FIŞA DISCIPLINEI

1. Date despre program

1.1 Instituţia de învăţământ 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)	Electronică Biomedicală/20.20.10.2152

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 activităţilor de curs			Conf.dr.ing. Georgiana Simion				
2.3 Titularul activităţilor aplicative[5]			Conf.dr.ing. Georgiana 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 neasistate[8])

3.1 Număr de ore asistate integral/săptămână	4 , din care:	ore curs	2	ore seminar/laborator/proiect			2
3.1* Număr total de ore asistate integral/sem.	56 , din care:	ore curs	28	ore seminar/laborator/proiect			28
3.2 Număr total de ore desfășurate on-line asistate integral/sem.	, din care:	ore curs		ore seminar/laborator/proiect			
3.3 Număr de ore asistate parțial/saptămână	, 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. Precondiţii (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. Condiţii (acolo unde este cazul)

5.1 de desfăşurare a cursului	• Laptop, videoproiector, tabletă, tablă/tablă inteligentă

5.2 de desfăşurare a activităţilor practice	• Laborator cu 8 stații echipate cu PC

6. **Rezultatele învățării** la formarea cărora contribuie disciplina

Cunoștințe	• C9. Studentul/absolventul cunoaște tehnici de analiză exploratorie și vizualizare a datelor pentru identificarea pattern-urilor și corelațiilor. • C10. Studentul/absolventul cunoaște concepte și metodologii pentru validarea modelelor analitice. • C12. Studentul/absolventul structurează și redactează documentație tehnică, rapoarte, prezentări, precum și articole științifice, de cercetare.
Abilități	• A6. Studentul/absolventul dezvoltă algoritmi avansați pentru procesarea semnalelor, control și comunicare în sistemele electronice. • A8. Studentul/absolventul realizează simulări complexe pentru evaluarea performanței și validarea modelelor, facilitând identificarea unor soluții inovatoare • A9. Studentul/absolventul automatizează procesele de simulare și interpretare a rezultatelor pentru accelerarea procesului de cercetare și dezvoltare..
Responsabilitate și autonomie	• RA3. Studentul/absolventul are autonomie în gestionarea resurselor, direcționarea echipei multidisciplinare și adoptarea unor soluții tehnice. • RA5. Studentul/absolventul este responsabil pentru acuratețea și validitatea modelelor și simulărilor realizate. • RA7. Studentul/absolventul este responsabil pentru gestionarea etică a datelor și rezultatelor, asigurând reproducibilitatea și transparența actului de cercetare, precum și pentru raportarea și prezentarea rezultatelor într-un mod clar. • RA8. Studentul/absolventul îți asumă răspunderea pentru integritatea și confidențialitatea datelor analizate cu respectarea normelor etice și legale privind manipularea și stocarea datelor sensibile..

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. **Conţinuturi**

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 si 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 apropiati 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 Activităţi aplicative[11]	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 Activităţi 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-R[14]:		
9.6 Standard minim de performanţă (volumul de cunoştinţe minim necesar pentru promovarea disciplinei şi modul în care se verifică stăpânirea lui)[15]			
• Nota minimă 5 la toate activitățile			

Data completării	Titular de curs (semnătura)	Titular activităţi aplicative (semnătura)
11.09.2026		

Director de departament (semnătura)	Data avizării în Consiliul Facultăţii[16]	Decan (semnătura)
	22.09.2026	