

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	UNIVERSITATEA “BABEȘ-BOLYAI” CLUJ-NAPOCA
1.2 Facultatea	FACULTATEA DE ȘTIINȚA ȘI INGINERIA MEDIULUI
1.3 Departamentul	ANALIZA ȘI INGINERIA MEDIULUI
1.4 Domeniul de studii	INGINERIA MEDIULUI
1.5 Ciclul de studii	LICENȚĂ
1.6 Programul de studiu / Calificarea	IM

2. Date despre disciplină

2.1 Denumirea disciplinei	Învățarea automată (ML) aplicată problemelor de mediu						
2.2 Titularul activităților de curs	CS III Dr. Mereuță Alexandru						
2.3 Titularul activităților de seminar	CS III Dr. Mereuță Alexandru						
2.4 Anul de studiu	3	2.5 Semestrul	6	2.6. Tipul de evaluare	C	2.7 Regimul disciplinei	Opt.

3. Timpul total estimat (ore pe semestru al activităților didactice)

3.1 Număr de ore pe săptămână	4	Din care: 3.2 curs	2	3.3 seminar/laborator	2
3.4 Total ore din planul de învățământ	56	Din care: 3.5 curs	28	3.6 seminar/laborator	28
Distribuția fondului de timp:					ore
Studiul după manual, suport de curs, bibliografie și notițe					18
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					10
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					10
Tutoriat					2
Examinări					2
Alte activități:					-
3.7 Total ore studiu individual	42				
3.8 Total ore pe semestru	98				
3.9 Numărul de credite	4				

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	•
4.2 de competențe	•

5. Condiții (acolo unde este cazul)

5.1 De desfășurare a cursului	• sală de curs dotată cu tablă, videoproiector și laptop
5.2 De desfășurare a seminarului/laboratorului	• sală de seminar cu calculator pentru fiecare student

6. Competențele specifice acumulate

Competențe profesionale	1. Înțelegeți conceptele și tehnicile fundamentale ML. 2. Să poată preprocesa date și să construiască modele ML. 3. Însușirea experienței practice cu bibliotecile ML Python. 4. Alegerea celui mai bun model pentru aplicațiile ML de mediu. 5. Dezvoltarea înțelegerii considerațiilor etice în aplicațiile ML. 6. Bază pentru explorarea subiectelor avansate în ML și învățare profundă.
Competențe transversale	• Creativitate și inovație. • Atitudini de comunicare și lucru în echipe interdisciplinare. • Capacitatea de a interpreta, analiza și sintetiza datele disponibile în analiza situațiilor complexe • Înțelegerea computațională a datelor. • Gândire critică și luare a deciziilor.

7. Obiectivele disciplinei (reieșind din grila competențelor acumulate)

7.1 Obiectivul general al disciplinei	• Dezvoltarea cunoștințelor de bază în Machine Learning • Instruirea, testarea, validarea și implementarea ML pentru aplicații în știința mediului
7.2 Obiectivele specifice	• Înțelegerea rolului învățării automate în analiza și modelarea sistemelor de mediu • Dezvoltarea abilităților de preprocesare și analiză a seturilor de date de mediu • Aplicarea tehnicilor de învățare automată pentru a rezolva provocările de mediu din lumea reală • Proiectarea și implementarea modelelor etice și durabile de învățare automată

8. Conținuturi

8.1 Curs	Metode de predare	Observații
1. Prezentare generală a cursului și introducere în învățarea automată • Ce este învățarea automată? • Aplicații ale ML în știința mediului. • Tipuri de ML: Învățare supravegheată, nesupravegheată, semi-supravegheată și prin întărire.	Prelegere participativă, dialogul, expunerea	
2. Preprelucrarea și explorarea datelor • Importanța calității datelor. • Gestionarea datelor lipsă, a valorilor aberante și a variabilelor categorice. • Tehnici de analiză exploratorie a datelor (EDA).	Prelegere participativă, dialogul, expunerea	
3. Învățare supravegheată I - Regresie • Regresie liniară. • Regresie polinomială. • Indicatori de performanță (MAE, MSE, R^2).	Prelegere participativă, dialogul, expunerea	
4. Învățare supravegheată II – Clasificare • Regresie logistică. • Arbori de decizie. • Indicatori de performanță (acuratețe, precizie, rechemare, scor F1, ROC-AUC).	Prelegere participativă, dialogul, expunerea	
5. Ingineria caracteristicilor • Selectarea caracteristicilor vs. extracție. • Analiza componentelor principale (PCA). • Importanța și interpretabilitatea caracteristicilor.		
6. Învățare nesupravegheată I – Grupare • Gruparea k-	Prelegere participativă, dialogul,	

Means. • Gruparea ierarhică. • Evaluarea clusterizării (scor siluetă, inerție).	expunerea	
7. Modelarea dispersiei poluanților atmosferici • Blestemul dimensionalității. • Tehnici: PCA, t-SNE.	Prelegere participativă, dialogul, expunerea	
8. Evaluarea și reglarea modelului • Tehnici de validare încrucișată. • Reglarea hiperparametrilor (căutare în grilă, căutare aleatorie). • Evitarea supraajustării și subajustării.	Prelegere participativă, dialogul, expunerea	
9. Învățarea ansamblului • Bagging (păduri aleatorii). • Boosting (Gradient Boosting, AdaBoost, XGBoost). • Modele de stivuire.	Prelegere participativă, dialogul, expunerea	
10. Introducere în învățarea profundă Noțiuni de bază despre rețelele neuronale. Propagare înainte și înapoi. Funcții de activare.	Prelegere participativă, dialogul, expunerea	
11. Subiecte și tendințe avansate în ML Învățare transferată. AI explicabil (XAI). Prezentare generală a învățării prin întărire.	Dialogul, expunerea	
12. Etică și responsabilă Prejudecăți și corectitudine în modelele ML. Preocupări legate de confidențialitatea datelor. Considerații etice în implementarea sistemelor ML.	Dialogul, expunerea	
13. Revizuirea cursului și lucrul de proiect Revizuirea conceptelor cheie. Deschideți sesiunea de întrebări și răspunsuri. Îndrumarea proiectului.	Prelegere participativă, dialogul, expunerea	
14. Prezentări de proiect și încheierea cursului Prezentări finale ale proiectelor. Evaluări și feedback de la egal la egal. Încheierea cursului.	Evaluare	

Bibliografie

1. Cambridge University Press , 2023, Dive into Deep Learning;
<https://d2l.ai/index.html>
2. O'Reilly Media, 2019, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, 2nd Edition;
3. Packt Publishing, 2022, Machine Learning with PyTorch and Scikit-Learn, Develop machine learning and deep learning models with Python;
4. Elsevier Science, 2023, Artificial Intelligence in Earth Science, Best Practices and Fundamental Challenges;
5. Wiley, 2021, Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science and Geosciences;
6. Springer, 2022, Introduction to Python in Earth Science Data Analysis
From Descriptive Statistics to Machine Learning;
7. Springer, 2021, Python Recipes for Earth Sciences;
8. Springer, 2023, Machine Learning for Earth Sciences, Using Python to Solve Geological Problems;
9. The MIT Press, 2020, Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies, 2nd Edition;

8.2 Seminar / laborator	Metode de predare	Observații
1. Configurarea mediului (Anaconda, Jupyter Notebook, biblioteci Python esențiale). Primul hands-on: Exemplu de regresie liniară folosind scikit-learn.	Programare practică Explicație Brainstorming	
2. Preprocesarea datelor cu Pandas și NumPy. EDA cu Matplotlib și Seaborn.	Programare practică Explicație Brainstorming	
3. Implementarea modelelor de regresie pe seturi de date de mediu din lumea reală. Scalarea și normalizarea caracteristicilor.	Programare practică Explicație Brainstorming	

4. Clasificarea pe seturi de date (de exemplu, clasificarea acoperirii terenurilor, identificarea speciilor). Evaluarea modelelor folosind matrice de confuzie și curbe ROC.	Programare practică Explicație Brainstorming	
5. Aplicarea tehnicilor PCA și de selecție a caracteristicilor. Utilizarea scikit-learn și a vizualizărilor de importanță a caracteristicilor.	Programare practică Explicație Brainstorming	
6. Implementarea tehnicilor de grupare pe seturi de date de mediu (de exemplu, zone climatice, date privind poluarea).	Programare practică Explicație Brainstorming	
7. Vizualizarea datelor de înaltă dimensiune folosind t-SNE. Aplicarea reducerii dimensionalității la datele de teledetecție.	Programare practică Explicație Brainstorming	
8. Folosind GridSearchCV de la scikit-learn. Tehnici de regularizare: L1 (Lasso), L2 (Gridsearch).	Programare practică Explicație Brainstorming	
9. Implementarea metodelor de ansamblu pe seturi de date de mediu (de exemplu, analiza defrișărilor, predicția inundațiilor).	Programare practică Explicație Brainstorming	
10. Construirea unei rețele neuronale simple folosind TensorFlow/Keras. Instruirea și evaluarea rețelei pe seturi de date de mediu (de exemplu, predicția precipitațiilor, indicii de calitate a aerului).	Programare practică Explicație Brainstorming	
11. Reglarea fină a unui model pre-antrenat (de exemplu, pentru clasificarea utilizării terenurilor).	Programare practică Explicație Brainstorming	
12. Auditarea unui model pentru părtinire. Discutarea studiilor de caz ale dilemelor etice în aplicațiile AI de mediu.	Programare practică Explicație Brainstorming	
13. Implementarea proiectelor de grup/individuale.	Programare practică Explicație Brainstorming	
14. Prezentare proiect de grup/individual.	Evaluare	

Bibliografie

- (2023). ARSET - Fundamentals of Machine Learning for Earth Science. NASA Applied Remote Sensing <https://appliedsciences.nasa.gov/get-involved/training/english/arset-fundamentals-machine-learning-earth-science>
- (2024). ARSET - Large Scale Applications of Machine Learning using Remote Sensing for Building Agriculture Solutions. NASA Applied Remote Sensing Training Program (ARSET). <https://appliedsciences.nasa.gov/get-involved/training/english/arset-large-scale-applications-machine-learning-using-remote-sensing>
- Github repository, 2022, Awesome-Earth-Artificial-Intelligence <https://github.com/ESIPFed/Awesome-Earth-Artificial-Intelligence>
- Github repository, 2024, Awesome Open Geoscience <https://github.com/softwareunderground/awesome-open-geoscience>

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

Structura de conținut a disciplinei a fost structurată prin studierea monografiilor recente din domeniu și prin consultarea programelor și a notelor disponibile de la unele instituții recunoscute în domeniu.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 metode de evaluare	10.3 Pondere din nota finală
----------------	---------------------------	-------------------------	------------------------------

10.4 Curs	Cunoașterea noțiunilor prezentate în cadrul cursului	Evaluare scrisă	3,0 puncte
10.5. Seminar	Verificarea abilităților de rezolvare a exercițiilor cu ajutorul programelor abordate	Evaluare pe calculator	6,0 puncte*
10.6 Standard minim de performanță			
Fiecare student trebuie să dovedească că a dobândit un nivel acceptabil de cunoștințe și înțelegere a: Înțelegerea tipurilor de modele ML utilizate în aplicațiile de mediu; Rularea unui model ML personalizat pentru orice set de date de mediu; Efectuarea analizei exploratorii a datelor și înțelegerea importanței calității datelor. Studentul va pregăti și susține un proiect / eseu conform conținutului cadrului. Obținerea punctajului minim de 5 este o condiție de intrare la examen.			

*La nota finală se va adăuga 1 punct din oficiu.

Data completării

Semnătura titularului de curs

Semnătura titularului de seminar

15.11.2024




Data avizării în departament

Semnătura directorului de departament

.....

.....