



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	Electronică Aplicată și Ingineria Informației
1.4 Domeniul de studii	Inginerie Electronică, Telecomunicații și Tehnologii Informaționale
1.5 Ciclu de studii	Licență
1.6 Specializarea	Electronică aplicată

2. Date despre disciplină

2.1 Denumirea disciplinei (ro)	Inteligență artificială						
(en)	Artificial intelligence						
2.2 Titularul activităților de curs	S.I./Lect. Dr. Liviu-Daniel ȘTEFAN						
2.3 Titularul activităților de seminar / laborator	S.I./Lect. Dr. Liviu-Daniel ȘTEFAN						
2.4 Anul de studiu	3	2.5 Semestrul	1	2.6 Tipul de evaluare	E	2.7 Regimul disciplinei	Ob
2.8 Tipul disciplinei	S	2.9 Codul disciplinei	04.S.05.O.105	2.10 Tipul de notare	Nota		

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

3.1 Număr de ore pe săptămână	3	Din care: 3.2 curs	2	3.3 seminar/laborator	1
3.4 Total ore din planul de învățământ	42	Din care: 3.5 curs	28	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					29
Tutorat					0
Examinări					4
Alte activități (dacă există):					0
3.7 Total ore studiu individual	33.00				
3.8 Total ore pe semestru	75				
3.9 Numărul de credite	3				

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	Parcursarea și/sau promovarea următoarelor discipline: • Programare Obiect Orientată; • Semnale și Sisteme 1; • Teoria Transmiterii Informației.
4.2 de rezultate ale învățării	Cunoștințe generale privind semnalele unidimensionale și bidimensionale, programare orientată pe obiecte și lucru cu biblioteci dedicate.



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

5.1 Curs	Sistem de videoproiecție pentru prezența fizică și acces la platforma e-learning Moodle și Microsoft Teams. Prezența la curs este stabilită conform regulament ETTI.
5.2 Seminar/ Laborator/Proiect	Laborator dotat cu sisteme de calcul pentru prezența fizică și acces la platforma de e-learning Moodle și Microsoft Teams. Prezența la laborator este obligatorie, conform regulament ETTI.

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.)*

Curs: însușirea mecanismelor de proiectare a modelelor de învățare automată: pre-procesare a datelor, selecția algoritmului specific problemei și/sau compunerea arhitecturii modelului, stabilirea strategiilor de antrenare, optimizare și evaluare. Studiul principiilor de bază utilizate în alcătuirea algoritmilor ca etapă esențială în dezvoltarea eficientă a aplicațiilor software. Criterii de proiectare eficientă a programelor. Studii de caz și metode de evaluare a performanțelor algoritmilor.

Laborator: însușirea practică, prin implementare de programe software, a noțiunilor predate la curs. Implementarea unor sisteme practice cu aplicații în viața reală.

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	• Demonstrează cunoștințe fundamentale și avansate în domeniul inteligenței artificiale, incluzând învățarea supervizată, nesupervizată și învățarea adâncă. • Stăpânește metodele și tehnicile de programare uzuale utilizate în prelucrarea datelor, antrenarea modelelor și optimizarea performanței acestora folosind metrice specifice, • Elaborează soluții software utilizând limbaje de programare obiect-orientată, pornind de la specificațiile cerințelor până la implementare, testare, depanare și analiza rezultatelor, • Identifică nevoia de formare continuă și utilizarea eficientă a surselor informaționale și a resurselor de comunicare și formare profesională asistată (portaluri Internet, aplicații software de specialitate, baze de date, cursuri on-line, etc.) atât în limba română cât și într-o limbă de circulație internațională.
Transversale (generale)	• Capacitatea de a lua decizii în vederea rezolvării problemelor curente, sau imprevizibile, care apar în procesul de exploatare a sistemelor de calcul, • Capacitatea de a se informa și documenta permanent pentru dezvoltarea personală și profesională prin citirea literaturii de specialitate, • Capacitatea de a comunica și de a prezenta conținut tehnic atât în limba română, cât și în limba engleză.



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 exemplurilor 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	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 factice. • însușirea conceptelor fundamentale referitoare la învățarea automată, • însușirea conceptelor fundamentale de programare în limbajul Python cu module specifice pentru manipularea datelor, gestionarea cadrelor de date, vizualizarea datelor, indexare avansată, sumarizarea numerică, grafica descriptivă, precum și învățării automate prin intermediul modulelor Scikit-learn și PyTorch, • însușirea cunoștințelor de a proiecta un model de învățare automată (sisteme de regresie, clasificare supervizată și nesupervizată, și arhitecturi de rețele neuronale adânci), pentru a rezolva o problemă specifică, • însușirea cunoștințelor despre relațiile între diferitele topologii de sisteme bazate pe învățarea profundă, • însușirea cunoștințelor de a urmări impactul asupra rezultatelor, ca urmare a schimbărilor punctuale aduse în modelul implementat și de a înțelege efectul practic pe care acestea îl au.
Aptitudini	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). • abilitatea de a înțelege și explica un model de învățare automată scris în cod Python, • abilitatea de a concepe un algoritm de învățare automată, • abilitatea de a valida rezultatele unui model de învățare automată, • abilitatea de a identifica soluții de programare, • abilitatea de a comunica și argumenta soluții.
Responsabilitate și autonomie	Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale. • selecția și analiza surselor bibliografice potrivite, • respectarea principiilor de etică academică, citând corect sursele bibliografice utilizate, • receptivitate pentru contexte noi de învățare, • colaborarea cu ceilalți colegi și cadre didactice în desfășurarea activităților didactice, • demonstrarea autonomiei în organizarea situației/contextului de învățare sau a situației problemă de rezolvat.

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.)



Pornindu-se de la analiza caracteristicilor de învățare ale studenților și de la nevoile lor specifice, procesul de predare va explora metode de predare atât expositive (prelegerea, expunerea), cât și conversative-interactive, bazate pe modele de învățare prin descoperire facilitate de explorarea directă și indirectă a realității (experimentul, demonstrația, modelarea), dar și pe metode bazate pe acțiune, precum exercițiul, activitățile practice și rezolvarea de probleme.

În activitatea de predare vor fi utilizate prelegeri, în baza unor prezentări Power Point care vor fi puse la dispoziția studenților. Fiecare curs va debuta cu recapitularea capitolelor deja parcurse, cu accent asupra noțiunilor parcurse la ultimul curs. Materialele de curs și de laborator sunt disponibile pe platforma e-learning Moodle, în format electronic.

Prezentările utilizează imagini, scheme și exemple de cod sursă, astfel încât informațiile prezentate să fie ușor de înțeles și asimilat.

10. Conținuturi

CURS		
Capitolul	Conținutul	Nr. ore
1	Introducere în inteligența artificială, prezentare context general. Concepte cheie: învățarea supervizată vs învățarea nesupervizată, regresie vs clasificare. Exemplificare aplicații cu caracter practic.	2
2	Descrierea conținutului datelor, terminologiilor și reprezentărilor asociate cu datele multimodale. Analiza și procesarea datelor.	6
3	Învățare nesupervizată și aplicații specifice. Prezentare generală a învățării nesupervizate, diferențe față de învățarea supervizată. Metode de Clustering: clustering K-Means, clustering ierarhic. Considerații practice și aplicații reale.	4
4	Învățare supervizată și aplicații specifice. Tehnici de regresie: regresie liniară simplă și multiplă. Tehnici de Clasificare: Regresia logistică, K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Arbori de Decizie. Considerații practice și aplicații reale.	4
5	Evaluarea performanței clasificatorilor. Metrice de similaritate între punctele de date și metrice de clasificare pentru evaluarea performanței unui model de clasificare. Compromis bias-diversitate.	2
6	Noțiuni fundamentale de învățare adâncă. Rețele neuronale cu un singur strat, cu mai multe straturi, rețele neuronale convoluționale, funcții de activare non-liniare, funcții de cost, hiperparametri. Rețele neuronale convoluționale-studiu de caz. Rețele neuronale recurente-studiu de caz. Autoencodere-studiu de caz.	4
7	Antrenarea rețelelor neuronale. Propagarea înainte, propagarea înapoi, regularizarea și SGD. Supra-învățarea și sub-învățarea rețelelor. Optimizarea rețelelor neuronale: Transfer Learning și Fine Tuning–studiu de caz.	2
8	Prezentarea diferitelor arhitecturi moderne de rețele neuronale: AlexNet, VGG, ResNet, Inception, Xception, R-CNN, SSD, YOLO.	4
Total:		28



Bibliografie:

1. Ionescu, B., & Mironică, I. (2013). The Content-Based Indexing Paradigm in the Context of Multimodal Data. MatrixRom.
2. Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer.
3. Kroese, D. P., Botev, Z., & Taimre, T. (2019). Data science and machine learning: mathematical and statistical methods. Chapman and Hall/CRC.
4. Jiang, H. (2021). Machine learning fundamentals: A concise introduction. Cambridge University Press.
5. Tom Bäckström, Okko Räsänen, Abraham Zewoudie, Pablo Pérez Zarazaga, Liisa Koivusalo, Sneha Das, Esteban Gómez Mellado, Mariem Bouafif Mansali, & Daniel Ramos. (2022). Introduction to Speech Processing: 2nd Edition.
6. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
7. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
8. Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). Dive into deep learning. arXiv preprint arXiv:2106.11342.

LABORATOR

Nr. crt.	Conținutul	Nr. ore
1	Introducere și familiarizare cu limbajul de programare Python și Google Colab. Utilizarea limbajului de programare Python3 în mediul de dezvoltare Jupyter Notebook, și acoperirea conceptelor precum manipularea datelor cu NumPy, gestionarea cadrelor de date cu Pandas, vizualizarea datelor cu Matplotlib, tehnici de indexare avansată, sumarizarea numerică și grafica descriptivă, precum și organizarea fișierelor și directoarelor.	2
2	Introducere în procesarea datelor de tip imagine, audio și text utilizând instrumente specializate—extragerea de reprezentări specifice. Vizualizarea seturilor mari de date folosind analiza exploratorie a datelor. Procesarea seturilor de date.	2
3	Explorarea metodelor de clasificare nesupervizată prin înțelegerea conceptelor de grupare (clustering), antrenarea modelelor de clustering și optimizarea performanței acestora.	2
4	Explorarea metodelor de regresie și de clasificare supervizată, construirea, antrenarea și evaluarea modelelor de clasificare.	4
5	Introducere și familiarizare cu modulul Pytorch. Utilizarea tensorilor de tip CPU și GPU, gestionarea, scalarea și normalizarea seturilor de date folosind torchvision. Construirea unei arhitecturi de rețea neuronală, antrenarea modelului și îmbunătățirea performanței acestuia folosind tehnici de transfer-learning și fine-tuning.	2
6	Colocviu de laborator.	2
Total:		14



Bibliografie:

1. Ionescu, B., & Mironică, I. (2013). The Content-Based Indexing Paradigm in the Context of Multimodal Data. MartrixRom.
2. Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer.
3. Kroese, D. P., Botev, Z., & Taimre, T. (2019). Data science and machine learning: mathematical and statistical methods. Chapman and Hall/CRC.
4. Jiang, H. (2021). Machine learning fundamentals: A concise introduction. Cambridge University Press.
5. Tom Bäckström, Okko Räsänen, Abraham Zewoudie, Pablo Pérez Zarazaga, Liisa Koivusalo, Sneha Das, Esteban Gómez Mellado, Mariem Bouafif Mansali, & Daniel Ramos. (2022). Introduction to Speech Processing: 2nd Edition.
6. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
7. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
8. Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). Dive into deep learning. arXiv preprint arXiv:2106.11342.

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare	11.3 Pondere din nota finală
11.4 Curs	- cunoașterea noțiunilor teoretice fundamentale de învățarea automată, - analiza diferențiată a tehnicilor și metodelor teoretice, - rezolvarea unor probleme comune de învățare automată.	Evaluare de tip parțial susținută la o dată fixată la începutul cursului; subiectele acoperă capitolele 1-4, realizând o sinteză între parcurgerea teoretică comparativă a materiei și explicitarea prin exerciții și probleme a modelelor de aplicație.	25%
	- cunoașterea noțiunilor teoretice fundamentale de învățarea automată, - analiza diferențiată a tehnicilor și metodelor teoretice, - rezolvarea unor probleme comune de învățare automată.	Examen final: subiectele acoperă capitolele 5-8, realizând o sinteză între parcurgerea teoretică comparativă a materiei și explicitarea prin exerciții și probleme a modelelor de aplicație.	25%



11.5 Seminar/laborator/proiect	- cunoașterea modului de utilizare limbajului de programare Python și ale librăriilor, numpy, matplotlib, pandas, opencv, scikit-learn, pytorch, - cunoașterea metodelor de procesare a datelor, - cunoaștere metodelor de regresie, clasificarea și grupare (clustering), - cunoașterea procesului de antrenare și validare a metodelor de învățare automată, - rezolvarea unor probleme comune de inteligență artificială, machine learning și deep learning în mediul Colab/Jupyter Notebook și limbajul Python.	Colocviu final de laborator, cuprinzând o componentă teoretică și o componentă practică. Componenta teoretică este verificată prin test; componenta practică este evaluată prin verificarea modului de rezolvare (implementare, testare, funcționare) de către student a unei probleme practice.	50%
11.6 Condiții de promovare			
• participarea la lucrările de laborator; • cumularea a minim 50% din punctajul aferent laboratorului; • cumularea a minim 50% din punctajul aferent disciplinei.			

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)

- Programa de curs oferă absolvenților fundamente solide în domeniul inteligenței artificiale, cu accent pe construirea și antrenarea modelelor de învățare automată în Python. Studenții dobândesc competențe esențiale pentru formularea corectă a unei probleme AI, preprocesarea adecvată a datelor, alegerea arhitecturii sau tehnicii de antrenare potrivite, evaluarea performanței modelelor de AI și utilizarea bibliotecilor moderne precum NumPy, Pandas, Matplotlib, scikit-learn, PyTorch, HuggingFace Transformers ș.a. Având în vedere că progresul tehnologic actual este puternic influențat de revoluția inteligenței artificiale, această disciplină joacă un rol fundamental în formarea noilor generații de ingineri și cercetători.



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



- Programa asigură astfel absolvenților competențe adecvate cu necesitățile calificărilor actuale și o pregătire științifică și tehnică modernă, de calitate și competitivă, care să le permită angajarea rapidă după absolvire. Aceasta este perfect încadrată în politica Universității Politehnica București, atât din punctul de vedere al conținutului și structurii, cât și din punctul de vedere al aptitudinilor și deschiderii internaționale oferite studenților. Posibili angajatori vizează atât mediul academic (profil didactic și de cercetare) cât și mediul industrial de cercetare-dezvoltare precum organizații/firme de orice dimensiune, de la cele mici create de studenți/masteranzi (de exemplu start-up și spin-off), până la cele multinaționale.

Data completării	Titular de curs	Titular(i) de aplicații
25.09.2025	S.I./Lect. Dr. Liviu-Daniel ȘTEFAN	S.I./Lect. Dr. Liviu-Daniel ȘTEFAN

Data avizării în departament	Director de departament
26.09.2025	Conf. Dr. Bogdan Cristian Florea

Data aprobării în Consiliul Facultății	Decan
26.09.2025	Prof. Dr. Mihnea Udrea