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	**Electronică Aplicată şi Ingineria Informaţiei**
1.4 Domeniul de studii	Inginerie Electronică, Telecomunicaţii şi Tehnologii Informaţionale
1.5 Ciclul de studii	Licenţă
1.6 Specializarea	Electronică aplicată

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)				Inteligenţă artificială Artificial intelligence			
2.2 Titularul activităţilor de curs				S.l./Lect. Dr. Liviu-Daniel ŞTEFAN			
2.3 Titularul activităţilor de seminar / laborator				S.l./Lect. Dr. Liviu-Daniel ŞTEFAN			
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 activităţilor 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 învăţământ	42	Din care: 3.5 curs	28	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					29
Tutorat					0
Examinări					4
Alte activităţi (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. Precondiţii (acolo unde este cazul)

4.1 de curriculum	Parcurgerea şi/sau promovarea următoarelor discipline: • Programare Obiect Orientată; • Semnale şi Sisteme 1; • Teoria Transmiterii Informatiei.
4.2 de rezultate ale învăţării	Cunoştinţe generale privind semnalele unidimensionale şi bidimensionale, programare orientată pe obiecte şi lucru cu biblioteci dedicate.

5. Condiţii necesare pentru desfăşurarea optimă a activităţilor 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 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.)*

Curs: însuşirea mecanismelor de proiectare a modelelor de învățarea 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. 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	• Demonstrează cunoştinţe fundamentale şi avansate în domeniul inteligenţei artificiale, incluzând învățarea supervizată, nesupervizată și învățarea adâncă. • Stăpâneşte metodele şi tehnicile de programare uzuale utilizate în prelucrarea datelor, antrenarea modelelor şi optimizarea performanţei acestora folosind metrici specifice, • Elaborează soluţii software utilizând limbaje de programare obiect-orientată, pornind de la specificaţiile cerinţelor până la implementare, testare, depanare şi analiza rezultatelor, • Identifică nevoia de formare continuă şi utilizarea eficientă a surselor informaţionale şi a resurselor de comunicare şi formare profesională asistată (portaluri Internet, aplicaţii software de specialitate, baze de date, cursuri on-line, etc.) atât în limba română cât şi într-o limbă de circulaţie internaţională.
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 şi de a prezenta conţinut tehnic atât în limba română, cât şi în limba engleză.

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.* • însuşirea conceptelor fundamentale referitoare la învăţarea automată, • însuşirea 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 şi învăţării automate prin intermediul modulelor Scikit-learn şi PyTorch, • însuşirea cunoştinţelor de a proiecta un model de învăţarea automată (sisteme de regresie, clasificare supervizată şi nesupervizată, şi arhitecturi de reţele neuronale adânci), pentru a rezolva o problemă specifică, • însuşirea cunoştinţelor despre relaţiile între diferitele topologii de sisteme bazate pe învăţarea profundă, • însuşirea cunoştinţelor de a urmări impactul asupra rezultatelor, ca urmare a schimbărilor punctuale aduse în modelul implementat şi de a înţelege efectul practic pe care acestea îl au.
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).* • abilitatea de a înţelege şi explica un model de învăţare automată scris în cod Python, • abilitatea de a de concepe un algoritm de învăţare automată, • abilitatea de a valida rezultatele unui model de învăţare automată, • abilitatea de a identifica soluţii de programare, • abilitatea de a comunica şi argumenta soluţii.
Responsabilitate şi autonomie	*Capacitatea cursantului de a aplica în mod autonom şi responsabil cunoştinţele şi aptitudinile sale.* • selecţia şi analiza surselor bibliografice potrivite, • respectarea principiilor de etică academică, citând corect sursele bibliografice utilizate, • receptivitate pentru contexte noi de învăţare, • colaborarea cu ceilalţi colegi şi cadre didactice în desfăşurarea activităţilor didactice, • demonstrarea autonomiei în organizarea situaţiei/contextului de învăţare sau a situaţiei 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 studenţilor la stabilirea propriului parcurs de învăţare, cum se identifică eventualele rămâneri în urmă şi ce măsuri remediale se adoptă în astfel de cazuri.)*

Pornindu-se de la analiza caracteristicilor de învăţare ale studenţilor şi de la nevoile lor specifice, procesul de predare va explora metode de predare atât expozitive (prelegerea, expunerea), cât şi conversative-interactive, bazate pe modele de învăţare prin descoperire facilitate de explorarea directă şi indirectă a realităţii (experimentul, demonstraţia, modelarea), dar şi pe metode bazate pe acţiune, precum exerciţiul, activităţile practice şi rezolvarea de probleme.

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

Prezentările utilizează imagini, scheme şi exemple de cod sursă, astfel încât informaţiile prezentate să fie uşor de înţeles şi asimilat.

10. Conţinuturi

CURS		
Capitolul	**Conţinutul**	**Nr. ore**
1	Introducere în inteligenţa artificială, prezentare context general. Concepte cheie: învăţarea supervizată vs învăţarea nesupervizată, regresie vs clasificare. Exemplificare aplicaţii cu caracter practic.	2
2	Descrierea conţinutului datelor, terminologiilor şi reprezentărilor asociate cu datele multimodale. Analiza şi procesarea datelor.	6
3	Învăţare nesupervizată şi aplicaţii specifice. Prezentare generală a învăţării nesupervizate, diferenţe faţă de învăţarea supervizată. Metode de Clustering: clustering K-Means, clustering ierarhic. Consideraţii practice şi aplicaţii reale.	4
4	Învăţare supervizată şi aplicaţii specifice. Tehnici de regresie: regresie liniară simplă şi multiplă. Tehnici de Clasificare: Regresia logistică, K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Arbori de Decizie. Consideraţii practice şi aplicaţii reale.	4
5	Evaluarea performanţei clasificatorilor. Metrici de similaritate între punctele de date şi metrici de clasificare pentru evaluarea performanţei unui model de clasificare. Compromis bias-diversitate.	2
6	Noţiuni fundamentale de învăţare adâncă. Reţele neuronale cu un singur strat, cu mai multe straturi, reţele neuronale convoluţionale, funcţii de activare non-liniare, funcţii de cost, hiperparametri. Reţele neuronale convoluţionale-studiu de caz. Reţele neuronale recurente-studiu de caz. Autoencodere-studiu de caz.	4
7	Antrenarea reţelelor neuronale. Propagarea înainte, propagarea înapoi, regularizarea şi SGD. Supra-învăţarea şi sub-învăţarea reţelelor. Optimizarea reţelelor neuronale: Transfer Learning şi Fine Tuning–studiu de caz.	2
8	Prezentarea diferitelor arhitecturi moderne de reţele 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. 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.

LABORATOR

Nr. crt.	Conţinutul	Nr. ore
1	Introducere şi familiarizare cu limbajul de programare Python şi Google Colab. Utilizarea limbajului de programare Python3 în mediul de dezvoltare Jupyter Notebook, şi acoperirea conceptelor precum manipularea datelor cu NumPy, gestionarea cadrelor de date cu Pandas, vizualizarea datelor cu Matplotlib, tehnici de indexare avansată, sumarizarea numerică şi grafica descriptivă, precum şi organizarea fişierelor şi directoarelor.	2
2	Introducere în procesarea datelor de tip imagine, audio şi 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 înţelegerea conceptelor de grupare (clustering), antrenarea modelelor de clustering şi optimizarea performanţei acestora.	2
4	Explorarea metodelor de regresie şi de clasificare supervizată, construirea, antrenarea şi evaluarea modelelor de clasificare.	4
5	Introducere şi familiarizare cu modulul Pytorch. Utilizarea tensorilor de tip CPU şi GPU, gestionarea, scalarea şi normalizarea seturilor de date folosind torchvision. Construirea unei arhitecturi de reţea neuronală, antrenarea modelului şi îmbunătăţirea performanţei acestuia folosind tehnici de transfer-learning şi fine-tunning.	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	- cunoaşterea noţiunilor teoretice fundamentale de învăţarea automată, - analiza diferenţiată a tehnicilor şi metodelor teoretice, - rezolvarea unor probleme comune de învăţare 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 şi explicitarea prin exerciţii şi probleme a modelelor de aplicație.	25%
	- cunoaşterea noţiunilor teoretice fundamentale de învăţarea automată, - analiza diferenţiată a tehnicilor şi metodelor teoretice, - rezolvarea unor probleme comune de învăţare automată.	Examen final: subiectele acoperă capitolele 5-8, realizând o sinteză între parcurgerea teoretică comparativă a materiei şi explicitarea prin exerciţii şi probleme a modelelor de aplicație.	25%

11.5 Seminar/laborator/proiect	- cunoaşterea modului de utilizare limbajului de programare Python şi ale librăriilor, numpy, matplotlib, pandas, opencv, scikit-learn, pytorch, - cunoaşterea metodelor de procesare a datelor, - cunoaştere metodelor de regresie, clasificarea şi grupare (clustering), - cunoaşterea procesului de antrenare şi validare a metodelor de învăţare automată, - rezolvarea unor probleme comune de inteligenţă artificială, machine learning şi deep learning în mediul Colab/Jupyter Notebook şi limbajul Python.	Colocviu final de laborator, cuprinzând o componentă teoretică şi o componentă practică. Componenta teoretică este verificată prin test; componenta practică este evaluată prin verificarea modului de rezolvare (implementare, testare, funcţionare) de către student a unei probleme practice.	50%
11.6 Condiţii 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 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)

- Programa de curs oferă absolvenţilor fundamente solide în domeniul inteligenţei artificiale, cu accent pe construirea şi antrenarea modelelor de învăţare automată în Python. Studenţii dobândesc competenţe esenţiale pentru formularea corectă a unei probleme AI, preprocesarea adecvată a datelor, alegerea arhitecturii sau tehnicii de antrenare potrivite, evaluarea performanţei modelelor de AI şi utilizarea bibliotecilor moderne precum NumPy, Pandas, Matplotlib, scikit-learn, PyTorch, HuggingFace Transformers ş.a. Având în vedere că progresul tehnologic actual este puternic influenţat de revoluţia inteligenţei artificiale, această disciplină joacă un rol fundamental în formarea noilor generaţii de ingineri şi cercetători.

- Programa asigură astfel absolvenţilor competenţe adecvate cu necesităţile calificărilor actuale şi o pregătire ştiinţifică şi tehnică modernă, de calitate şi competitivă, care să le permită angajarea rapidă după absolvire. Aceasta este perfect încadrată în politica Universităţii Politehnica Bucureşti, atât din punctul de vedere al conţinutului şi structurii, cât şi din punctul de vedere al aptitudinilor şi deschiderii internaţionale oferite studenţilor. Posibilii angajatori vizează atât mediul academic (profil didactic şi de cercetare) cât şi mediul industrial de cercetare-dezvoltare precum organizaţii/firme de orice dimensiune, de la cele mici create de studenţi/masteranzi (de exemplu start-up şi spin-off), până la cele multinaţionale.

Data completării	Titular de curs	Titular(i) de aplicaţii
21.09.2026	S.l./Lect. Dr. Liviu-Daniel ŞTEFAN	S.l./Lect. Dr. Liviu-Daniel ŞTEFAN

Data avizării în departament	Director de departament
22.09.2026	Conf. Dr. Bogdan Cristian Florea

Data aprobării în Consiliul Facultăţii	Decan
22.09.2026	Prof. Dr. Mihnea Udrea