

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea Tehnică din Cluj-Napoca
1.2 Facultatea	Automatică și Calculatoare
1.3 Departamentul	Calculatoare
1.4 Domeniul de studii	Calculatoare și Tehnologia Informației
1.5 Ciclu de studii	Master
1.6 Programul de studii / Calificarea	Rețele de Comunicații și Sisteme Distribuite / Master
1.7 Forma de învățământ	IF – învățământ cu frecvență

2. Date despre disciplină

2.1 Denumirea disciplinei	Modele matematice destinate învățării automate			Codul disciplinei	100
2.2 Titularul de curs	Prof. dr. Ioan Radu Peter - Ioan.Radu.Peter@math.utcluj.ro				
2.3 Titularul activităților de seminar / laborator / proiect	Prof. dr. Ioan Radu Peter - Ioan.Radu.Peter@math.utcluj.ro				
2.4 Anul de studiu	I	2.5 Semestrul	1	2.6 Tipul de evaluare	E
2.7 Regimul disciplinei	Categorii formative: <i>DF – fundamentală, DS - de specialitate, DC - complementară</i>				DF
	Opționalitate: <i>DOB - obligatorie, DOP - opțională, DFA - facultativă</i>				DFA

3. Timpul total estimat

3.1 Număr de ore pe săptămână	3	din care:	Curs	2	Seminar	1	Laborator	-	Proiect	-
3.2 Număr de ore pe semestru	42	din care:	Curs	28	Seminar	14	Laborator	-	Proiect	-
3.3 Distribuția fondului de timp (ore pe semestru) pentru:										
(a) Studiul după manual, suport de curs, bibliografie și notițe										
(b) Documentare suplimentară în bibliotecă, pe platforme electronice de specialitate și pe teren										
(c) Pregătire seminar / laborator, teme, referate, portofolii și eseuri										
(d) Tutoriat										
(e) Examinări										
(f) Alte activități:										
3.4 Total ore studiu individual (suma (3.3(a)...3.3(f)))							33			
3.5 Total ore pe semestru (3.2+3.4)							75			
3.6 Numărul de credite							3			

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Student master sau doctorand.
4.2 de competențe	

5. Condiții (acolo unde este cazul)

5.1. de desfășurare a cursului	Proiector, Calculator
5.2. de desfășurare a seminarului / laboratorului / proiectului	Prezență obligatorie 70% pentru admiterea la examenul final

6. Competențele specifice acumulate

6.1 Competențe profesionale	Întelegerea unor metode matematice folosite în învățare automată, deep learning.
6.2 Competențe transversale	Aplicarea cunoștințelor în înțelegerea unor algoritmi majori folosiți și pe baza cunoștințelor dobândite, motivarea alegerii unor algoritmi în probleme date.

7. Rezultatele așteptate ale învățării

Cunoștințe	Descrive, i_d_e_n_t_i_f_i_c_ă, _s_u_m_a_r_i_z_e_a_z_ă_c_o_n_c_e_p_t_e_și metode elementare privitoare la inteligența artificială, ML și pattern recognition. optimizează, sintetizează, argumentează, compară, selectează, propune algoritmi de ML, Deep Learning, Pattern recognition.
Aptitudini	Înțelege, matematica din algoritmi, aplica metode de ML, Deep Learning, Pattern recognition, compară metode, evaluează metode. Implementează metode și găsește algoritmi potriviți problemelor.
Responsabilitate și autonomie:	A_r_e_o_c_o_m_p_o_r_t_a_r_e_o_n_o_r_a_b_i_l_ă, _r_e_s_p_o_n_s_a_b_i_l_ă, _e_t_i_c_ă, _î_n_s_p_i_r_i_t_u_l_l_e_g_i_i_p_e_n_t_r_u_a_a_s_i_g_u_r_a_r_e_p_u_t_ă_ț_i_a_profesiei Abordează probleme complexe, face distincție între metode.

8. Obiectivele disciplinei

8.1 Obiectivul general al disciplinei	Înțelegerea unor modele matematice care apar în învățare automată, deep learning.
8.2 Obiectivele specifice	Înțelegerea funcționării, acțiunii unor algoritmi majori în deep learning. Asemănări și diferențe între algoritmi.

9. Conținuturi

9.1 Curs	Nr.ore	Metode de predare	Observații
Introducere	2	Prezentare, discutii, demonstratii	
Normalizari de vectori, semnificatii. Utilizari.	2		
Inverse generalizate I	2		
Inverse generalizate II. Aplicatii.	2		
Factorizari. (QR, LD)	2		
Descompunere dupa valori singulare.	2		
Aplicatii in rezolvare de sisteme.	2		
Valori si vectori proprii. Matrici de Gram.	2		
Forma Jordan. Matrice diagonalizabile.	2		
Criterii Rayleigh. Aplicatii in algoritmi de invatare automata.	2		
Metode de optimizare legate de invatare automata.	2		
Aparitia unor algoritmi clasici folosind optimizare matriceala. Directii principale.	2		
Optimizare cu restrictii. Metode de tip Karush Kuhn Tucker.	2		
Discutii. Metode de abordare.	2		
Bibliografie Articole din reviste orientate pe agenti care sunt accesibile pe web			
9.2 Aplicații (seminar)*	Nr.ore	Metode de predare	Observații
Normalizari de vectori. Inverse generalizate I	2	Prezentare, discutii, demonstratii	
Inverse generalizate II. Factorizari.	2		
Valori si vectori proprii.	2		
Evaluarea securitatii platformelor de agenti mobili	2		
Criterii Rayleigh. Aplicatii in algoritmi de invatare automata.	2		

Optimizare cu restrictii. Metode de tip Karush Kuhn Tucker.	2		
Discutii. Metode de abordare.	2		
Bibliografie Articole din reviste, tutoriale, Note de curs (prezentari)			

**Se vor preciza, după caz: tematica seminariilor, lucrările de laborator, tematica și etapele proiectului.*

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

Înțelegerea unor metode matematice este esențială în alegerea și aplicarea algoritmilor de învățare automată, deep learning.

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare	11.3 Pondere din nota finală
11.4 Curs	Înțelegerea noțiunilor prezentate. Legătura cu algoritmi de învățare automată.	Examen scris	75%
11.5 Seminar/ Laborator /Proiect	Înțelegerea unor metode matematice „ascunse” în învățare automată.	Notare laborator	25%
11.6 Standard minim de performanță: Capacitatea de a modela/reprezenta cunoștințe și raționarea cu acestea la nivelul capitolelor acoperite.			

Data completării: 08.07.2026	Titulari	Titlu Prenume NUME	Semnătura
	Curs	Prof. dr. Ioan-Radu PETER	
	Aplicații	Prof. dr. Ioan-Radu PETER	

Data avizării în Consiliul Departamentului Calculatoare	Director Departament, Prof.dr.ing. Rodica Potolea
Data aprobării în Consiliul Facultății de Automatică și Calculatoare	Decan, Prof.dr.ing. Vlad Mureșan