

# Contract nr.17 din 01/04/2024,etapa 1-REPLACER

**RAPORT ȘTIINȚIFIC ȘI TEHNIC 2024**

Referință 7076/02.12.2024

Manager de proiect: ***Oliviu Matei***

## Istoricul versiunilor

Versiune	Autor	Modificări
0.1	Oliviu Matei	Versiunea inițială
0.5	Oliviu Matei	Versiunea intermediară
1.0	Oliviu Matei	Versiunea finală

## Cuprins

<b>1</b>	<b>Introducere</b>	<b>5</b>
<b>2</b>	<b>Despre proiectul REPLACER</b>	<b>5</b>
2.1	Obiectivele proiectului . . . . .	6
2.2	Structura proiectului REPLACER . . . . .	6
<b>3</b>	<b>Activități planificate</b>	<b>7</b>
<b>4</b>	<b>Activități efectuate</b>	<b>7</b>
4.1	Devieri de la planificare . . . . .	7
<b>5</b>	<b>Starea curentă a domeniului</b>	<b>7</b>
5.1	Introducere . . . . .	7
5.2	Biofilmele microbiene: caracteristici și importanță . . . . .	8
5.3	Rolul Machine Learning în studiul biofilmelor . . . . .	8
5.4	Aplicații ale Machine Learning în studiul biofilmelor . . . . .	8
5.5	Provocări și perspective viitoare . . . . .	8
<b>6</b>	<b>Cerințele platformei</b>	<b>9</b>
6.1	Cerințe funcționale . . . . .	9
6.2	Cerințe nonfuncționale . . . . .	10
6.3	Impactul așteptat al platformei . . . . .	10
<b>7</b>	<b>Strategia de agregare pentru algoritmul de învățare automată federată</b>	<b>10</b>
7.1	Strategia de agregare pentru învățarea federată . . . . .	10
7.2	Impactul calculului MImp asupra agregării . . . . .	11
7.3	Rezultate experimentale . . . . .	11
7.4	Progres în integrarea materialelor hibride vii . . . . .	11
7.5	Viitorul proiectului . . . . .	11
<b>8</b>	<b>Rolul HOLISUN în cadrul proiectului</b>	<b>12</b>
8.1	Contribuția HOLISUN la platforma Design-Build-Test-Learn (DBTL) . . . . .	12
8.2	Integrarea în WP4: Modelare și predicție folosind AI . . . . .	12
8.3	Impactul HOLISUN asupra scalabilității și sustenabilității platformei . . . . .	12
8.4	Rezultate așteptate . . . . .	12
<b>9</b>	<b>Extras din planul de riscuri</b>	<b>13</b>
<b>10</b>	<b>Rezultatele proiectului</b>	<b>14</b>
10.1	Livrabile . . . . .	14
10.2	Articole științifice . . . . .	14

<b>11 Diseminare și exploatare</b>	<b>15</b>
11.1 Activități de diseminare . . . . .	15
<b>12 Concluzii</b>	<b>16</b>

## Parteneri



UNIVERSITÄT  
LEIPZIG

(a) University of Leipzig (Germania) Coordonator



(b) Holisun SRL(Romania)



(c) Leibniz Institute of Surface Engineering  
(Germania)



UNIVERSITY  
OF LATVIA

(d) University of Latvia (Letonia)



(e) qCoat (Germania)

Figura 1: Partenerii proiectului *REPLACER*

## 1 Introducere

Proiectul **REPLACER** abordează una dintre cele mai mari provocări globale ale momentului: reducerea poluării cu plastic și a emisiilor de gaze cu efect de seră (GHG), alături de asigurarea securității alimentare. Cu o abordare interdisciplinară, **REPLACER** își propune să dezvolte materiale hibride vii (HLMs) care să ofere soluții sustenabile pentru captarea și valorificarea dioxidului de carbon ( $\text{CO}_2$ ) și metanului ( $\text{CH}_4$ ).

Proiectul integrează știința materialelor, biotehnologia, fizica, știința calculatoarelor și matematica într-o platformă inovatoare de tip Design-Build-Test-Learn (DBTL), care folosește plastic reciclat pentru a construi structuri avansate menite să susțină creșterea biofilmului microbial. Această platformă permite un ciclu închis de dezvoltare a materialelor și susține aplicarea unor metode computaționale avansate și modele bazate pe inteligență artificială (AI) pentru optimizarea producției de proteine microbiene din gaze cu efect de seră.

Astfel, proiectul contribuie la reducerea poluării, la sprijinirea economiei circulare și la asigurarea unei surse sustenabile de hrană pentru animale, diminuând dependența Uniunii Europene de importul de proteine din soia.

Prezentul raport oferă o perspectivă detaliată asupra obiectivelor, abordării și implementării proiectului **REPLACER**, subliniind contribuțiile tehnologice, economice și ecologice ale acestuia la nivel european și global.

## 2 Despre proiectul REPLACER

Proiectul **REPLACER** urmărește să dezvolte soluții sustenabile pentru captarea gazelor cu efect de seră ( $\text{CO}_2$  și  $\text{CH}_4$ ) și pentru valorificarea acestora prin producția de proteine microbiene. Aceste soluții se bazează pe integrarea materialelor hibride vii (HLMs) în cadrul unei platforme inovatoare Design-Build-Test-Learn (DBTL), utilizând plastic reciclat și energie lumină. Figura 2 descrie structura principală a proiectului **REPLACER** și evidențiază principalele pachete de lucru (WP-uri) și componente tehnologice.

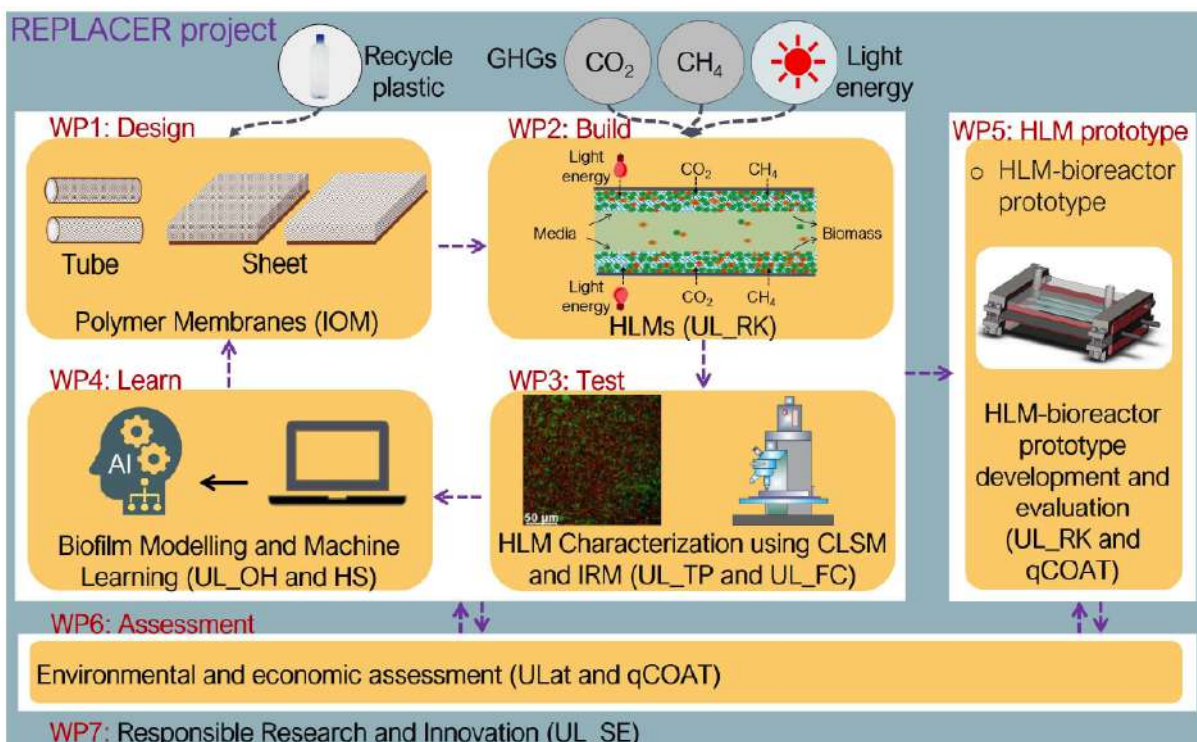


Figura 2: Structura proiectului REPLACER: pachetele de lucru și interacțiunile dintre componente.

## 2.1 Obiectivele proiectului

Proiectul **REPLACER** urmărește realizarea următoarelor obiective principale:

- **Obiectivul 1.** Dezvoltarea unei noi platforme de cercetare în circuit închis, de tip design-build-test-learn (DBTL), care combină reciclarea materialelor, procesarea consorțiilor microbiene sintetice prin captarea gazelor cu efect de seră, analize transversale și utilizarea strategiilor de modelare și inteligență artificială pentru construirea unor HLM-uri inovatoare. Platforma va permite proiectarea materialelor cu proprietăți personalizate pentru construirea eficientă a consorțiilor microbiene, va oferi capacitate predictivă și va furniza cunoștințe practice pentru dezvoltarea HLM-urilor, aducând aceste materiale din concept în piață.
- **Obiectivul 2.** Dezvoltarea unor HLM-uri performante ca soluție eficientă energetic și economică pentru captarea gazelor cu efect de seră și producerea de biomasa utilizabilă (proteine microbiene) folosind ciclul iterativ DBTL. Captarea și sechestrarea CO<sub>2</sub> și CH<sub>4</sub> este una dintre cele mai promițătoare tehnologii pentru reducerea emisiilor de gaze cu efect de seră și stabilizarea planetei împotriva consecințelor catastrofale ale schimbărilor climatice. Dezvoltarea unor tehnologii scalabile, eficiente energetic și rentabile pentru captarea gazelor cu efect de seră va deschide o industrie globală nouă și masivă.
- **Obiectivul 3.** Proiectarea prototipurilor de bioreactoare HLM și demonstrarea fezabilității procesului dezvoltat pentru producerea de proteine microbiene, utilizând evaluări economice și de mediu și abordând aspecte sociale și etice prin aplicarea tehnicilor de cercetare și inovare responsabilă (RRI). Scalarea cu succes a HLM-urilor pentru a obține performanța dorită este un pas crucial în transferul tehnologic. Proiectul **REPLACER** va permite o abordare de scalare printr-un concept de creștere modulară pentru demonstrarea prototipurilor HLM.

## 2.2 Structura proiectului REPLACER




Figura 3: Diagrama Gantt care arată calendarul pachetelor de lucru și activităților proiectului

- **WP1: Design** – Proiectarea membranelor poroase din plastic reciclat, sub formă de tuburi sau foi. Aceste membrane sunt esențiale pentru suportul biofilmului microbial. Institutul de Membrane Organice și Materiale (IOM) joacă un rol cheie în această etapă.

- **WP2: Build** – Dezvoltarea materialelor hibride vii (HLMs) prin integrarea biofilmurilor microbiene în structurile poroase create. Aceste structuri sunt optimizate pentru captarea CO<sub>2</sub> și CH<sub>4</sub>, utilizând energie din lumină pentru susținerea proceselor microbiene. Universitatea de la Riga (UL\_RK) este responsabilă pentru această etapă.
- **WP3: Test** – Caracterizarea materialelor HLM utilizând tehnici avansate, cum ar fi microscopie confocală cu scanare laser (CLSM) și microscopie cu reflexie internă (IRM). Această etapă validează performanța materialelor și evaluarea biofilmului.
- **WP4: Learn** – Modelarea biofilmurilor și optimizarea proceselor prin învățare automată (AI). Algoritmii avansați analizează datele obținute pentru a îmbunătăți performanța materialelor. Universitatea de Științe Aplicate din Oslo (UL\_OH) contribuie la această etapă.
- **WP5: HLM Prototype** – Dezvoltarea unui prototip de bioreactor HLM pentru utilizare industrială. Universitatea de la Riga (UL\_RK) și partenerii qCOAT se ocupă de această etapă.
- **WP6: Assessment** – Evaluarea impactului economic și ecologic al soluțiilor dezvoltate. Echipele ULat și qCOAT conduc această etapă.
- **WP7: Responsible Research and Innovation** – Cercetare responsabilă și inovare, asigurând implicarea etică și sustenabilă în toate etapele proiectului.

### 3 Activități planificate

În perioada 01.03.2024 - 05.12.2024 au fost planificate următoarele activități:

- Cercetarea literaturii de specialitate;
- Cercetare pentru stabilirea nevoilor și cerințelor platformei *REPLACER* ;
- Întâlniri de progres.

### 4 Activități efectuate

În perioada 01.03.2024 - 05.12.2024 au fost efectuate următoarele activități:

- Cercetare pentru stabilirea nevoilor și cerințelor platformei *REPLACER* ;
- Întâlniri de progres și tehnice la fiecare trimestru.
- 1 întâlnire fizică cu toți partenerii proiectului pe 6 Iunie 2024 Riga, Letonia.

#### 4.1 Devieri de la planificare

În perioada raportată nu au fost devieri de la planificare, sub nici un aspect.

## 5 Starea curentă a domeniului

### 5.1 Introducere

Machine Learning (ML) și biofilmele microbiene sunt două domenii care, în ultimii ani, au început să se intersecteze, având un impact semnificativ în diverse aplicații industriale, medicale și de mediu. Dezvoltările recente în inteligența artificială și analiza datelor au permis studierea și modelarea biofilmelor microbiene cu o precizie fără precedent, oferind noi perspective asupra comportamentului lor complex și heterogen [4, 6].

Biofilmele sunt comunități microbiene organizate care se dezvoltă pe suprafețe, caracterizate de producerea unei matrice extracelulare complexe. Ele joacă un rol esențial în procesele naturale, cum ar fi ciclurile biogeochimice, dar sunt și factori perturbatori majori în aplicațiile industriale și medicale, unde pot cauza biofouling sau infecții cronice [3].



Utilizarea tehnicilor de ML pentru a modela și înțelege biofilmele deschide noi oportunități pentru dezvoltarea de soluții sustenabile și eficiente în gestionarea lor.

## 5.2 Biofilmele microbiene: caracteristici și importanță

Biofilmele sunt structuri complexe formate din microorganisme care aderă la suprafețe și sunt înconjurate de o matrice extracelulară de substanțe polimerice [7]. Ele sunt implicate în diverse aplicații industriale, cum ar fi tratarea apelor uzate, captarea gazelor cu efect de seră și producția de biocombustibili, dar sunt și o problemă în industriile medicale și maritime din cauza biofouling-ului [3].

Dezvoltarea biofilmelor este influențată de numeroși factori, inclusiv tipul microorganismelor implicate, proprietățile suprafeței substratului și condițiile de mediu, cum ar fi pH-ul, temperatura și disponibilitatea nutrienților [4]. Această variabilitate face ca studiul lor să fie extrem de complex, motiv pentru care metodele convenționale de analiză au limitări în înțelegerea completă a dinamicii biofilmelor.

## 5.3 Rolul Machine Learning în studiul biofilmelor

Machine Learning este un subset al inteligenței artificiale care permite sistemelor să învețe din date și să facă predicții sau decizii fără a fi programate explicit [5]. Aplicarea ML în studiul biofilmelor a deschis noi direcții de cercetare, inclusiv:

- **Predicția formării biofilmelor:** Modelele bazate pe ML pot analiza date despre condițiile de mediu și proprietățile suprafeței pentru a prezice probabilitatea formării unui biofilm [6].
- **Modelarea creșterii și structurii:** Algoritmii de ML, cum ar fi rețelele neuronale convoluționale (CNN), sunt folosiți pentru a analiza imagini microscopice și a modela structura tridimensională a biofilmelor [4].
- **Optimizarea tratamentelor anti-biofilm:** Modelele ML pot fi utilizate pentru a optimiza utilizarea dezinfectanților și a altor tratamente chimice, minimizând impactul asupra mediului [3].
- **Analiza interacțiunilor microbiene:** Algoritmii de ML, cum ar fi învățarea nesupervizată (unsupervised learning), ajută la identificarea relațiilor complexe între diferite specii microbiene dintr-un biofilm [5].

## 5.4 Aplicații ale Machine Learning în studiul biofilmelor

1. **Detectarea și monitorizarea biofilmelor:** Dezvoltarea de biosenzori inteligenți integrați cu ML permite detectarea rapidă și în timp real a biofilmelor. De exemplu, senzorii optici și electrochimici, în combinație cu algoritmi de învățare profundă, pot detecta biofilme la niveluri incipiente [6].

2. **Proiectarea materialelor anti-biofilm:** ML poate fi utilizat pentru a proiecta suprafețe și materiale care previn formarea biofilmului prin analiza unui set vast de date despre interacțiunile microbiene cu substratul [4].

3. **Medicina personalizată:** În domeniul medical, ML este utilizat pentru a dezvolta tratamente personalizate împotriva biofilmelor care cauzează infecții cronice, cum ar fi cele asociate cu protezele sau cateterele [3].

4. **Captarea gazelor cu efect de seră:** Biofilmele microbiene optimizate cu ajutorul ML sunt utilizate pentru captarea CO<sub>2</sub> și CH<sub>4</sub>, oferind soluții sustenabile pentru reducerea emisiilor de gaze cu efect de seră [7].

## 5.5 Provocări și perspective viitoare

Deși ML a adus progrese remarcabile în studiul biofilmelor, există încă numeroase provocări:

- **Calitatea datelor:** Modelarea precisă a biofilmelor necesită seturi de date mari și variate, iar colectarea unor astfel de date poate fi costisitoare și dificilă [4].
- **Explicabilitatea algoritmilor:** Modelele ML sunt adesea considerate cutii negre, ceea ce face dificilă interpretarea modului în care iau decizii [5].

- **Integrarea interdisciplinară:** Studiul biofilmelor necesită colaborare între microbiologi, chimiști, ingineri și experți în știința datelor [6].

Perspectivile viitoare includ integrarea unor tehnici avansate, cum ar fi învățarea transferului (transfer learning) și AI explicabilă (explainable AI), pentru a îmbunătăți înțelegerea și aplicarea biofilmelor în diverse industrii. În plus, utilizarea datelor generate de senzori IoT și analiza acestora cu ajutorul ML ar putea revoluționa modul în care biofilmele sunt gestionate în timp real [7].

Machine Learning reprezintă o unealtă puternică pentru avansarea înțelegerii și aplicării biofilmelor microbiene. Prin integrarea modelării computaționale, a tehnicilor de învățare automată și a experimentării interdisciplinare, se pot dezvolta soluții inovatoare pentru gestionarea biofilmelor și valorificarea potențialului lor în diverse industrii.

## 6 Cerințele platformei

În dezvoltarea unei platforme hibride hardware-software pentru realizarea materialelor hibride vii (HLMs) utilizate în cadrul proiectului **REPLACER**, este esențială o abordare multidisciplinară și sistemică. Această platformă trebuie să fie optimizată pentru a răspunde provocărilor actuale legate de sustenabilitate, eficiență energetică și scalabilitate, fără a compromite performanța procesului de captare a gazelor cu efect de seră (CO<sub>2</sub>, CH<sub>4</sub>). Pe baza obiectivelor și metodologiei proiectului, cerințele platformei pot fi împărțite în două categorii: **cerințe funcționale** și **cerințe nonfuncționale** (Figura 4).

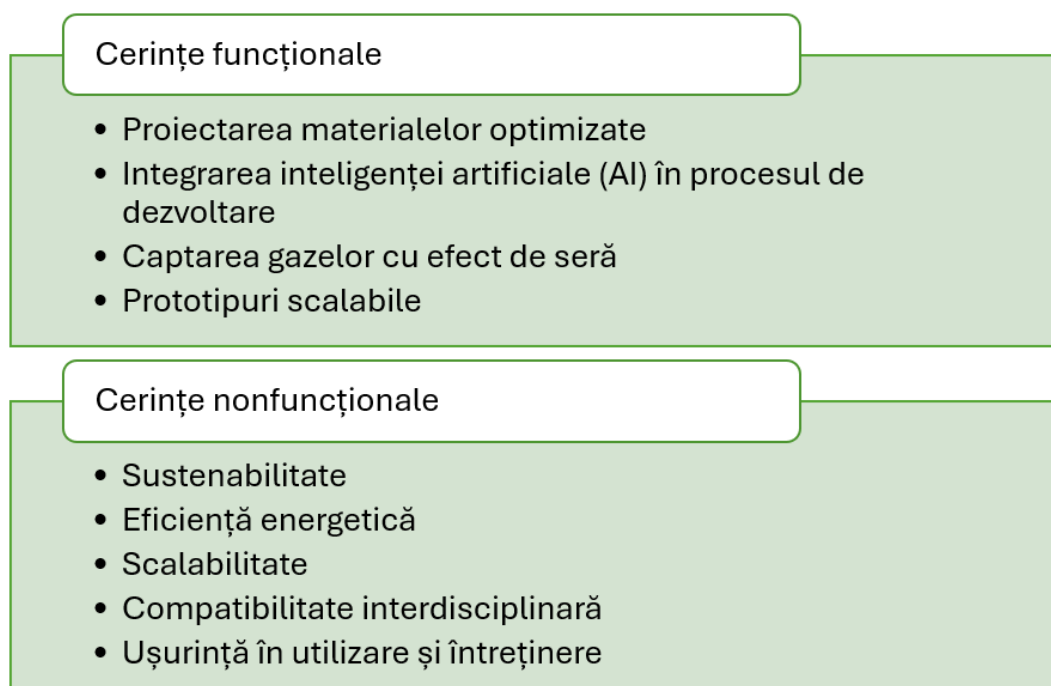


Figura 4: Cerințele funcționale și non-funcționale pentru platforma REPLACER.

### 6.1 Cerințe funcționale

#### 1. Proiectarea materialelor optimizate

- Dezvoltarea structurilor HLM eficiente pentru captarea gazelor cu efect de seră.
- Integrarea consorțiilor microbiene sintetice în materialele poroase dezvoltate.

#### 2. Integrarea inteligenței artificiale (AI) în procesul de dezvoltare

- Modelarea și simularea comportamentului biofilmului folosind algoritmi de învățare automată.
- Optimizarea parametrilor pentru formarea și funcționarea HLM prin algoritmi de învățare iterativă.

### 3. Captarea gazelor cu efect de seră

- Proiectarea de soluții energetice eficiente pentru captarea CO<sub>2</sub> și CH<sub>4</sub>.
- Minimizarea pierderilor și maximizarea eficienței proceselor de conversie microbiană.

### 4. Prototipuri scalabile

- Construirea prototipurilor de bioreactoare care să integreze materialele hibride dezvoltate.
- Asigurarea unei funcționări stabile și eficiente la scară industrială.

## 6.2 Cerințe nonfuncționale

### 1. Sustenabilitate

- Utilizarea plasticului reciclat în dezvoltarea materialelor poroase.
- Minimizarea impactului ecologic prin optimizarea proceselor de producție.

### 2. Eficiență energetică

- Reducerea consumului energetic prin integrarea tehnologiilor eficiente.
- Optimizarea proceselor de captare și conversie pentru reducerea costurilor operaționale.

### 3. Scalabilitate

- Asigurarea posibilității de extindere a platformei la nivel industrial.
- Dezvoltarea modulară a bioreactoarelor pentru a permite scalarea cu ușurință.

### 4. Compatibilitate interdisciplinară

- Integrarea componentelor hardware și software pentru a susține colaborarea între diferite domenii.
- Asigurarea interoperabilității între platforma digitală și sistemele fizice.

### 5. Ușurință în utilizare și întreținere

- Oferirea unei interfețe intuitive pentru utilizatorii industriali.
- Instrumente avansate pentru monitorizare și diagnosticare.

## 6.3 Impactul așteptat al platformei

Platforma **REPLACER**, bazată pe integrarea tehnologiilor AI, a biotehnologiei avansate și a materialelor sustenabile, va permite captarea eficientă a gazelor cu efect de seră și conversia acestora în biomasa utilizabilă. Această platformă va contribui semnificativ la reducerea emisiilor de CO<sub>2</sub> și CH<sub>4</sub>, sprijinind astfel inițiativele globale de combatere a schimbărilor climatice. Scalabilitatea și eficiența energetică a soluțiilor propuse vor permite aplicarea lor pe scară largă, având un impact economic și ecologic semnificativ. De asemenea, utilizarea plasticului reciclat în dezvoltarea HLM-urilor promovează economia circulară și reduce dependența de materiale virgine.

## 7 Strategia de agregare pentru algoritmul de învățare automată federată

Proiectul **REPLACER** a obținut rezultate semnificative în primul an, concentrându-se pe dezvoltarea unei metodologii eficiente pentru integrarea materialelor hibride vii (*Hybrid Living Materials* - HLM) și aplicarea acestora în cadrul platformei hibride *Design-Build-Test-Learn* (DBTL). În cadrul activităților desfășurate, o contribuție importantă a fost dezvoltarea unei strategii inovatoare de agregare pentru învățarea federată (*Federated Learning* - FL), care facilitează optimizarea algoritmilor ML utilizați în platformă.

### 7.1 Strategia de agregare pentru învățarea federată

Metodologia propusă introduce trei metrici fundamentale pentru calcularea unui *Model Impact Score* (MImp), care determină greutatea fiecărui model local în procesul de agregare. Aceste metrici includ:

- **Calitatea modelului (MQ):** determinată direct de calitatea datelor de antrenament (*Data Quality* - DQ). Această metrică utilizează valori precum numărul de date lipsă (*NaN/null*), forma datasetului și cantitatea de informații disponibile, toate convertite într-un procent intuitiv [1].
- **Importanța modelului (MI):** o măsură relativă care compară numărul de observații din datele utilizate pentru antrenament cu acuratețea obținută. Relația este exprimată prin:

$$MI_a = \frac{\text{row\_cnt}_a}{\text{total\_rows}} \cdot Acc_a, \quad Acc_a \in [0, 1]$$

unde  $Acc_a$  reprezintă acuratețea relativă a modelului  $a$ , iar  $\text{row\_cnt}_a$  este numărul de rânduri din datele sursă [2].

- **Relevanța modelului (MR):** o metrică temporală care acordă o greutate mai mare modelelor recente. Relevanța este definită printr-un interval de actualizare (*Update Interval* - UI) și un timp scurs  $\Delta t$ :

$$MR = 1 - \frac{\Delta t}{UI}, \quad \Delta t \leq UI$$

sau prin funcții avansate, precum sigmoid modificat:

$$MR = -\frac{1}{1 + e^{-\Delta t + \frac{UI}{2}}} + 1$$

care permite o scădere lentă inițială, urmată de o diminuare rapidă [1].

## 7.2 Impactul calculului MImp asupra agregării

Valoarea finală a *Model Impact Score* poate fi calculată prin media celor trei metrici sau prin produsul acestora:

$$MImp_{avg} = \frac{MQ + MR + MI}{3}, \quad MImp_{mul} = MQ \cdot MR \cdot MI$$

Metoda de calcul este aleasă în funcție de aplicație: media compensează valorile extreme, în timp ce produsul penalizează drastic abaterile. Această flexibilitate permite adaptarea la diverse scenarii, inclusiv date eterogene și condiții de calitate variabilă [2].

## 7.3 Rezultate experimentale

Strategia a fost validată folosind un set de date de mediu, cu citiri zilnice agregate timp de 10 ani. Modelele antrenate cu această metodă au demonstrat o îmbunătățire a acurateții globale față de algoritmi standard, precum *FedAvg* și *FedProx*. Testele au arătat o scădere cu 98,85% a volumului de date transmis, datorită compresiei eficiente a modelelor. Modelul global generat a obținut o eroare medie absolută (MAE) de 0.46, comparabilă cu cea a metodelor centralizate [2].

## 7.4 Progres în integrarea materialelor hibride vii

Pe lângă contribuțiile în domeniul ML, echipa proiectului a progresat în proiectarea și testarea materialelor hibride. Structurile re-PET utilizate ca suport pentru biofilme au fost optimizate pentru a asigura captarea eficientă a gazelor CO<sub>2</sub> și CH<sub>4</sub>. Platforma DBTL a permis iterarea rapidă a parametrilor și ajustarea designului pentru a maximiza eficiența procesului.

## 7.5 Viitorul proiectului

În continuare, eforturile se vor concentra pe integrarea acestor metode în prototipurile bioreactoarelor și extinderea aplicabilității platformei la scenarii complexe, precum agricultura de precizie și tratarea apelor uzate. Validarea tehnică și extinderea la nivel industrial vor constitui pașii următori, consolidând impactul proiectului **REPLACER**.

## 8 Rolul HOLISUN în cadrul proiectului

În cadrul proiectului REPLACER, HOLISUN joacă un rol esențial, contribuind prin expertiza sa în integrarea inteligenței artificiale și a tehnologiilor informatice în procesele de dezvoltare și scalare a materialelor hibride vii (*Hybrid Living Materials* - HLM). Rolul HOLISUN poate fi definit prin două direcții principale: dezvoltarea modelelor computaționale și utilizarea instrumentelor de inteligență artificială (AI) pentru optimizarea performanței HLM și integrarea acestora în prototipuri scalabile, eficiente din punct de vedere energetic.

### 8.1 Contribuția HOLISUN la platforma Design-Build-Test-Learn (DBTL)

HOLISUN contribuie la dezvoltarea platformei *Design-Build-Test-Learn* (DBTL) prin implementarea algoritmilor de *machine learning* și modelelor hibride pentru predicția și optimizarea creșterii biofilmului în structurile poroase re-PET. Prin utilizarea tehnologiilor avansate de inteligență artificială, HOLISUN sprijină:

- Dezvoltarea modelelor predictive care integrează date experimentale și simulări computaționale pentru a maximiza producția de biomateriale și rata de creștere a biofilmului;
- Optimizarea transferului de masă, căldură și lumină în structurile membranare utilizate în procesul de producție a HLM;
- Analiza spațio-temporală a comportamentului biofilmului pentru îmbunătățirea designului materialelor și a prototipurilor de bioreactoare.

### 8.2 Integrarea în WP4: Modelare și predicție folosind AI

HOLISUN este liderul pachetului de lucru WP4, care se axează pe utilizarea inteligenței artificiale pentru a învăța și prezice performanțele HLM. Acest pachet de lucru integrează:

- Modele bazate pe date experimentale pentru a estima creșterea și dezvoltarea biofilmului;
- Algoritmi de învățare automată pentru predicția și controlul parametrilor cheie ai HLM în timp real;
- Soluții software care permit integrarea AI cu alte componente ale platformei REPLACER, facilitând o buclă completă și iterativă DBTL.

### 8.3 Impactul HOLISUN asupra scalabilității și sustenabilității platformei

HOLISUN colaborează cu ceilalți parteneri pentru a asigura scalabilitatea și sustenabilitatea HLM dezvoltate în cadrul proiectului. Prin expertiza sa în dezvoltarea de soluții informatice avansate, HOLISUN:

- Sprijină prototiparea și validarea bioreactoarelor capabile să producă 1 kg de biomasă zilnic;
- Optimizează procesele de colectare, procesare și analiză a datelor pentru a îmbunătăți eficiența proceselor și a reduce costurile;
- Contribuie la aplicarea evaluărilor de mediu și economice pentru soluțiile dezvoltate, integrând principiile sustenabilității și ale economiei circulare.

### 8.4 Rezultate așteptate

Participarea HOLISUN în proiectul REPLACER va contribui la:

- Dezvoltarea unei platforme DBTL robuste, integrate cu tehnologii AI de ultimă generație;
- Crearea de modele computaționale hibride care să asigure performanțe optime ale HLM și scalabilitate industrială;
- Producerea de rezultate inovatoare care să sprijine obiectivele UE legate de reducerea emisiilor de gaze cu efect de seră și de dezvoltarea sustenabilă.

## 9 Extras din planul de riscuri

În Tabelul 1, sunt prezentate principalele riscuri identificate în cadrul proiectului REPLACER, care se concentrează pe dezvoltarea materialelor hibride vii (HLM), integrarea biofilmurilor și utilizarea inteligenței artificiale (AI). Fiecare risc este evaluat pe baza probabilității, impactului și valorii totale a riscului, iar măsurile propuse pentru mitigare sunt detaliate.

Tabela 1: Tabel de analiză a riscurilor și metode de mitigare pentru proiectul REPLACER.

Risc	Probabilitate	Impact	Valoare	Mitigare
Ineficiența biofilmului în captarea gazelor CO <sub>2</sub> și CH <sub>4</sub>	3	5	15	Optimizarea iterativă a consorțiilor microbiene utilizând ciclul DBTL, ajustarea parametrilor de mediu
Degradarea prematură a materialelor hibride vii (HLM)	2	4	8	Identificarea unor polimeri mai rezistenți la uzură și optimizarea condițiilor de mediu
Instabilitatea consorțiilor microbiene în biofilm	3	4	12	Monitorizarea continuă a interacțiunilor microbiene, selecția de consorții alternative, implementarea ajustărilor rapide
Date experimentale insuficiente pentru antrenarea algoritmilor ML	3	5	15	Utilizarea simulărilor pentru generarea de date suplimentare, aplicarea tehnicilor de augmentare a datelor
Model ML inadecvat sau ineficient	2	5	10	Generarea mai multor modele și utilizarea unui sistem automat de selecție bazat pe performanță
Eșec în integrarea biofilmului în structurile re-PET	2	4	8	Testarea prototipurilor cu structuri variate și ajustarea tehnicilor de integrare
Performanță scăzută a prototipurilor bioreactoarelor	2	5	10	Implementarea unui proces iterativ de testare și optimizare, introducerea de tehnologii de monitorizare avansată
Întârzieri în dezvoltarea software-ului AI	3	4	12	Prioritizarea cerințelor critice, alocarea suplimentară de resurse de dezvoltare
Defecțiuni hardware în bioreactoare	2	5	10	Introducerea redundanței hardware, implementarea de procese de mentenanță preventivă
Coruperea sau pierderea datelor critice experimentale	1	5	5	Backup redundant și criptare, implementarea unui sistem de recuperare automată

## 10 Rezultatele proiectului

### 10.1 Livrabile

În perioada raportată am furnizat livrabile din tabelul 2 și am început lucrul intens asupra celorlalte livrabile.

Tabela 2: Tabel cu livrabile și statusul acestora.

Nr. livrabil	Termen	Livrabil	Status livrabil
D4.2	M24	Algoritmi hibridi de învățare automată pentru HLM	În lucru

### 10.2 Articole științifice

În perioada de raportare s-a lucrat intens la mai multe articole științifice, unele dintre acestea au fost prezentate la conferințe, iar unele urmează să fie prezentate/publicate.

În Tabelul sunt listate toate articolele din cadrul proiectului:

Tabela 3: Lista de articole

Articolul	Detalii Conferința / Jurnal	Link-ul pentru Acces
Rudolf Erdei, Daniela Delinschi, Iulia Bărbăian, Oliviu Matei, " <b>Aggregation Strategy for Federated Machine Learning Algorithm</b> "	19th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2024)	Link articol
Andreea Tatar, Andrei Fat, Adrian Petrovan, Oliviu Matei, " <b>A new vision of social behavior on genetic algorithm performance</b> "	19th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2024)	Link articol

## 11 Diseminare și exploatare

### 11.1 Activități de diseminare

Proiectul a fost diseminat în următoarele moduri:

- pe pagina web: <https://research.holisun.com/ro/proiecte/materials/replacer-ro>, având un număr de 180 de vizitatori lunari
- pe pagina web a proiectului: <https://home.uni-leipzig.de/replacer/en/>, având un număr de 21 de vizitatori lunari
- pe contul de LinkedIn: <https://www.linkedin.com/company/holisun>, cu 400 de adepți
- pe pagina de Facebook: <https://www.facebook.com/Holisun.IT/>, având 1881 de urmăritori

Au fost desfășurate o serie de activități de diseminare în cadrul unor evenimente de afaceri, expoziții și evenimente de brokeraj sau networking, listate în Tabelul 4.

Tabela 4: Lista de activități de diseminare

Nume	Data	Link	Participanți	Rezultate
Cluj Innovation Days 2024	21.03.2024-22.03.2024	<a href="https://clujinnovationdays.com/">https://clujinnovationdays.com/</a>	Oliviu Matei	Prezentare <i>REPLACER</i>
BOOSTing European collaboration among Industry 4.0 stakeholders	16.04.2024-26.04.2024	<a href="https://boosting-european-collaboration-among-industry.b2match.io/">https://boosting-european-collaboration-among-industry.b2match.io/</a>	Rudolf Erdei	Prezentare <i>REPLACER</i>
Clean Energy Transition Partnership	12.09.2024	<a href="https://www.b2match.com/e/clean-energy-transition-partnership-2024">https://www.b2match.com/e/clean-energy-transition-partnership-2024</a>	Rudolf Erdei Daniela Delinschi	Prezentare <i>REPLACER</i>



## 12 Concluzii

Primul an al proiectului **REPLACER** a fost dedicat fundamentării conceptuale a unei platforme inovatoare care vizează transformarea captării și valorificării gazelor cu efect de seră ( $\text{CO}_2$  și  $\text{CH}_4$ ). Activitățile desfășurate până în prezent s-au concentrat pe analiza detaliată a stadiului actual al domeniului, identificarea provocărilor și definirea cerințelor tehnice pentru dezvoltarea materialelor hibride vii (HLM) și prototiparea bioreactoarelor.

Un accent deosebit a fost pus pe conturarea metodologiei *Design-Build-Test-Learn* (DBTL), care oferă un cadru iterativ pentru integrarea experimentelor practice cu modelarea computațională. În acest context, echipa proiectului a stabilit parametri critici pentru integrarea biofilmurilor microbiene în structurile poroase re-PET utilizate pentru captarea gazelor cu efect de seră, contribuind la elaborarea planului de arhitectură a platformei hibride. Această arhitectură va integra componente hardware și software menite să optimizeze procesele, să asigure scalabilitatea și să faciliteze tranziția către aplicabilitatea industrială.

În următorul an, proiectul va avansa către o etapă practică mai complexă, ce va include finalizarea arhitecturii platformei și integrarea datelor experimentale obținute. Vor începe lucrările dedicate algoritmilor de machine learning, care vor fi dezvoltați pentru optimizarea creșterii biofilmurilor, captarea gazelor și procesele de conversie microbiană. De asemenea, se vor construi și valida prototipurile bioreactoarelor, care vor încorpora materialele HLM dezvoltate și tehnologiile avansate de monitorizare, contribuind la demonstrarea performanțelor sistemului în condiții reale.

Activitățile de diseminare inițiate în primul an au pus bazele promovării proiectului la nivel internațional. A fost creat și întreținut un website oficial al proiectului, care furnizează informații actualizate despre obiectivele și progresul activităților. În plan științific, rezultatele inițiale ale proiectului au fost prezentate în două articole la conferințe internaționale.

Proiectul **REPLACER** își continuă implementarea conform planului, cu o bază solidă pentru activitățile viitoare. Platforma dezvoltată promite să contribuie semnificativ la crearea de soluții sustenabile pentru captarea și valorificarea gazelor cu efect de seră, reducând emisiile globale de  $\text{CO}_2$  și  $\text{CH}_4$ . Totodată, inițiativa promovează economia circulară și sprijină tranziția către tehnologii mai curate și mai eficiente, aliniindu-se obiectivelor globale pentru combaterea schimbărilor climatice și dezvoltare durabilă.

## Referințe

- [1] Delinschi, D., Erdei, R., Matei, O.: Ontology driven high performance messaging system for distributed software platforms. In: 2022 IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR). pp. 1–6. IEEE (2022)
- [2] Erdei, R., Delinschi, D., Baraian, I., Matei, O.: Aggregation strategy for federated machine learning algorithm. In: International Conference on Soft Computing Models in Industrial and Environmental Applications. pp. 157–167. Springer (2025)
- [3] Flemming, H.C., Wingender, J., Szewzyk, U., Steinberg, P., Rice, S.A., Kjelleberg, S.: Biofilms: An emergent form of bacterial life. *Nature Reviews Microbiology* **14**(9), 563–575 (2016)
- [4] Karimi, M., Karig, D.K., Kumar, A., Ardekani, A.M.: Machine learning for biofilm formation and control. *Current Opinion in Microbiology* **57**, 24–31 (2020)
- [5] LeCun, Y., Bengio, Y., Hinton, G.: Deep learning. *Nature* **521**(7553), 436–444 (2015)
- [6] Stevens, D.R., Smith, C.J., Douglas, T.: Artificial intelligence in biofilm research: Opportunities and challenges. *Biofilm Journal* **3**, 100–112 (2021)
- [7] Stewart, P.S., Costerton, J.W.: Mechanisms of biofilm resistance to antimicrobial agents. *Nature Reviews Microbiology* **10**(6), 377–390 (2012)

