



Universitatea Națională de Știință și Tehnologie Politehnica București
Facultatea de Electronică, Telecomunicații și
Tehnologia Informației



FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea Națională de Știință și Tehnologie Politehnica București
1.2 Facultatea	Electronică, Telecomunicații și Tehnologia Informației
1.3 Departamentul	Telecomunicații
1.4 Domeniul de studii	Inginerie Electronică, Telecomunicații și Tehnologii Informaționale
1.5 Ciclu de studii	Licență
1.6 Specializarea	Tehnologii și Sisteme de Telecomunicații

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)	Inteligență artificială - Proiect						
2.2 Titularul activităților de curs	Prof. Dr. Razvan Craciunescu						
2.3 Titularul activităților de seminar / laborator	Drd. Dan Curavale						
2.4 Anul de studiu	4	2.5 Semestrul	1	2.6 Tipul de evaluare	V	2.7 Regimul disciplinei	Op
2.8 Tipul disciplinei	S	2.9 Codul disciplinei	04.S.07.A.209	2.10 Tipul de notare	Nota		

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

3.1 Număr de ore pe săptămână	1	Din care: 3.2 curs	0.00	3.3 seminar/laborator	1
3.4 Total ore din planul de învățământ	14	Din care: 3.5 curs	0	3.6 seminar/laborator	14
Distribuția fondului de timp:					ore
Studiul după manual, suport de curs, bibliografie și notițe Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate Pregătire seminarii/ laboratoare/proiecte, teme, referate, portofolii și eseuri					30
Tutorat					4
Examinări					2
Alte activități (dacă există):					0
3.7 Total ore studiu individual	36.00				
3.8 Total ore pe semestru	50				
3.9 Numărul de credite	2				

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Nu este cazul
4.2 de rezultate ale învățării	Nu este cazul

5. Condiții necesare pentru desfășurarea optimă a activităților didactice (acolo unde este cazul)

5.1 Curs	Nu este cazul
5.2 Seminar/ Laborator/Proiect	Stații de lucru cu Python (Anaconda), Git, Jupyter/VS Code; acces la seturi de date; conectivitate la platforme (GitHub). GPU opțional pentru antrenare accelerată.



6. Obiectiv general (Se referă la intențiile profesorilor pentru studenți, la ceea ce studenții vor fi învățați în timpul cursului. Oferă o orientare cu privire la locul cursului în cadrul domeniului științific abordat, precum și la rolul pe care acesta îl are în cadrul specializării studiate. Vor fi descrise de o manieră generală tematicile abordate, justificarea includerii cursului în planul de învățământ al specializării studiate etc.)

Disciplina urmărește să îi ghideze pe studenți în realizarea unui proiect aplicat de inteligență artificială, la alegere dintre clasificare EEG, computer vision sau sisteme agentice bazate pe LLM - de la definirea clară a problemei și a criteriilor de succes, până la o implementare reproductibilă și bine argumentată. Pe parcurs, echipele (2–3 studenți) învață să își construiască propriul pipeline (analiză exploratorie a datelor, preprocesare/augmentare, proiectare și antrenare de modele, evaluare cu metrici adecvate precum F1, acuratețe echilibrată, ROC/PR sau task-success pentru agenți), să documenteze riguros rezultatele și să le prezinte convingător. Punem accent pe bune practici de reproducibilitate (structură de repo, control al versiunilor, ghid de rulare), pe etica datelor și pe organizarea proiectului, finalizate cu livrabile clare: cod, raport și prezentare.

7. Competențe (Capacitatea dovedită de a utiliza cunoștințe, aptitudini și abilități personale, sociale și/sau metodologice în situații de muncă sau de studiu și pentru dezvoltarea profesională și personală. Reflectă cerințele angajatorilor.)

Specifice	• Proiectarea unui proiect AI (date → explorarea datelor → preprocesare/augmentare → modele → evaluare → raportare). • Analiza critică a setului de date (distribuții pe clase, dezechilibre, diagrame). • Aplicarea de metode / arhitecturi moderne în domeniul ML. • Bune practici în a scrie și menține cod (GitHub, versiuni, documentare științifică) • Capacitatea de a susține în mod argumentat o prezentare tehnică.
Transversale (generale)	• Gândire critică și rezolvare de probleme: Dezvoltarea abilității de a analiza probleme complexe și de a propune soluții inovatoare utilizând IA. • Lucru în echipă multidisciplinară: management de proiect, comunicare tehnică. • Adaptabilitate la tehnologii emergente: Însușirea rapidă a cunoștințelor privind noile tendințe și instrumente din domeniul IA. • Căutare și sinteză de literatură. • Comunicare profesională: Prezentarea clară și coerentă a soluțiilor dezvoltate, atât în scris, cât și oral, în contexte profesionale.

8. Rezultatele învățării (Sunt enunțuri sintetice referitoare la ceea ce un student va fi capabil să facă sau să demonstreze la finalizarea unui curs. Rezultatele învățării reflectă realizările studentului și mai puțin intențiile profesorului. Rezultatele învățării informează studenții despre ceea ce se așteaptă de la ei din punct de vedere al performanței, pentru a obține notele și creditele dorite. Sunt definite în termeni concreți, folosind verbe similare exemplelor de mai jos și indică ceea ce se va urmări prin evaluare. Rezultatele învățării vor fi astfel redactate încât să fie evidențiată clar relația față de competențele definite la punctul 7.)



Cunoștințe	<i>Rezultatul asimilării de informații prin învățare. Cunoștințele reprezintă ansamblul de fapte, principii, teorii și practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice și/sau faptice.</i> • Explică componentele unui pipeline ML end-to-end (problem framing, EDA, preprocesare, modelare, evaluare, raportare) și argumentează alegeri metodologice în funcție de date/obiective. • Describe tehnici uzuale de preprocesare (filtrare/ferestruire EEG, normalizare, augmentare imagini, curățare text/loguri pentru agenți). • Identifică familii de modele potrivite pe fiecare direcție (EEGNet / CNN simple / transfer learning vizual / fluxuri agentice LLM cu planner–executor–critic). • Selectează metrici adecvate: F1, acuratețe echilibrată, ROC/PR; pentru agenți: task-success rate, număr de pași, timp. • Cunoaște bune practici de reproductibilitate (structura repo, fixed seeds, versionare, README/runbook) și cerințe etice/legal-de licențiere a datelor.
Aptitudini	<i>Capacitatea de a aplica cunoștințe și de a utiliza know-how pentru a duce la îndeplinire sarcini și a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive și creative) sau practice (implicând dexteritate manuală și utilizarea de metode, materiale, unelte și instrumente).</i> • Construiesc un pipeline funcțional pe una dintre direcții (EEG / CV / Agentic LLMs), de la EDA la evaluare finală. • Implementeze modele de bază și variante îmbunătățite (transfer learning, ablații, reglaj hiperparametri) și să compare riguros rezultatele. • Instrumenteze experimentarea: loguri, salvare modele, grafice, tabele, comparații cross-validation; automatizeze pașii cheie (scripturi/Makefile). • Integreze cod + date + rezultate într-un repo reproductibil cu instrucțiuni de rulare și să redacteze un raport tehnic coerent cu figuri/tabele corecte. • Prezintă public soluția și să răspundă clar la întrebări tehnice.
Responsabilitate și autonomie	<i>Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale.</i> • Planifică și execută activitățile proiectului în echipă (2–3 pers.). • Aplică principii de etică și integritate academică (citare corectă, folosire responsabilă a LLM-urilor/comp. pre-antrenate, respectarea licențelor). • Critică limitările soluției și propune pași de îmbunătățire.

9. Metode de predare (Se vor avea în vedere metode care să asigure predarea centrată pe student. Se va descrie modul în care se asigură participarea studenților la stabilirea propriului parcurs de învățare, cum se identifică eventualele rămânări în urmă și ce măsuri remediale se adoptă în astfel de cazuri.)

Proiectul de inteligență artificială este structurat pentru a încuraja o abordare centrată pe student, combinând activități practice cu îndrumare individualizată. Activitățile sunt organizate astfel încât să permită studenților să își personalizeze parcursul de învățare, în funcție de interesele și nivelul lor de cunoștințe.

Metodele de predare includ sesiuni de consultare și mentorat, în cadrul cărora studenții discută cu profesorii despre proiectele lor și primesc feedback personalizat. Lucrările practice sunt puse în valoare prin utilizarea unor seturi de date reale și a unor platforme de inteligență artificială, precum TensorFlow, PyTorch sau scikit-learn, aplicate problemelor de securitate cibernetică. Progresul este monitorizat prin livrabile intermediare (exemple: plan de proiect, modele preliminare) care permit identificarea timpurie a posibilelor decalaje.



Pentru a sprijini studenții cu dificultăți, sunt organizate sesiuni suplimentare de meditații, iar materialele de învățare includ exemple practice și resurse teoretice suplimentare. Proiectul promovează colaborarea între studenți prin formarea de echipe care lucrează pe teme similare, stimulând schimbul de idei și crearea de soluții inovatoare. Această metodologie asigură implicarea activă a studenților, sprijinind procesul de învățare și atingerea obiectivelor stabilite în proiect.

10. Conținuturi

PROIECT		
Nr. crt.	Conținutul	Nr. ore
1	Disciplina are ca produs final un proiect aplicat de inteligență artificială, ales dintre trei direcții: clasificare EEG, computer vision sau sisteme agentice bazate pe LLM. Studenții parcurg cap-coadă un pipeline reproducibil: definirea problemei și a criteriilor de succes, alegerea și analizarea setului de date, preprocesare/augmentare, proiectarea și antrenarea modelelor (inclusiv variante cu transfer learning sau arhitecturi dedicate, ex. EEGNet), urmărirea experimentelor și evaluarea cu metrici adecvate (F1, acuratețe echilibrată, ROC/PR; pentru agenți: task-success, pași, timp). Proiectul este structurat pe predări intermediare (S5 - problemă + diagramă + EDA; S7 - literatură + plan de experimente) și se încheie cu repo reproducibil, raport tehnic (~10 pagini) și prezentare (10-12 min), punând accent pe rigoare și comunicare clară a rezultatelor.	14
	Total:	14
Bibliografie: Dan Curavale, Note de proiect		

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare	11.3 Pondere din nota finală
11.4 Curs			



11.5 Seminar/laborator/proiect	• Cunoașterea și utilizarea noțiunilor fundamentale privind sursele de informare: Capacitatea de a identifica și accesa surse relevante pentru domeniul AI. • Evaluarea calității și structurii documentației proiectului: Analizarea clarității, coerenței și relevanței informațiilor furnizate în raportul final. • Modul de întocmire a bibliografiei: Selectarea surselor relevante și compararea referințelor pentru a demonstra o înțelegere critică și riguroasă a literaturii de specialitate. • Calitatea prezentării și a discursului: Capacitatea de a prezenta într-un mod structurat o temă tehnică și de a concepe un suport de prezentare.	Notarea acestei activități este în regim de verificare pe parcurs (cu notă de la 1 la 10). Pentru notare: - se vor aprecia modul de constituire a raportului final aferent tematicii de cercetare abordate - se va realiza o evaluare orală a cunoștințelor studenților privind domeniul și subiectele abordate în raport.	100%
11.6 Condiții de promovare			
– Obținerea a minimum 50% din punctajul total.			

12. Coroborarea conținutului disciplinei cu așteptările reprezentanților angajatorilor și asociațiilor profesionale reprezentative din domeniul aferent programului, precum și cu stadiul actual al cunoașterii în domeniul științific abordat și practicile în instituții de învățământ superior din Spațiul European al Învățământului Superior (SEİS)

Conținutul disciplinei este aliniat cu așteptările actuale ale angajatorilor și ale asociațiilor profesionale din domeniul IT&C: proiectarea de **pipeline-uri ML reproductibile**, lucru cu **seturi de date reale**, **măsurarea corectă a performanței** (metrici potrivite problemei), **versionare și colaborare** pe repo, documentație tehnică clară și **etică a datelor**. Direcțiile propuse (EEG, computer vision, sisteme agentice cu LLM) reflectă tendințele din industrie și cercetare (transfer learning, automatizarea experimentelor, testare pe scenarii), pregătind studenții pentru roluri de tip data/ML engineer sau applied researcher. Metodologia urmează practicile consacrate în SEİS: **învățare centrată pe student**, rezultate ale învățării explicit formulate, **evaluare continuă pe jaloane** cu rubrici transparente și proiect final care integrează cunoașterea științifică actuală cu rezolvarea de probleme reale. Integrarea disciplinei în programul de studii sprijină formarea unor specialiști cu competențe avansate în utilizarea IA pentru securitatea informațională. Aceasta contribuie la crearea unui profil profesional adaptat nevoilor pieței muncii, asigurând totodată dezvoltarea capacităților de cercetare și inovare, în conformitate cu tendințele globale din industria tehnologică.

Data completării

Titular de curs

Titular(i) de aplicații

25.09.2025

Drd Dan Curavale



Universitatea Națională de Știință și Tehnologie Politehnica București
Facultatea de Electronică, Telecomunicații și
Tehnologia Informației



Data avizării în departament

26.09.2025

Director de departament

Conf. Dr. Serban Georgica Obreja

Data aprobării în Consiliul Facultății

26.09.2025

Decan

Prof. Dr. Mihnea Udrea