

FIȘA DISCIPLINEI

Anul universitar 2024 - 2025

1. Date despre program

1.1. Instituția de învățământ superior	Universitatea Lucian Blaga din Sibiu
1.2. Facultatea	Științe
1.3. Departament	Departamentul de Matematică și Informatică
1.4. Domeniul de studiu	Informatică
1.5. Ciclu de studii ¹	Master
1.6. Specializarea	Sisteme si Tehnologii Informatice Avansate (STIA)

2. Date despre disciplină

2.1. Denumirea disciplinei	Machine Learning (Invatare automata)			Cod	FSTI.MAI.STIA.M.SO. 1.2020.E-7.3
2.2. Titular activități de curs	Prof. Univ. Dr. Dana Simian				
2.3. Titular activități practice	Prof. Univ. Dr. Dana Simian				
2.4. An de studiu ²	1	2.5. Semestrul ³	1	2.6. Tipul de evaluare ⁴	E
2.7. Regimul disciplinei ⁵	O	2.8. Categoria formativă a disciplinei ⁶	S		

3. Timpul total estimat

3.1. Extinderea disciplinei în planul de învățământ – număr de ore pe săptămână					
3.1.a.Curs	3.1.b. Seminar	3.1.c. Laborator	3.1.d. Proiect	3.1.e Alte	Total
2	-	2	-	-	4
3.2. Extinderea disciplinei în planul de învățământ – total ore din planul de învățământ					
3.2.a.Curs	3.2.b. Seminar	3.2.c. Laborator	3.2.d. Proiect	3.2.e Alte	Total ⁷
28	0	28	0	0	56
Distribuția fondului de timp pentru studiu individual⁸					Nr. ore
Studiul după manual, suport de curs, bibliografie și notițe					20
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					15
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					66
Tutoriat ⁹					14
Examinări ¹⁰					4
3.3. Total ore alocate studiului individual¹¹ (NOS_{sem})					119
3.4. Total ore din Planul de învățământ (NOAD_{sem})					56
3.5. Total ore pe semestru¹² (NOAD_{sem} + NOS_{sem})					175
3.6. Nr ore / ECTS					25
3.7. Număr de credite¹³					7

4. Precondiții (acolo unde este cazul)

4.1. Discipline necesar a fi promovate anterior (de curriculum) ¹⁴	-
4.2. Competențe	-

5. Condiții (acolo unde este cazul)

5.1. De desfășurare a cursului ¹⁵	Sală de curs, dotată cu tablă, calculator, videoproiector și software specific (Adobe Reader, PowerPoint, Python, Jupyter Notebook), coonexiune internet, classroom aferent disciplinei (curs si laborator), meet (pentru desfasurarea consultatiilor, discutiilor, sau o desfasurare online a cursului in cazul unor conditii speciale)
5.2. De desfășurare a activităților practice (lab/sem/pr/alte) ¹⁶	Sală de laborator, dotată cu tablă, calculatoare, videoproiector și software specific (Adobe Reader, PowerPoint, Python, Jupyter Notebook), coonexiune internet, Classroom aferent disciplinei (curs si laborator),,, meet (pentru desfasurarea consultatiilor, discutiilor, sau o desfasurare online a laboratorului in cazul unor conditii speciale)

6. Competențe specifice acumulate¹⁷

Număr de credite alocat disciplinei ¹⁸		7	Repartizare credite pe competențe ¹⁹
6.1. Competențe profesionale	CP1	Cunoașterea și utilizarea adecvată a noțiunilor teoretice fundamentale legate de învățarea inductivă supervizată	6
	CP2	Capacitatea de a explica modul de construcție a diferiților clasificatori si regresori	
	CP3	Capacitatea de a interpreta rezultatele obținute	
	CP4	Capacitatea de a implementa algoritmi de clasificare si regresie si de a modifica conform cerințelor algoritmi deja implementați	
6.2. Competențe transversale	CT1	Exprimarea unui mod de gândire creativ in structurarea si rezolvarea problemelor.	1
	CT2	Dezvoltarea spiritului de muncă în echipă	
	CT3	Dezvoltarea capacităților de abordare de taskuri cu deadline strict precizat	
	CT4	Manifestarea inițiativei si disponibilității de a aborda sarcini variate.	
	CT5	Dezvoltarea capacităților de documentare individuală	

7. Obiectivele disciplinei (reieșind din grila competențelor specifice acumulate)

7.1. Obiectivul general	Înțelegerea principiilor de baza precum si utilizarea practica a principalelor tehnici de invatare automata Cunoasterea stadiului curent al cercetărilor in domeniul Machine Learning pentru a putea realiza o activitate de cercetare in acest domeniu.
7.2. Obiectivele specifice	Implementarea principalilor algoritmi de învățare automată pe baza unor biblioteci existente precum si de la zero. Realizarea unui proiect complex care sa acopere toți pașii caracteristici lucrului cu



	tehnici de ML
--	---------------

8. Conținuturi

8.1. Curs ²⁰	Metode de predare ²¹	Nr. ore	
Curs 1-2. Noțiuni de bază în învățarea automată (ML). ML blackbox.	Expunerea sistematică a cunoștințelor (deductivă, inductivă și formalizată, expuneri la tablă/ in meet); Conversația frontală; Conversație individuală; Conversația euristică; Problematizare; Studii de caz; Design de proiecte complexe; Învățarea prin descoperire. Discuții și explicații pe proiecte complexe	4	
Curs 3. Învățarea conceptelor		2	
Curs 4-5. Arbori de decizie		4	
Curs 6-7. Rețele neuronale		4	
Curs 8. Deep learning. Rețele convoluționare		2	
Curs 9-10. Mașini vector suport (SVM).		4	
Curs 11. Învățare Bayesiană		2	
Curs 12. Reinforcement learning		2	
Curs 13. Tehnici hibride de învățare automată. Optimizarea alegerii parametrilor în algoritmi de ML. Feature selection		2	
Curs 14. Overview asupra altor metode de ML (Ensemble Learning, kNearest Neighbors)		2	
Total ore curs:		28	



8.2. Activități practice (8.2.a. Seminar ²² / 8.2.b. Laborator ²³ / 8.2.c. Proiect ²⁴ / 8.2.d. Alte act.practice ²⁵)	Metode de predare	Nr. ore
Lab.1. Noțiuni de bază în învățarea automată. Noțiuni de bază Python, Jupyter Notebook, principalele librării din Pyhon. Enunțare și explicare teme practice de laborator	Conversația frontală; Conversație individuală; Problematizare;	2
Lab.2 Date, analiză și vizualizare în Python și scikit-learn. Enunțare și explicare temă proiect	Studii de caz; Design de proiecte	2
Lab.3 Învățarea conceptelor. Exerciții și implementări from scrach și folosind scikit-learn.	complexe; Modelare folosind calculatorul	2
Lab.4 Arbori de decizie. Exerciții și implementări from scrach și folosind scikit-learn		2
Lab 5-6. Rețele neuronale. Exerciții și implementări from scrach și folosind scikit-learn. Optimizarea parametrilor		4
Lab.7 Deep learning. Exemple practice de probleme rezolvate folosind deep learning		2
Lab.8 Analiză proiect și teme pentru evaluarea finală. Exerciții și implementări from scrach și folosind scikit-learn. Evaluarea și compararea clasificatorilor învățați, pe problema din proiect		2
Lab.9-10 Învățare Bayesiană. Exerciții și implementări from scrach și folosind scikit-learn. Aplicarea tehnicii la proiect		2
Lab.11-12 Mașini vector suport (SVM). Exerciții și implementări from scrach și folosind scikit-learn. Optimizarea parametrilor. Aplicarea tehnicii la proiect		4
Lab.13 Ensemble learning. Aplicarea tehnicii la proiect. Probleme complexe reale.		4
Lab.14 Discuții pe proiecte		2
Total ore seminar/laborator		28

9. Bibliografie

9.1. Referințe bibliografice recomandate	<ol style="list-style-type: none"> 1. Dana Simian – Machine Learning an introductory course (slides) – disponibile pe classroom 2. Dana Simian – Machine Learning. Notițe de curs (suport electronic) - disponibil pe classroom 3. Jake VanderPlas - Python Data Science Handbook https://jakevdp.github.io/PythonDataScienceHandbook/ 4. Tom Mitchell, Machine Learning, McGraw Hill http://www.cs.cmu.edu/~tom/ 5. Python Machine Learning Library – Scikit-learn library http://scikit-learn.org/stable/ 6. Mia Williams, Fundamentals of Machine Learning, Willford Press 2022
9.2. Referințe bibliografice suplimentare	<ol style="list-style-type: none"> 1. Andrew Ng – Machine learning, Coursera-online 2. Nilsson, N., Introduction to Machine Learning, Stanford University, 1996 3. Cristian, N., Support Vector and Kernel Machines, BIOwulf Technologies, 2001 4. Gabriela Czibula, Sisteme inteligente. Instruire automată, Ed. Risoprint, Cluj-Napoca, 2008



10. Coroborarea conținuturilor disciplinei cu așteptările reprezentanților comunității epistemice, asociațiilor profesionale și angajatorilor reprezentativi din domeniul aferent programului²⁶

Învățarea automată se folosește de către majoritatea sistemelor inteligente integrate (in industria automotive, la recunoașterea sunetelor, imaginilor, etc). Este un domeniu esențial în cadrul tematicii actuale „smart”. Toate firmele cu care colaboram au subiecte de cercetare si de activitate care se preteaza a fi rezovate folosind tehnici de Machine Learning.

Coroborarea conținuturilor disciplinei se realizează prin contacte periodice cu reprezentantii companiilor de profil in vederea analizei problemelor specifice. Învățarea automată se folosește de către majoritatea sistemelor inteligente integrate (in industria automotive, la recunoașterea sunetelor, imaginilor, etc). Este un domeniu esențial în cadrul tematicii actuale „smart”. Toate firmele cu care colaboram au subiecte de cercetare si de activitate care se preteaza a fi rezovate folosind tehnici de Machine Learning

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare	11.3 Pondere din nota finală	Obs. ²⁷
11.1a Examen	- corectitudinea și completitudinea cunoștințelor asimilate; - capacitatea de sinteza a cunostintelor dobandite; - o înțelegere de ansamblu a importanței disciplinei studiate și a legăturii cu celelalte discipline fundamentale	Evaluare finală scrisa	40%	CPE CEF
11.4c Laborator	- capacitatea de aplicare în practică a cunoștințelor teoretice; - capacitatea de a replica exemple facute pentru probleme similare; - capacitatea de generalizare; - abilitatea de a alege, implementa și compara tehnicile (algoritmii) de ML pentru o problemă dată; - activitate de cercetare științifică în domeniu; - criterii ce vizează aspectele atitudinale: seriozitatea, interesul pentru studiul individual; Rigoarea științifică a limbajului.	Teme laborator, evaluari pe parcurs	10%	CPE CEF
		Proiect individual	50%	CPE CEF
<ul style="list-style-type: none"> 11.5 Standard minim de performanță²⁸: Cunoașterea noțiunilor de bază din învățarea supervizată. Cunoașterea principiilor de lucru a tehnicilor ML studiate. Capacitatea de a pune o pb. practică într-o formă acceptată de algoritmii ML. Capacitatea de a utiliza tehnicile studiate folosind functii din biblioteci existente Realizarea în proporție de cel 				



puțin 50% a proiectului final de laborator

- Toate aceste cerințe se reflectă în modul de notare pentru a obține nota minimă 5.

Fișa disciplinei cuprinde componente adaptate persoanelor cu CES (persoane cu dizabilități și persoane cu potențial înalt), în funcție de tipul și gradul acestora, la nivelul tuturor elementelor curriculare (competențe, obiective, conținuturi, metode de predare, evaluare alternativă), pentru a asigura șanse echitabile în pregătirea academică a tuturor studenților, acordând atenție sporită nevoilor individuale de învățare.

Data completării: |_0_|_5_| / |_0_|_9_| / |_2_|_0_|_2_|_4_|

Data avizării în Departament: |_1_|_7_| / |_0_|_9_| / |_2_|_0_|_2_|_4_|

	Grad didactic, titlul, prenume, numele	Semnătura
Titular disciplină	Prof. Dr. Dana Simian	
Responsabil program de studii	Conf. Dr. Florin Stoica	
Director Departament	Prof. Dr. Mugur Acu	

¹ Licență / Master

² 1-4 pentru licență, 1-2 pentru master

³ 1-8 pentru licență, 1-3 pentru master

⁴ Examen, colocviu sau VP A/R – din planul de învățământ

⁵ Regim disciplină: O=Disciplină obligatorie; A=Disciplină opțională; U=Facultativă

⁶ Categoria formativă: S=Specialitate; F=Fundamentală; C=Complementară; I=Asistată integral; P=Asistată parțial; N=Neasistată

⁷ Este egal cu 14 săptămâni x numărul de ore de la punctul 3.1 (similar pentru 3.2.a.b.c.d.e.)

⁸ Linile de mai jos se referă la studiul individual; totalul se completează la punctul 3.37.

⁹ Între 7 și 14 ore

¹⁰ Între 2 și 6 ore

¹¹ Suma valorilor de pe liniile anterioare, care se referă la studiul individual.

¹² Suma (3.5.) dintre numărul de ore de activitate didactică directă (NOAD) și numărul de ore de studiu individual (NOSI) trebuie să fie egală cu numărul de credite alocate disciplinei (punctul 3.7) x nr. ore pe credit (3.6.)

¹³ Numărul de credit se calculează după formula următoare și se rotunjește la valori vecine întregi (fie prin micșorare fie prin majorare)

$$\text{Nr. credite} = \frac{\text{NOCpSpD} \times C_C + \text{NOApSpD} \times C_A}{\text{TOCpSdP} \times C_C + \text{TOApSdP} \times C_A} \times 30 \text{ credite}$$

Unde:

- NOCpSpD = Număr ore curs/săptămână/disciplina pentru care se calculează creditele
- NOApSpD = Număr ore aplicații (sem./lab./pro.)/săptămână/disciplina pentru care se calculează creditele
- TOCpSdP = Număr total ore curs/săptămână din plan
- TOApSdP = Număr total ore aplicații (sem./lab./pro.)/săptămână din plan
- C_C/C_A = Coeficienți curs/aplicații calculate conform tabelului

Coeficienți	Curs	Aplicații (S/L/P)
Licență	2	1
Master	2,5	1,5
Licență lb. străină	2,5	1,25

¹⁴ Se menționează disciplinele obligatoriu a fi promovate anterior sau echivalente

¹⁵ Tablă, videoproiector, flipchart, materiale didactice specifice, platforme on-line etc.

¹⁶ Tehnică de calcul, pachete software, standuri experimentale, platforme on-line etc.

¹⁷ Competențele din Grilele aferente descrierii programului de studii, adaptate la specificul disciplinei

¹⁸ Din planul de învățământ

¹⁹ Creditele alocate disciplinei se distribuie pe competențe profesionale și transversale în funcție de specificul disciplinei

²⁰ Titluri de capitole și paragrafe

²¹ Expunere, prelegere, prezentare la tablă a problematicii studiate, utilizare videoproiector, discuții cu studenții (pentru fiecare capitol, dacă este cazul)

²² Discuții, dezbateri, prezentare și/sau analiză de lucrări, rezolvare de exerciții și probleme etc.

²³ Demonstrație practică, exercițiu, experiment etc.

²⁴ Studiu de caz, demonstrație, exercițiu, analiza erorilor etc.

²⁵ Alte tipuri de activități practice specifice

²⁶ Legătura cu alte discipline, utilitatea disciplinei pe piața muncii

²⁷ CPE – condiționează participarea la examen; nCPE – nu condiționează participarea la examen; CEF - condiționează evaluarea finală; N/A – nu se aplică

²⁸ Se particularizează la specificul disciplinei standardul minim de performanță din grila de competențe a programului de studii, dacă este cazul.