

Contract nr.1 din 01/03/2024, etapa 2 - GenDeg

RAPORT ȘTIINȚIFIC ȘI TEHNIC 2025

Referință 7767/ 24.11.2025

Manager de proiect: ***Laura Andreica***

Istoricul versiunilor

Versiune	Autor	Modificări
0.1	Laura Andreica	Versiunea inițială
0.5	Laura Andreica	Versiunea intermediară
1.0	Laura Andreica	Versiunea finală

Cuprins

1	Introducere	4
2	Despre proiectul GenDeg	4
3	Activități planificate	5
4	Activități efectuate	6
4.1	Devieri de la planificare	6
5	Algoritm hibrid de detecție și mitigare a efectelor degradării modelelor de învățare automată	6
5.1	Arhitectura și Etapele Algoritmului	6
5.1.1	Pasul 1: Segmentarea Datelor prin Clusterizare	6
5.1.2	Pasul 2: Antrenarea Modelelor Parțiale (Experți Locali)	6
5.1.3	Pasul 3: Predicția Agregată Ponderată	8
5.1.4	Pasul 4: Detecția Drift-ului și Adaptarea Ponderilor cu EWMA	8
5.2	Avantajele Abordării Hibride	9
5.3	Rezultate preliminare	9
5.3.1	Metodologia de Testare și Setul de Date	9
5.3.2	Performanța Modelului de Referință (Baseline)	9
5.3.3	Performanța Algoritmului Hibrid GenDeg	9
5.3.4	Analiză Comparativă și Discuții	12
6	Rolul HOLISUN în cadrul proiectului	12
6.1	Contribuții tehnice	12
6.2	Impact asupra produselor și serviciilor HOLISUN	12
6.3	Abordare interdisciplinară	12
7	Extras din planul de riscuri	13
8	Rezultatele proiectului	14
8.1	Livrabile	14
8.2	Articole științifice	14
9	Diseminare și exploatare	15
9.1	Activități de diseminare	15
10	Concluzii	16

Parteneri



(a) AI Investments (Polonia) Coordonator



(b) InbestMe (Spania)



(c) Holisun SRL (Romania)

Figura 1: Partenerii proiectului *GenDeg*

1 Introducere

GenDeg își propune să inoveze evaluarea modelelor de prognoză bazate pe serii temporale prin monitorizarea generalizărilor și a degradării acestora în timp. Proiectul va dezvolta metode avansate care să funcționeze cu o varietate de algoritmi de inteligență artificială (AI) și să fie aplicabile în diverse domenii. Aceste progrese vor fi integrate în serviciile oferite de AI Investments, inbestMe și Holisun, adăugând caracteristici noi și inovatoare.

Soluțiile rezultate din proiect GenDeg vor avea un impact semnificativ în domeniul financiar și dincolo de acesta, utilizând cele mai recente progrese în învățarea automată (ML) și AI pentru a revoluționa procesele de investiții. Funcționalități precum selecția strategiilor viitoare optime (rezultate out-of-sample) și monitorizarea degradării modelelor (cum ar fi pierderea progresivă a "alphas") vor remodela industria investițiilor. Proiectul își propune, de asemenea, să demonstreze aplicabilitatea metodelor dezvoltate în alte sectoare prin intermediul Holisun care va folosi modele și rezultatele proiectului pentru îmbunătățirea aplicației de mentenanță predictivă, îmbunătățind astfel serviciile oferite de toți cei trei parteneri din consorțiu.

Prezentul raport oferă o imagine de ansamblu asupra cadrului operațional și a designului metodologiilor din cadrul proiectului GenDeg. Acesta subliniază contribuția proiectului la crearea unor soluții integrate pentru evaluarea și optimizarea modelelor de prognoză, oferind funcționalități inovatoare care pot aduce beneficii tangibile în domeniul financiar și în alte industrii.

2 Despre proiectul GenDeg

Proiectul **GenDeg** își propune să inoveze evaluarea modelelor de prognoză bazate pe serii temporale prin monitorizarea generalizabilității și degradării acestora în timp. Acest proiect vizează dezvoltarea unor algoritmi unici pentru identificarea degradării performanței modelelor predictive bazate pe inteligență artificială (AI) și evaluarea capacității acestora de a generaliza rezultatele pe perioade viitoare. Metodele rezultate vor putea fi aplicate într-o gamă largă de aplicații AI și vor contribui la îmbunătățirea produselor și serviciilor oferite de AI Investments, inbestMe și Holisun.

Figura 2 prezintă arhitectura logică de înalt nivel a proiectului **GenDeg**.

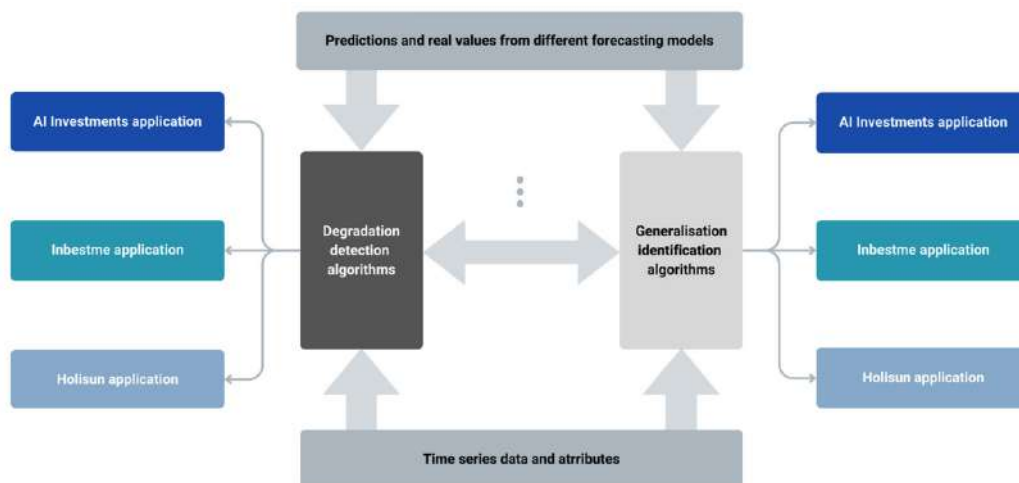


Figura 2: Arhitectura logică de înalt nivel a proiectului GenDeg

Aceasta evidențiază fluxurile de informații și componentele cheie implicate în procesele de detectare a degradării și identificare a generalizabilității modelelor predictive. Sistemul propus include următoarele componente majore:

- **Algoritmi de detectare a degradării:** Responsabili pentru identificarea scăderii performanței modelelor predictive în timp, utilizând date din serii temporale și valorile reale generate.
- **Algoritmi de identificare a generalizabilității:** Proiectați pentru a selecta modelele care au capacitatea de a oferi performanțe optime pentru date viitoare, maximizând acuratețea predicțiilor.

4 Activități efectuate

În perioada Ianuarie - Decembrie 2025 au fost efectuate următoarele activități:

- Cercetare literaturii de specialitate cu privire la conceptele de Model Drift și Model Degradation;
- Întâlniri bi-săptămânale de progres.

4.1 Devieri de la planificare

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

5 Algoritm hibrid de detecție și mitigare a efectelor degradării modelelor de învățare automată

Abordarea propusă în cadrul proiectului **GenDeg** se bazează pe un algoritm hibrid, conceput pentru a oferi un mecanism robust și adaptiv de combatere a degradării performanței modelelor (*model degradation*) și a derivei de date (*data drift*). În loc să utilizeze un singur model monolitic, care devine vulnerabil la schimbările în distribuția datelor, algoritmul nostru segmentează spațiul problemei în regiuni distincte, antrenează modele specializate (parțiale) pentru fiecare regiune și ajustează dinamic contribuția acestora la predicția finală. Acest algoritm reprezintă o noutate absolută în domeniu, rezultatele inițiale în domeniul predicției financiare fiind cel puțin promițătoare.

Mecanismul algoritmului este inspirat de principiul "divide et impera", permițând sistemului să izoleze schimbările de distribuție la nivel local și să se adapteze rapid, fără a necesita o reantrenare costisitoare a întregului sistem. Componenta centrală a acestei adaptări este utilizarea mediei mobile ponderate exponențial (Exponentially Weighted Moving Average - EWMA) pentru a actualiza în timp real relevanța fiecărui model parțial, pe baza performanței sale recente.

5.1 Arhitectura și Etapele Algoritmului

Algoritmul poate fi descompus în patru etape principale, care formează un ciclu continuu de predicție, evaluare și adaptare. Arhitectura conceptuală este prezentată în Figura 4.

5.1.1 Pasul 1: Segmentarea Datelor prin Clusterizare

Prima etapă, realizată în faza de antrenare inițială, constă în partiționarea setului de date istoric în k clustere distincte. Scopul este de a identifica sub-populații sau "regimuri" de operare în date, unde fiecare cluster reprezintă un model de comportament specific.

- **Metodă:** Se pot utiliza algoritmi de clusterizare nesupervizată, precum K-Means, DBSCAN sau algoritmi bazați pe modele de mixtură Gaussiană (GMM). Alegerea algoritmului depinde de structura datelor. Pentru implementare, am ales algoritmul K-Means, urmând ca în etapa de optimizare să testăm și alte variante.
- **Rezultat:** Setul de date de antrenament D este împărțit în k subseturi disjuncte: $D = \{D_1, D_2, \dots, D_k\}$. Fiecare subset D_i conține date care sunt similare conform metricei de distanță utilizate.

5.1.2 Pasul 2: Antrenarea Modelelor Parțiale (Experți Locali)

Pentru fiecare cluster D_i identificat, se antrenează un model de învățare automată dedicat, M_i . Aceste modele, denumite "parțiale" sau "experți locali", devin specializate în a face predicții pentru tiparul de date specific clusterului respectiv.

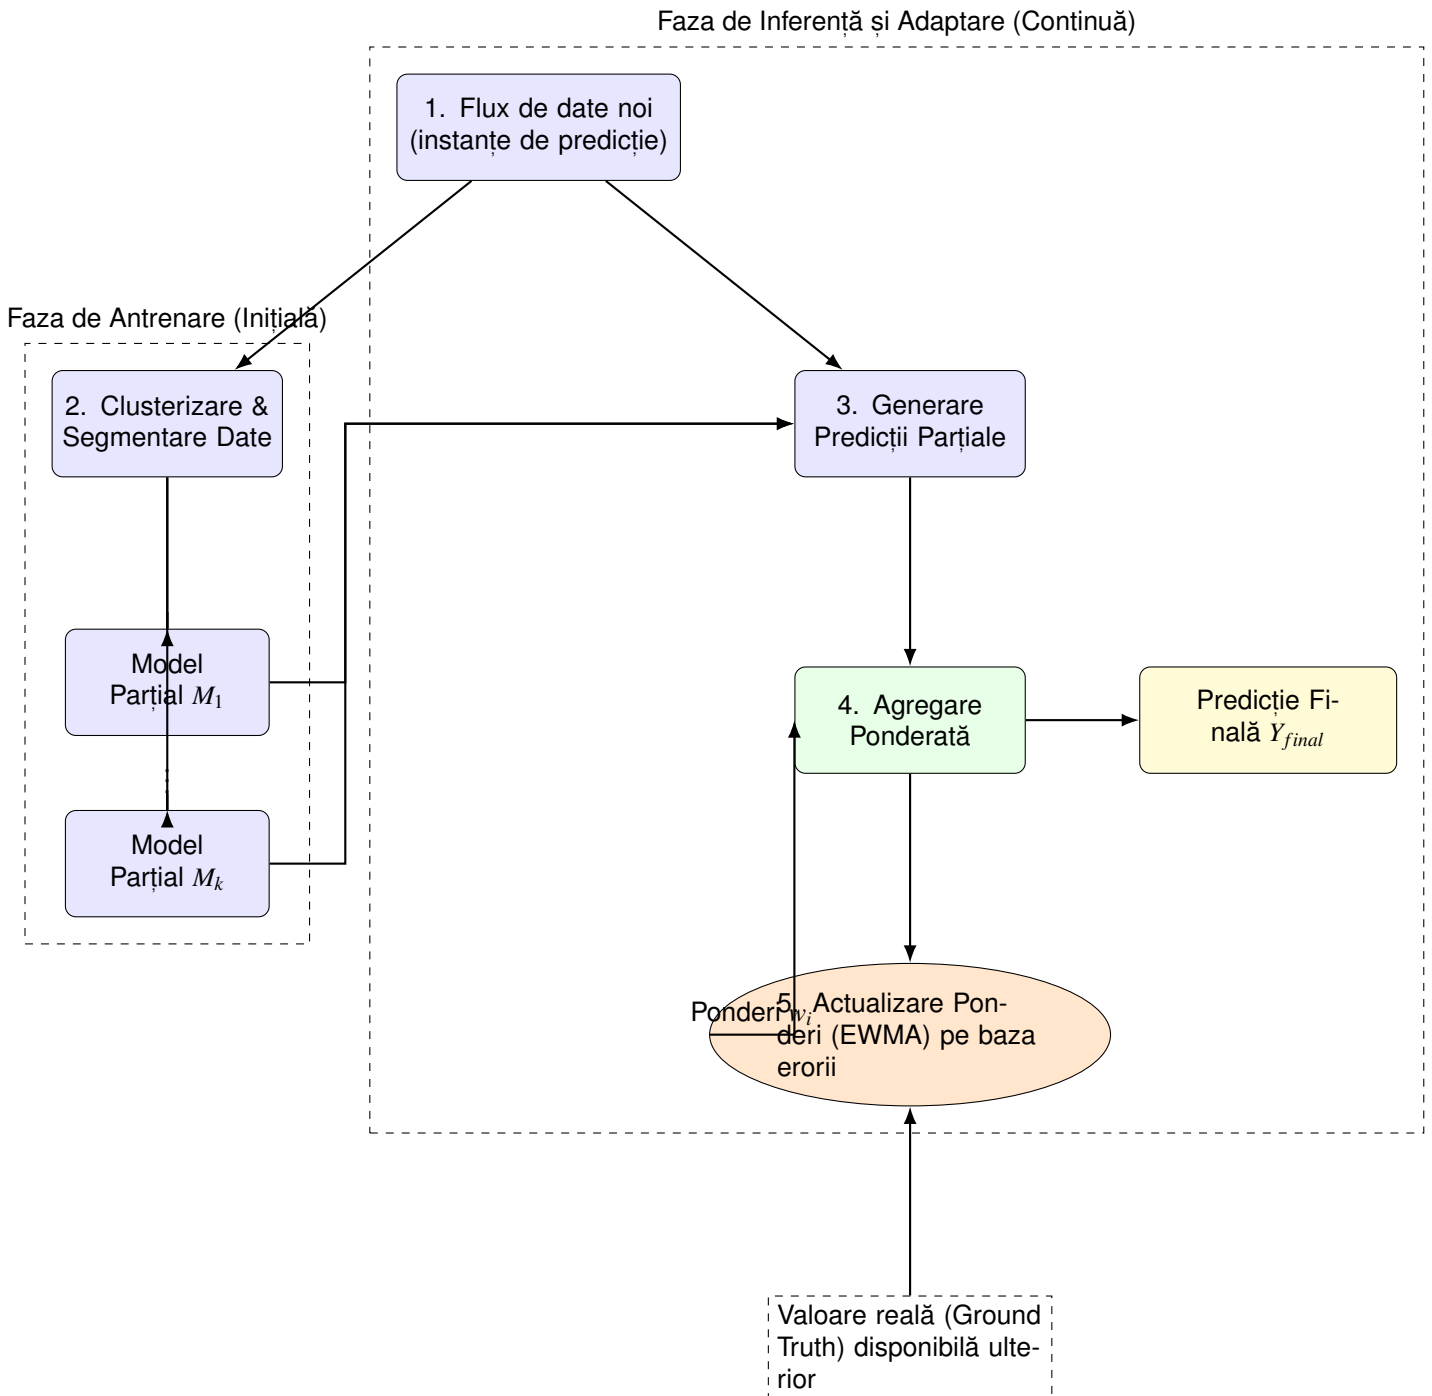


Figura 4: Diagrama conceptuală a algoritmului hibrid de detecție și mitigare a drift-ului.

- **Flexibilitate:** Modelele M_i pot fi de orice tip (ex. regresie liniară, rețele neuronale, arbori de decizie), în funcție de complexitatea datelor din clusterul D_i .
- **Avantaj:** Această specializare face sistemul mai robust. O schimbare în distribuția datelor care afectează un singur regim (cluster) va degrada performanța unui singur model parțial, nu a întregului sistem.

5.1.3 Pasul 3: Predicția Agregată Ponderată

În faza de operare (inferență), pentru o nouă instanță de date x_{new} , predicția finală nu este generată de un singur model. În schimb, se calculează o medie ponderată a predicțiilor tuturor modelelor parțiale.

1. Fiecare model parțial M_i generează o predicție $P_i = M_i(x_{new})$.
2. Predicția finală, Y_{final} , este calculată ca suma ponderată a acestor predicții:

$$Y_{final} = \sum_{i=1}^k w_i \cdot P_i \quad (1)$$

unde w_i este ponderea asociată modelului M_i , iar $\sum_{i=1}^k w_i = 1$. Inițial, ponderile pot fi uniforme ($w_i = 1/k$) sau pot fi proporționale cu dimensiunea clusterului corespunzător sau, în varianta adoptată în cadrul proiectului, cu acuratețea bazată pe istoria recentă.

5.1.4 Pasul 4: Detecția Drift-ului și Adaptarea Ponderilor cu EWMA

Aceasta este etapa cheie pentru detecția și mitigarea degradării. Atunci când valoarea reală (ground truth) Y_{true} devine disponibilă pentru o predicție anterioară, sistemul își evaluează performanța și își ajustează ponderile.

1. **Calculul Erorii Individuale:** Pentru fiecare model parțial M_i , se calculează eroarea sa de predicție, $E_i = |Y_{true} - P_i|$ (sau altă metrică, precum eroarea pătratică).
2. **Actualizarea Ponderilor cu EWMA:** Ponderile w_i sunt actualizate folosind o formulă EWMA care prioritizează performanța recentă. În loc să ponderăm direct eroarea, vom pondera o măsură a "performanței", $Perf_i$, care este invers proporțională cu eroarea:

$$Perf_i = \frac{1}{E_i + \varepsilon} \quad (2)$$

unde ε este o constantă mică pentru a evita împărțirea la zero.

Noua pondere ne-normalizată, $w'_{i,t}$, pentru fiecare model este actualizată astfel:

$$w'_{i,t} = \alpha \cdot Perf_{i,t} + (1 - \alpha) \cdot w'_{i,t-1} \quad (3)$$

unde:

- $w'_{i,t-1}$ este ponderea ne-normalizată de la pasul anterior.
- $Perf_{i,t}$ este performanța curentă a modelului M_i .
- $\alpha \in [0, 1]$ este factorul de netezire (smoothing factor). O valoare mare a lui α face ca sistemul să reacționeze rapid la schimbările recente, în timp ce o valoare mică îl face mai stabil și mai dependent de istoricul pe termen lung.

3. **Normalizarea Ponderilor:** Pentru a se asigura că suma ponderilor este 1, acestea sunt normalizate:

$$w_{i,t} = \frac{w'_{i,t}}{\sum_{j=1}^k w'_{j,t}} \quad (4)$$

Acest proces continuu face ca modelele parțiale care performează constant bine pe datele recente să primească ponderi mai mari, contribuind mai mult la predicția finală. În esență, sistemul "învață" care dintre experții săi locali sunt cei mai de încredere pentru distribuția curentă a datelor, mitigând astfel efectele model drift.

5.2 Avantajele Abordării Hibride

- **Adaptabilitate Ridicată:** Sistemul se adaptează la schimbări fără a necesita reentrenări complete, care sunt costisitoare din punct de vedere computațional și al timpului.
- **Robustețe:** Erorile localizate într-o anumită distribuție de date afectează doar o parte a sistemului, permițând celorlalte modele parțiale să mențină performanța globală.
- **Interpretabilitate:** Evoluția ponderilor w_i în timp oferă o perspectivă valoroasă asupra modului în care se schimbă distribuția datelor. O creștere bruscă a ponderii unui anumit model indică faptul că tiparul de date corespunzător a devenit dominant.
- **Eficiență:** Actualizarea ponderilor este o operație mult mai rapidă și mai eficientă decât reentrenarea unui model complex de la zero.

5.3 Rezultate preliminare

Faza de testare preliminară a fost esențială pentru a valida eficacitatea algoritmului hibrid propus. Pentru a cuantifica îmbunătățirile aduse, am stabilit un model de referință (baseline) cu care să comparăm performanța. Această secțiune detaliază metodologia de testare, performanța modelului de referință și rezultatele obținute de algoritmul nostru.

5.3.1 Metodologia de Testare și Setul de Date

Testarea a fost realizată pe un set de date financiare de înaltă frecvență, specific perechii valutare **EUR/USD** pe un interval de timp de 15 minute (M15). Am ales acest set de date datorită lichidității sale ridicate și a utilizării intensive în literatura de specialitate, ceea ce facilitează compararea rezultatelor. Obiectivul modelului a fost de a clasifica direcția prețului (creștere sau scădere) în următoarea perioadă, o problemă de clasificare binară. Datele au fost împărțite cronologic, utilizând 80% pentru antrenare și 20% pentru testare (out-of-sample), pentru a simula un scenariu real de predicție.

5.3.2 Performanța Modelului de Referință (Baseline)

Modelul de referință este un model monolitic, antrenat pe întregul set de date de antrenament, folosind algoritmul **XGBoost**, recunoscut pentru performanța sa în probleme de clasificare tabulară. După optimizarea hiperparametrilor, modelul a atins o acuratețe de predicție de **53%** pe setul de testare.

Această valoare, deși aparent modestă, este considerată o performanță decentă în contextul piețelor financiare, care sunt caracterizate de un nivel ridicat de zgomot și eficiență. Un rezultat care depășește pragul aleatoriu de 50% este semnificativ și se aliniază cu valorile de top raportate în studii similare. Totuși, analiza performanței în timp a relevat principala slăbiciune a abordării monolitice: vulnerabilitatea la schimbările de regim de piață (ex. trecerea de la o piață în trend la una laterală), unde acuratețea sa a înregistrat scăderi bruște (degradare).

5.3.3 Performanța Algoritmului Hibrid GenDeg

În etapa următoare, am aplicat algoritmul nostru pe același set de date. Configurația inițială a inclus:

- **Clusterizare:** Am împărțit setul de date de antrenament în mai multe cluster folosind algoritmul K-Means, cu scopul de a izola regimuri de piață distincte (ex. trend ascendent volatil, piață laterală stabilă etc.).
- **Modele Parțiale:** Pentru fiecare cluster a fost antrenat un model XGBoost specializat.
- **Adaptare EWMA:** Am utilizat un factor de netezire $\alpha = 0.1$ pentru a asigura un echilibru între reactivitatea la performanța recentă și stabilitatea pe termen lung a ponderilor.

Algoritmul hibrid a fost testat pe mai multe dimensiuni de cluster și mai mulți pași de istoric, obținând o acuratețe agregată mult superioară pe setul de testare, așa cum se arată în Tabelul 1 și Figurile 5, 6 și 7.

Tabela 1: Tabel comparativ al rezultatelor obținute de algoritmul dezvoltat cu numărul optim de clustere

Pași istoric utilizat	Acuratețea maximă	Nr optim clustere
10	58,3%	5
7	61,5%	9
5	65,3%	7
3	72,3%	4
2	74,1%	8
1	77,4%	4

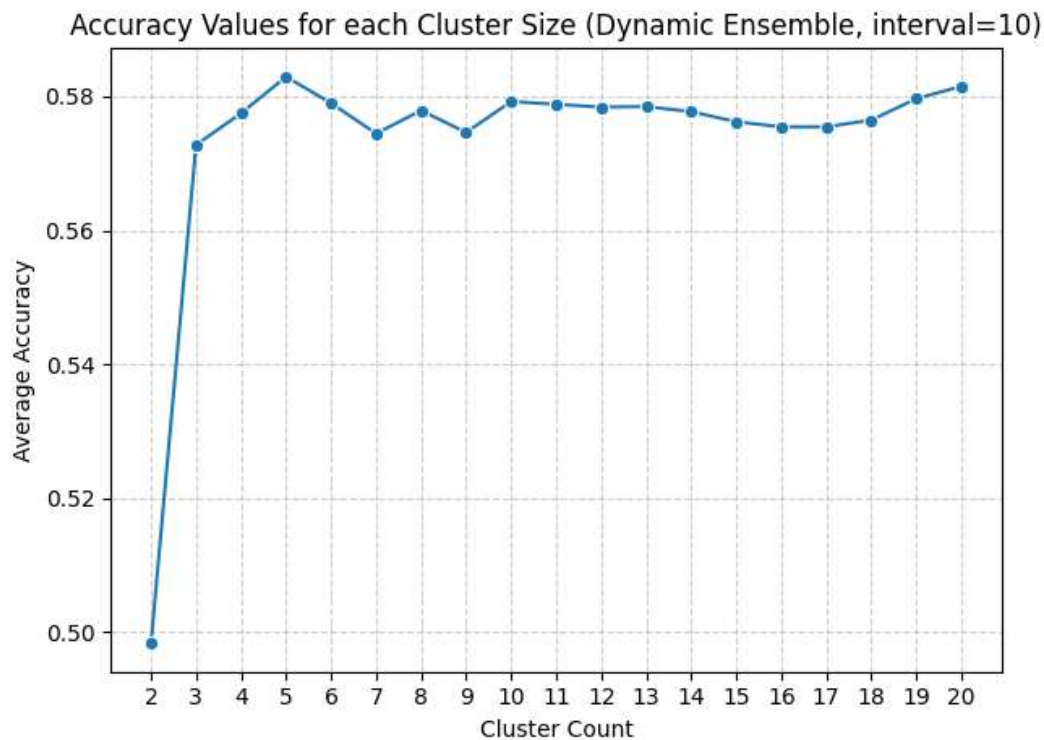


Figura 5: Graficul de acuratețe raportat la numărul de clustere pentru 10 pași de istoric




Figura 6: Graficul de acuratețe raportat la numărul de clustere pentru 5 pași de istoric

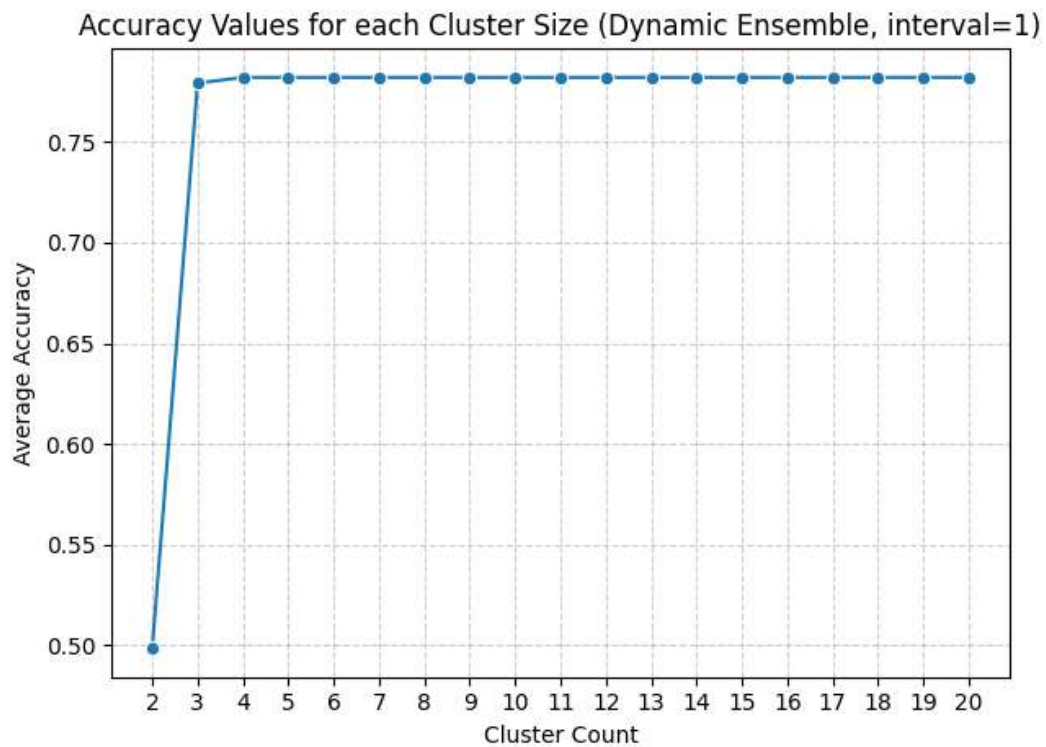


Figura 7: Graficul de acuratețe raportat la numărul de clustere pentru 1 pas de istoric

5.3.4 Analiză Comparativă și Discuții

Algoritmul demonstrează o capacitate superioară de adaptare, vizibilă din rezultatele superioare obținute. Mecanismul de ponderare dinamică (EWMA) ajustează rapid importanța modelelor parțiale, acordând o pondere mai mare "exper-tului" cel mai potrivit pentru noile condiții de piață. Acest lucru duce la o performanță mult mai stabilă și la o acuratețe minimă superioară, reducând riscul de pierderi în perioade de instabilitate.

Aceste rezultate preliminare sunt extrem de încurajatoare și validează ipoteza fundamentală a proiectului: o arhitec-tură bazată pe experți locali, gestionată de un mecanism de ponderare adaptiv, este superioară unui model monolitic în medii dinamice, predispușe la *model drift* și *degradation*.

În prezent, HOLISUN lucrează la un articol de jurnal în care se vor publica atât algoritmul cât și o analiză compa-rativă a rezultatelor obținute de acesta pe mai multe seturi de date.

6 Rolul HOLISUN în cadrul proiectului

Rolul HOLISUN în cadrul proiectului **GenDeg** este esențial, contribuind atât la dezvoltarea algoritmilor inovativi de identificare a degradării performanței modelelor predictive, cât și la integrarea acestora în soluții software scalabile. HOLISUN aduce expertiza sa în cercetarea și dezvoltarea inteligenței artificiale și în construirea de sisteme software performante, având ca obiectiv îmbunătățirea preciziei predicțiilor și extinderea durabilității modelelor AI.

6.1 Contribuții tehnice

HOLISUN se implică activ în:

- **Dezvoltarea algoritmilor de detecție a degradării modelelor predictive:** HOLISUN explorează metode avan-sate, inclusiv abordări bazate pe învățare automată și analize probabilistice, pentru a monitoriza și detecta scă-derile de performanță ale modelelor predictive în timp. Acest proces este esențial pentru menținerea eficienței și a fiabilității modelelor implementate.
- **Implementarea metodelor pentru generalizarea performanței modelelor:** HOLISUN lucrează la evaluarea capacității modelelor predictive de a performa pe seturi de date neobservate anterior. Prin aceasta, se urmărește reducerea riscurilor de suprapotrivire și creșterea aplicabilității modelelor pe perioade viitoare.
- **Integrarea rezultatelor în soluții software:** HOLISUN asigură integrarea algoritmilor dezvoltați în platforme software adaptabile, optimizând infrastructura de procesare a datelor și fluxurile de lucru existente.

6.2 Impact asupra produselor și serviciilor HOLISUN

Rezultatele proiectului vor fi incluse în portofoliul de soluții inteligente HOLISUN, oferind clienților:

- Sisteme software capabile să monitorizeze și să gestioneze performanța modelelor predictive în timp real.
- Reducerea costurilor de mentenanță prin detectarea timpurie a degradării și prin reantrenarea eficientă a mode-lor.
- Extinderea duratei de viață a soluțiilor software, prin reducerea necesității de intervenții manuale frecvente.

6.3 Abordare interdisciplinară

HOLISUN colaborează îndeaproape cu ceilalți parteneri din proiect, incluzând AI Investments și inbestMe, pentru a asigura o integrare fluidă a algoritmilor dezvoltați în domenii diverse precum finanțele și mentenanța predictivă. Această abordare interdisciplinară sporește potențialul de aplicare a rezultatelor proiectului, oferind soluții inovative adaptate mai multor sectoare.

Prin implicarea sa, HOLISUN consolidează capacitatea proiectului **GenDeg** de a livra soluții de ultimă generație care să adreseze provocările legate de degradarea modelelor predictive și să susțină adoptarea inteligenței artificiale în medii operaționale complexe.

7 Extras din planul de riscuri

În Tabelul 2 este reprezentat planul de riscuri ce ține de partea de implementare a proiectului **GenDeg**.

Tabela 2: Tabel de analiză a riscurilor și metode de mitigare pentru proiectul **GenDeg**.

Risc	Probabilitate	Impact	Valoare	Mitigare
Erori în identificarea degradării modelelor predictive	Mediu	Mare	12	Dezvoltarea unei funcționalități de monitorizare continuă pentru verificarea corectitudinii rezultatelor și a KPI-urilor algoritmilor.
Vulnerabilitatea algoritmilor GenDeg la amenințări externe	Mic	Mare	10	Implementarea unor configurații de disponibilitate ridicată, teste riguroase de asigurare a calității și verificări de securitate pentru fiecare versiune de software.
Preocupări privind confidențialitatea datelor în prognozele demografice	Mare	Mediu	15	Implementarea criptării robuste a datelor, a controlului accesului, tehnici de anonimizare și respectarea reglementărilor relevante privind protecția datelor.
Proiecții inexacte ale infrastructurii de mediu	Mic	Mare	10	Validarea regulată a modelelor cu date istorice și scenarii multiple pentru a gestiona incertitudinea.
Dependența excesivă de GenDeg pentru intervenții climatice	Mediu	Mediu	12	Refinarea continuă a modelului pentru a include cele mai recente avansuri științifice privind clima și colaborarea cu experți în domeniu.
Capacitate insuficientă de procesare a datelor	Mic	Mediu	8	Achiziția de servicii de cloud și hardware corespunzătoare; extinderea capacităților de procesare la nevoie.
Probleme cu scalabilitatea sistemului în scenarii comerciale	Mediu	Mare	15	Testarea sarcinii pentru fluxuri de date ridicate și adaptarea parametrilor de cercetare la cerințele de producție.

8 Rezultatele proiectului

8.1 Livrabile

În perioada raportată am furnizat livrabile din tabelul 3 și am început lucrul intens asupra celorlalte livrabile.

Tabela 3: Tabel cu livrabile și statusul acestora.

Nr. livrabil	Termen	Livrabil	Status livrabil
D3.1	M20	Descrierea algoritmilor de detectare a degradării, inclusiv abordarea științifică și starea curentă, precum și rezultatele evaluării - raport	Livrat
D4.1	M30	Descrierea metodelor de generalizare, inclusiv abordarea științifică și cea de ultimă generație, precum și rezultatele evaluării - raport	În lucru

8.2 Articole științifice

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

În Tabelul sunt listate toate articolele din cadrul proiectului:

Tabela 4: Lista de articole

Articolul	Detalii Conferința / Jurnal	Link-ul pentru Open-Access
Iulia Baraian, Rudolf Erdei, Rares Tamaian, Daniela Delinschi, Emil Pașca, Oliviu Matei, " Trend-Enabled Recommender System with Diversity Enhancer for Crop Recommendation "	Agriculture MDPI	Link articol
Ionela Chereja, Rudolf Erdei, Emil Pașca, Daniela Delinschi, Anca Avram, Oliviu Matei, " A Privacy Assessment Framework for Data Tiers in Multilayered Ecosystem Architectures "	Mathematics MDPI	Link articol

9 Diseminare și exploatare

9.1 Activități de diseminare

Proiectul a fost diseminat în următoarele moduri:

- pe pagina web: <https://research.holisun.com/ro/proiecte/predictive-analysis/gendeg-ro>, având un număr de 150 de vizitatori lunari
- pe contul de LinkedIn: <https://www.linkedin.com/company/holisun>, cu peste 550 de adepți
- pe pagina de Facebook: <https://www.facebook.com/Holisun.IT/>, având peste 2400 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 5.

Tabela 5: Lista de activități de diseminare

Nume	Data	Link	Participanți	Rezultate
CUNBM Research Workshop 2025	02.03.2025	—	Delinschi Daniela	Prezentare <i>GenDeg</i>
International Mobility Days 2025	19.11.2025-21.11.2025	https://www.mobility-days.at/	Rudolf Erdei	Prezentare <i>GenDeg</i>
InnoComp Research Project Panel	24.10.2025	https://innocomp.eu/storage/app/media/files/InnoComp-Programme.pdf	Mihai Crisan	Prezentare <i>GenDeg</i>



Figura 8: InnoComp Research Project Panel - Prezentare proiect GenDeg

10 Concluzii

În cel de-al doilea an al proiectului, consorțiul a realizat progrese substanțiale în direcția dezvoltării, testării și validării arhitecturii algoritmice hibride pentru detectarea degradării modelelor predictive și evaluarea generalizabilității acestora. Dacă primul an s-a concentrat pe analiza conceptuală, definirea cadrului metodologic și explorarea limitărilor algoritmilor existenți, anul al doilea a fost marcat de trecerea la dezvoltare tehnică avansată, experimente sistematice și validare pe seturi de date reale.

Un rezultat central al acestui an îl reprezintă finalizarea și testarea unei versiuni funcționale a algoritmului hibrid bazat pe *experti locali* și ajustarea ponderilor prin *Exponentially Weighted Moving Average (EWMA)*. Abordarea propusă, dezvoltată conform arhitecturii detaliate în Secțiunea 5, integrează patru componente majore: segmentarea datelor prin clusterizare, antrenarea modelelor specializate, agregarea ponderată a predicțiilor și adaptarea dinamică a ponderilor. Rezultatele preliminare au evidențiat creșteri consistente ale acurateței predictive în comparație cu un model monolitic de referință, confirmând ipoteza proiectului privind superioritatea arhitecturilor compuse în contexte cu regimuri variabile ale datelor.

Testele comparative efectuate pe setul EUR/USD M15 au demonstrat o îmbunătățire substanțială a performanței, în unele configurații depășind cu peste 20 puncte procentuale rezultatele modelului baseline. Capacitatea algoritmului de a adapta în timp real ponderile modelelor parțiale, în funcție de performanța recentă, s-a dovedit esențială în scenariu afectate de *model drift* și schimbări bruște de regim, caracteristice domeniului financiar. Analiza comparativă realizată evidențiază robustețea și stabilitatea soluției propuse, confirmând viabilitatea implementării sale în sisteme operaționale.

Pe lângă progresul algoritmic, anul al doilea a marcat și consolidarea contribuțiilor HOLISUN în direcția integrării soluțiilor dezvoltate într-un cadru software scalabil, capabil să gestioneze fluxuri continue de date și să ofere mecanisme automate de monitorizare a performanței modelelor predictive. Activitățile de cercetare și dezvoltare realizate au generat premise solide pentru includerea tehnologiilor GenDeg în platforme comerciale destinate atât partenerilor financiari, cât și scenariilor de mentenanță predictivă.

În paralel, proiectul a continuat eforturile de diseminare și consolidare a vizibilității în comunitatea științifică și industrială. Rezultatele tehnice au fost prezentate în cadrul unor conferințe internaționale relevante și au stat la baza mai multor articole științifice aflate în proces de publicare. Activitățile de comunicare online, împreună cu participarea la evenimente tematice, au contribuit la creșterea gradului de cunoaștere a proiectului și la stimularea colaborărilor interdisciplinare.

În ansamblu, anul al doilea al proiectului *GenDeg* a reprezentat o etapă critică, în care conceptele teoretice definite anterior au fost transformate în soluții tehnice validate și promițătoare. Progresele obținute confirmă direcția de dezvoltare aleasă și creează premise solide pentru activitățile din anul următor, care vor viza finalizarea platformei integrate, optimizarea componentelor algoritmice și extinderea testării pe seturi multiple de date și pe scenarii aplicaționale complexe. Rezultatele de până acum demonstrează potențialul substanțial al proiectului în a livra tehnologii avansate pentru monitorizarea și îmbunătățirea performanței modelelor predictive în domenii dinamice și critice.

