

Fișa disciplinei

1. Date despre program

1.1. Instituția de învățământ	ACADEMIA DE STUDII ECONOMICE
1.2. Facultatea	CIBERNETICĂ, STATISTICĂ ȘI INFORMATICĂ ECONOMICĂ
1.3. Departamente	(Departament) INFORMATICA SI CIBERNETICA ECONOMICA
1.4. Domeniul de studii	Informatică economică
1.5. Ciclul de studii	MASTERAT
1.6. Forma de învățământ	CU FRECVENȚĂ
1.7. Programul de studii	Tehnologii informatice pentru ingineria datelor
1.8. Limba de studiu	Română
1.9. Anul universitar	2025-2026

2. Date despre disciplina

2.1. Denumire	Tehnici de învățare automată și aplicații									
2.2. Cod	25.0319IF1.2-0001									
2.3. Anul de studii	1	2.4. Semestrul	2	2.5. Forma de evaluare	Examen	2.6. Regimul disciplinei	O (Obligato riu)	2.7. Nr. credite ECTS	8	
2.8. Titulari	C(C)	prof.univ.dr. FURTUNĂ Titus Felix					felix.furtuna@ie.ase.ro			
	S(S)	prof.univ.dr. FURTUNĂ Titus Felix					felix.furtuna@ie.ase.ro			

3. Timp total estimat

3.1. Număr de săptămâni	14.00
3.2. Număr de ore pe săptămână	4.00 din care
	S(S) 2.00
	C(C) 2.00
3.3. Total ore din planul de învățământ	56.00 din care
	S(S) 28.00
	C(C) 28.00
3.4. Total ore de studiu pe semestru (număr ECTS*25 ore)	200.00
3.5. Total ore studiu individual	144.00
<i>Distribuția fondului de timp pentru studiu individual</i>	
Studiu după manual, suport de curs, bibliografie și notițe	56.00
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren	25.00
Pregătire seminarii, laboratoare, teme, referate, portofolii și eseuri	42.00
Tutoriat	14.00
Examinări	2.00
Alte activități	5.00

4. Precondiții

4.1. de curriculum	Programare avansată pentru ingineria datelor Matematică aplicată și analiza datelor
4.2. de competențe	- Concepte de bază din statistică, statistică-matematică și analiza datelor - Elemente de bază de algebră liniară - Abilitate în programarea calculatoarelor - Elemente de algoritmică - Elemente de bază din limbajul Python

5. Condiții desfășurare activități

pentru S(S)	Seminariile se desfășoară în săli cu calculatoare pe care există software de specialitate
pentru C(C)	Cursurile se vor desfășura în săli cu videoproiector

6. Competențe specifice acumulate

PROFESIONALE	CC1	Competențe digitale – utilizarea avansată a instrumentelor și platformelor software, dezvoltarea de aplicații software pe diferite platforme.
PROFESIONALE	CP3	Utilizarea tehnicilor bazate pe algoritmi de inteligență artificială pentru procesarea și extragerea de noi cunoștințe din date
PROFESIONALE	CP5	Implementarea de soluții software pentru prelucrarea datelor folosind tehnici de ML și DL

7. Obiectivele disciplinei

7.1. Obiectivul general	Dezvoltarea cunoștințelor și formarea abilităților necesare pentru implementarea și utilizarea eficientă a tehnicilor de învățare automată în principal în domeniile social și economic dar și în alte domenii de activitate.
7.2. Obiective specifice	A7. Studentul/Absolventul dezvoltă și testează aplicații software utilizând tehnologii moderne (web, mobile, multimedia) pentru a implementa soluții inovative în domeniul economic. A8. Studentul/Absolventul optimizează și validează algoritmi și paradigme de programare pentru a îmbunătăți performanța, scalabilitatea și calitatea aplicațiilor informatice. RA7. Studentul/Absolventul răspunde de dezvoltarea și implementarea aplicațiilor informatice bazate pe tehnologii moderne, asigurând inovarea și adaptabilitatea soluțiilor economice. RA8. Studentul/Absolventul gestionează procese de evaluare și optimizare a algoritmilor și aplicațiilor informatice, garantând performanța și calitatea soluțiilor software.

8. Conținuturi

8.1. C(C)		Metode de predare/ lucru	Recomandări
1	Analiza exploratorie a datelor. Reducerea dimensionalității. Metode clasice de reducere a dimensionalității datelor: Analiza factorială, Analiza în componente principale (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1-5
2	Analiza exploratorie a datelor. Reducerea dimensionalității: Extragerea caracteristicilor esențiale - Non Negative Matrix Factorization (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
3	Analiza exploratorie a datelor. Alte metode de reducere a dimensionalității: Scalarea multidimensională, ICA - Analiza componentelor independente, k-SVD, Kernel PCA (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
4	Metode de învățare supervizată. Analiza și evaluarea algoritmilor de clasificare supervizată. Selecția atributelor în modelele de învățare supervizată - algoritmul Weights of Evidence & Information Value (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1-4
5	Metode de învățare supervizată. Arbori de decizie. (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
6	Metode de învățare supervizată. Algoritmii Random Forest. Algoritmi bazați pe proximitate - kNN. (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
7	Metode de învățare supervizată. Modele stohastice - modelul Bayesian (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1-4
8	Metode de învățare supervizată. Vectori suport - SVM (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
9	Metode de învățare supervizată. Regresia liniară. Regresia logistică. Modelul liniar generalizat. Învățare sensibilă la raritate: Regresia Lasso. (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
10	Învățare nesupervizată. Algoritmi ierarhici. Partiționarea optimă: algoritmi Silhouette și Elbow (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1-4
11	Învățare nesupervizată. Algoritmi de partiționare - kMeans, BisectingKMeans. (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
12	Învățare nesupervizată. Algoritmi bazați pe densitate - DBSCAN. Algoritmii Expectation Maximization (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
13	Învățare nesupervizată. Algoritmi de tip grid - OptiGrid, OCluster (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1,3,4
14	Studiul asocierilor. Algoritmii Apriori (A7, A8, RA7, RA8)	Prelegere interactivă susținută de prezentare multimedia (2h)	Consultarea platformei online.ase.ro Referințe bibliografice 1

Bibliografie

- Titus Felix Furtună, Tehnici de învățare automată și aplicații, <https://online.ase.ro>, România
- Claudiu Vințe, Titus Felix Furtună, Multivariate Data Analysis in Python, ASE, București, 2023, România
- Andreas C. Muller, Sarah Guido, Introduction to machine learning with Python : a guide for data scientists, O'Reilly Media, 2017, Biblioteca ASE, Statele Unite ale Americii
- Sebastian Raschka, Vahid Mirjalili, Python machine learning : machine learning and deep learning with Python, Packt Publishing, Birmingham , 2019, Biblioteca ASE, Marea Britanie

8.2. S(S)		Metode de predare/ lucru	Recomandări
1	Studiu de caz pentru reducerea dimensionalității și sintetizarea informației în tabelele de mari dimensiuni. Utilizarea modulelor Python sklearn.decomposition si factor-analyzer. Analiză factorială și analiză în componente principale. (A7, A8, RA7, RA8)	Prezentare și implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs și seminar/laborator

2	Studiu de caz pentru reducerea dimensionalității și sintetizarea informației în tabelele de mari dimensiuni. Extragerea caracteristicilor esențiale - Non Negative Matrix Factorization. (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
3	Studiu de caz pentru alte metode de reducere a dimensionalității: Scalarea multidimensională, ICA - Analiza componentelor independente, k-SVD, Kernel PCA (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
4	Studiu de caz pentru metode de învățare supervizată. Arbori de decizie. (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
5	Studiu de caz pentru metode de învățare supervizată. Algoritmul Random Forest. Algoritmi bazați pe proximitate - kNN. (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
6	Studiu de caz pentru metode de învățare supervizată. Modele stohastice - modelul Bayesian. (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
7	Studiu de caz pentru metode de învățare supervizată. Modelul SVM. (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
8	Metode de învățare supervizată. Analiza și evaluarea algoritmilor de clasificare supervizată. Selecția atributelor în modelele de învățare supervizată - algoritmul Weights of Evidence & Information Value (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
9	Studiu de caz pentru metode de învățare supervizată. Regresia liniară. Regresia logistică. Modelul liniar generalizat. învățare sensibilă la raritate: Regresia Lasso. (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
10	Studiu de caz pentru învățare nesupervizată. Algoritmi ierarhici. Partiționarea optimală: algoritmi Silhouette și Elbow (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
11	Studiu de caz pentru învățare nesupervizată. Algoritmi de partiționare - kMeans, BisectingKMeans. Partiționarea optimală: algoritmi Silhouette și Elbow (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
12	Studiu de caz pentru învățare nesupervizată. Algoritmi bazați pe densitate - DBSCAN. Algoritmul Expectation Maximization. Partiționarea optimală: algoritmi Silhouette și Elbow (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
13	Studiu de caz pentru învățare nesupervizată. Algoritmi de tip grid - OptiGrid, OCluster. Partiționarea optimală: algoritmi Silhouette și Elbow (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator
14	Studiu de caz. Algoritmul Apriori (A7, A8, RA7, RA8)	Prezentare si implementare studiu de caz (2h)	Se recomandă studenților parcurgerea suportului de curs si seminar/laborator

Bibliografie

- Titus Felix Furtună, Tehnici de învățare automată și aplicații, <https://online.ase.ro>, România
- Claudiu Vințe, Titus Felix Furtună, Multivariate Data Analysis in Python, ASE, București, 2023, România
- Andreas C. Muller, Sarah Guido, Introduction to machine learning with Python : a guide for data scientists, O'Reilly Media, 2017, Biblioteca ASE, Statele Unite ale Americii
- Sebastian Raschka, Vahid Mirjalili, Python machine learning : machine learning and deep learning with Python, Packt Publishing, Birmingham , 2019, Biblioteca ASE, Marea Britanie
- Wes McKinney, Python for Data Analysis, O'Reilly Media, 2018, Biblioteca ASE, Statele Unite ale Americii

9. Coroborarea conținuturilor disciplinei cu așteptările reprezentanților comunității epistemice, asociațiilor profesionale și angajatori reprezentativi din domeniul aferent programului

Conținutul temelor aferente activităților de curs și de seminar este strâns corelat cu realitatea practică și a fost elaborat pe baza recomandărilor reprezentanților mediului de business,

10. Evaluare

Activitatea	Criterii de evaluare	Metode de evaluare	Pondere în nota finală
10.1. S(S)	Elaborare proiect	Suținere orală a proiectului	40.00
10.2. Evaluare finală	Examen	Examen scris la calculator	60.00
10.3. Modalitatea de notare	Note întregi 1-10		
10.4. Standard minim de performanță	Nota finală calculată ca medie ponderată a notei la examen (60%) și a notei la seminar (40%) trebuie să fie cel puțin 5. Pentru a promova disciplina, studentul: - dovedește cunoașterea aspectelor teoretice și practice de bază privind algoritmi de învățare automată; - se dovedește capabil să implementeze funcționalități de bază ale algoritmilor de învățare automată; - se dovedește capabil să utilizeze algoritmi de învățare automată în realizarea unor studii de caz simple.		

Data listării,
10/07/2026

Titulari,

Data avizării în departament,

Director departament,