

RAPORTARE ȘTIINȚIFICĂ etapa anuală 2025

- Contract nr. 11/2024 din 21.03.2024; Etapa nr. 2 / 2025;
 - UN MODEL DIGITAL BAZAT PE DATE PENTRU RECIPIENTE DE STOCARE A HIDROGENULUI RASPUNZAND PROVOCARILOR DE TRANZITIE ENERGETICA.
- Proiect COFUND-LEAP-RE D3T4H2S;

DESCRIEREA ȘTIINȚIFICĂ

1. Rezumatul etapei anuale – coordonate științifice ¹

Din punctul de vedere al colectivului Universității Dunarea de Jos din Galați (partener UGAL), etapa a doua a proiectului D3T4H2S a continuat cu modelarea materialelor compozite –prevazute pentru fabricarea tankurilor de hidrogen– utilizand algoritmi de învățare automată (Machine Learning - ML). Cei 6 parteneri internaționali implicați în proiectul D3T4H2S au continuat sa dezvolte metodologia propusă, bazată pe o abordare hibrida ce presupune:

1. -priectarea materialelor compozite,
2. -studiul experimental al comportamentului lor termo-mecanic,
3. -modelarea numerica si simularea comportamentului materialelor compozite utilizate,
4. -utilizarea învățării automate (machine learning) pentru modele predictive și procese optimale.

Partenerii au avut taskuri separate, dar complementare, în cadrul proiectului, fiecare acționând pe competența științifică si experimentală proprie. Coordonatorul, S Vertical, si-a asumat rolul de integrator. Trebuie mentionat că, în cadrul consorțiului, UGAL a fost singurul specialist cu expertiză în domeniul 4, care a acoperit doua zone științifice esentiale în proiect:

- *Modele regresive obtinute cu algoritmi de ML*; modelele au vizat comportamentul tensiune-elongație (stress-strain) la teste de tractiune.

- *Algoritmi de inteligență computațională bazați pe metaeuristici cum ar fi Particle Swarm Optimization și Evolutionary Algorithms*; acestia au fost folosiți în colaborare cu modelele de ML pentru a propune, în cadrul proiectului, un cadru sistematic de optimizare (Optimization Framework – OFW).

Domeniul științific abordat in cadrul etapei

Din punct de vedere științific, activitățile derulate de colectivul de cercetatori (doi profesori și un cercetator postdoctoral) de la UGAL, în cadrul etapei, se refera la domeniul 4, adica utilizarea învățării automate (ML) pentru modele predictive și procese optimale.

Și în etapa a doua a proiectului, UGAL este, în principal, responsabilă pentru doua tipuri de taskuri:

- (A) Predicția comportamentului materialelor compozite utilizate la fabricarea tankurilor de hidrogen, avand diferite structuri, la variația unor parametri fizici. Acest task este acoperit de Activitățile 2.1 și 2.2, din planul de realizare.
- (B) Contributii la optimizarea structurii laminatelor compozite multistrat utilizand AI (algoritmi metaeuristici). Acest task este dezvoltat de Activitățile 2.3 și 2.4, din planul de realizare.

Taskurile (A) au dus la construcția de modele ML în doua situații specifice:

- Specimenele de materiale compozite au fost modelate și în *zona de deformație neliniară*, mai precis în *zona plastică*.
- Au fost considerate laminate compozite (composite laminates) cu 16 straturi avand orientari diferite față de direcția de încărcare principală.

¹ Rezumatul executiv este plasat la sfarsitul acestui document

Taskul (B) a dus la dezvoltarea unui *cadru sistematic de optimizare (Optimization Framework – OFW)* care a fost utilizat în probleme de optimizare implicând laminate compozite. Datorită caracterului său sistematic, OFW este folosit și în optimizări ce privesc proiectarea recipientelor de stocare a hidrogenului (etapa 3).

Modul de lucru interactiv cu partenerii din consorțiu

Datorită rolului de integrator al proiectului pe care și l-a asumat coordonatorul S VERTICAL și partenerul P2 (ENSTA Bretagne), pe de o parte, și competenței UGAL oarecum unice în consorțiu în domeniul Machine Learning și optimizări, pe de altă parte, activitățile noastre s-au desfășurat independent. Prezentările în întâlniri de lucru pe Teams au avut rolul de a valida soluțiile și metodele propuse de UGAL la nivel aplicativ.

În felul acesta activitățile derulate și rezultatele propuse se pot integra într-o activitate de cercetare care a utilizat preponderent studiile simulate. Datele inițiale au fost furnizate de S VERTICAL și partenerul P2. Simulările au fost realizate pe numeroasele programe și scripturi scrise de colectivul nostru și furnizate coordonatorului alături de articolele și rapoartele scrise, pentru a putea fi utilizate de membrii consorțiului.

Pe scurt, temele de lucru ale UGAL și datele au fost furnizate de S VERTICAL și partenerul P2, iar rezultatele au fost validate de parteneri în sesiuni de lucru comune pe Teams. Ulterior rezultatele au fost încărcate pe platforma comună.

Interacțiunea dintre UGAL și cei doi parteneri din consorțiu s-a realizat ca secvența de subactivități ordonate temporal astfel:

<i>Subactivități</i>	<i>Activitate</i>	<i>Parteneri implicați</i>
A1. Definirea la nivel tehnologic a problemei de modelare cu modele de ML a materialelor compozite în zona elastică și plastică.	Activitatea 2.1	S VERTICAL și P2, UGAL
A2. Prelucrarea datelor primite și definirea setului de date (data set) pentru problema de ML.	Activitatea 2.1	UGAL
A3. Definirea datelor de antrenare (training) și testare (testing) pentru diversele tipuri de modele ML.	Activitatea 2.2	UGAL
A4. Dezvoltarea de algoritmi de predicție utilizând diferite modele de ML pentru un singur material compozit.	Activitatea 2.2	UGAL
A5. O metoda de reprezentare a dependenței stress-strain ca o funcție, folosind predictorul furnizat de ML.	Activitatea 2.2	UGAL
A6. Posibilitatea reprezentării familiei de MC (CF/6, CF/12, CF/11) mai eficient la nivelul dimensiunii datelor de antrenare.	Activitatea 2.2	S VERTICAL și P2, UGAL
A7. Implementarea procedurii de determinare a unui model de ML comun pentru întreaga familie de MC.	Activitatea 2.2	UGAL
A8. Caracterizarea celui mai bun model de regresie ML pentru familia de MC	Activitatea 2.2	UGAL
A9. Selectarea unui model regresiv de ML pentru laminate compozite cu putere mare de generalizare.	Activitatea 2.3	UGAL
A10. Colaborarea unui algoritm de optimizare metaeuristic cu un model regresiv de ML pentru laminate compozite.	Activitatea 2.3	S VERTICAL și P2, UGAL
A11. Studiul de caz 1 – Compromis între rigiditate și rezistența la forfecare pentru un LC.	Activitatea 2.4	UGAL
A12. Studiul eficacității structurii "Optimization Framework" – Studiul de caz 2.	Activitatea 2.4	UGAL

Rezultate obținute în etapa 2025 (2)

(1) Raport de cercetare 1 intitulat:

Implementation aspects of stress-strain characteristics' regression models for composite materials.

Part I: The modeling of the stress-strain characteristic -including the "damaged" zone.

Part II: Machine Learning Predictions for the Comparative Mechanical Analysis of Composite Laminates with Various Fiber Orientations.

În Partea I, acest raport conține rezultate obținute în cadrul Activităților 2.1 și 2.2 din etapa 2025. Acest studiu de cercetare a fost livrat coordonatorului S VERTICAL pentru a fi disponibil tuturor partenerilor.

(2) Arhiva de programe ART_Matlab.zip. Raportul 1 este însoțit de această arhivă de programe ce conține programele și fișierele MATLAB care au implementat metodele propuse. Acestea pot fi folosite la înțelegerea și verificarea rezultatelor obținute. Sunt comentate și însoțite de un ghid de utilizare.

(3) Articol publicat în revista Processes (IF 2.2, CiteScore 5.5 -Q2).

Brayek, B. E.; Sayed, S.; ***Mînz**u, V., Tarfaoui, M.;

Machine Learning Predictions for the Comparative Mechanical Analysis of Composite Laminates with Various Fibers. Processes, 13(3), 602. Published: 20 February 2025.

<https://doi.org/10.3390/pr13030602>.

Acest articol, cu autor corespondent de la UGAL, comunică rezultatele originale din Partea a II-a a Raportului de cercetare 1.

(4) Raport de cercetare 2 intitulat:

Implementation of Machine Learning Models for Composite Materials with the Same Carbon Fiber but Different Matrices.

Raportul este axat pe prezentarea rezultatelor subactivităților 6, 7 și 8 de activitatea 2.2, adică pe obținerea unui model unic pentru o familie de materiale compozite. Această contribuție originală duce la scăderea volumului de date de antrenare când familia are în comun aceeași fibră de carbon.

(5) Arhiva de programe JMSCE_supplementary.zip. Raportul de cercetare 2 este însoțit de această arhivă de programe ce conține programele și fișierele MATLAB ce implementează metodele propuse. Acestea pot fi folosite la înțelegerea și verificarea rezultatelor obținute. Sunt comentate și însoțite de un ghid de utilizare.

(6) Articol publicat în revista "Journal of Materials Science and Chemical Engineering"

Mînz

u, V. and Arama, I.;

A New Method to Predict the Mechanical Behavior for a Family of Composite Materials.

Journal of Materials Science and Chemical Engineering Vol.13 No.9. Published: 23.09.2025.

<https://www.scirp.org/journal/paperinformation?paperid=145844>;

DOI: 10.4236/msce.2025.139009;

(7) Raport de cercetare 3 intitulat:

Contributions to the Optimization of Multilayer Composite Laminate Structures Using Particle Swarm Optimization and Machine Learning

Raportul acoperă activitățile 2.3 și 2.4, și prezintă o metodă originală de a realiza o platformă pentru rezolvarea sistematică a optimizării structurii laminatelor compozite multilayer cu diferite orientări.

(8) Arhiva de programe OFW_Mtlb.zip. Raportul de cercetare 3 este însoțit de această arhivă de programe ce conține programele și fișierele MATLAB care au implementat structura propusă pentru optimizare (Optimization FrameWork).

(9) Articol pregătit pentru publicare într-o revistă cu vizibilitate importantă (unpublished).

Mînz

u, V. and Arama, I.;

Optimal Structure Determination for Composite Laminates Using Particle Swarm Optimization and Machine Learning

(10) Trei articole ce au fost acceptate să fie prezentate la conferința internațională

Mihalcea, A.; *Chirosca, A-M.*; Rusu, L.;

A new approach to green hydrogen research – challenges and solutions towards emission reduction and a cleaner maritime transportation

Chirosca, A-M.; Popa, V-I.; Rusu, E.

Assessment of green hydrogen production and potential utilization in the hydrodynamic environment of the Danube

Bujor, A.; *Chirosca, A-M.*; Gasparotti, C.; Rusu, E.

Hybrid energy solutions: hydrogen integration in floating production, storage, and offloading units.

Toate articolele din reviste sau la conferință au "acknowledgment" de finanțare UEFISCDI.

2. Descrierea activităților

Activitatea 2.1

Preluarea și analiza datelor obținute de la parteneri, modelarea și predicția încărcării materialelor compozite și pentru zona plastică și de ruptură; se va genera setul de date utilizabil pentru ML din Acțiunea 2.2 și integrarea într-un model extins față de cel rezultat în Etapa 1.

Activitățile se referă la taskul (A) (definit în rezumat)–predicția comportamentului materialelor compozite– și vor fi analizate în cele ce urmează.

Subactivitatea A1.

Definirea la nivel tehnologic a problemei de modelare cu modele de ML a materialelor compozite în zona elastică și plastică.

Partenerii S VERTICAL și ENSTA Bretagne au furnizat date referitoare la specimene de materiale compozite (MC), dar mai complete față de etapa 1. Specimenele de MC sunt fabricate din fibra de carbon AS4, iar matricea din rasina epoxidica 8552. Matricea este dublu ranforsată cu poliamide (PA6, PA12, PA11) și dopată cu nanotuburi de carbon. Cunoscându-se parametrii de material și raportul volumic dintre fibra și matrice, testul de tracțiune a fost înlocuit cu simulări de mare precizie bazată pe integrarea cu element finit, folosind simulatorul DIGMAT-VA. Aceste simulări au furnizat date tabelare despre dependența stress-strain, ca și când au fost furnizate de teste de tracțiune.

Datele au fost furnizate în 3 fișiere Excel: "PA6.xlsx", "PA12.xlsx" și "PA11.xlsx" ca rezultat exportat de platforma de simulare DIGMAT.

Obiectivele activităților A2.1 și A2.2 completate cu cele ce au rezultat pe durata proiectului sunt:

- I. Dezvoltarea de modele de regresie ML pentru comportarea stress-strain a acestor MC care să acopere zona elastică, dar și practică.
- II. O metodă de a furniza dependența stress-strain ca o funcție obișnuită, folosind predictorul furnizat de modelul ML asociat MC în cauză.
- III. Explorarea posibilității de a reprezenta familia de MC (PA6, PA12, PA11) mai eficient la nivelul dimensiunii datelor de antrenare, utilizând faptul că au aceeași fibra de carbon.

Cele trei MC sunt notate în continuare CF/6, CF/12, and CF/11, în funcție de poliamida folosită. Modelele obținute prin algoritmi de ML vor fi notate ML/6, ML/12, and ML/11 respectiv.

Subactivitatea A2.

Prelucrarea datelor primite și definirea setului de date (data set) pentru problema de ML.

Obiectivul acestei subactivități este acela de a genera setul de date utilizabil pentru ML din Acțiunea 2.2. Printr-o conversie a celor 3 fișiere Excel în tabele și matrici se obțin tabele cu datele reprezentând relația stress-strain pentru cele 3 MC. **Table 1** arată cum sunt generate tabelele inițiale.

Tabelul 1 este suficient pentru a construi algoritmi de predicție (PA) pentru relația stress-strain a fiecărui MC și corespunzând unei direcții de încărcare, Parametrii de material indicați mai jos trebuie adăugați la fiecare "data point" pentru a identifica MC. În acest fel vom putea crea un model comun pentru întreaga familie, în cele ce urmează.

Table 1. Primele 10 linii ale tabelului cu 203 linii +pentru CF/6

Strain11	Stress11 (MPa)
5e-14	6.0014e-09
0.0005	60.014
0.000853	102.38
0.001353	129.17
0.001853	153.49
0.002353	175.29
0.002853	194.54
0.003353	211.3
0.003853	225.68
0.004353	237.84

Parametri de material:

Density (tonne/mm³) [20-25°C],
Matrix Young Modulus E_m (MPa),
Poisson ratio, Yield stress (MPa),
Yield stress (MPa),

Hardening modulus (MPa),
Hardening exponent,
Linear hardening modulus (MPa),
Volume fraction V_f .

În plus de direcția de încărcare codificată printr-o eticheta, se aduga la **Table 1** și cei 8 parametri de material. Se obține astfel **Table 2** cu primele 5 linii din datele primite pentru CF/6

Table 2. The first five lines of the dataset for CF/6, which consists of 203 data points.

LoadD	Density	Em	Poisson	YieldS	Hm	He	Lhm	Vf	Strain11	Stress11
LD11	1.14e-09	3000	0.37	25	3000	0.17	1000	0.6	5e-14	6.0014e-09
LD11	1.14e-09	3000	0.37	25	3000	0.17	1000	0.6	0.0005	60.014
LD11	1.14e-09	3000	0.37	25	3000	0.17	1000	0.6	0.000853	102.38
LD11	1.14e-09	3000	0.37	25	3000	0.17	1000	0.6	0.001353	129.17
LD11	1.14e-09	3000	0.37	25	3000	0.17	1000	0.6	0.001853	153.49

Cu datele din tabelele corespunzatoare verificăm relațiile stress-strain pentru CF/6 și CF/12




Figure 1. Zonele elastic și plastic pentru CF/6 și CF/12

Pentru detalii, programul Table6_12_11B.m este accesibil în documentele anexate.

Activitatea 2.2

Construcția și implementarea de modele de tip ML pentru predicția încărcării materialelor compozite și pentru zona plastică și de rupere, utilizând datele generate în cadrul activității 2.1 și sistemul de programare/simulare MATLAB.

Subactivitatea A3.

Definirea datelor de antrenare (training) și testare (testing) pentru diversele tipuri de modele ML.

Ca și în cazul activitatilor din etapa 1, pentru generarea algoritmilor de predicție inclusiv zona plastică, următoarele etape au fost parcurse:

1. Generarea unui "dataset" suficient de mare pentru a construi modele de ML care pot generaliza răspunsul pentru orice pattern și valoare Strain.
2. Stabilirea datelor de antrenare, validare și testare pentru fiecare MC.

Programul `Table6_12_11B.m` generează datele prezentate anterior, în timp ce programul `TablesTrainTest.m` realizează cel de-al doilea obiectiv. Testarea se referă la predicția unor exemple (data points) care nu au participat la antrenarea PA.

Pentru detalii, programele menționate mai sus sunt accesibile în documentele anexate.

Subactivitatea A4.

Dezvoltarea de algoritmi de predicție utilizând diferite modele de ML pentru un singur material compozit.

Această subactivitate a fost derulată, similar cu construcția de PA din etapa 1. Adăugăm la cele de mai sus, încă două etape:

3. Construirea mai întâi a unui model de regresie parametric (e.g. regresie liniară multiplă step-wise) care este ușor de înțeles și care poate fi comparat cu modelele dezvoltate ulterior.
4. Construirea unor modele nonparametrice (decision trees, Support Vector Machines, Gaussian process regression, Regression Neural Networks), analiza preciziei lor, și compararea lor cu modelul parametric.

Pentru fiecare ML algorithm (PA) dezvoltat în această etapă, s-a parcurs o întreagă **Sesiune de Proiectare** care se poate caracteriza prin:

- A fost folosită Regression Learner Application (RLA) din mediul MATLAB pentru a analiza PA generați de diferite modele de ML, pe datele de antrenare și testare stabilite.
- Au fost utilizate în cadrul RLA, pentru instruire cele 5 modele regresive de ML enumerate anterior.
- Procedura a permis o comparație a parametrilor statistici ce caracterizează fiecare PA generat.
- Selecția celui "mai bun" PA s-a făcut pe baza acurateții de predicție exprimată, în principal, prin valoarea RMSE (root mean square error) între valoarea reală și cea predicată.

Au fost realizate programe care să construiască algoritmi de predicție (PA) specifici modelului de ML ales. De exemplu, pentru obiectivul 3, `PA6Model_SW.m` realizează un PA bazat pe regresie liniară multiplă de tip step-wise (pentru `matCF/6`).

Pentru a exemplifica (tot pentru `CF/6`), menționăm că am parcurs o Sesiune de Proiectare utilizând RLA din mediul MATLAB. Dintre toate modelele, cel mai acurat este o RNN. Scriptul `PA6DamageRNN4` generează și utilizează acest model regresiv.

Mai întâi, funcția `trainRegNN4` generează un algoritm ML antrenat. Funcția `fitrnet` este apelată cu următorii parametri pentru a genera o RNN care constituie algoritmul de predicție construit. El este numit în proiect `mdlNN4`.

```
regressionNeuralNetwork = fitrnet(...
    predictors, ...
    response, ...
    'LayerSizes', 226, ...
    'Activations', 'relu', ...
    'Lambda', 6.366e-08, ...
    'IterationLimit', 1000, ...
    'Standardize', true);
```

Apoi se apelează funcția de predicție a obiectului `mdlNN4`. Apelând `mdlNN4.predictFcn`, se calculează 40 de predicții pentru setul `D6Test`. Rezultatul este arătat în figura 2. Predicțiile sunt de o acuratețe remarcabilă.

Toți pașii parcurși în subactivitățile A3 și A4 au fost repetați și pentru celelalte materiale, `CF/12` și `CF/11`, cu tot ceea ce implică: sesiuni de proiectare, scrieri de programe și teste.




Figure 2. Stress versus strain functions: real and predicted values (with mdlNN4) .

Subactivitatea A5.

O metoda de reprezentare a dependenței stress-strain ca o funcție, folosind predictorul furnizat de ML.

Obiectivul II de mai sus poate fi atins folosind funcția de predictor, implementată ca metodă a obiectului ce codifica PA (de ex RNN). Acest lucru poate fi implementat ținând cont de posibilitățile oferite de limbajul în care se face dezvoltarea algoritmilor de ML.

Pentru diverse aplicații, este de preferat ca relația stress-strain să fie reprezentată printr-o funcție, în sensul de unitate de program a limbajului ales pentru dezvoltare:

$$\text{stress} = f(\text{strain}, \text{ML_model}, \text{other parameters}).$$

Indiferent de tipul de model ML ales, exista o metodă ce permite specificarea valorii `stress` când este cunoscută valoarea `strain` și ceilalți parametri dintr-un data point. Mai jos, furnizăm un șablon de implementare a acestei funcții, presupunand că predictorul ML/6 a fost deja construit.

Function F_PA6 using the prediction algorithm as an argument.

```

1. function stress=F_PA6(strain,mdl)
    /* The function F_PA6 serves as an example for function f:*/
    /* strain: the strain's value */
    /* mdl: the prediction algorithm as an object reference */
2.   Define the table Tabj with one line and two columns
3.   Tabj{1,2} ← strain;
4.   Tabj{1,1} ← "PA6";
5.   stress=mdl.predictFcn(tabj);
6. return stress;
```

Subactivitatea A6.

Posibilitatea reprezentării familia de MC (CF/6, CF/12, CF/11) mai eficient la nivelul dimensiunii datelor de antrenare.

Cele trei materiale alcătuiesc o familie de MC pentru ca au în componență aceeași fibră de carbon. Întrabarea ridicată de specialiști văzând succesele în predicție ale modelelor de ML a fost dacă

Putem construi un singur model de predicție care să reprezinte întreaga familie?

O reunire a modelelor singulare prin reunirea celor 3 dataset-uri este o soluție trivială care, practic, nu aduce niciun avantaj. Un caz interesant ar fi dacă putem răspunde afirmativ la întrebarea:

Putem construi un model comun familiei de MC care să necesite o dimensiune mai mică a setului de date pentru antrenare, datorită caracteristicii comune, aceeași CF?

Cum putem folosi, practic, "caracteristica comuna"? Răspunsul a fost intuitiv și a fost verificat practic.

Comportamentul materialelor rezultă din suprapunerea a doi factori: influența CF și influența matricii. Datele de antrenare sunt expresia numerică a comportamentului materialelor. În cazul a trei modele regresive separate, influența CF asupra setului de date al unui anumit material nu se manifestă, în mod evident, și la celelalte două modele regresive. În schimb, pentru un PA comun care modelează familia de MC, influența CF asupra setului de date apare "ca repetându-se". Ea crează o anumită "redundanță" în datele de antrenare. Această ipoteză se verifică practic printr-o procedură iterativă creată pe acest subiect. Posibilitatea care apare acum de a exploata "caracteristica comuna" este eliminarea acestei redundanțe în dimensiunea dataset-ului pentru PA comun.

În dezvoltarea până la implementare a acestor idei au fost parcurse câteva etape pe care le sintetizăm mai jos.

- 1) Am construit un model comun de predicție pentru CF/6 și CF/12, numit ML/6-12 prin unirea seturilor de date de antrenare corespunzătoare celor două modele ML/6 și ML/12.
- 2) Am construit un model comun *exploratoriu* de predicție pentru CF/6, CF/12 și CF/11, numit ML/6-12-11 pentru care la dataset-ul modelului ML/6-12 am adăugat un număr mic, $n_{11}=12$, de data points caracterizând ML/11. Predicția pentru CF/11 nu a funcționat cu acuratețe.
- 3) Printr-o procedură iterativă, sub controlul dezvoltatorului de model, a fost mărit succesiv numărul n_{11} de data points, până când s-a atins acuratețea dorită.

Figura 3 prezintă grafic această dezvoltare de modele de predicție (TD6, TD12 și TD11 sunt datele de antrenare corespunzătoare).




Figure 3. Construction phases of the common model for the entire family of composite materials

În fiecare etapă au fost lansate Sesiuni de Proiectare utilizând cele 5 modele de ML.

Subactivitatea A7.

Implementarea procedurii de determinare a unui model de ML comun pentru întreaga familie de MC.

Procedura iterativă de la punctul 3) de mai sus trebuie implementată sub controlul dezvoltatorului de model comun pentru familia de MC, din două motive:

- Există mai multe soluții și implementatorul trebuie să aleagă în funcție de acuratețea dorită a PA;

- Implementatorul trebuie să execute niște sesiuni de proiectare de modele ML utilizand RLA.

ALGORITHM GenerateCommonPA

/* Joint prediction algorithms for the entire family are developed */	
Input Data: The training data used for the model ML/6–12 The complete training data used for the model ML/11	
Output: The solution considered the best by the developer: the regression ML/6–12–11 represented by an object that can be used subsequently.	
begin	
Initializations: Generate a test dataset (TD) consisting only of unseen data points related to the CF/11 1 $n11 \leftarrow n11_0$; /*Initialize n11, the number of datapoints concerning CF/11, added to the general dataset. */ stop $\leftarrow 0$; /*Stops the iterative procedure when it equals 1*/	
2	while $(n11/(n6+n12+n11) \leq p$ and stop=0) do
3	Select n11 data points related to the material CF/11, ensuring they are evenly distributed across the strain range.
4	Prepare a new dataset for training a new PA, ML/6–12–11, by adding the new n11 datapoints.
5	Conduct a Developing Session aimed at constructing a new prediction algorithm ML/6–12–11.
6	Test the prediction accuracy of the new algorithm ML/6-12-11 using TD.
7	Save the statistics and plots.
8	if (ML/6–12–11 has a satisfying accuracy), then stop $\leftarrow 1$ else {Select an increment Δn ; $n11 \leftarrow n11 + \Delta n$;} end /*while*/
9	end /*while*/
end	

Subactivitatea A8.

Caracterizarea celui mai bun model de regresie ML construit pentru familia de MC.

Pe datele noastre, sesiunile de proiectare arată ca PA sunt fie RNN, fie GPR (Gaussian Process Regression). Soluția care a avut acurătatea necesară a fost generat de un model GPR. Figura 4 arată comparația dintre valorile reale și cele predictate de modelul de regresie comun al familiei.




Figure 4. The selected ML/6–12–11 algorithm: predicted and real values for all the records.

Statisticile sunt:

- GPR, Bayesian optimization,

- Size of training data: 470 observations; validation: 5-fold cross-validation.
- $\text{vrms} = 0.91445$ (the RMSE using the test data set during the training procedure),
- $R^2 = 1$; $\text{MAE} = 0.59945$ (the Mean Absolute Error in test during the training procedure);
- $\text{RMSEValid} = 1.970$ (the RMSE after training using a test dataset composed of unseen data points).

Activitatea 2.3

Contributii la optimizarea structurii laminatelor compozite multistrat utilizand AI (meta-uristici de decizie optimala).

Subactivitatea A9.

Selectarea unui model regresiv de ML pentru laminate compozite cu putere mare de generalizare.

De la modelarea laminatelor compozite (LC) (Activitatea 1.2 – Etapa I, subactivități B1-B6), în această etapă am trecut la analiza posibilităților de optimizare și crearea de unelte adecvate. Pentru ca prezentarea să fie auto-conținută reluăm mai jos (Figure 5) prezentarea răspunsului celor 12 LC.




Figure 5. Dependenta stress-strain în timpul testului de traciune pentru cele 12 specimene.

Reluăm și structura unui data point pentru specimenul k :

$$\alpha_1, \alpha_2, \dots, \alpha_{16}, \text{strain}(S_k, j), \text{stress}(S_k, j), j=1, \dots, M.$$

În Etapa I, subactivitatea B5, a fost prezentat cel mai bun model de predicție realizat printr-o RNN, numit în proiect RNN2 (Figure 6).

Ceea ce caracterizează RNN2 nu este doar acuratețea predicțiilor pe datele de test, ci mai ales proprietatea de *generalizare* pe combinații noi de unghiuri care nu au făcut parte din datele de antrenare și test (nevazute). Aceasta proprietate este, în general, dificil de apreciat.

Existența unui astfel de PA (prediction algorithm) permite aflarea răspunsului oricărei combinații din *domeniul de reprezentare al modelului*. Optimizarea structurii LC înseamnă stabilirea unghiurilor $\alpha_1, \alpha_2, \dots, \alpha_{16}$ a.î. să se maximizeze sau minimizeze un indice de performanță. O primă abordare a optimizării este legată de selecția celei mai bune combinații de orientări pentru un LC, în funcție de un criteriu ales de specialistul în MC:

- Se trasează răspunsurile pentru combinațiile candidat folosind funcția creată la subactivitatea A5.
- Se cuantifică criteriul de selecție pentru cele câteva răspunsuri.
- Se alege combinația cea mai bună în funcție de valoarea criteriului.

Deși simplă, această procedură se poate dovedi eficientă. Dacă însă numărul de soluții candidat al problemei de optimizare (OP) este foarte mare (chiar infinit), atunci avem nevoie de o altă abordare.




Figura 6. Raspunsurile modelului RNN2 pentru cele 12 specimene de MC.

Subactivitatea A10.

Colaborarea unui algoritm de optimizare metaeuristic cu un model regresiv de ML pentru laminate compozite

Soluția care se impune este adoptarea unui cadru sistematic de optimizare (Optimization Framework – OFW). **Figura 7** prezintă o propunere de cadru sistematic de optimizare dezvoltată în proiect.




Figure 7: Structure of the Optimization Framework

Caracterul de *sistematic* ține de faptul că toate elementele ce caracterizează problema de optimizare, adică modelul obiectului sau sistemului, restricțiile și funcția obiectiv, sunt tratate de "Prediction and Computation Module". În cadrul activității 2.3, nu am considerat că predicția răspunsului unui LC este obligatorie. Ea poate fi înlocuită de furnizarea funcției f de la Subactivitatea A5, care poate fi codificată în diverse moduri.

În **figura 7** se considera că mecanismul de căutare a soluției optimale este asigurat de o variantă a algoritmului PSO (Particle Swarm Optimization). Acesta poate fi înlocuit, în funcție de problemă, cu un alt algoritm metaeuristic pe care computational intelligence îl oferă. De exemplu, Evolutionary Algorithms, GA, etc.

Remarcă: Deși PSO este o metaeuristică cunoscută, în proiect a fost furnizată varianta actualizată pentru structura OFW și laminate compozite. De aceea am reamintit cele două îmbunătățiri care o fac mai performantă, obținând algoritmul HTPSO.

Topologia hibridă

Utilizând notațiile consacrate descrierii PSO, dăm mai jos, elementele suplimentare ale acestei duble topologii. Forma standard de comunicare a PSO – care definește și prima topologie – este cea care utilizează

rețeaua formată din toate particulele din roi –care se deplasează– și cea mai buna soluție găsită la un moment dat, $Pgbest$. A doua topologie este dată de "vecinatatea socială". Particula #i va determina cea mai bună experiență locală, $Pbest(i)$, ca fiind cea mai bună experiență din "vecinatatea socială", adică 3 particule cu care comunică, desemnate aleatoriu la fiecare iterație a algoritmului, plus ea însăși. În general, avem:

$$Pbest(i) = \left(Pbest(i)^1, K, Pbest(i)^d, K, Pbest(i)^n \right); \quad d = 1, L, n; \quad (1)$$

Un nou termen apare în ecuația vitezei conținând C_3 și $rand_3$. La pasul următor, $t+1$, viteza și poziția particulelor se actualizează după următoarele ecuații:

$$\begin{cases} v(i)^d|_{t+1} = \left[w \cdot v(i)^d + C_1 \cdot rand_1 \cdot \left(Pbest(i)^d - x(i)^d \right) \right] + \\ + \left[C_2 \cdot rand_2 \cdot \left(Pgbest^d - x(i)^d \right) + C_3 \cdot rand_3 \cdot \left(Pbest(i)^d - x(i)^d \right) \right] ; \quad d = 1, \dots, n \\ x(i)^d|_{t+1} = x(i)^d|_t + v(i)^d|_t \end{cases} \quad (2)$$

Adaptarea vitezei particulelor

Această tehnică modifică coeficienții C_1 , C_2 , C_3 , și w în timpul procesului de căutare. Obiectivul este să fie adaptați la faza procesului de căutare și să îmbunătățească convergența. Adaptarea este realizată prin creșterea liniară a coeficienților C_1 , C_2 , and C_3 între valorile lor minimă și maximă. Simultan, parametrul w scade ca mai jos:

$$\begin{aligned} C1(t) &= C1_{min} + (C1_{max} - C1_{min})t / T; \quad C2(t) = C2_{min} + (C2_{max} - C2_{min})t / T; \\ C3(t) &= C3_{min} + (C3_{max} - C3_{min})t / T; \quad w(t) = w_{max} - (w_{max} - w_{min})t / T \end{aligned} \quad (3)$$

T este numărul de iterații estimat până la convergență.

Rezultate comunicate în lucrarea *Machine Learning Algorithms That Emulate Controllers Based on Particle Swarm Optimization. Processes* 2024, 12, 991; <https://doi.org/10.3390/pr12050991> arată, printre altele, și foarte buna comportare unei versiuni "adaptive cu topologie hibridă" a algoritmului PSO în asigurarea mecanismului de cautare a soluției quasi-optime.

Activitatea 2.4

Contributii la optimizarea proiectarii recipientelor de stocare a hidrogenului. Se vor integra algoritmi de tip ML si algoritmi meta-euristici de decizie optimala.

Subactivitatea 11

Studiu de caz 1– Compromis între rigiditate și rezistența la forfecare pentru un LC.

Contextul de optimizare se refera la "off-axis oriented specimens", adică la LC având paternurile de forma $[a1/-a1/a2/-a2/..., a8/-a8]$. Aplicând predicția cu RNN2 (modelul cu putere mare de generalizare) se obțin răspunsurile pentru 3 specime (S2 ($[\pm 20]_s$), S3 ($[\pm 30]_s$), S4 ($[\pm 45]_s$)), în figura 8. $Strain0$ este valoarea maximă a elongației pentru intervalul de referință $[0, Strain0]$.




Figure 8: Stress-strain curves for three off-axis oriented laminates

Studiul de caz 1. Se caută o structura de LC din familia "off-axis oriented specimens", Soluția optimă trebuie să îndeplinească două condiții:

1. Valoarea *Stress* pentru *Strain0* trebuie să fie de minimum 1000 MPa.
2. Curba stress-strain trebuie să fie cat mai apropiată de curba pentru S3.

Semnificația este următoarea: Prima condiție setează un minim de rigiditate (stiffness) a.î. curba pentru optim va sta cat mai aproape de S2 care are o valoare maximă de 1500 MPa. A doua restricție reflectă necesitatea de a avea o buna rezistență la forfecare (shear), ceea ce înseamnă ca soluția trebuie să fie cat mai apropiat de curba S3.

Această problema de optimizare (OP1) poate fi formulată astfel:

I. Modelul obiectului sau sistemului ce face obiectul optimizării

Obiectul este definit prin toate speciemenele pentru care avem:

$$X = [x_1, x_2, \dots, x_8] \subset \Omega = [0, 30]^8 \quad (x_i \in R, i=1, \dots, 8).$$

RNN2 este modelul regresiv pentru curba stress-strain.

II. Restricții

$$Stress0 \geq 1000, \text{ cu } Stress0 = \text{stress}(Strain0).$$

III. Funcția obiectiv

$$J(X) = \sum_{i=1}^8 (x_i - 30)^2; \text{ Criteriul de optim: } J_0 = \min_{X \in \Omega} J(X).$$

Pentru a folosi platforma OFW propusă mai sus, trebuie sa proiectăm doar Prediction and Computation Module (PCM) care va reuni toate specificitățile problemei OP1. Rezultatul este o funcție MATLAB, JXRefCurve, care se apelează după șablonul:

```
/* Function call: [ssp0, J] ← JXRefCurve (x, xRef, MLmodel, Strain0, Stress0) */
```

Input: *x*, the vector with the positive angles of the balanced specimen, *xRef*, the reference stress-strain curve, *MLmodel*, the ML regression model, *Strain0*, the upper limit of the strain interval, *Stress0*, the minimum admissible stress value

Output: *J*, the value of the objective function, and *ssp0*, the predicted stress value for *Strain0*.

Argumentul *x* este soluția candidat – analizată de HTPSO – pentru care se calculează *J*, valoarea funcției obiectiv. Dacă restricțiile nu sunt verificate, *J* ia valoarea infinit. In cazul nostru *xRef* corespunde curbei S3

($[\pm 30]_s$). Implementarea PCM, adică funcția $JXRefCurve$, este detaliată în raportul 3 și articolul din lista de livrabile.

În general, funcția obiectiv este de forma unde $xRef$ este vectorul cu unghiurile pozitive din pattern:

$$J(x) = \sum_{i=1}^8 (x_i - xRef_i)^2$$

Soluția optimă este dată mai jos:

Unghiuri: 25.22/ -25.22/ 27.53/ -27.53/ 26.13/ -26.13/ 26.94/ -26.94/
 26.99/ -26.99/ 26.86/ -26.86/ 25.63/ -25.63/ 28.08/ -28.08/
Stress max=*Stress*(*Strain0*)= 1000.0 MPa

Răspunsul acestui specimen este dat de **Figura 9** și corespunde curbei colorată în verde.




Figure 9: The optimal solution curve for OP1 compared to other oriented laminates.

Rezultatul are o explicație logică. Pentru a avea o rigiditate cât mai bună, curba optimă trebuie să fie mai apropiată de S2, dar pentru o rezistență la forfecare cât mai bună trebuie să fie cât mai apropiată de referința S3. Soluția optimă stabilește un echilibru între cele două tendințe.

Subactivitatea 12

Studiul eficacității structurii "Optimization Framework" – Studiu de caz 2.

Studiul de caz 2. Se caută o structură de LC din familia "off-axis oriented specimens", Soluția optimă trebuie să aibă structura $[a/-a/ a/-a/... a/-a]$ și să asigure un răspuns de exact $Stress0 = 1000$ MPa pentru $Strain0 = 0.017$.

Pentru un specimen caracterizat de unghiul a , valoarea maximă $Stress0$ pentru $Strain0$ poate fi privită ca o funcție $S(a) = stress(a, Strain0)$.

Această problemă de optimizare (OP2) poate fi formulată astfel:

I. Modelul obiectului sau sistemului ce face obiectul optimizării

Obiectul este definit prin toate specițiile pentru care avem:

- $a \in \Omega = [20, 30]$
- RNN2 este modelul regresiv pentru curba stress-strain.

II. Restricții

Nu există în afară de $a \in \Omega$.

III. Funcția obiectiv

$$J(a) = |S(a) - S_0|; \text{ unde } S_0 = 1000. \text{ MPa; Performance index: } J_0 = \min_{a \in \Omega} J(a).$$

Trebuie să proiectăm doar "Prediction and Computation Module (PCM)" care va reuni toate specificitățile problemei OP2. Rezultatul este o funcție MATLAB `JFixPoint` care se apelează după șablonul:

```
/* Function call:  $J \leftarrow J\text{FixPoint}(x, MLmodel, Strain0, Stress0)$  */
/* Calculate the cost function for a specimen with the pattern  $[x, -x, x, -x, \dots, x, -x]$  */
Input:  $x$ , the positive angle of the balanced specimen,  $MLmodel$ , the ML regression model,  $Strain0$ , the given limit of the strain interval,  $Stress0$ , the imposed stress value for the  $Strain0$ .
```

Output: J , the value of the cost function for the given arguments.

O execuție tipică a OFW, care apelează în mod repetat funcția `JFixPoint` până la convergență, produce următoarele rezultate:

Optimal $a=26.43$; $J_0=1.136868e-13$; $S_0=1000.00$ MPa.
 Orientările optime ale straturilor: 26.43/-26.43/...../26.43/-26.43/

Funcția `JFixPoint` a fost apelată de 4260 de ori, ceea ce ne dă o imagine a complexității computaționale pentru rezolvarea OP2 prin metoda propusă.




Figura 10. Curba stress-strain pentru soluția optimă a OP2 ($a=26.43$) și pentru celelalte trei laminate compozite

Putem alege și o altă valoare pentru $S_0 = 900.00$ MPa. În acest caz, OFW furnizează o altă soluție tipică:

Optimal $a=27.87^\circ$; $J_0=1.136868e-13$; $S_0=900.00$ MPa.
 Orientările optime ale straturilor: 27.87/-27.87/...../27.87/-27.87/

De data aceasta, numărul de apeluri ale funcției `JFixPoint` este 4320. Acest comportament variabil este, desigur, datorat faptului că HTPSO este un algoritm stochastic, cu soluții aproximative, dar precise la convergență.

În figurile 9 și 10, curbele stress-strain asociate problemelor OP1 și OP2, pleacă din (0, 0) și ajung în același punct ($Strain0, 1000.0$). Ele sunt totuși diferite, pentru că straturile au orientări diferite. Lucrul acesta este demonstrat de **Figura 11**.




Figure 11. The "distance" between the optimal solution curves for OP2 and OP1.

Valorile minimă, medie, maximă și tipică, precum și deviația standard a indecelui de performanță J_0 sunt furnizate de **Table 1**. Un alt fapt ce ilustrează natura stochastică a OFW este numărul de apelări, N_{calls} , ale funcției ce implementează PCM. Ultimul integrează și calculul criteriului de optim. O statistică pentru N_{calls} este prezentată în linia a doua a acestui tabel, pentru aceleași 30 de execuții ale OFW.

Table 1. OP1–Statistics on the performance index and call count for the PCM function.

	min	avg	max	typical	Sdev
J_0	94.522	94.738	95.653	94.74	0.274
N_{calls}	3300	5987	8760	5940	1445

Valoarea tipică pentru un lot de 30 execuții succesive este cea mai apropiată valoare a unei execuții de valoarea medie. Deviația standard a valorii N_{calls} este destul de mare pentru ca inițializarea roiului de particule s-a făcut într-o manieră simplă: 30 de particule – vectori cu 8 elemente pozitive – au fost distribuiți uniform în domeniul de căutare $[20, 30]^8$. Aici este loc de ameliorare a procedurii de inițializare pentru o mai bună acoperire a domeniului.

Tabelul 2 prezintă statistici similare pentru soluția optimă a OP2.

Table 2. OP2–Statistics on the angle α , performance index, and call count for the PCM function.

	min	avg	max	typical	Sdev
α	26.4301	26.4304	26.4312	26.4304	0.0002
J_0	274074e-07	1.600905e-03	1.651415e-02	3.737492e-03	174176e-02
N_{calls}	140	254.8	413	252	67.2

OP2 a fost rezolvată pentru diferite valori ale lui S_0 (la elongația considerată $Strain0$) utilizând același LC modelat de RNN2. Valorile lui S_0 au fost alese să acopere domeniul dintre S2 și S3, adică 900, 1000, 1100, 1200, și 1300 MPa. Cele 5 execuții cu un roi mare de 30 particles au produs soluții cu curbele asociate din Figura 12.

Soluțiile sunt date în Table 3, indicând unghiul α pentru fiecare S_0 .

Table 3. OP2–The solution α , and the performance index for the five runs

S_0 [MPa]	900	1000	1100	1200	1300
α	27.87°	26.43°	24.98°	23.52°	22.04°

Rezultatele obținute prin simulări MATLAB au dovedit că ambele studii de caz pot fi rezolvate eficient.

Limitare în utilizarea platformei și programului OFW.

Structura și programul OFW nu asigură rezolvarea unei OP referitoare la LC decât dacă modelul de regresie ML are într-adevăr o bună putere de generalizare și o utilizăm corect, adică în interiorul domeniului de reprezentare al modelului de ML. Acesta este mai greu de stabilit a priori. El nu este atât de mare pe cât ne-

am dorit să fie, a.î să nu abordăm problema cu precauție. Dezvoltatorul trebuie să stabilească a priori prin analiză limitele "geometrice" între care curbele asociate soluțiilor candidat se pot situa. Depinzând de dataset și de aplicația practică, utilizatorul poate presupune din start domeniul de reprezentare al modelului regresiv ML și să verifice prin teste și simulări dacă ipoteza este corectă.




Figure 12. Optimal solution curves for OP2 and different values of S_0

OFW introdus în această lucrare oferă perspective importante care îi extind aplicabilitatea.

- În afară de AHTPSO, alți algoritmi metaheuristic pot fi adaptați la cadrul propus, cum ar fi algoritmi evolutivi, genetici, alte metode bazate pe populații de soluții, etc.
- În loc de un model RNN, poate fi folosit ca predictor un alt tip de model de ML, dacă oferă predicții foarte precise și o bună capacitate de generalizare pentru specițiile candidate de LC.
- Platforma OFW poate fi aplicată la diferite tipuri de probleme, unde predicțiile pot înlocui cu acuratețe stările fizice ale sistemului.

Activitatea 2.5

Participari la intalniri ale consorțiului, vizite de lucru, sau participari la manifestari tehnico-stiintifice internationale pe domeniu

Rezultatele obtinute de echipa UGAL au fost prezentate în cadrul numeroaselor întâlniri de lucru online organizate pe platforma TEAMS si care sunt înregistrate. Participarea echipei noastre a fost activa si rezultatele au fost apreciate si validate la nivelul discuțiilor. Precizez ca rapoarte știintifice, aricolele si arhivele cu programe au fost trimise coordonatorului proiectului care le-a amplasat pe platforma proiectului comun.

În octombrie 2025, LEAP-RE (Parteneriatul pe termen lung UE-UA) a organizat un Forum important al Părților Interesate la Bruxelles, în perioada 21-23 octombrie. În data de 22 Octombrie, 2025 s-a organizat conferința "Scientific & Methodological Clusters" la care prof. V Mînză a participat online la sesiunea "Grid Modelling Cluster" cu teme: a) Energy Planning challenges; b) Energy Modelling Approaches of the different speakers; c) Data availability and Data collection techniques.

GRADUL DE REALIZARE A OBIECTIVELOR

În planul de realizare a proiectului, ne-am angajat la obtinerea urmatoarelor rezultate minime:

(I)- Modele extinse de tip machine-learning ce caracterizeaza comportamentul la tractiune in zona plastica si de ruptura, precum si comportamentul termo-mecanic, pentru materialele compozite.

Rezultatele care atestă îndeplinirea obiectivului (I) sunt prezentate în:

- Raportul 1: *Implementation aspects of stress-strain characteristics' regression models for composite materials. Part I: The modeling of the stress-strain characteristic -including the "damaged" zone.*
- Arhiva de programe: *ART_Matlb.zip*.
- Articol publicat în revista *Processes*
 Brayek, B. E.; Sayed, S.; *Mînză, V.; Tarfaoui, M.; (IF 2.8; CITESCORE 5.5-Q2)
Machine Learning Predictions for the Comparative Mechanical Analysis of Composite Laminates with Various Fibers. *Processes*, 13(3), 602. Published: 20 February 2025.
<https://doi.org/10.3390/pr13030602>
- Raportul 2: *Implementation of Machine Learning Models for Composite Materials with the Same Carbon Fiber but Different Matrices.*
- Arhiva de programe: *JMSCE_supplementary.zip*.
- Articol publicat în revista "Journal of Materials Science and Chemical Engineering"
 Mînză, V. and Arama, I.;
A New Method to Predict the Mechanical Behavior for a Family of Composite Materials.
Journal of Materials Science and Chemical Engineering Vol.13 No.9. Published: 23.09.2025.
<https://www.scirp.org/journal/paperinformation?paperid=145844>;
 DOI: 10.4236/msce.2025.139009

(II)- Algoritmi de optimizare a structurii laminatelor compozite multistrat utilizand AI (meta-euristici de decizie optima)

(III)- Algoritmi utilizabili in proiectarea optimizata a structurilor ce constitue recipiente de stocare a hidrogenului;

Rezultatele care atestă îndeplinirea obiectivele (II) și (III) sunt prezentate integrat în:

- Raportul 3: *Contributions to the Optimization of Multilayer Composite Laminate Structures Using Particle Swarm Optimization and Machine Learning.*
- Arhiva de programe: *OFW_Mtlb.zip*.
- Articol pregătit pentru publicare (unpublished).
 Mînză, V. and Arama, I.;
Optimal Structure Determination for Composite Laminates Using Particle Swarm Optimization and Machine Learning

Structura de optimizare OFW se poate aplica la orice problema de optimizare la care modelul obiectului este un model de ML.

(IV)-Studiu publicabil in revista/volum conferinta nationala/internationala, eventual in colaborare cu alti parteneri din proiect.

Pe langa cele trei studii publicate în reviste, amintite mai sus, remarcăm și cele 3 articole acceptate la conferința internațională "SGEM International Scientific Conferences on Earth & Planetary Science, Extended Scientific Sessions *GREEN SCIENCES FOR GREEN LIFE*. Schönbrunn Palace, Vienna 03 - 06 December 2025"; <https://sgemviennagreen.org/index.php>.

Mihalcea, A.; Chiroasca, A-M.; Rusu, L.;
A new approach to green hydrogen research – challenges and solutions towards emission reduction and a cleaner maritime transportation
 Chiroasca, A-M.; Popa, V-I.; Rusu, E.
Assessment of green hydrogen production and potential utilization in the hydrodynamic environment of the Danube
 Bujor, A; Chiroasca, A-M. ; Gasparotti, C.; Rusu, E.
Hybrid energy solutions: hydrogen integration in floating production, storage, and offloading units.

Contribuțiile prezentate în lucrările publicate și rapoarte depășesc obiectivele minimale la care ne-am angajat. De exemplu, modelarea unei familii de materiale compozite ce au o caracteristică comună.

SUMAR AL PROGRESULUI

Livrabile:

- Cele 3 rapoarte de cercetare amintite mai sus.
- Cele trei articole în reviste cu vizibilitate (doi deja publicate și unul în curs de publicare – unpublished)
- Arhivele cu programe și fișiere ce implementează toate metodele propuse: **ART_Matlb.zip**, **JMSCE_supplementary.zip**, **OFW_Mtlb.zip**.
- Cele trei articole acceptate la conferința internațională.

Indicatori de rezultat:

- studii: 3
- articole publicate ISI: 3
- produse informatice: programele de implementare a modelelor propuse (Arhivele **ART_Matlb.zip**, **JMSCE_supplementary.zip**, **OFW_Mtlb.zip**)
- participari conferințe: 3 (SGEM International Scientific Conferences on Earth & Planetary Science, Extended Scientific Sessions GREEN SCIENCES FOR GREEN LIFE.)

Diseminare rezultate prin:

- site proiect <https://www.d3t4h2s.ugal.ro/index.php>
- cele 3 publicații în reviste+ 3 articole la conferință
- participare la conferința de la Viena, cu trei articole, în decembrie 2025.

Concluzie: *Gradul de realizare al acestei etape este de 100%*

Rezumat executiv al activităților realizate în anul 2025-etapa a doua

Proiect: Un model digital bazat pe date pentru recipiente de stocare a hidrogenului răspunzând provocărilor de tranziție energetică.

COD: COFUND-LEAP-RE D3T4H2S

În anul 2025, pe parcursul căruia s-a desfășurat cea de a doua etapă a proiectului, colectivul de cercetători de la Universitatea din Galați (UGAL) și-a continuat cercetările alături de ceilalți 5 parteneri internaționali implicați în proiectul D3T4H2S. Metodologia propusă de consorțiu este bazată pe o abordare hibridă ce presupune: 1. proiectarea materialelor compozite, 2. studiul experimental al comportamentului lor termomecanic, 3. modelarea și simularea numerică a comportamentului materialelor compozite utilizate, 4. utilizarea învățării automate (machine learning -ML) pentru modele predictive și procese optime.

Coordonatorul și-a asumat rolul de integrator. În cadrul consorțiului, UGAL a fost singurul partener cu expertiză în domeniul 4, care a acoperit două zone științifice esențiale în proiect: modele regresive obținute cu algoritmi de ML și algoritmi metaeuristici de inteligență computațională. Obiectivele urmărite și realizate s-au referit la:

- Preluarea și prelucrarea datelor furnizate de parteneri, ce caracterizează comportamentul mecanic la tracțiune al materialelor compozite. S-a generat setul de date utilizabil de algoritmi de ML în antrenare și testare.
- Construcția de modele regresive de ML pentru comportamentul în sarcină a materialelor compozite atât în zona elastică cât și cea plastică. Materialele compozite sunt fabricate din fibra de carbon AS4, iar matricea din rasina epoxidică 8552. Matricea este dublu ranforsată cu poliamide (PA6, PA12, PA11) și dopată cu nanotuburi de carbon.
- Dezvoltarea de modele regresive de ML pentru relația stress-strain al unui lot de 12 laminate compozite (LC) multilayer de diferite orientări, în zona elastică. Aceste modele regresive au fost folosite în studiile de caz pentru optimizarea structurii LC.
- Crearea unui cadru de lucru pentru optimizare (Optimization FrameWork - OFW) bazat pe colaborarea dintre un algorithm metauristic, o variantă ameliorată a PSO– Hybrid Topolgy PSO adaptiv– și un model de ML –Regressive Neural Network – al laminatului compozit.

- Definirea a doua studii de caz de optimizare a structurii laminatului compozit și rezolvarea problemelor de optimizare aferente utilizării OFW. Analiza eficacității și eficienței OFW.

Ca rezultat al cercetării, a fost elaborate trei studii de cercetare:

- (1). *Implementation aspects of stress-strain characteristics' regression models for composite materials. Part I: The modeling of the stress-strain characteristic -including the "damaged" zone. Part II: Machine Learning Predictions for the Comparative Mechanical Analysis of Composite Laminates with Various Fiber Orientations.*
- (2). *Implementation of Machine Learning Models for Composite Materials with the Same Carbon Fiber but Different Matrices.*
- (3). *Contributions to the Optimization of Multilayer Composite Laminate Structures Using Particle Swarm Optimization and Machine Learning.*

Cele 3 studii de cercetare sunt însoțite de 3 arhive cu programele implementate în MATLAB ce pot fi consultate pentru înțelegere și verificare.

Alte rezultate ale proiectului au fost incluse în 3 articole publicate în reviste indexate în baze de date semnificative:

- (1) Brayek, B. E.; Sayed, S.; *Mînză, V.; Tarfaoui, M.; (IF 2.8; CITESCORE 5.5-Q2)
Machine Learning Predictions for the Comparative Mechanical Analysis of Composite Laminates with Various Fibers. Processes, 13(3), 602. Published: 20 February 2025.
<https://doi.org/10.3390/pr13030602>
- (2) Mînză, V. and Arama, I. (CrossRef, ResearchGate, SciLit, Worldcat, etc)
A New Method to Predict the Mechanical Behavior for a Family of Composite Materials.
Journal of Materials Science and Chemical Engineering Vol.13 No.9. Published: 23.09.2025.
<https://www.scirp.org/journal/paperinformation?paperid=145844>; DOI: 10.4236/msce.2025.139009;
- (3) Mînză, V. and Arama, I.;
Optimal Structure Determination for Composite Laminates Using Particle Swarm Optimization and Machine Learning (unpublished – trimis la publicare).

Menționăm și cele trei articole acceptate ce vor fi prezentate de membri ai echipei de cercetare la "SGEM International Scientific Conferences on Earth & Planetary Science", Vienna 03 - 06 December 2025.

Director Proiect
Viorel MÎNZU

