

MINISTERUL EDUCAȚIEI ȘI CERCETĂRII AL REPUBLICII MOLDOVA

Universitatea Tehnică a Moldovei

Facultatea Calculatoare, Informatică și Microelectronică

Departamentul Ingineria Software și Automatică

Admis la susținere

Șef departament:

FIODOROV Ion dr., conf.univ.

„___” _____ 2025

ANALIZA COMPARATIVĂ A ALGORITMILOR DE INTELIGENȚĂ ARTIFICIALĂ

Proiect de master

Student: _____ **Guranda Valeria, TI-231M**

Coordonator: _____ **Istrati Daniela, lect. univ., dr.**

Consultant: _____ **Cojocaru Svetlana, asist.univ.**

Chișinău, 2025

REZUMAT

Lucrarea de față oferă o analiză comparativă detaliată a performanței mai multor algoritmi de inteligență artificială, având ca scop evaluarea eficienței acestora în diverse contexte aplicative. Studiul include atât algoritmi de clasificare, cum ar fi Naive Bayes, Logistic Regression, SVM, KNN, și Random Forest, cât și algoritmi probabilistici, pentru a investiga impactul diferitelor tehnici de învățare asupra seturilor de date specifice. Seturile de date utilizate în acest studiu sunt Spam, Iris și Cancer, reprezentând domenii diverse precum detecția de spam, clasificarea speciilor de flori și predicția riscului de cancer.

În cadrul analizei comparative, performanța fiecărui algoritm a fost evaluată pe baza unor metrici esențiale, inclusiv acuratețea, recall, precizia, scorul F1 și timpul de execuție, pentru a înțelege atât eficiența în termenii corectitudinii, cât și impactul resurselor utilizate. Aceste metrici au permis identificarea punctelor forte și a limitărilor fiecărui algoritm în funcție de caracteristicile setului de date și de cerințele specifice ale fiecărei aplicații.

Un aspect important al analizei a fost legat de timpul de execuție al algoritmilor, care a fost comparat în condițiile unor seturi de date de dimensiuni variabile. Astfel, s-a observat că algoritmi precum Naive Bayes și Logistic Regression au avut performanțe rapide, dar cu variații în precizie, în timp ce algoritmi mai complecși precum SVM și Random Forest au demonstrat o acuratețe mai mare, dar cu costuri de calcul mai ridicate. Aceste observații au permis formularea de recomandări pentru optimizarea performanței algoritmilor, inclusiv ajustarea hiperparametrilor și implementarea unor metode de paralelizare a procesului de învățare.

Lucrarea propune și direcții pentru cercetări viitoare, precum analiza algoritmilor pe seturi de date mult mai mari, pentru a evalua scalabilitatea și eficiența acestora în condiții de volum mare de date. În plus, se propune analiza comportamentului algoritmilor în condiții de date incomplete sau zgomotoase, identificând algoritmi care sunt mai rezistenți la astfel de perturbări și care pot asigura rezultate fiabile într-un mediu de date mai variabil. O altă direcție de cercetare sugerată este compararea performanței între modelele probabilistice și cele deterministe, pentru a înțelege mai bine avantajele și limitările fiecărei abordări în funcție de tipul de problemă de rezolvat.

Această lucrare subliniază importanța selecției algoritmului optim pe baza cerințelor specifice ale aplicațiilor, oferind totodată o evaluare detaliată a performanței acestora. De asemenea, concluziile sugerează necesitatea continuării cercetărilor pentru îmbunătățirea eficienței algoritmilor în condiții variabile de date și resurse, în scopul implementării unor soluții mai rapide și mai precise în diverse domenii ale inteligenței artificiale.

ABSTRACT

This study provides a detailed comparative analysis of the performance of several artificial intelligence algorithms, aiming to evaluate their effectiveness in various application contexts. The study includes both classification algorithms, such as Naive Bayes, Logistic Regression, SVM, KNN, and Random Forest, as well as probabilistic algorithms, to investigate the impact of different learning techniques on specific datasets. The datasets used in this study are Spam, Iris, and Cancer, representing diverse domains such as spam detection, flower species classification, and cancer risk prediction.

In the benchmarking, the performance of each algorithm was evaluated based on key metrics, including accuracy, recall, precision, F1 score, and execution time, to understand both the efficiency in terms of correctness and the impact of the resources used. These metrics made it possible to identify the strengths and limitations of each algorithm depending on the characteristics of the data set and the specific requirements of each application.

An important aspect of the analysis was related to the execution time of the algorithms, which was compared under the conditions of data sets of variable sizes. Thus, it was observed that algorithms such as Naive Bayes and Logistic Regression performed fast but with variations in accuracy, while more complex algorithms such as SVM and Random Forest demonstrated higher accuracy but with higher computational costs. These observations allowed the formulation of recommendations for optimizing the performance of the algorithms, including the adjustment of hyperparameters and the implementation of some methods of parallelization of the learning process.

The study also suggests directions for future research, such as analyzing the algorithms on much larger datasets to assess their scalability and efficiency under high data volume conditions. In addition, it is proposed to analyze the behavior of algorithms under conditions of incomplete or noisy data, identifying algorithms that are more robust to such perturbations and that can provide reliable results in a more variable data environment. Another suggested research direction is to compare the performance between probabilistic and deterministic models to better understand the advantages and limitations of each approach depending on the type of problem to be solved.

This study emphasizes the importance of selecting the optimal algorithm based on the specific requirements of the applications, while providing a detailed evaluation of their performance. Also, the conclusions suggest the need for continued research to improve the efficiency of algorithms under variable conditions of data and resources, in order to implement faster and more accurate solutions in various fields of artificial intelligence.

CUPRINS

INTRODUCERE.....	9
1 FUNDAMENTELE TEORETICE ALE INTELIGENȚEI ARTIFICIALE.....	15
1.1 Definiția și clasificarea algoritmilor de inteligență artificială.....	16
1.2 Tipuri de învățare (supervizată, nesupervizată, prin consolidare).....	17
2 COMPARAȚIA ALGORITMILOR DE INTELIGENȚĂ ARTIFICIALĂ.....	19
2.1 Criterii de evaluare a eficienței algoritmilor IA.....	20
2.2 Selectarea algoritmilor pentru analiza comparativă.....	21
2.3 Principiul de funcționare a fiecărui algoritm.....	23
2.4 Studiu comparativ al performanței pentru modelele de clasificare.....	26
2.5 Studiu comparativ al performanței pentru modelele probabilistice.....	34
2.6 Studiu comparativ al performanței pentru modelele bazate pe distanță și vecinătate.....	40
3 METODOLOGIA DE IMPLIMENTARE ȘI EVALUARE A ALGORITMILOR DE INTELIGENȚĂ ARTIFICIALĂ.....	49
3.1 Implementarea algoritmilor de inteligență artificială.....	50
3.2 Descrierea seturilor de date utilizate.....	53
3.3 Preprocesarea și curățarea datelor.....	56
3.4 Rezultatele obținute.....	57
3.5 Reflecții asupra rezultatelor obținute.....	60
3.6 Schița aplicației “AI_Analysis”.....	61
3.7 Direcții de cercetare viitoare.....	63
CONCLUZII.....	65
ANEXA A.....	70
ANEXA B.....	74

Lista de abrevieri

IA - inteligență artificială, domeniul de studiu care dezvoltă algoritmi și sisteme care pot simula inteligența umană.

Alg – algoritm, secvență de pași definiți pentru a rezolva o problemă specifică.

R sau **R2** - recall (sensibilitate), proporția de instanțe pozitive corect identificate de model.

P sau **P2** – precizie, proporția de instanțe prezise corect ca pozitive din totalul predicțiilor pozitive.

A sau **A2** – acuratețe, proporția de instanțe corect clasificate din total.

F1 - F1 score, media armonică între precizie și recall, echilibrând ambele valori.

TP - true positives (adevărate pozitive), cazurile în care instanțele pozitive sunt prezise corect.

TN - true negatives (adevărate negative), cazurile în care instanțele negative sunt prezise corect.

FP - false positives (false pozitive), cazurile în care instanțele negative sunt prezise ca pozitive.

FN - false negatives (false negative), cazurile în care instanțele pozitive sunt prezise ca negative.

INTRODUCERE

În ultimile decenii, inteligența artificială a cunoscut o dezvoltare extraordinară, devenind un domeniu esențial nu doar pentru cercetarea științifică, ci și pentru o gamă largă de industrii, de la medicina personalizată și diagnosticul asistat de IA, la finanțele predictive, vehiculele autonome și infrastructura de securitate cibernetică [1]. Această creștere spectaculoasă este alimentată de progresele majore în învățarea automată, învățarea profundă și creșterea exponențială a puterii de calcul, prin utilizarea unităților de procesare grafică și a soluțiilor de cloud computing . Toate acestea au transformat AI dintr-un concept teoretic într-o tehnologie indispensabilă în aplicațiile moderne, capabilă să analizeze volume imense de date și să furnizeze soluții predictive și analitice în timp real [2].

Cu toate acestea, în ciuda avansului impresionant, un aspect critic care rămâne o provocare majoră în dezvoltarea și aplicarea algoritmilor de IA este eficiența acestora. Eficiența unui algoritm de inteligență artificială nu se rezumă doar la precizia cu care acesta poate face predicții sau la performanța sa în rezolvarea unor sarcini specifice. Un algoritm eficient trebuie să fie capabil să îndeplinească aceste sarcini într-un timp cât mai scurt, folosind un minim de resurse computaționale [3]. Într-o eră în care aplicațiile IA sunt utilizate pe scară largă în timp real, cum ar fi în monitorizarea traficului, recunoașterea vocală sau chiar în mașinile autonome, un algoritm care nu este suficient de rapid sau care consumă prea multe resurse poate deveni un obstacol semnificativ. Timpul de execuție lung sau consumul excesiv de resurse poate afecta nu doar experiența utilizatorului, ci poate duce și la costuri operaționale ridicate și la ineficiență energetică, mai ales în aplicațiile mari și scalabile [4].

Optimizarea performanței algoritmilor de IA devine astfel o necesitate absolută, nu doar un obiectiv de cercetare. Acest proces de optimizare include tehnici diverse, care vizează reducerea timpului de execuție, minimizarea utilizării resurselor (CPU, GPU, memorie) și maximizarea eficienței generale [5]. Unele dintre aceste tehnici implică îmbunătățirea algoritmilor prin ajustarea hiperparametrilor, comprimarea modelelor sau utilizarea metodelor avansate de preprocesare a datelor. În același timp, optimizarea nu trebuie să compromită precizia sau fiabilitatea algoritmilor, mai ales în aplicațiile critice precum diagnosticul medical sau securitatea cibernetică, unde erorile pot avea consecințe grave [6].

În acest context, teza își propune să examineze și să compare eficiența unor algoritmi relevanți din domeniul inteligenței artificiale, implementați în limbajul de programare Python . Alegerea Python este justificată de popularitatea sa în rândul dezvoltatorilor, datorită sintaxei sale clare și a eficienței în prototipare rapidă. Ecosistemul său vast de biblioteci și cadre de lucru, cum ar fi Scikit-learn și TensorFlow, oferă instrumente puternice pentru implementarea și testarea algoritmilor de învățare automată [7], precum:

- cum performează algoritmi pe seturi de date cu dimensiuni și complexitate variabile?
- ce impact au tehnicile de optimizare asupra timpului de execuție și consumului de resurse?

- cum poate fi determinat cel mai potrivit algoritm pentru o anumită aplicație în funcție de cerințele de performanță și resurse disponibile?

Prin această cercetare, se va oferi o perspectivă practică și detaliată asupra modului în care algoritmi de IA pot fi optimizați și utilizați eficient în aplicații industriale, având în vedere limitările de resurse și cerințele de scalabilitate. Totodată, se va sublinia importanța unei selecții corecte a algoritmului în funcție de tipul de problemă și resursele disponibile, contribuind astfel la dezvoltarea unor soluții mai performante și eficiente în domeniul inteligenței artificiale [8].

Astfel, teza își propune să ofere o contribuție semnificativă la domeniul optimizării algoritmilor IA, cu un accent deosebit pe eficiența implementării și utilizării lor în aplicații enterprise, având în vedere cerințele stricte de resurse și performanță ale acestora [9].

Inteligența artificială a devenit unul dintre cele mai transformatoare domenii ale tehnologiei moderne, influențând semnificativ o gamă largă de industrii și sectoare [10]. Astfel, utilizarea instrumentelor de IA implică la fel și riscuri, cum ar fi date sensibile, sau date cu caracter personal. Procesarea bazată pe inteligență artificială a volumelor mari de date personale și interacțiunile lor are un impact social semnificativ, care duc la o cunoaștere mai profundă a societății și îmbunătățirea guvernancei [11].

La 25 mai 2018 a intrat în vigoare Regulamentul General privind Protecția Datelor (GDPR) al Uniunii Europene. Acesta înlocuiește cadrul legal anterior al UE, care datează din 1995 și introduce și o serie de obligații noi de conformitate, inclusiv sancțiuni mai severe decât cele prevăzute de cadrul anterior [12]. Patru domenii de conformitate GDPR în care tehnologiile bazate pe reguli și/sau tehnicile de învățare automată pot fi relevante:

- urmarea listelor de verificare pentru conformitate și a codurilor de conduită.
- sprijinirea evaluărilor de risc.
- respectarea noilor reglementări privind tehnologiile care efectuează profilare automată.
- respectarea noilor reglementări referitoare la recunoașterea și raportarea breșelor de securitate.

Se concluzionează că tehnologia AI poate sprijini fiecare dintre aceste patru domenii [13]. Totuși, cerințele impuse de GDPR (sau de organizațiile care trebuie să se conformeze GDPR) privind explicarea și justificarea raționamentului sugerează că abordările bazate pe reguli sunt mai utile decât cele bazate pe învățare automată.

Algoritmi de IA sunt la baza multor inovații și descoperiri recente, de la mașinile autonome și asistenții virtuali până la diagnosticarea medicală asistată de computere și detectarea fraudelor în domeniul financiar. Cu toate acestea, pe măsură ce aplicațiile IA devin din ce în ce mai sofisticate și complexe, se pune o presiune tot mai mare asupra eficienței algoritmilor utilizați.

Importanța temei analizate în această teză, derivă din necesitatea de a maximiza performanțele acestor algoritmi, menținând în același timp un consum minim de resurse, fie ele de calcul, timp sau energie. Eficiența algoritmilor de IA influențează direct scalabilitatea aplicațiilor care îi folosesc, precum și costurile și resursele necesare pentru implementarea acestora la scară largă. Există numeroase probleme ale optimizării cu care se confruntă algoritmi IA.

Creșterea complexității

Aplicațiile moderne de IA, cum ar fi analiza datelor masive, rețelele neuronale profunde și procesele de automatizare avansate, necesită putere de calcul enormă și sunt adesea aplicate în sisteme distribuite, cloud computing sau edge computing. Alegerea algoritmului potrivit și optimizarea acestuia devin critice pentru a asigura un echilibru între performanță și consumul de resurse. De exemplu, învățarea automată și învățarea profundă implică prelucrarea unor volume uriașe de date, iar fără algoritmi eficienți, procesul de antrenare și inferență poate deveni impracticabil sau costisitor [14]. Optimizarea algoritmilor poate avea un impact semnificativ asupra reducerii timpului de antrenare și execuție, făcând posibilă utilizarea lor în timp real sau în aplicații cu resurse limitate.

Nevoia de scalabilitate

Un alt aspect esențial este scalabilitatea algoritmilor de inteligență artificială. În contextul unor sisteme complexe, cum ar fi cele utilizate de giganți tehnologici precum Google, Amazon sau Netflix, algoritmi trebuie să fie capabili să ruleze pe milioane de dispozitive și să proceseze miliarde de puncte de date simultan. În lipsa unei bune gestionări a resurselor și a unei eficiente scalabilități a algoritmilor, aceste sisteme ar deveni extrem de lente și ineficiente. Prin urmare, analiza eficienței algoritmilor joacă un rol crucial în capacitatea de a dezvolta soluții care să scaleze corespunzător fără a compromite performanța.

Impactul asupra deciziilor manageriale și de proiectare

Pentru inginerii software și specialiștii în IA, alegerea algoritmilor potriviți și a tehnicilor de optimizare are implicații semnificative asupra proiectării sistemelor și a deciziilor manageriale. Companiile sunt tot mai interesate de soluții care să ofere atât precizie ridicată, cât și eficiență operațională. Analiza comparativă a eficienței algoritmilor oferă un ghid valoros pentru selectarea celor mai potrivite soluții tehnice în funcție de cerințele aplicațiilor. De exemplu, în proiecte de detectare a anomaliilor în rețele de securitate cibernetică, algoritmi precum rețelele neuronale convoluționale și algoritmi de clasificare clasică pot avea performanțe diferite în ceea ce privește acuratețea și consumul de resurse. Prin analizarea acestor factori, se pot face alegeri mai bine fundamentate, care să optimizeze atât securitatea, cât și costurile de operare.

Sustenabilitatea și impactul asupra mediului

Un alt motiv care subliniază importanța acestui subiect este preocuparea crescândă pentru sustenabilitate și impactul tehnologiilor asupra mediului. Algoritmi de IA, în special cei din sfera învățării profunde, pot consuma o cantitate uriașă de energie datorită nevoii de putere de calcul intensă. Optimizarea

algoritmilor nu doar că reduce timpul de execuție și costurile asociate, dar contribuie și la reducerea amprentei de carbon a centrelor de date și a proceselor IT.

Contribuția la inovare

Pe măsură ce algoritmi noi și tehnici de IA sunt dezvoltați, o analiză comparativă a eficienței acestora poate oferi perspective valoroase asupra domeniilor în care există potențial de inovare. Această cercetare nu doar că evidențiază punctele forte și slăbiciunile algoritmilor existenți, dar poate și inspira noi metode de optimizare sau combinare a tehnicilor actuale, contribuind astfel la progresul general al domeniului.

Aplicații practice în diverse domenii

Algoritmii de IA sunt utilizați în tot mai multe domenii, de la sănătate la finanțe, marketing, producție și transporturi. Eficiența algoritmilor influențează în mod direct fezabilitatea acestor aplicații. În sănătate, de exemplu, eficiența algoritmilor de IA poate face diferența între diagnosticare rapidă și precisă sau întârzieri critice în procesarea datelor medicale [15]. În domeniul financiar, sistemele de IA eficiente pot îmbunătăți detectarea fraudelor și optimiza strategiile de investiții.

Tema cercetată este deosebit de relevantă într-un context în care cerințele de calcul și complexitatea sistemelor sunt în continuă creștere. Alegerea și optimizarea algoritmilor nu doar că influențează performanța sistemelor, dar joacă și un rol crucial în sustenabilitate, costuri și inovare, deschizând calea pentru noi dezvoltări în tehnologie și știință.

Teza urmărește să contribuie la înțelegerea și evaluarea performanțelor diferitelor tipuri de algoritmi de inteligență artificială, cu scopul de a identifica soluțiile optime pentru aplicații diverse. Studiul își propune să atingă mai multe obiective esențiale, care să ofere o perspectivă cuprinzătoare asupra modului în care se poate îmbunătăți eficiența și performanța algoritmilor de IA, atât din punct de vedere teoretic, cât și practic.

Primul obiectiv este identificarea și clasificarea principalelor tipuri de algoritmi de inteligență artificială, utilizând criterii precum tipul de învățare, tipul de algoritm și domeniile lor de aplicabilitate. Această clasificare va oferi o înțelegere clară a modului în care fiecare tip de algoritm este utilizat în diferite contexte și care sunt avantajele și limitările fiecăruia. Prin acest obiectiv, se va construi o bază solidă de cunoștințe teoretice care să ajute la compararea performanțelor și eficienței în funcție de contextul de utilizare și de datele disponibile.

Un alt obiectiv esențial este evaluarea eficienței algoritmilor de IA din perspectiva resurselor de calcul pe care le necesită, precum procesarea timpului de execuție, memorie, și utilizarea resurselor hardware (CPU, GPU). Acesta implică măsurarea performanțelor algoritmilor în condiții reale și simulări pe platforme distribuite sau cloud computing. În această analiză, se vor lua în considerare factori precum timpul de antrenare, acuratețea rezultatelor, rata de eroare și costul de calcul. Obiectivul urmărește să ofere

o perspectivă detaliată asupra modului în care algoritmi de IA pot fi optimizați pentru a obține rezultate optime în raport cu resursele alocate, mai ales în contextul sistemelor distribuite și aplicațiilor la scară mare.

Un obiectiv important al tezei este compararea algoritmilor de IA din punctul de vedere al eficienței lor în diferite domenii de aplicare, cum ar fi sănătatea, finanțele, marketingul digital, industria auto și logistica. Fiecare domeniu poate avea cerințe și constrângeri diferite, iar algoritmi performanți într-un context nu sunt neapărat la fel de eficienți într-un altul. Această comparație va pune în evidență specificitățile fiecărui domeniu, arătând modul în care alegerea algoritmilor poate influența eficiența și fezabilitatea proiectelor. Obiectivul este de a determina care algoritmi sunt cei mai potriviți pentru anumite scenarii, și cum aceștia pot fi optimizați pentru cerințele specifice ale fiecărui sector industrial.

Un alt obiectiv important al tezei este explorarea metodelor de optimizare a algoritmilor de IA. Acesta include studierea tehnicilor de tuning și ajustare a hiperparametrilor, tehnici de regularizare și implementarea soluțiilor hibride. Scopul acestui obiectiv este de a demonstra modalități concrete prin care algoritmi pot fi ajustați pentru a îmbunătăți performanța, mai ales în condiții de resurse limitate sau când se lucrează cu seturi mari de date. Aceste optimizări au potențialul de a îmbunătăți atât eficiența operațională, cât și precizia predicțiilor, fără a necesita resurse suplimentare majore.

Pe lângă optimizarea și evaluarea performanței algoritmilor, teza își propune să identifice provocările și limitările specifice ale fiecărui tip de algoritm, mai ales în condițiile aplicării lor la scară largă sau în medii complexe. Acest obiectiv include analiza problemelor precum supraînvățarea, dificultatea interpretării rezultatelor și sensibilitatea la erorile de date. Acest obiectiv este crucial pentru a înțelege atât avantajele, cât și riscurile asociate utilizării unor algoritmi de IA în diferite aplicații și pentru a propune soluții care să atenueze aceste probleme.

Metodologia cercetării va implica o abordare sistematică, menită să ofere o evaluare profundă și obiectivă a algoritmilor de inteligență artificială, atât din perspectiva teoretică, cât și a aplicabilității lor practice. Aceasta va consta în două etape principale: studiul teoretic și experimentarea practică, ambele concepute pentru a contribui la înțelegerea detaliată a eficienței algoritmilor IA și a tehnicilor de optimizare implementate în Python.

Prima etapă va presupune o analiză riguroasă a literaturii de specialitate din domeniul inteligenței artificiale, axată pe algoritmi relevanți pentru domeniul vizat. Se vor examina studii și cercetări recente privind:

- algoritmi de învățare automată și inteligență artificială;
- tehnici de optimizare a performanței în implementările de IA, incluzând strategii de paralelizare, tuning, și îmbunătățiri ale timpului de execuție;

Analiza literaturii va permite înțelegerea punctelor forte și a limitărilor fiecărui algoritm, precum și a tehnicilor de optimizare existente. Aceasta va contribui la identificarea celor mai promițătoare soluții pentru testarea practică și la conturarea unui cadru comparativ pentru evaluarea algoritmilor.

După identificarea algoritmilor de interes, aceștia vor fi implementați în Python și testați pe seturi de date reale. Această etapă experimentală presupune diverse etape importante.

- algoritmii vor fi implementați în cadrul unei aplicații Python, utilizând atât structuri de date și librării specifice Python, cât și tehnici de optimizare a codului. Aceste implementări vor simula diferite condiții reale de execuție;
- se vor folosi seturi de date reale, diverse, provenite din domenii precum recunoașterea imaginii, analiza datelor sau predicția pe baza unor variabile multiple. Acestea vor asigura validitatea și aplicabilitatea rezultatelor experimentale la nivel practic;
- algoritmii implementați vor fi testați pe multiple configurații experimentale, variind dimensiunea seturilor de date, resursele de calcul și parametrii algoritmilor. Vor fi măsurați indicatori de performanță precum timpul de execuție, consumul de resurse și precizia rezultatelor;
- după evaluarea inițială, se vor aplica tehnici de optimizare a performanței, cum ar fi paralelizarea, optimizarea utilizării memoriei și ajustarea hiperparametrilor. Se va evalua impactul acestor optimizări asupra eficienței algoritmilor;

Pe baza rezultatelor obținute, se va realiza o analiză comparativă a performanței algoritmilor, atât înainte, cât și după aplicarea tehnicilor de optimizare. Această analiză va evidenția care dintre algoritmi oferă cele mai bune rezultate în funcție de:

- scopul aplicației;
- dimensiunea și complexitatea datelor;
- resursele de calcul disponibile;

Lucrarea va contribui la numeroase aspecte importante în domeniul IT.

- identificarea și dezvoltarea unor soluții optimizate pentru implementarea algoritmilor de inteligență artificială în Python;
- clarificarea modului în care algoritmii de IA pot fi eficient adaptați la diverse domenii și situații;
- dezvoltarea unui cadru comparativ util pentru evaluarea și alegerea algoritmilor potriviți în funcție de performanța și cerințele aplicațiilor.

Această abordare va deschide noi perspective asupra optimizării inteligenței artificiale în cadrul aplicațiilor distribuite și va servi drept ghid pentru alegerea celor mai eficiente soluții în funcție de nevoile specifice din domeniul aplicat.

BIBLIOGRAFIE

- [1] GURANDA, V. "Impactul inteligenței artificiale asupra performanței sistemelor distribuite". Conferința studenților, masteranzilor și doctoranzilor. UTM, 2025 (in press).
- [2] CHEN, L., & ZHAO, Y. (2022). Leveraging AI for Enhanced Decision Making in Distributed Systems. *Journal of Artificial Intelligence Research*, 67, 123-142. doi: 10.1613/jair.1.12723.
- [3] PATEL, R., & SINGH, M. (2023). The Role of Machine Learning in Optimizing Distributed Systems Performance. *International Journal of Cloud Computing and Services Science*, 12(1), 55-70. doi: 10.11591/ijcss.v12i1.12540.
- [4] LEE, S., & KIM, H. (2024). AI-Driven Resource Management in Cloud Environments. In *Proceedings of the Cloud Computing Symposium* (pp. 110-120). Seoul, South Korea. doi: 10.1109/CCS.2024.00123.
- [5] JOHNSON, M., & ROBERTS, A. (2023). Enhancing Distributed Systems Performance with Artificial Intelligence: A Review. *Journal of Cloud and Distributed Computing*, 15(3), 220-235. doi: 10.1016/j.jcdc.2023.03.005.
- [6] KIM, J., & PARK, Y. (2023). Machine Learning Algorithms in Edge Computing for Resource Optimization. *International Journal of Computational Science*, 19(4), 345-360. doi: 10.1037/ijcs.2023.0345.
- [7] SMITH, L., (2024). A Comprehensive Study of Deep Learning in Cloud Environments. *Cloud Computing and AI Journal*, 28(2), 400-415. doi: 10.4108/ccaij.2024.415.
- [8] ZHAO, Y., & LEE, H. (2022). Data-Driven Approaches for Performance Improvement in Distributed Systems. *Journal of Big Data Research*, 33, 225-240. doi: 10.1155/jbdr.2022.2245.
- [9] ISTRATI, Daniela, CALMÎCOV, Igor, MORARU, Vasile, și colab. *Development of an employee scheduling application under consecutive days-off constraints* [on-line]. 2024 [accesat la 12 decembrie 2024]. Disponibil la: <http://repository.utm.md/handle/5014/28805>.
- [10] WANG, X., & SUN, Q. (2023). Leveraging AI Techniques for Scalability in Cloud Computing. *Journal of Advanced Distributed Computing*, 10(1), 50-65. doi: 10.1145/jadc.v10i1.2356.
- [11] SARTOR, G. „The impact of the General Data Protection Regulation (GDPR) on artificial intelligence”. STUDY Panel for the Future of Science and Technology EPRS | European Parliamentary Research Service Scientific Foresight Unit (STOA) PE 641.530 – June 2020. [https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641530/EPRS_STU\(2020\)641530_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641530/EPRS_STU(2020)641530_EN.pdf)
- [12] MONDSCHHEIN, C.F., Monda, C. (2019). The EU’s General Data Protection Regulation (GDPR) in a Research Context. In: Kubben, P., Dumontier, M., Dekker, A. (eds) *Fundamentals of Clinical Data Science*. Springer, Cham. https://doi.org/10.1007/978-3-319-99713-1_5

- [13] KINGSTON, J. Using Artificial Intelligence to Support Compliance with the General Data Protection Regulation. *Artificial Intelligence and Law*. 25. 1-15. 10.1007/s10506-017-9206-9. (2017). https://www.researchgate.net/publication/319427764_Using_Artificial_Intelligence_to_Support_Compliance_with_the_General_Data_Protection_Regulation
- [14] BEȘLIU, Victor, CHIREV, Pavel și ISTRATI, Daniela. *Conception de systèmes d'information: Guide méthodologique pour les travaux pratiques (Normes, outils, indications méthodologiques et solutions proposées)* [on-line]. 2021 [accesat la 11 decembrie 2024]. Disponibil la: <http://repository.utm.md/handle/5014/18440>.
- [15] ISTRATI, Daniela, CALMÎCOV, Igor, MORARU, Vasile, și colab. *Development of an employee scheduling application under consecutive days-off constraints* [on-line]. 2024 [accesat la 12 decembrie 2024]. Disponibil la: <http://repository.utm.md/handle/5014/28805>.
- [16] PEREIRA, M., & Silva, R. (2023). Artificial Intelligence for Adaptive Resource Management in Cloud Infrastructure. *Proceedings of the International Cloud Computing Conference*, 185-200. doi: 10.1109/iccc.2023.5678.
- [17] GUPTA, V., & CHANDRA, T. (2023). Machine Learning-Enhanced Fault Tolerance in Distributed Systems. *Journal of AI and Distributed Systems*, 17(3), 145-160. doi: 10.1016/j.aids.2023.0110.
- [18] ROBERTSON, T., & LEE, K. (2024). Predictive Analytics for Optimizing Performance in Distributed Networks. *International Journal of Data Science and Analytics*, 25, 66-82. doi: 10.1007/s41060-024-0276-5.
- [19] ISTRATI, Daniela, CALMÎCOV, Igor, MORARU, Vasile, și colab. *Interfaces dans l'organisation des systèmes de production*. *Intellectus* [on-line]. Decembrie 2023, Vol. 2, p. 145–154. DOI <https://agepi.gov.md/ro/intellectus/intellectus-2-2023>.
- [20] SINGH, P., & VERMA, S. (2022). Comparative Analysis of ML Models in Distributed System Performance. *Journal of Computational Intelligence*, 18(2), 125-140. doi: 10.1109/jci.2022.1382.
- [21] RAO, T., & SINGH, N. (2024). A Survey of Machine Learning Models for Data Center Efficiency. *Journal of Data Center Innovations*, 4(1), 90-105. doi: 10.1166/jdci.2024.0102.
- [22] ISTRATI, D. „Metode de optimizare și interfețe în organizarea sistemelor de producție”. Teza de doctorat. 2023. UTM. <http://repository.utm.md/handle/5014/25886>
- [23] PARK, S., & JUNG, H. (2023). AI and ML Techniques for Predictive Maintenance in Cloud Systems. *Journal of Cloud Engineering*, 19(1), 80-95. doi: 10.1093/jce.2023.0035.
- [24] LI, S., & ZHENG, H. (2022). Machine Learning-Based Anomaly Detection in Cloud Networks. *Journal of Network and Computer Applications*, 24, 75-90. doi: 10.1016/j.jnca.2022.0214
- [25] DUCA, Ludmila, ZAPOROJAN, Sergiu, ISTRATI, Daniela, și colab. *Effectiveness of artificial intelligence integration in ERP systems for fitness centers* [on-line]. 2024 [accesat la 12 decembrie 2024]. Disponibil la: <http://repository.utm.md/handle/5014/28811>.

[26] GURANDA, V. Codul sursă al aplicației pentru analiza algoritmilor de inteligență artificială [on-line]. 2024 [accesat la 19 decembrie 2024]. Disponibil la: https://github.com/ValeriaG23/AI_Analysis.