Universitatea Naţională de Ştiinţă şi Tehnologie Politehnica Bucureşti

Facultatea de Electronică, Telecomunicaţii şi

Tehnologia Informaţiei

FIŞA DISCIPLINEI

1. Date despre program

1.1 Instituţia de învăţământ superior	**Universitatea Naţională de Ştiinţă şi Tehnologie Politehnica Bucureşti**
1.2 Facultatea	**Electronică, Telecomunicaţii şi Tehnologia Informaţiei**
1.3 Departamentul	**Telecomunicaţii**
1.4 Domeniul de studii	Inginerie Electronică, Telecomunicaţii şi Tehnologii Informaţionale
1.5 Ciclul de studii	Licenţă
1.6 Specializarea	Tehnologii şi Sisteme de Telecomunicaţii

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)				Inteligenţă artificială - Proiect			
2.2 Titularul activităţilor de curs				Prof. Dr. Razvan Craciunescu			
2.3 Titularul activităţilor 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 activităţilor 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 învăţământ	14	Din care: 3.5 curs	0	3.6 seminar/laborator	14
Distribuţia fondului de timp:					ore
Studiul după manual, suport de curs, bibliografie şi notiţe Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate Pregătire seminarii/ laboratoare/proiecte, teme, referate, portofolii şi eseuri					30
Tutorat					4
Examinări					2
Alte activităţi (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. Precondiţii (acolo unde este cazul)

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

5. Condiţii necesare pentru desfăşurarea optimă a activităţilor didactice (acolo unde este cazul)

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

6. Obiectiv general *(Se referă la intenţiile profesorilor pentru studenţi, la ceea ce studenţii vor fi învăţaţi în timpul cursului. Oferă o orientare cu privire la locul cursului în cadrul domeniului ştiinţific abordat, precum şi 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 învăţământ 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. Competenţe *(Capacitatea dovedită de a utiliza cunoştinţe, aptitudini şi abilităţi personale, sociale şi/sau metodologice în situaţii de muncă sau de studiu şi pentru dezvoltarea profesională şi personală. Reflectă cerinţele 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 şi rezolvare de probleme:** Dezvoltarea abilităţii de a analiza probleme complexe şi de a propune soluţii inovatoare utilizând IA. · **Lucru în echipă multidisciplinară:** management de proiect, comunicare tehnică. · **Adaptabilitate la tehnologii emergente:** Însuşirea rapidă a cunoştinţelor privind noile tendinţe şi instrumente din domeniul IA. · Căutare şi **sinteză de literatură.** · **Comunicare profesională:** Prezentarea clară şi coerentă a soluţiilor dezvoltate, atât în scris, cât şi oral, în contexte profesionale.

8. Rezultatele învăţării *(Sunt enunţuri sintetice referitoare la ceea ce un student va fi capabil să facă sau să demonstreze la finalizarea unui curs. Rezultatele învăţării reflectă realizările studentului şi mai puţin intenţiile profesorului. Rezultatele învăţării informează studenţii despre ceea ce se aşteaptă de la ei din punct de vedere al performanţei, pentru a obţine notele şi creditele dorite. Sunt definite în termeni concreţi, folosind verbe similare exemplelor de mai jos şi indică ceea ce se va urmări prin evaluare. Rezultatele învăţării vor fi astfel redactate încât să fie evidenţiată clar relaţia faţă de competenţele definite la punctul 7.)*

Cunoştinţe	*Rezultatul asimilării de informaţii prin învăţare. Cunoştinţele reprezintă ansamblul de fapte, principii, teorii şi practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice şi/sau faptice.* · **Explică** componentele unui pipeline ML end-to-end (problem framing, EDA, preprocesare, modelare, evaluare, raportare) şi **argumentează** alegeri metodologice în funcţie de date/obiective. · **Descrie** tehnici uzuale de preprocesare (filtrare/ferestruire EEG, normalizare, augmentare imagini, curăţare text/loguri pentru agenţi). · **Identifică** familii de modele potrivite pe fiecare direcţie (EEGNet / CNN simple / transfer learning vizual / fluxuri agentice LLM cu planner–executor–critic). · **Selectează** metrici adecvate:F1, acurateţe echilibrată, ROC/PR; pentru agenţi: task-success rate, număr de paşi, timp. · **Cunoaşte** bune practici de reproductibilitate (structura repo, fixed seeds, versionare, README/runbook) şi cerinţe etice/legal-de licenţiere a datelor.
Aptitudini	*Capacitatea de a aplica cunoştinţe şi de a utiliza know-how pentru a duce la îndeplinire sarcini şi a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive şi creative) sau practice (implicând dexteritate manuală şi utilizarea de metode, materiale, unelte şi instrumente).* · **Construiască** un pipeline funcţional pe una dintre direcţii (EEG / CV / Agentic LLMs), de la EDA la evaluare finală. · **Implementeze** modele de bază şi variante îmbunătăţite (transfer learning, ablaţii, reglaj hiperparametri) şi să **compare** riguros rezultatele. · **Instrumenteze** experimentarea: loguri, salvare modele, grafice, tabele, comparaţii cross-validation; **automatizeze** paşii cheie (scripturi/Makefile). · **Integreze** cod + date + rezultate într-un **repo reproductibil** cu instrucţiuni de rulare şi să **redacteze** un raport tehnic coerent cu figuri/tabele corecte. · **Prezinte** public soluţia şi să **răspundă** clar la întrebări tehnice.
Responsabilitate şi autonomie	*Capacitatea cursantului de a aplica în mod autonom şi responsabil cunoştinţele şi aptitudinile sale.* · **Planifică** şi **execută** activităţile proiectului în echipă (2–3 pers.). · **Aplică** principii de etică şi integritate academică (citare corectă, folosire responsabilă a LLM-urilor/comp. pre-antrenate, respectarea licenţelor). · **Critică** limitările soluţiei şi **propune** paşi de îmbunătăţire.

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 studenţilor la stabilirea propriului parcurs de învăţare, cum se identifică eventualele rămâneri în urmă şi ce măsuri remediale se adoptă în astfel de cazuri.)*

Proiectul de inteligenţă artificială este structurat pentru a încuraja o abordare centrată pe student, combinând activităţi practice cu îndrumare individualizată. Activităţile sunt organizate astfel încât să permită studenţilor să îşi personalizeze parcursul de învăţare, în funcţie de interesele şi nivelul lor de cunoştinţe.

Metodele de predare includ sesiuni de consultare şi mentorat, în cadrul cărora studenţii discută cu profesorii despre proiectele lor şi primesc feedback personalizat. Lucrările practice sunt puse în valoare prin utilizarea unor seturi de date reale şi a unor platforme de inteligenţă 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 studenţii cu dificultăţi, sunt organizate sesiuni suplimentare de meditaţii, iar materialele de învăţare includ exemple practice şi resurse teoretice suplimentare. Proiectul promovează colaborarea între studenţi prin formarea de echipe care lucrează pe teme similare, stimulând schimbul de idei şi crearea de soluţii inovatoare. Această metodologie asigură implicarea activă a studenţilor, sprijinind procesul de învăţare şi atingerea obiectivelor stabilite în proiect.

10. Conţinuturi

PROIECT		
Nr. crt.	**Conţinutul**	**Nr. ore**
1	Disciplina are ca produs final un proiect aplicat de inteligenţă artificială, ales dintre trei direcţii: clasificare EEG, computer vision sau sisteme agentice bazate pe LLM. Studenţii parcurg cap-coadă un pipeline reproducibil: definirea problemei şi a criteriilor de succes, alegerea şi analizarea setului de date, preprocesare/augmentare, proiectarea şi antrenarea modelelor (inclusiv variante cu transfer learning sau arhitecturi dedicate, ex. EEGNet), urmărirea experimentelor şi evaluarea cu metrici adecvate (F1, acurateţe echilibrată, ROC/PR; pentru agenţi: task-success, paşi, timp). Proiectul este structurat pe predări intermediare (S5 - problemă + diagramă + EDA; S7 - literatură + plan de experimente) şi se încheie cu repo reproductibil, raport tehnic (~10 pagini) şi prezentare (10-12 min), punând accent pe rigoare şi 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 evaluarea 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 conţinutului disciplinei cu aşteptările reprezentanţilor angajatorilor şi asociaţiilor profesionale reprezentative din domeniul aferent programului, precum şi cu stadiul actual al cunoaşterii în domeniul ştiinţific abordat şi practicile în instituţii de învăţământ superior din Spaţiul European al Învăţământului Superior (SEÎS)

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 SEÎS: **învăţare 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 aplicaţii
21.09.2026		Drd Dan Curavale

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

Data avizării în departament

22.09.2026

Director de departament

Conf. Dr. Serban Georgica Obreja



Data aprobării în Consiliul Facultății

22.09.2026

Decan

Prof. Dr. Mihnea Udrea

