

FIȘA DISCIPLINEI

Metode inteligente pentru modelarea datelor (instruire automată avansată)

Anul universitar 2025-2026

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea Babeș-Bolyai Cluj-Napoca
1.2 Facultatea	Facultatea de Matematică și Informatică
1.3 Departamentul	Departamentul de Matematică și Informatică al Liniei Maghiare
1.4 Domeniul de studii	Informatică
1.5 Ciclul de studii	Masterat
1.6 Programul de studiu / Calificarea	Analiza datelor și modelare

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)	Metode inteligente pentru modelarea datelor (instruire automată avansată) Intelligent data modelling (advanced machine learning)						
2.2 Titularul activităților de curs	Prof dr. Lehel CSATÓ						
2.3 Titularul activităților de seminar	Prof dr. Lehel CSATÓ						
2.4 Anul de studiu	1	2.5 Semestrul	2	2.6. Tipul de evaluare	Collocviu	2.7 Regimul disciplinei	Specialitate obligatorie
2.8 Codul disciplinei	MMM8078						

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

3.1 Număr de ore pe săptămână	5	Din care: 3.2 curs	2	3.3 seminar/laborator	3
3.4 Total ore din planul de învățământ	70	Din care: 3.5 curs	28	3.6 seminar/laborator	42
Distribuția fondului de timp:					Ore
Studiul după manual, suport de curs, bibliografie și notițe					50
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					24
Pregătire seminare/laboratoare, teme, referate, portofolii și eseuri					36
Tutorat					14
Examinări					6
Alte activități: proiect					
3.7 Total ore studiu individual	130				
3.8 Total ore pe semestru	200				
3.9 Numărul de credite	8				

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Nu este cazul
4.2 de competențe	Cunoștințe de programare, bazele algebrei vectoriale, bazele calculului probabilităților.

5. Condiții (acolo unde este cazul)

5.1 De desfășurare a cursului	• Pentru prezentări este necesar un videoproiector. • Este necesară o tablă pentru explicații ale exemplelor și pentru ilustrații.
5.2 De desfășurare a seminarului/laboratorului	• În timpul laboratoarelor, elevii folosesc calculatorul, iar profesorul folosește o tablă.

6.1. Competențele specifice acumulate

Competențe profesionale	• CE1.3 Folosirea metodelor, tehnicilor și algoritmilor din inteligența artificială pentru modelarea soluțiilor unor clase de probleme. • CE1.4 Identificarea și explicarea tehnicilor și algoritmilor proprii inteligenței artificiale și folosirea acestora la rezolvarea unor probleme specifice. • CE1.5 Încorporarea modelelor și soluțiilor specifice inteligenței artificiale în aplicații dedicate. • C3.3 Utilizarea modelelor și instrumentelor informatice și matematice pentru rezolvarea problemelor specifice domeniului de aplicare.
Competențe transversale	• CT1 Aplicarea regulilor de muncă organizată și eficientă, a unor atitudini responsabile față de domeniul didactic-științific, pentru valorificarea creativă a propriului potențial, cu respectarea principiilor și a normelor de etică profesională. • CT2 Desfășurarea eficientă a activităților organizate într-un grup inter-disciplinar și dezvoltarea capacităților empatice de comunicare inter-personală, de relaționare și colaborare cu grupuri diverse.

6.2. Rezultatele învățării

Cunoștințe	• Studentul are un vocabular adecvat pentru a interacționa cu colegi programatori pentru folosirea diferitelor concepte de instruire automată a mașinilor. • Studentul este capabil să identifice probleme complexe, să analizeze în mod abstract pentru a rezolva și implementa soluții.
Aptitudini	• Studentul este capabil să identifice soluții pentru probleme complexe și implementa soluții.

Responsabilități și autonomie	Studentul are capacitatea de a lucra independent în rezolvarea de probleme și în implementarea soluțiilor.
--------------------------------------	--

7. Obiectivele disciplinei (reieșind din grila competențelor acumulate)

7.1 Obiectivul general al disciplinei	Scopul este de a procesa datele și de a extrage informații. În prezent, fiecare "mișcare" a noastră este înregistrată sub formă de date care trebuie procesate. Metodologia de procesare a acestor date este introdusă la un nivel avansat.
7.2 Obiectivele specifice	- Înțelegerea tipurilor de date și a algoritmilor care le corespund; - Înțelegerea aprofundată a modelelor care corespund anumitor probleme și a tipurilor de modele folosite. - Estimarea "calității" modelelor, recunoașterea și aplicarea importanței stabilității.

8. Conținuturi

8.1 Curs	Metode didactice	Observații
1. Noțiuni introductive, definiții. Atribuire de tematici pentru prezentări la sfârșit de an.	Explicații, căutare noțiuni similare, testare de coduri sursă	
2. Introducere în modelele Bayesiene: utilizarea modelelor probabilistice la proiecția datelor / reducerea dimensiunii acestora	Explicații, căutare noțiuni similare, testare de coduri sursă	
3. Analiza probabilistică a componentelor principale: PPCA, teorie și aplicații.	Explicații, căutare noțiuni similare, testare de coduri sursă	
4-5. Modele cu variabile ascunse, modele generative și aplicațiile lor.	Explicații, căutare noțiuni similare, testare de coduri sursă	
6-7. Modele discrete: modelul Markov ascuns, Învățarea prin întărire (reinforcement learning).	Explicații, căutare noțiuni similare, testare de coduri sursă	
8-9. Procese de decizie Markov și aplicarea lor în învățarea prin reîntărire (reinforcement learning).	Explicații, căutare noțiuni similare, testare de coduri sursă	
9. Modele neparametrice: conceptul de "lipsa de parametri" în modelele computaționale.	Explicații, căutare noțiuni similare, testare de coduri sursă	

10-11. Mașini cu vectori de suport și aplicațiile lor, clasificatori robuste și aplicațiile lor în lumea reală: SVMlight și algoritmi derivați.	Explicații, căutare noțiuni similare, testare de coduri sursă	
12-13. Modele probabilistice neparametrice: cazuri discrete și continue. Aplicații.	Explicații, căutare noțiuni similare, testare de coduri sursă	
14. Agregarea modelelor. Combinarea clasificatorilor simpli: metode bagging, boosting.	Explicații, căutare noțiuni similare, testare de coduri sursă	

Bibliografie

- [1]. Bishop C.M (2006) Pattern Recognition and Machine Learning, Springer Verlag.
[2]. Bernardo J.M, Smith A.F.M (2000) Bayesian Theory, John Wiley & Sons, ISBN: 978-0-471-92416-6
[3]. Mitchell T (1997) Machine Learning, McGraw Hill.
[4]. Rabiner L.R, Juang, B.H (1986) An introduction to Hidden Markov models, IEEE ASSP Magazine.
[5]. Hastie T, Friedman J, Tibshirani R (2003) The Elements of Statistical Learning: Data mining, Inference, and Prediction, Springer HTTP: <http://statweb.stanford.edu/~tibs/ElemStatLearn>
[6]. Rasmussen C.E, Williams C.K.I (2006) Gaussian Processes for Machine Learning, The MIT Press.

8.2 Seminar/Laborator	Metode didactice	Observații
1. Prezentarea limbajului de programare Julia, specifici, avantaje. Cazuri de folosire. Metode de citire și vizualizare a datelor.	Explicații, prezentare de coduri sursă	
2. Aplicații ale metodelor PPCA. Prezentări și aplicații.	Explicații, prezentare de coduri sursă	
3. Modelul Markov cu parametri latenți.	Explicații, prezentare de coduri sursă	
4-5. Instruire cu întăriri. Formalizare cu procese Markoviene ascunse.	Explicații, prezentare de coduri sursă	
6. Modelele de SVM și GP. Folosire acestora la clasificare și regresie.	Explicații, prezentare de coduri sursă	
7. Prezentări ale problemelor individuale.	Prezentări cu teme legate de capitolele cursului.	

Bibliografie

- [1].-[6]. +
[7]. MacKay D.J.C (2003) Information Theory, Inference and Learning Algorithms, Cambridge University Press, HTTP: <http://wol.ra.phy.cam.ac.uk/mackay/itila/book.html>.
[8]. A. Webb: Statistical Pattern Recognition, Wiley, 2002
[9]. E. Alpaydin: Introduction to Machine Learning, The MIT Press, 2004
[10]. Hyvärinen A, Karhunen J, Oja E (2001) Independent Component Analysis, Wiley-Interscience.
[11]. Barto A. (2002): Statistical Pattern Recognition, John Wiley & Sons.
[12]. Sherrington M (2015) Mastering Julia, Pact Publishing.

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

- Structura și conținutul cursului este bazat pe cursuri cu tematica "Machine Learning" de la universitățile Stanford din Statele Unite ale Americii și UCL din Londra, Anglia. Cursuri similare sunt și la universitățile din Edinburgh sau Finlanda, de exemplu Turku.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 metode de evaluare	10.3 Ponderea din nota finală
10.4 Curs	Examen scris în perioada de sesiune	Examen scris	60%
10.5 Seminar / Laborator	Prezentarea de NOTEBOOK-uri, seturi de algoritmi cu tematica capitolelor din curs.	Evaluarea metodelor de rezolvare	40%
10.6 Standarde minime de performanță			
Cel puțin 50% din puncte pe parcursul semestrului. Proporția de 50% este obligatorie pentru fiecare capitol.			

11. Etichete ODD (Obiective de Dezvoltare Durabilă / Sustainable Development Goals)

	
Nu se aplică	

Data completării

10.04.2025.

Semnătura titularului de curs

Prof. dr. Lehel CSATÓ

Semnătura titularului de seminar

Prof. dr. Lehel CSATÓ

Data avizării în departament

24.04.2025

Semnătura directorului de departament

Conf. dr. András Szilárd