinescu, A. Vasile, A. I. Indreș, Ștefan Sorohan, and D. A. Apostol, “Direct search methods for determining new designs of auxetic materials,” *J. Theor. Appl. Mech.*, vol. 63, no. 3, pp. 479–489, 2024, doi: 10.15632/jtam-pl/200711.

UNSTPB	Teză de doctorat	Optimizarea bazată pe inteligență artificială pentru realizarea de structuri topologice de configurație specială	Iulian-Constantin COROPEȚCHI
--------	------------------	--	------------------------------

- [15] S. Teraiya, S. Vyavahare, and S. Kumar, “Numerical and Experimental Investigation on Effect of Design Factors on Shear Properties of Additively Manufactured Tetra-Anti-Chiral Cellular Metamaterial,” *Int. J. Mod. Manuf. Technol.*, vol. 14, no. 1, pp. 104–112, 2022, doi: 10.54684/ijmmt.2022.14.1.104.
- [16] H. I. On, L. Jeong, M. Jung, D. J. Kang, J. H. Park, and H. J. Lee, “Optimal design of microwave absorber using novel variational autoencoder from a latent space search strategy,” *Mater. Des.*, vol. 212, 2021, doi: 10.1016/j.matdes.2021.110266.
- [17] I. C. Coropețchi, D. M. Constantinescu, A. Vasile, A. I. Indreș, and Ștefan Sorohan, “Design of Novel Auxetic Bi-Materials Using Convolutional Neural Networks,” *Materials*, vol. 18, no. 8, 1772, 2025, doi: 10.3390/ma18081772.
- [18] M. I. Khan, M. Umair, and Y. Nawab, „Use of auxetic material for impact/ballistic applications”, *Composite Solutions for Ballistics*, pp. 199-228, Elsevier, <https://doi.org/10.1016/B978-0-12-821984-3.00012-7>, 2021.
- [19] S. Rose, D. Siu, J. Zhu, and R. Roufail, “Auxetics in Biomedical Applications: A Review,” *J. Miner. Mater. Charact. Eng.*, vol. 11, no. 02, pp. 27–35, 2023, doi: 10.4236/jmmce.2023.112003.
- [20] Z. Wang, H. Zulifqar, and H. Hu, “7 - Auxetic composites in aerospace engineering,” in *Advanced Composite Materials for Aerospace Engineering Processing, Properties and Applications*, S. Rana and R. Fangueiro, Eds. Woodhead Publishing, 2016, pp. 213–240.
- [21] V. Siniauskaya, H. Wang, Y. Liu, Y. Chen, M. Zhuravkov, and Y. Lyu, “A review on the auxetic mechanical metamaterials and their applications in the field of applied engineering,” *Front. Mater.*, vol. 11, no. August, pp. 1–14, 2024, doi: 10.3389/fmats.2024.1453905.