FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea Tehnică din Cluj-Napoca
1.2 Facultatea	Facultatea de Științe
1.3 Departamentul	Matematică și Informatică
1.4 Domeniul de studii	Informatică
1.5 Ciclul de studii	Master
1.6 Programul de studii / Calificarea	Informatică și Inginerie software
1.7 Forma de învățământ	IF – învățământ cu frecvență

2. Date despre disciplină

2.1 Denumirea disciplinei	Tehnici Avansate de Data Mining				Codul disciplinei	12.20
2.2 Titularul de curs	*Conf. habil. Ovidiu Cosma – ovidiu.cosma@mi.utcluj.ro*					
2.3 Titularul activităților de seminar / laborator / proiect / practică	*Conf. habil. Ovidiu Cosma – ovidiu.cosma@mi.utcluj.ro*					
2.4 Anul de studiu	I	2.5 Semestrul	1	2.6 Tipul de evaluare		E
2.7 Regimul disciplinei	Categoria formativă					DS
	Opționalitate					DA

3. Timpul total estimat

3.1 Număr de ore pe săptămână	4	din care:	3.2 Curs	2	3.3 Seminar	0	3.3 Laborator	2	3.3 Proiect	0	3.3 Practică	0
3.4 Număr de ore pe semestru	56	din care:	3.5 Curs	28	3.6 Seminar	0	3.6 Laborator	28	3.6 Proiect	0	3.3 Practică	0

3.7 Distribuția fondului de timp (ore pe semestru) pentru studiu individual și evaluare:	
(a) Evaluare	4
(b) Studiul după manual, suport de curs, bibliografie și notițe	28
(c) Documentare suplimentară în bibliotecă, pe platforme electronice de specialitate și pe teren	44
(d) Pregătire seminarii / laboratoare, teme, referate, portofolii și eseuri	40
(e) Tutoriat	
(f) Alte activități: Programare aplicații	28
3.8 Total ore studiu individual și evaluare (suma (3.7(a)...3.7(f))	144
3.9 Total ore pe semestru (3.4+3.8)	200
3.10 Numărul de credite	8

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Programare Orientată pe Obiecte
4.2 de competențe	Limbajul Python, mediul de programare PyCharm

5. Condiții (acolo unde este cazul)

5.1. de desfășurare a cursului	sală de curs
5.2. de desfășurare a seminarului / laboratorului / proiectului	laborator de calculatoare

6. Competențele specifice acumulate

Competențe profesionale	CUNOȘTINȚE: C4.1 Definirea şi descrierea principiilor, conceptelor, teoriilor si modelelor specifice domeniului de aplicare C4.2 Identificarea si explicarea modelelor matematice şi informatice de bază adecvate domeniului de aplicare ABILITĂȚI: C2.3 Utilizarea metodologiilor, limbajelor şi mecanismelor de modelare şi a mediilor de dezvoltare pentru realizarea aplicațiilor informatice C2.5 Realizarea unor proiecte informatice profesionale pentru diverse domenii de aplicație
Competențe transversale	CT1. Aplicarea regulilor de muncă organizată şi eficientă, a unor atitudini responsabile față de domeniul științific- profesional, pentru valorificarea creativă a propriului potențial, cu respectarea principiilor şi a normelor de etică profesională; CT2. Desfășurarea eficientă a activităților organizate într-o echipă interdisciplinară prin asumarea unor funcții de execuție şi conducere, cu dezvoltarea capacităților empatice de comunicare inter-personală, de relaționare şi colaborare cu grupuri diverse; CT3. Elaborarea proiectului propriu de dezvoltare profesională; utilizarea unor metode şi tehnici eficiente de învățare, informare, cercetare şi dezvoltare a capacităților, de valorificare a cunoștințelor, de adaptare la cerințele unei societăți dinamice şi de comunicare în limba română şi în limba engleză.

7. Rezultatele așteptate ale învățării

Cunoștințe	Cunoașterea principiilor și etapelor procesului de data mining; explicarea metodelor de preprocesare, selecție a caracteristicilor și reducere a dimensionalității (PCA); descrierea algoritmilor de regresie, clasificare, clustering (K-means, DBSCAN), detecție a anomaliilor, asociere (Apriori, FP-Growth) și analiză secvențială; înțelegerea principiilor algoritmilor genetici, rețelelor neuronale, CNN, RNN/LSTM și a tehnicilor de text mining (TF-IDF, Word2Vec); cunoașterea metricilor de evaluare a modelelor.
Abilități	Pregătirea și explorarea seturilor de date folosind Python și biblioteci specifice; implementarea și antrenarea modelelor de regresie, clasificare și clustering; aplicarea metodelor de reducere a dimensionalității și detecție a anomaliilor; folosirea algoritmilor genetici pentru selecția caracteristicilor și optimizarea hiperparametrilor; realizarea unor aplicații de analiză secvențială, asociere și text mining; evaluarea și compararea modelelor folosind metrici adecvate.
Responsabilitate și autonomie	Planificarea și realizarea autonomă a unui proiect de analiză a datelor, de la pregătirea datelor la interpretarea rezultatelor; alegerea și justificarea metodelor și parametrilor în funcție de problema analizată; verificarea calității rezultatelor și documentarea limitărilor modelelor; asumarea responsabilității pentru utilizarea corectă și etică a datelor; colaborarea eficientă în echipe și dezvoltarea continuă a competențelor profesionale.

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

8.1 Obiectivul general al disciplinei	Obiectivul general al disciplinei Tehnici Avansate de Data Mining este de a dezvolta competențele studenților în utilizarea algoritmilor și tehnicilor avansate de explorare, procesare și analiză a datelor, cu scopul de a extrage cunoștințe utile și de a dezvolta modele predictive robuste.

	Disciplina vizează formarea unei înțelegeri profunde a proceselor și metodologiilor specifice data mining-ului, prin aplicarea practică a algoritmilor avansați, precum și integrarea tehnicilor de optimizare și evaluare a modelelor în contexte reale de utilizare.
8.2 Obiectivele specifice	Familiarizarea studenților cu metodele avansate de preprocesare a datelor, incluzând selecția caracteristicilor, reducerea dimensionalității și tratarea valorilor aberante și lipsă, pentru a îmbunătăți performanța modelelor. Dezvoltarea competenței de a aplica tehnici de regresie și clasificare, precum regresia liniară, logistică și rețele neuronale, în scopul construirii de modele predictive eficiente. Însușirea algoritmilor de clustering și înțelegerea modului în care aceștia pot fi folosiți pentru segmentarea datelor și identificarea de grupuri de interes în seturile de date complexe. Formarea abilității de a utiliza metode de optimizare și selecție automată a parametrilor, cum ar fi algoritmii genetici, pentru a îmbunătăți precizia și eficiența modelelor predictive. Dezvoltarea capacității de a evalua performanța modelelor și de a compara diferite abordări, folosind metrici de evaluare specifice, cum ar fi acuratețea, precizia, recall-ul și f1-score-ul, pentru a asigura robustețea soluțiilor obținute. Exersarea integrării tehnicilor și algoritmilor avansați de data mining în aplicații practice, prin utilizarea limbajelor de programare relevante (Python, Java) și a unor biblioteci specifice pentru machine learning și data mining.

9. Conținuturi

9.1 Curs	**Nr. ore**	**Metode de predare**	**Observații**
Introducere în Programarea Python pentru Data Mining Pandas, NumPy, Matplotlib, Seaborn, Scikit-learn, SciPy, TensorFlow și Keras, NLTK	4h	expunere, algoritmizare, explicație, problematizare, exemple, demonstrație didactică.	
Învățarea automată Regresia liniară și logistică, Rețele neuronale	4h		
Clustering K-means, DBSCAN, Hierarchical Clustering	2h		
Algoritmi genetici Principii ale algoritmilor genetici, Aplicații în selecția caracteristicilor și optimizarea hiperparametrilor.	4h		
Detecția anomaliilor Isolation Forest, Local Outlier Factor (LOF)	2h		
Reducerea dimensionalității Principal Component Analysis (PCA)	2h		
Deep Learning pentru Data Mining Convolutional Neural Networks, Analiza secvențelor și aplicații în time-series și text mining: RNN și LSTM	4h		

9.1 Curs	Nr. ore	Metode de predare	Observații
Analiza secvențială Pattern Discovery, Generalized Sequential Pattern (GSP)	2h		
Asociere Apriori, FP-Growth	2h		
Text Mining Term Frequency-Inverse Document Frequency (TF-IDF), Reprezentări vectoriale pentru relațiile semantice între cuvinte Word2Vec.	2h		
Bibliografie: Pang-Ning Tan, Michael Steinbach, Anuj Karpatne, Vipin Kumar: Introduction to Data Mining, Pearson, 2018. Aurélien Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, O'Reilly, 2019. Jure Leskovec, Anand Rajaraman, Jeffrey D. Ullman, Mining of Massive Datasets, Cambridge University Press, 2020 Jiawei Han, Micheline Kamber, Jian Pei, Data Mining: Concepts and Techniques, Morgan Kaufmann, 2011 Galit Shmueli, Peter C. Bruce, Mia L. Stephens, Nitin R. Patel, Peter Gedeck, Data Mining for Business Analytics: Concepts, Techniques, and Applications in Python, Wiley, 2020			

9.2 Seminar / laborator / proiect / practică	Nr. ore	Metode de predare	Observații
Introducere în Programarea Python pentru Data Mining Familiarizarea cu bibliotecile de bază pentru data mining în Python	4h	explicație, justificare, dialog, exemplificare, dezbatere, evaluare.	
Învățarea automată Implementarea modelelor de bază de regresie și rețele neuronale.	4h		
Clustering Învățarea tehnicilor de clustering pentru segmentarea datelor.	2h		
Algoritmi genetici Familiarizarea cu principiile algoritmilor genetici și aplicația lor în optimizare.	4h		
Detecția anomaliilor Învățarea tehnicilor de detectare a anomaliilor pentru seturi de date complexe.	2h		
Reducerea dimensionalității Aplicarea PCA pentru simplificarea seturilor de date.	2h		
Deep Learning pentru Data Mining Introducerea în arhitecturi avansate de rețele neuronale pentru analiză secvențială și imagistică.	4h		
Analiza secvențială Implementarea tehnicilor de analiză secvențială pentru descoperirea de tipare.	2h		
Asociere Descoperirea regulilor de asociere pentru date de tip coș de cumpărături.	2h		

9.2 Seminar / laborator / proiect / practică	Nr. ore	Metode de predare	Observații
Text Mining Familiarizarea cu tehnicile de reprezentare a textului pentru data mining.	2h		
Bibliografie: Pang-Ning Tan, Michael Steinbach, Anuj Karpatne, Vipin Kumar: Introduction to Data Mining, Pearson, 2018. Aurélien Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, O'Reilly, 2019. Jure Leskovec, Anand Rajaraman, Jeffrey D. Ullman, Mining of Massive Datasets, Cambridge University Press, 2020 Jiawei Han, Micheline Kamber, Jian Pei, Data Mining: Concepts and Techniques, Morgan Kaufmann, 2011 Galit Shmueli, Peter C. Bruce, Mia L. Stephens, Nitin R. Patel, Peter Gedeck, Data Mining for Business Analytics: Concepts, Techniques, and Applications in Python, Wiley, 2020			

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

Conținutul disciplinei Tehnici Avansate de Data Mining este aliniat cu cerințele actuale ale comunității academice, ale asociațiilor profesionale și ale angajatorilor prin integrarea tehnicilor moderne și aplicate în data mining.
Disciplina abordează subiecte importante și actuale, precum învățarea automată, clustering-ul, reducerea dimensionalității și deep learning-ul, fiind în concordanță cu standardele internaționale în cercetarea științei datelor.
Cursul acoperă competențe fundamentale, incluzând tehnici recunoscute de analiză secvențială, detecția anomaliilor și optimizarea hiperparametrilor.
Conținutul orientat pe Python și biblioteci de machine learning (Scikit-learn, TensorFlow, Keras) răspunde cerințelor pieței muncii, pregătind studenții pentru aplicații practice în securitate, e-commerce, profilare și analiză de afaceri, domenii în care data mining-ul este esențial.

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare (și forma evaluare: continuă/sumativă)	11.3 Pondere din nota finală
11.4 Curs	Nivelul cunoștințelor prezentate la curs	Evaluare sumativă: evaluare online sau proiect	2/3
11.5 Seminar/Laborator /Proiect / practică	Activitatea la laborator. Probe practice, realizarea unor aplicații folosind mediul de dezvoltare de la laborator	Evaluare continuă prin observare sistematică, proiecte individuale;	1/3
11.6 Standard minim de performanță Cunoașterea noțiunilor fundamentale prezentate la curs, care este echivalentă cu promovarea examenului. Realizarea activităților de la laborator la un nivel satisfăcător.			

Data completării:	Titulari	grad didactic, titlu Prenume NUME	Semnătura
10.09.2026	Curs	Conf. univ. habil. Ovidiu COSMA	
	Aplicații	Conf. univ. habil. Ovidiu COSMA	

Avizul Directorului departamentului care coordonează disciplina, doar dacă acesta diferă de departamentul organizator al programului de studii	Director Departament ..... grad didactic, titlu Prenume NUME

Data avizării în Consiliul Departamentului de Matematică și Informatică 14.09.2026	Director Departament Matematică și Informatică Conf. univ. dr. Cosmin Sabo
Data aprobării în Consiliul Facultății de Științe 17.09.2026	Decan Conf. univ. dr. Monica Marian