

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea Politehnica Timișoara
1.2 Facultatea ¹ / Departamentul ²	Electronica, Telecomunicații și Tehnologii Informaționale / Electronică Aplicată
1.3 Domeniul de studii (denumire/cod ³)	Inginerie Electronica, Telecomunicații și Tehnologii Informaționale / 20.20.10
1.4 Ciclul de studii	Master
1.5 Programul de studii (denumire/cod/calificarea)	Ingineria datelor / 20.20.10.238 / Ingineria datelor

2. Date despre disciplină

2.1a Denumirea disciplinei/Categoria formativă ⁴	Sisteme cu învățare automată / DF						
2.1b Denumirea disciplinei în limba engleză	Machine Learning						
2.2 Titularul activităților de curs	Conf.dr.ing. Georgiana Simion						
2.3 Titularul activităților aplicative ⁵	Conf.dr.ing. Gerogiana Simion						
2.4 Anul de studiu ⁶	1	2.5 Semestrul	2	2.6 Tipul de evaluare	E	2.7 Regimul disciplinei ⁷	DOP

3. Timp total estimat - ore pe semestru (activități directe (asistate integral), activități asistate parțial și activități neasistate⁸)

3.1 Număr de ore asistate integral/săptămână	4 , din care:	ore curs	2	ore seminar/laborator/proiect			0 / 1 / 1
3.1* Număr total de ore asistate integral/sem.	56 , din care:	ore curs	28	ore seminar/laborator/proiect			0 / 14 / 14
3.2 Număr total de ore desfășurate on-line asistate integral/sem.	24 , din care:	ore curs	16	ore seminar/laborator/proiect			0 / 0 / 8
3.3 Număr de ore asistate parțial/săptămână	, din care:	ore proiect, cercetare		ore practică		ore elaborare lucrare de disertație	
3.3* Număr total de ore asistate parțial/semestru	, din care:	ore proiect cercetare		ore practică		ore elaborare lucrare de disertație	
3.4 Număr de ore activități neasistate/săptămână	4.9 , din care:	ore documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					1
		ore studiu individual după manual, suport de curs, bibliografie și notițe					1.9
		ore pregătire seminarii/laboratoare, elaborare teme de casă și referate, portofolii și eseuri					2
3.4* Număr total de ore activități neasistate/ semestru	69 , din care:	ore documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					28
		ore studiu individual după manual, suport de curs, bibliografie și notițe					27
		ore pregătire seminarii/laboratoare, elaborare teme de casă și referate, portofolii și eseuri					14
3.5 Total ore/săptămână ⁹	8.9						
3.5* Total ore/semestru	125						
3.6 Număr de credite	5						

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Matematică Algebra liniară: matrici, vectori, operații, Calcul diferențial și integral, Probabilități
4.2 de rezultate ale învățării	Python

5. Condiții (acolo unde este cazul)

5.1 de desfășurare a cursului	• Laptop, videoproiector, tabletă, tablă/tabla inteligentă
5.2 de desfășurare a activităților practice	• Laborator cu 8 stații echipate cu PC

6. Rezultatele învățării la formarea cărora contribuie disciplina

Cunoștințe	• C1. Studentul/absolventul explică concepte avansate și interdisciplinare din ingineria datelor (big data, machine learning, cloud computing, vizualizare date). • C2. Studentul/absolventul analizează tehnologii, metode și algoritmi specifici procesării de date masive. • C3. Studentul/absolventul explică fundamentele statistice și matematice ale învățării automate și ale modelării datelor. •
Abilități	• A1. Studentul/absolventul aplică metode ingineresti pentru colectarea, procesarea și vizualizarea datelor. • A2. Studentul/absolventul dezvoltă aplicații software scalabile pentru analiza datelor. • A4. Studentul/absolventul utilizează modele predictive și algoritmi de învățare automată pentru extragerea de informații utile. • A5. Studentul/absolventul evaluează calitatea și consistența datelor utilizate în aplicații reale.
Responsabilitate și autonomie	• R1. Studentul/absolventul gestionează proiecte complexe de analiză și prelucrare a datelor. • R3. Studentul/absolventul ia decizii strategice și tehnice bazate pe analiza datelor.

7. Obiectivele disciplinei (asociate rezultatelor învățării specifice acumulate)

- Familiarizarea studenților cu conceptele specifice sistemelor cu învățare automată
- La absolvirea cursului, studenții vor avea cunoștințele, expertiza și deprinderile necesare prelucrării, analizei, vizualizării, clasificării și evaluării datelor

8. Conținuturi

8.1 Curs	Număr de ore	Din care on-line	Metode de predare
Introducere în sisteme cu învățare automată (învățare supervizată, nesupervizată, învățare prin întărire). Procesarea datelor (medie, mediană, deviație standard, varianță, normalizare și standardizare, tratarea valorilor lipsă, detectarea și eliminarea valorilor aberante). Regularizare și optimizare (supraantrenarea, subantrenarea, optimizarea funcției obiectiv; , gradient descendent, metoda lui Newton, Adam, RMSProp) Evaluarea modelelor (Estimarea și selecția unui model, matricea de confuzie, metrici de performanță: acuratețe, precizie, recall, F1-score)	8	4	Tabla, Tableta, Campus Virtual, Videoproiector
Regresie (liniară, logistică)	3	3	
Metoda celor mai apropiați k vecini (KNN). Arbori de decizie, Algoritmul Random Forest. Modele Markov ascunse. Mașinii cu suport vectorial (SVM).	10	5	

Clustering: Algoritmul k-medii (K-means), DBSCAN, Mean-Shift clustering, Gaussian Mixture Models (GMM), Hierarchical Clustering	4	4	
Învățarea în ansambluri (ensemble learning)	3		
Bibliografie ¹⁰ Andrew Ng, Machine Learning, Stanford, http://openclassroom.stanford.edu/MainFolder/CoursePage.php?course=MachineLearning M. Kirk, Thoughtful Machine Learning with Python, O'Reilly, 2017			
8.2 Activități aplicative¹¹	Număr de ore	Din care on-line	Metode de predare
Unelte software pentru sisteme cu învățare automată	2		Tabla, Tableta, Campus Virtual, Videoproiector
Regresia liniară și logistică	2		
Metoda celor mai apropiați k vecini	2		
Arbori de decizie	2		
Sisteme cu suport vectorial - SVM	2		
Algoritmi de clustering : Algoritmul k-medii,), DBSCAN etc.	2		
Învățarea în ansambluri (bagging , boosting, AdaBoost, Gradient Boosting, XGBoost / LightGBM / CatBoost	2		
Proiect aplicat	14	8	
Bibliografie ¹² Armando Fandango, Python Data Analysis - Second Edition, 2017 Packt Publishing Aurélien Géron, Hands-On Machine Learning with Scikit-Learn and TensorFlow, O'Reilly, 2017 Prateek Joshi, Artificial Intelligence with Python, Packt Publishing, 2017. Nick McClure, TensorFlow Machine Learning Cookbook, Packt Publishing, 2017			

9. Evaluare

Tip activitate	9.1 Criterii de evaluare ¹³	9.2 Metode de evaluare	9.3 Pondere din nota finală
9.4 Curs	Teorie	Evaluare pe Campusul Virtual	1/2
9.5 Activități aplicative	S:		
	L: Media aritmetica a notelor de la laborator	Implementare algoritmi	1/4
	P: Prezentare proiect	Implementare algoritmi și prezentare concluzii	1/4
	Pr:		
	Tc-R¹⁴:		
9.6 Standard minim de performanță (volumul de cunoștințe minim necesar pentru promovarea disciplinei și modul în care se verifică stăpânirea lui) ¹⁵			
Nota minimă 5 la toate activitățile			

Data completării

05.10.2025

**Titular de curs
(semnătura)**

**Titular activități aplicative
(semnătura)**

**Director de departament
(semnătura)**

Data avizării în Consiliul Facultății¹⁶

07.10.2025

**Decan
(semnătura)**