



## FIȘA DISCIPLINEI ÎNVĂȚARE AUTOMATĂ

### 1. Date despre program

1.1 Instituția de învățământ superior	UNIVERSITATEA „OVIDIUS” DIN CONSTANȚA
1.2 Facultatea	Facultatea de Matematică și Informatică
1.3 Departamentul	Matematică și Informatică
1.4 Domeniul de studii	Informatică
1.5 Ciclul de studii	Master
1.6 Programul de studii	Securitate cibernetică și învățare automată
1.7 Anul universitar	2025-2026

### 2. Date despre disciplină

2.1 Denumirea disciplinei	Învățare automată (Machine Learning)						
2.2 Cod disciplină	CSML.1.1.02						
2.3 Titularul activităților de curs	Conf.univ.dr. Elena Pelican						
2.4 Titularul activităților aplicative	Conf.univ.dr. Elena Pelican						
2.5 Anul de studii	1	2.6 Semestrul	1	2.7 Tipul de evaluare	E	2.8 Regimul disciplinei */**	DF/DOB

\* DF – disciplină fundamentală, DS – disciplină de specializare, DC – disciplină complementară

\*\* DOB – disciplină obligatorie; DOP – disciplină opțională; DFA – Disciplină facultativă

### 3. Timpul total (ore pe semestru)

3.1 Număr de ore activități didactice pe săptămână	4	din care: 3.2 curs	2	3.3 aplicații***	2
3.4 Total ore activități didactice pe semestru	56	din care: 3.5 curs	28	3.6 aplicații	28
3.7 Total ore de studiu individual					69
Distribuția fondului de timp					ore
Studiul cărților, manualelor, suportului de curs, notițelor, bibliografie minimală recomandată					20
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					8
Pregătire seminar / laborator / proiect, teme, referate, portofolii și eseuri					26
Pregătire pentru prezentări sau verificări					8
Pregătire pentru examinarea finală					5
Alte activități: consultații					2
3.8 Total ore pe semestru	125				
3.9 Numărul de credite	5				

\*\*\* S - seminar; L - laborator; P - proiect

### 4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Optimizare, Probabilități și statistică, Algebră Liniară, Fundamentele programării, Algoritmi fundamentali și Structuri de date
4.2 de rezultate ale învățării	

### 5. Condiții necesare pentru desfășurarea optimă a activităților didactice (acolo unde este cazul)

5.1. de desfășurare a cursului	Sală de clasă dotată cu videoprojector disponibil
--------------------------------	---



5.2. de desfășurare a seminarului/laboratorului/ proiectului*	Sală de laborator cu calculatoare disponibile
---	---

\*Se alege tipul de aplicație aferent disciplinei

## 6. Obiectivele disciplinei

6.1 Obiectivul general al disciplinei	Introducerea principiilor si mecanismelor învățării automate.
6.2 Obiectivele specifice	Înțelegerea principiilor algoritmilor de învățare automată. Dezvoltarea de aplicații software bazate pe algoritmi din acest domeniu.

## 7. Rezultatele învățării

Cunoștințe	<p>Studentul:</p> <ul style="list-style-type: none"><li>– înțelege, explică și utilizează corect algoritmi si caracteristicile claselor importante de algoritmi din învățarea automată (probleme de clasificare, regresie, clusterizare (grupare), reducere a dimensionalității)</li><li>– cunoaște și utilizează corect terminologia din învățarea automată</li><li>– alege modelul adecvat pentru problema studiată</li><li>– interpretează corect rezultatele obținute prin aplicarea modelelor de învățare automată, conform indicilor de performanță corespunzători problemei studiate</li><li>– alege arhitectura optimă pentru o rețea neuronală care rezolvă o anumită problemă</li><li>– definește avantajele și dezavantajele principalelor soluții din domeniu</li><li>– explică impactul algoritmilor în performanțele sistemului/aplicației create.</li></ul>
Aptitudini	<p>Studentul:</p> <ul style="list-style-type: none"><li>– implementează algoritmi specifici, utilizează instrumentele software specifice și modifică codul conform cerințelor</li><li>– identifică scenarii practice în care este oportună folosirea unui model de învățare automată</li><li>– realizează modelul pentru o problemă concretă, folosind unelte disponibile</li><li>– implementează un clasificator, regresor, rețea neuronală</li><li>– demonstrează abilități de management de sine, în termeni de autodisciplină, punctualitate și planificare a timpului, responsabilitate;</li><li>– lucrează în echipă, planifică, execută și evaluează modele de învățare automată potrivite contextului</li><li>– comunică eficient cu colegii și diversele părți interesate, prevenind conflictele și negociind soluții.</li></ul>
Responsabilitate și autonomie	<p>Studentul:</p> <ul style="list-style-type: none"><li>– manifestă disponibilitatea de a rezolva probleme prin tehnologii digitale;</li><li>– demonstrează deschidere pentru a proiecta și a co-crea produse și servicii noi folosind dispozitive digitale, pentru a genera valoare economică sau socială pentru alții;</li><li>– acționează conform codului de conduită etică și deontologie profesională</li><li>– abordează provocările existente în problemele de învățare automată cu curiozitate și dorința de a explora soluții inovatoare.</li><li>– este deschis la experimentarea cu diferiți algoritmi și chiar framework-uri de programare diverse</li><li>– adoptă o abordare activă și motivată de curiozitate a inovației pentru transformarea digitală;</li><li>– respectă principiile, normele și valorile de etică și integritate academică;</li></ul>



## 8. Conținuturi

8.1 Curs	Metode de predare	Număr ore alocate
1. Definiție. Motivație. Prezentare generală. Tipuri de învățare. Indici de performanță.		2
2. Algoritmi de învățare supervizată. Clasificatori și regresori. Regresie liniară (simplă și multiplă, univariată și multivariată). Tehnici de regularizare (Ridge, Lasso, ElasticNet). Regresie logistică. Clasificatorul k-NN. Mașini cu suport vectorial SVM (SVC și SVR). Arbori de decizie. Păduri aleatoare. Rețele de tip Naive Bayes	Metode de predare-învățare interactive;  Metode care implică activ studentii în învățare, punându-i în situația de a realiza conexiuni logice, de a produce idei și opinii proprii argumentate	10
3. Algoritmi de învățare nesupervizată. Algoritmi de clusterizare: k-means, Expectation Maximization (EM), Gaussian Mixture (GM) Analiza componentelor principale (PCA) și T-SNE ca tehnici de reducere a dimensionalității și de vizualizare Analiza componentelor independente (ICA)	Problematizarea; Conversația;  Metodele active Sintetiza/ esențializarea informațiilor	4
4. Învățare profundă (Deep learning) Arhitectura unei rețele neuronale. Algoritmul de propagare înainte/înapoi. Rețele neuronale convoluționale (CNNs). Rețele neuronale recurente (RNNs). Rețele de tip GAN. Transformeri.	Învățarea independentă și prin cooperare	12
<b>Bibliografie</b> <ol style="list-style-type: none"><li>1. C. Bishop – Pattern Recognition and Machine Learning, Springer, 2006</li><li>2. T. Hastie, R. Tibshirani, J. Friedman - The Elements of Statistical Learning. Data Mining, Inference, and Prediction, Second Edition, Springer 2009</li><li>3. I. Goodfellow, Y. Bengio, A. Courville – Deep Learning, MIT Press, 2016</li><li>4. C.C. Aggarwal, C.K. Reddy - Data Clustering, CRC Press, 2014</li><li>5. M. Emre Celebi - Partitional Clustering Algorithms, Springer, 2014</li><li>6. L.Ciortuz, A. Munteanu, E. Badarau – Exerciții de învățare automată, Ed. Univ. Al.I.Cuza, Iasi, 2015.</li><li>7. S. Theodoridis, K. Koutroumbas, Pattern Recognition, Fourth Edition (Hardcover), Academic Press, 2009</li><li>8. I.H. Witten, E. Frank, M.A. Hall, C.J. Pal, Data Mining, Fourth Edition: Practical Machine Learning Tools and Techniques (Morgan Kaufmann Series in Data Management Systems) 3rd Edition, Elsevier, 2011</li></ol>		
<b>8.2 Aplicații (seminar/laborator/proiect)*</b> <i>*Se alege tipul de aplicație aferent disciplinei</i>	<b>Metode de predare</b>	<b>Număr ore alocate</b>
1. Definiție. Motivație. Prezentare generală. Tipuri de învățare. Indici de performanță.	Metode de predare-învățare interactive;	2



2. Algoritmi de învățare supervizată. Clasificatori și regresori. Regresie liniară (simplă și multiplă, univariată și multivariată). Tehnici de regularizare (Ridge, Lasso, ElasticNet). Regresie logistică. Clasificatorul k-NN. Mașini cu suport vectorial SVM (SVC și SVR). Arbori de decizie. Păduri aleatoare. Rețele de tip Naive Bayes	Metode care implică activ studentii în învățare, punându-i în situația de a realiza conexiuni logice, de a produce idei și opinii proprii argumentate Problematizarea; Conversatia;	10
3. Algoritmi de învățare nesupervizată. Algoritmi de clusterizare: k-means, Expectation Maximization (EM), Gaussian Mixture (GM) Analiza componentelor principale (PCA) și T-SNE ca tehnici de reducere a dimensionalității și de vizualizare Analiza componentelor independente (ICA)	Metodele active Sintetiza/ esențializarea informațiilor Învățarea independentă și prin cooperare	4
4. Învățare profundă (Deep learning) Arhitectura unei rețele neuronale. Algoritmul de propagare înainte/înapoi. Rețele neuronale convoluționale (CNNs). Rețele neuronale recurente (RNNs). Rețele de tip GAN. Transformeri.		12
<b>Bibliografie</b> <ol style="list-style-type: none"><li>1. C. Bishop – Pattern Recognition and Machine Learning, Springer, 2006</li><li>2. T. Hastie, R. Tibshirani, J. Friedman - The Elements of Statistical Learning. Data Mining, Inference, and Prediction, Second Edition, Springer 2009</li><li>3. I. Goodfellow, Y. Bengio, A. Courville – Deep Learning, MIT Press, 2016</li><li>4. C.C. Aggarwal, C.K. Reddy - Data Clustering, CRC Press, 2014</li><li>5. M. Emre Celebi - Partitional Clustering Algorithms, Springer, 2014</li><li>6. L.Ciortuz, A. Munteanu, E. Badarau – Exerciții de învățare automată, Ed. Univ. Al.I.Cuza, Iasi, 2015.</li><li>7. S. Theodoridis, K. Koutroumbas, Pattern Recognition, Fourth Edition (Hardcover), Academic Press, 2009</li></ol>		

## 9. Evaluare

Tip activitate	9.1 Criterii de evaluare	9.2 Metode de evaluare	9.3 Pondere din nota finală
9.4 Curs	Participare activă	Evaluare orală continuă pe parcursul semestrului	10%
9.5 Aplicații*	Interes și capacitate de lucru pentru studiu individual și în echipă	Teme de casă prezentate pe parcursul semestrului	30%
		Prezentarea unui proiect	25%
Examen	Cunoașterea și înțelegerea noțiunilor discutate	Prezentarea unui proiect	25%



**UOC-PO-10 Anexa 3a**

<i>Din oficiu</i>	10%
9.6 Standard minim de performanță / Condiții de promovare - Nota 5 (din 10)	
Cunoașterea (explicații și implementare/apel comenzi Python) a principalilor clasificatori și regresori studiați.	

*\*Se alege tipul de aplicație aferent disciplinei (Seminar/Laborator/Proiect)*

Data completării,  
12.09.2025

Titular activităților de curs,  
Conf.univ.dr. Elena Pelican

Titular aplicații,  
Conf.univ.dr. Elena Pelican

Data avizării în Departament,  
19.09.2025

Director de Departament,  
Conf.univ.dr. Elena Pelican

Decan,  
Conf.univ.dr. Aurelian Nicola