

FIȘA DISCIPLINEI
pentru anul universitar 2025/26

1. Date despre program

1.1. Instituția de învățământ superior	Universitatea Sapiientia din Cluj-Napoca
1.2. Facultatea/ DSPP	Științe Economice, Socio-Umane și Inginerești din Miercurea Ciuc
1.3. Domeniul de studii	Economie
1.4. Ciclul de studii	MASTERAT
1.5. Programul de studiu	Economie aplicată și finanțe
1.6. Calificarea	Masterat în științe economice

2. Date despre disciplină

2.0. Departamentul				Științe Economice			
2.1. Denumirea disciplinei				Data minig			
2.2. Tipul activității				Asistat integral	Asistat parțial:		Neasistat
				x	-		-
2.3. Titularul disciplinei /Titularul cursului				Lect. univ.dr. Illyés László			
2.4. Titularul(ii) activităților de			seminar				
			laborator	Lect. univ.dr. Illyés László			
			proiect				
2.5. Anul de studiu	II	2.6. Semestrul	4	2.7. Forma de verificare	C	2.8. Tipul disciplinei	DOB
2.9. Categoria formativă	DAP	2.10 Categoria disciplinei	DA	2.11. Codul disciplinei	CMGF0111		

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

3.1. Număr de ore pe săptămână	3	Din care: 3.2. curs	2	3.3. seminar / laborator / proiect/ practică	1
3.4. Total ore din planul de învățământ	36	Din care: 3.5. curs	24	3.6. seminar/ laborator / proiect/ practică	12
3.7. Numărul de puncte de credit conform planului de învățământ					4
3.8. Total ore pe semestru					100
3.9. Total ore studiu individual					64
3.10. Distribuția fondului de timp:					Ore
a) Studiul după manual, suport de curs, bibliografie și notițe					20
b) Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					16
c) Pregătire seminarii /laboratoare, teme, referate, portofolii și eseuri					20
d) Tutoriat					4
e) Examinări					4
f) Alte activități:					

4. Precondiții (acolo unde este cazul)

4.1. de curriculum	Nu este cazul
4.2. de competențe	Nu este cazul

5. Condiții (acolo unde este cazul)

5.1. De desfășurare a cursului	Sală echipată cu videoproiector, tablă și conexiune la Internet. Utilizarea telefonului mobil interzis.
5.2. De desfășurare a seminarului/ laboratorului	Sală de laborator cu aprox. 15 locuri, echipat cu tot atâtea calculatoare conectate la Internet, cu videoproiector sau monitor smart dotată cu software adecvat. Utilizarea telefonului mobil interzis

6. Rezultatele învățării

Cunoștințe	- Studentul/Absolventul înțelege clasificarea, regresia, clustering-ul, regulile de asociere și detecția anomaliilor; explică etapele procesului KDD și diferențele dintre învățarea supervizată și nesupervizată. - Studentul/Absolventul aplică algoritmi de clasificare (Decision Trees, Naïve Bayes, SVM), clustering (K-means, DBSCAN, Hierarchical) și reguli de asociere (Apriori) pentru analiză economică.. - Studentul/Absolventul lucrează cu Weka și SQL pentru procesarea datelor; utilizează instrumente de vizualizare și analizează pe seturi mari de date.
Aptitudini	- Studentul/Absolventul utilizează instrumente de automatizare, pentru a automatiza sarcinile repetitive în activitățile economice - Studentul/Absolventul creează și administrează baze de date economice pentru stocarea și analiza informațiilor - Studentul/Absolventul utilizează Data Mining pentru analiza comportamentului consumatorilor, evaluarea riscului de creditare și segmentarea clienților în campanii de marketing - Studentul/Absolventul gestionează corect procesul de curățare și transformare a datelor, reduce dimensionalitatea și respectă principiile etice și de confidențialitate a datelor economice.
Responsabilitate și autonomie	- Studentul/Absolventul verifică și monitorizează corectitudinea proceselor automatizate, asigurând acuratețea datelor și conformitatea cu reglementările în vigoare - Studentul/Absolventul administrează autonom sisteme complexe

7. Obiectivele disciplinei (reieșind din grila competențelor acumulate)

7.1. Obiectivul general al disciplinei	Însușirea tehnicilor de data mining
7.2. Obiectivele specifice	Folosirea aplicației Weka Data Mining pe diverse date preparate și date din economie și interpretarea rezultatelor

8. Conținuturi

8.1. Curs	Metode de predare	Fond de timp alocat / Observații
1. Introducere în Weka	Expunere: descriere, explicații, exemple, demonstrații.	4
2. Cei mai simpli algoritmi: ZeroR, OneR și Naive Bayes – prin calcul tabelar		2
3. User Classifier și J48		2
4. Metode de învățare și testare		2
5. Învățare supervizată Arbori de decizie. Random Forest, kNN		2
6. Învățare supervizată. Regresia		2

7. Granițe de clasificare. Vizualizare pe 2D al algoritmilor. Regresia logistică.		2
8. SVM		2
9. Ensemble learning		2
10. Data mining și etica		2
11. Verificare finală		2
Bibliografie		
1. Illyés László, Note de curs 2025 – available on classrooms		
2. Tomaž Bratanič, Graph Algorithms for Data Science, 2024		
3. Jiawei Han, Jian Pei, Data Mining: Concepts and Techniques: The Morgan Kaufmann Series in Data management Systems, 2022		
4. Singh Sengar Dusyant, Modern Data Mining with Python: A Risk-Managed Approach to Developing and Deploying Explainable and Efficient Algorithms Using Modelops, 2024		
5. Zaki Mohammed, Data Mining and Machine Learning: Fundamental Concepts and Algorithms, 2020		
6. Weka MOOC		
8.3. Laborator	Metode de predare	Fond de timp alocat/ Observații
Introducere în folosirea aplicației Weka	Explicații, exemplificări, dialog	2
Utilizarea filtrelor		1
Vizualizarea datelor		1
Metode de învățare și testare		2
Învățarea supervizată. Regresia		1
Verificare		1
SVM		1
Granițe de clasificare. Vizualizare pe 2D al algoritmilor. Regresia logistică.		1
Data mining și etica		1
Verificare finală		1
Bibliografie		
1. Illyés László, Note de curs 2025 – available on classrooms		
2. Singh Sengar Dusyant, Modern Data Mining with Python: A Risk-Managed Approach to Developing and Deploying Explainable and Efficient Algorithms Using Modelops, 2024		
3. Zaki Mohammed, Data Mining and Machine Learning: Fundamental Concepts and Algorithms, 2020		
4. Weka MOOC		

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

- Prin însușirea conceptelor teoretico-metodologice și abordarea aspectelor practice incluse în disciplina Data mining, studenții dobândesc un bagaj de cunoștințe consistent, în concordanță cu competențele parțiale cerute pentru ocupațiile posibile prevazute în Grila 1 – RNCIS
- Cursul există în programa de studii a multor universităților și facultăților de profil din România și din străinătate
- Conținutul cursului este apreciat de către companii

10. Evaluare

A. Condiții de îndeplinit pentru prezentarea la evaluare:

-

B. Criterii, metode și ponderi în evaluare:

Tip activitate		10.1. Criterii de evaluare	10.2. Metode de evaluare	10.3. Pondere din nota finală
10.4. Curs		Corectitudinea și completitudinea cunoștințelor; Coerența logică;	Rezolvarea în Excel al unei probleme de Data Mining prin algoritmi OneR și Naive Bayes	34%
	Laborator	Gradul de asimilare al limbajului Weka	Două verificări a cunoștințelor privind utilizarea aplicației Weka, prin folosirea mai multor algoritmi de inteligență artificială	66%
	Proiect			
10.6. Standard minim de performanță				
Pentru obținerea notei de trecere, la examen și la reexaminare se cere, ca fiecare notă parțială să fie de trecere (nota 5 pentru fiecare notă parțială).				

Data completării
03.09.2025

Semnătura titularului disciplinei
Lect. dr. Illyés László

Semnătura titularului/rilor de aplicații
Lect. dr. Illyés László

Data avizării în departament
05.09.2025

Semnătura directorului de departament
Lect. dr. Illyés László.

Semnătura responsabilului programului de studii
Conf. Dr. Lázár Ede