

FIȘA DISCIPLINEI

Bazele instruirii automate a mașinilor

Anul universitar 2025-2026

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea Babeș-Bolyai
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 Ciclu de studii	Licență
1.6 Programul de studiu / Calificarea	Informatică (în lb. maghiară)

2. Date despre disciplină

2.1 Denumirea disciplinei(hu), (ro), (en)	Bazele instruirii automate a mașinilor / A gépi tanulás alapjai / Introduction to machine learning						
2.2 Titularul activităților de curs	prof. dr. Csató Lehel						
2.3 Titularul activităților de seminar	prof. dr. Csató Lehel						
2.4 Anul de studiu	3	2.5 Semestrul	6	2.6. Tipul de evaluare	examen	2.7 Regimul disciplinei	DS opțională
2.8 Codul disciplinei	MLM5090						

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	1+2
3.4 Total ore din planul de învățământ	60	Din care: 3.5 curs	24	3.6 seminar/laborator	36
Distribuția fondului de timp:					Ore
Studiul după manual, suport de curs, bibliografie și notițe					36
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					14
Pregătire seminare/laboratoare, teme, referate, portofolii și eseuri					24
Tutorat					12
Examinări					4
Alte activități:					-
3.7 Total ore studiu individual	90				
3.8 Total ore pe semestru	150				
3.9 Numărul de credite	6				

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Nu sunt
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	• Sală dotată cu videoproiector • Tablă pentru explicații detaliate, pentru rezolvarea problemelor
5.2 De desfășurare a seminarului/laboratorului	• Tablă pentru rezolvarea problemelor • Laborator cu calculatoare dotate cu softuri necesare pentru rezolvarea temelor de laborator

6. 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. • C3.4 Analiza datelor și a modelelor
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. CT3 Utilizarea unor metode și tehnici eficiente de învățare, informare, cercetare și dezvoltare a capacităților de valorificare a cunoștințelor, de adaptare la cerințele unei societăți dinamice și de comunicare în limba română și într-o limbă de circulație internațională

6.2. Rezultatele învățării

Cunoștințe	Studentul are un vocabular adecvat pentru a interacționa cu colegi programatori pentru folosirea diferitelor concepte de IA. 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 acestui curs este de a introduce algoritmi de instruire automată și aplicațiile acestora. Prezentările se vor axa pe utilizarea algoritmilor prezentați. - Vom acoperi o gamă largă de aplicații, de la aplicații ale modelelor Bayesiene la modelarea cu componentelor independente și de la recunoașterea vocii la recunoașterea moleculelor și a imaginilor.
7.2 Obiectivele specifice	Tematicile sunt următoarele: - Conceptul de modelare matematică; paradigma de modelare Bayesiană: Metode de estimare, Modele ierarhice și estimarea parametrilor modelului, modelarea Bayesiană: utilizarea distribuțiilor a-posteriori și predictive. - Analiza componentelor: Noțiuni de bază ale modelării statistice - valori proprii și vectori proprii, Componente principale, componente independente și separarea semnalelor. - Algoritmi de cliusterizare și aplicațiile lor. Derivarea familiei de algoritmi EM și prezentarea aplicațiilor.

8. Conținuturi

8.1 Curs	Metode de predare	Observații
Săpt.1 Concepte introductive, definiții, concepte de instruire automată, conceptul de învățare și estimarea parametrilor,	Problematizare, discuție.	
Săpt.2 Metode de estimare: metoda maximum likelihood și metoda de maxim a-posteriori. Aplicații și exemple.	Problematizare, discuție.	
Săpt.3 Estimarea Bayesiană: modelul probabilistic, parametri, aplicații.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.4 Tehnici alternative de aproximare în modelarea Bayesiană. Bazele calculului variațional.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.5 Aplicații ale estimării Bayesiene la probleme reale. Caracteristicile metodelor de învățare supravegheată.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.6	Explicații, căutare noțiuni	

Învățare nesupravegheată: fundamentarea teoretică a regăsirii automate a informațiilor, corelația, interpretări geometrice.	similare, testare de coduri sursă	
Săpt.7 Analiza componentelor principale și aplicațiile sale: fundamentele matematice ale algoritmilor de compresie cu pierderi. Aplicații.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.8 Conceptul de model factorial și modalități de interpretare a "factorilor". Metode specializate de factorizare.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.9 Modelul cu componente independente: aplicații la separarea statistică și relația cu prelucrarea informației umane.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.10 Modele de clustering, utilitate, aplicabilitate. Algoritmul EM pentru estimarea parametrilor.	Problematizare, discuție.	
Săpt.11 Aplicații ale algoritmului EM; optimizarea diferitelor modele de clusterizare.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Săpt.12 Repetiție și exemple practice.	Explicații, căutare noțiuni similare, testare de coduri sursă	
Bibliografie: [1]. Bishop C.M (2006) Pattern Recognition and Machine Learning, Springer Verlag. [2]. Russell S, Norvig P (2003) Artificial Intelligence: A Modern Approach (Second Edition), Prentice Hall. [3]. Mitchell T (1997) Machine Learning, McGraw Hill. [4]. Bernardo J.M, Smith A.F.M (2000) Bayesian Theory, John Wiley & Sons. [5]. 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 . [6]. Rasmussen C.E, Williams C.K.I (2006) Gaussian Processes for Machine Learning, The MIT Press. [7]. Durbin R, Eddy S.R, Krogh A, Mitchison G (1999) Biological Sequence Analysis: Probabilistic Models of Proteins and Nucleic Acids. Cambridge University Press. [8]. Hyvärinen A, Karhunen J, Oja E (2001) Independent Component Analysis, Wiley-Interscience. [9]. Barto A. (2002): Statistical Pattern Recognition, John Wiley & Sons.		
8.2 Seminar / laborator	Metode de predare	Observații
Lab.Sem.1 Stabilirea primului set de probleme problema de regresie	Dialogul, dezbateră, studiul de caz, exemplificarea	
Lab.Sem.2 Verificarea sarcinilor, prezentarea celui de-al doilea set de sarcini, explicații	Dialogul, dezbateră, studiul de caz, exemplificarea	
Lab.Sem.3 Discutarea seturilor opționale de sarcini, verificarea sarcinilor. Probleme de pe Kaggle, evaluare.	Dialogul, dezbateră, studiul de caz, exemplificarea	
Lab.Sem.4 Verificarea celui de-al doilea set de sarcini, prezentarea celui de-al treilea.	Dialogul, dezbateră, studiul de caz, exemplificarea	
Lab.Sem.5 Verificarea celui de-al treilea set de sarcini, prezentarea celui de-al patrulea. Clusterizare și PCA	Dialogul, dezbateră, studiul de caz, exemplificarea	

Lab.Sem.6 Verificarea celui de-al treilea set de exerciții, verificarea exercițiilor opționale, prezentarea celui de-al patrulea set de exerciții	Dialogul, dezbateră, studiul de caz, exemplificarea	
Lab.Sem.7 Verificări / feedback	Dialogul, dezbateră, studiul de caz, exemplificarea	
Bibliografie: [1]–[9] + [10]. M.A. Arbib (ed.): The Handbook of Brain Theory and Neural Networks, The MIT Press, 2002. [11]. P. Baldi, S. Brunak: Bioinformatics: the Machine Learning Approach, The MIT Press, 2001. [12]. T. Hastie, J. Friedman, R. Tibshirani: The Elements of Statistical Learning: Data mining, Inference, and Prediction, Springer 2003. [13]. S.J. Russell, P. Norvig: Artificial Intelligence - a modern approach, Prentice Hall, 1995 [14]. A. Webb: Statistical Pattern Recognition, Wiley, 2002		

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

- Cursurile urmăresc structura cursurilor susținute la universități de top din Anglia (University College London, University of Edinburgh) și din SUA (MIT, Stanford).
- Exercițiile sunt similare cu cele publice ale cursurilor acestor universități.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 metode de evaluare	10.3 Pondere 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 Standard minim de performanță			
Cunoștințele minime necesare: • Cunoașterea conceptelor de bază ale învățării automate. • Cunoașterea conceptelor de bază ale învățării automate.			
Condițiile notei minime: • Obținerea a 60% din punctele din activitatea de la jumătatea anului (24 de puncte; condiție necesară). • Cel puțin jumătate din puncte (condiție necesară). • Obținerea a minimum 50% din punctajul final (=5; condiție necesară).			

11. Etichete ODD (Obiective de Dezvoltare Durabilă / Sustainable Development Goals)¹

¹ Păstrați doar etichetele care, în conformitate cu [Procedura de aplicare a etichetelor ODD în procesul academic](#), se potrivesc disciplinei și ștergeți-le pe celelalte, inclusiv eticheta generală pentru *Dezvoltare durabilă* - dacă nu se aplică. Dacă nicio etichetă nu descrie disciplina, ștergeți-le pe toate și scrieți "Nu se aplică".

Nu se aplică.

Data completării:

10.04.2025

Semnătura titularului de curs

prof. dr. Csató Lehel

Semnătura titularului de seminar

prof. dr. Csató Lehel

Data avizării în departament:

24.04.2025

Semnătura directorului de departament

Conf.dr. András Szilárd-Károly