

PROIECT ALGORITMI DE INVATARE AUTOMATA
1. Date despre disciplină/modul

Facultatea	Calculatoare, Informatică și Microelectronică				
Departamentul	Inginerie Software și Automatică				
Ciclul de studii	Ciclul II, Studii superioare de master				
Programul de studii	Inginerie Software				
Anul de studii	Semestrul	Tip de evaluare	Categoria formativă	Categoria de opționalitate	Credite ECTS
Anul I (<i>învățământ cu frecvență</i>)	I	PA	S – uniate de curs de specialitate	O - unitate de curs obligatorie	5

2. Timpul total estimat

Total ore în planul de învățământ		Din care		
		Ore auditoriale	Lucrul individual	
Învățământ cu frecvență	150	Proiect	Studiul materialului teoretic	Pregătire aplicații
		40	40	70

3. Precondiții de acces la disciplină/modul

Conform planului de învățământ	Bazele învățării automate, Statistică aplicată, Algebra liniară, Probabilități, Structuri de date, Programare în Python.
Conform competențelor	Să înțeleagă conceptele fundamentale de învățare supravegheată, să poată interpreta metrici statistici de performanță, să prelucreze și să vizualizeze date, să implementeze algoritmi de clasificare sau regresie și să comunice eficient rezultatele unei analize predictive.

4. Condiții de desfășurare a procesului educațional pentru

Proiect	<ul style="list-style-type: none"> Pentru prezentarea proiectului sunt necesare tablă, tablă interactivă, proiector și calculator conectat la internet. Tema proiectului trebuie selectată din tematicile corespunzătoare disciplinei, vizând aplicarea unui algoritm de învățare supravegheată pe un set de date real. Proiectul se desfășoară în echipe de 3–4 studenți. Este necesar accesul la platforme software pentru dezvoltare și analiză: Jupyter Notebook, Google Colab, scikit-learn, pandas, matplotlib etc., precum și la resurse didactice puse la dispoziție de cadrul didactic. Se vor organiza întâlniri săptămânale pentru raportarea progresului, clarificări și feedback personalizat. Documentația proiectului trebuie să includă: descrierea problemei, sursa și analiza datelor, justificarea alegerii algoritmilor, evaluarea performanței modelului, raport final, prezentare orală. Soluția trebuie demonstrată și argumentată în fața comisiei de evaluare, inclusiv deciziile luate în etapele de preprocesare, selecție de modele și interpretare a rezultatelor.
----------------	--

5. Competențe specifice acumulate

Competențe profesionale	<p>C1: Capacitatea de a defini și formula o problemă de învățare automată supravegheată:</p> <ul style="list-style-type: none"> Identificarea obiectivului analitic și alegerea unui set de date adecvat. Formularea ipotezei și a tipului de problemă (clasificare sau regresie) în funcție de date și context. <p>C2: Aplicarea algoritmilor și metodelor de învățare supravegheată:</p> <ul style="list-style-type: none"> Alegerea și justificarea algoritmilor (ex. Logistic Regression, Decision Trees, SVM, k-NN etc.). Optimizarea modelelor prin ajustarea hiperparametrilor și validare încrucișată. Utilizarea metodelor de evaluare relevante pentru a măsura performanța modelului (accuracy, F1-score, RMSE etc.). <p>C3: Implementarea și documentarea completă a unei soluții ML:</p> <ul style="list-style-type: none"> Preprocesarea și explorarea datelor, pregătirea pipeline-ului de antrenare. Analiza rezultatelor și redactarea unui raport tehnic clar, argumentat și replicabil. Prezentarea concluziilor și justificarea deciziilor în fața comisiei.
--------------------------------	---

Competențe transversale	<p>CT1: Capacitatea de a lucra eficient în echipă:</p> <ul style="list-style-type: none"> • Colaborarea activă în cadrul echipei; împărțirea responsabilităților și integrarea rezultatelor. • Comunicarea eficientă și clară a progresului și a deciziilor tehnice. <p>CT2: Gândire critică și analitică aplicată în contextul datelor:</p> <ul style="list-style-type: none"> • Compararea alternativelor tehnice în funcție de performanță, complexitate și interpretabilitate. • Argumentarea deciziilor de proiect și identificarea limitărilor soluției propuse. <p>CT3: Respectarea principiilor etice și profesionale în știința datelor:</p> <ul style="list-style-type: none"> • Utilizarea responsabilă a datelor și conștientizarea implicațiilor posibilelor biasuri. • Asigurarea transparenței în documentare și replicabilitate în implementare.
--------------------------------	---

6. Obiectivele disciplinei/modulului

Obiectivul general	Pregătirea studenților pentru dezvoltarea unui proiect complet de învățare automată supravegheată, folosind metode moderne de analiză a datelor, selecție de modele, optimizare și evaluare, în conformitate cu bunele practici din domeniul științei datelor.
Obiectivele specifice	<p>Se urmărește dezvoltarea următoarelor competențe:</p> <ul style="list-style-type: none"> • Familiarizarea cu etapele esențiale ale unui proiect de machine learning aplicat. • Aplicarea corectă a tehnicilor de preprocesare a datelor, antrenare și evaluare a modelelor. • Crearea unei soluții predictive robuste, reproductibile și bine documentate.

7. Conținutul disciplinei/modulului

Tematica activităților didactice	Numărul de ore
	învățământ cu frecvență
1. Introducere în proiectele de învățare automată supravegheată – etape, tipuri de probleme, fluxuri de lucru ML	4
2. Colectarea, analiza și preprocesarea datelor – curățare, transformări, vizualizare exploratorie	8
3. Alegerea modelelor și justificarea algoritmilor – clasificare vs regresie, bias/variance, overfitting	6
4. Antrenarea și validarea modelelor – metrici de performanță, cross-validation, tuning	6
5. Testarea și evaluarea finală – analiza erorilor, comparații între modele	
6. Optimizarea hiperparametrilor și interpretarea rezultatelor – grid search, interpretabilitate	6
7. Implementarea pipeline-ului complet – organizarea codului, reproductibilitate, modularitate	4
8. Documentarea și prezentarea proiectului – raport tehnic, aspecte etice, susținere orală	6
Total:	40

8. Referințe bibliografice

Principale	<ol style="list-style-type: none"> 1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). <i>Deep learning</i>. MIT Press. http://www.deeplearningbook.org 2. Theobald, O. (2017). <i>Machine learning for absolute beginners: A plain English introduction</i> (2nd ed.). Scatterplot Press. 3. Universitatea Tehnică a Moldovei. (n.d.). <i>Educational materials and bibliographic sources on FCIM's ELSE platform</i>. https://else.fcim.utm.md/course/view.php?id=702
Suplimentare	<ol style="list-style-type: none"> 1. Burkov, A. (2019). <i>The hundred-page machine learning book</i>. Andriy Burkov. ISBN: 978-1999579500 2. Kelleher, J. D., & Mac Namee, B. (2015). <i>Fundamentals of machine learning for predictive data analytics: Algorithms, worked examples, and case studies</i>. MIT Press. ISBN: 978-0262029445 3. Géron, A. (2019). <i>Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow</i> (2nd ed.). O'Reilly Media, Inc. https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/

4. Utilizarea IA generativă

Permisivitatea de utilizare	<p>Utilizarea IA generative în cadrul temelor și proiectelor este permisă, cu condiția ca studenții să respecte următoarele reguli:</p> <ul style="list-style-type: none"> IA generativă poate fi utilizată pentru generarea de idei, structuri de text sau cod, dar toate materialele generate trebuie să fie revizuite și ajustate de către student pentru a se asigura că acestea corespund cerințelor academice. Orice utilizare a IA generative trebuie să fie declarată în secțiunea de appendice a fiecărei lucrări, folosind fraza: "În timpul pregătirii acestei lucrări, autorul a utilizat [NUME INSTRUMENT / SERVICIU] în scopul [MOTIV]. După utilizarea acestui instrument/serviciu, autorul a revizuit și editat conținutul după cum a fost necesar și își asumă întreaga responsabilitate pentru conținutul lucrării."
Restricții de utilizare	<p>Studenții nu trebuie să considere IA generativă ca o sursă de încredere pentru informații, deoarece nu oferă referințe clare sau surse documentate.</p> <ul style="list-style-type: none"> Nu este permisă citarea directă a conținutului generat de IA în lucrările academice ca și cum ar fi sursă primară. Activitățile în care este interzis utilizarea IA generativă sunt specificate de profesor și sunt de regulă evaluări intermediare și finale sau care nu presupun activități de dezvoltare a competențelor profesionale.

5. Evaluare

Periodică și curentă		Evaluarea finală
Evaluare 1	Evaluare 2	
30%	30%	40%
Standard minim de performanță: definirea unei probleme a unui grup social și descrierea în ansamblu a soluției/soluțiilor utilizând tehnologia informației și comunicației.		
<p>Prezența și activitatea la seminarele/atelierele de lucru; <i>Obținerea notei „5” la fiecare dintre evaluări;</i> <i>Obținerea notei „5” la lucrarea de examinare finală;</i></p> <p>Evaluarea curentă, fiind de tip formativ și oferind studenților/echipei un feedback continuu la activitățile de proiectare sau modulele integrate, asigură evaluarea studentului cu nota echipei de lucru.</p> <p>Examenul final, fiind o evaluare sumativă, se realizează oral în baza proiectului prezentat public de echipă și discuții/interviuri individuale (în prezența echipei sau nu). Aprecierile obținute la examinare sunt individuale și constituie 40% din nota finală.</p>		

6. Criterii de evaluare

Activitate	Componente evaluare	Metodă de evaluare, criterii de evaluare	Pondere în nota finală a activității	Ponderea în evaluarea disciplinei
Evaluare I	Prezența și participarea la seminare	Observație directă, fișă de prezență	50%	30 %
	Calitatea lucrărilor realizate în timpul atelierelor	Analiză practică, punctaj pentru fiecare sarcină rezolvată	50%	
Evaluare II	Prezentarea unei soluții funcționale	Evaluare practică, demonstrarea funcționalității soluției propuse	70%	30 %
	Colaborarea în echipă și respectarea termenelor	Feedback de la colegi și observațiile coordonatorului	30%	
Evaluarea finală	Prezentarea publică a proiectului final	Examinare orală, claritatea expunerii, justificarea deciziilor	60%	40%
	Documentația proiectului (conținut, structură, claritate)	Analiza documentației conform criteriilor predefinite	40%	