



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 | Dispozitive, Circuite și Arhitecturi Electronice |
| 1.4 Domeniul de studii | Inginerie Electronică, Telecomunicații și Tehnologii Informaționale |
| 1.5 Ciclul de studii | Masterat |
| 1.6 Specializarea | Tehnologii Multimedia în Aplicații de Biometrie și Securitatea Informației |

2. Date despre disciplină

| | | | | | | | |
|--|----|---|-------------------|-----------------------|------|-------------------------|----|
| 2.1 Denumirea disciplinei (ro) | | Inteligență artificială I: sisteme clasice de învățare automată | | | | | |
| (en) | | Artificial Intelligence I: Classical Machine Learning Systems | | | | | |
| 2.2 Titularul activităților de curs | | Ș.L. dr. ing. Șerban MIHALACHE | | | | | |
| 2.3 Titularul activităților de seminar / laborator | | Ș.L. dr. ing. Șerban MIHALACHE | | | | | |
| 2.4 Anul de studiu | 1 | 2.5 Semestrul | I | 2.6 Tipul de evaluare | E | 2.7 Regimul disciplinei | Ob |
| 2.8 Tipul disciplinei | DA | 2.9 Codul disciplinei | UPB.04.M1.O.20-08 | 2.10 Tipul de notare | Nota | | |

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

| | | | | | |
|--|-------|--------------------|------|-----------------------|-----|
| 3.1 Număr de ore pe săptămână | 4 | Din care: 3.2 curs | 2.00 | 3.3 seminar/laborator | 2 |
| 3.4 Total ore din planul de învățământ | 56.00 | Din care: 3.5 curs | 28 | 3.6 seminar/laborator | 28 |
| Distribuția fondului de timp: | | | | | ore |
| Studiul după manual, suport de curs, bibliografie și notițe | | | | | 65 |
| Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate | | | | | |
| Pregătire seminarii/ laboratoare/proiecte, teme, referate, portofolii și eseuri | | | | | |
| Tutorat | | | | | 0 |
| Examinări | | | | | 4 |
| Alte activități (dacă există): | | | | | 0 |
| 3.7 Total ore studiu individual | 69.00 | | | | |
| 3.8 Total ore pe semestru | 125 | | | | |
| 3.9 Numărul de credite | 5 | | | | |

4. Precondiții (acolo unde este cazul)

| | |
|-------------------|--|
| 4.1 de curriculum | Parcursarea următoarelor discipline: – Programarea calculatoarelor – Prelucrarea digitală a semnalelor |
|-------------------|--|



| | |
|--------------------------------|---|
| 4.2 de rezultate ale învățării | Acumularea următoarelor cunoștințe generale: – concepte fundamentale de programare a calculatoarelor; – tehnici de bază de prelucrare a semnalelor. |
|--------------------------------|---|

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

| | |
|-----------------------------------|---|
| 5.1 Curs | – Cursul se va desfășura într-o sală dotată cu videoproiector și computer. |
| 5.2 Seminar/ Laborator/Proiect | – Laboratorul se va desfășura într-o sală cu dotare specifică, care trebuie să includă: videoproiector, computer și software specific (Python). – Prezența obligatorie la laboratoare (conform regulamentului studiilor universitare de masterat în UNSTPB). |

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 oferă o perspectivă detaliată asupra domeniului învățării automate folosind modele clasice: modelul celor K medii (K-means Model, KMM), algoritmul celor mai apropiați K vecini (K-nearest Neighbors, KNN), modele cu mixturi de Gaussiene (Gaussian Mixture Models, GMM), regresie liniară și logistică, arbori de decizie (Decision Trees, DT), ansambluri de arbori de decizie (Random Forests, RF), mașini cu vectori suport (Support Vector Machines, SVM), modele Markov ascunse (Hidden Markov Models, HMM) și rețele neuronale artificiale fundamentale, în particular rețele neurale complet-conectate (Fully-connected Neural Networks, FCNN).

– Cursul oferă o introducere în problematicile specifice domeniului și abordează cele trei paradigme fundamentale (învățare supervizată, învățare nesupervizată și învățare susținută), realizându-se o analiză comparativă a acestora și a tipurilor de aplicații care se pretează nativ fiecăreia. Sunt prezentate în detaliu cele mai importante tehnici și metode de învățare automată, particularizate pentru probleme de clasificare nesupervizată, clasificare supervizată și regresie (KMM, KNN, GMM, regresie liniară și logistică, DT, RF, SVM și FCNN).

– Laboratorul debutează cu o introducere comprehensivă în utilizarea limbajului de programare Python și a pachetelor esențiale utilizate în domeniul învățării automate (numpy, scipy, pandas, matplotlib etc.). Restul lucrărilor acoperă implementarea practică a principalelor modelelor de învățare automată studiate la curs, folosind pachetele Python scikit-learn și Keras/TensorFlow, și utilizarea acestora pentru aplicații diverse de clasificare nesupervizată, clasificare supervizată și regresie.

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 | <ul style="list-style-type: none">– Demonstrează că deține cunoștințe de bază privind conceptele teoretice și modelele și tehnicile moderne de inteligență artificială și învățare automată clasică.– Aplică în practică cunoștințele teoretice dobândite și utilizează medii de simulare pentru analiza și prelucrarea diverselor tipuri de date și de semnale (în special semnalul vocal).– Aplică metode, tehnici și metodologii standardizate, specifice domeniului inteligenței artificiale și învățării automate clasice, pentru rezolvarea problemelor de clasificare sau regresie, în funcție de natura aplicației.– Argumentează și analizează coerent și corect contextul de aplicare a cunoștințelor de bază ale domeniului inteligenței artificiale și învățării automate clasice, utilizând concepte cheie ale disciplinei și metodologia specifică.– Comunicare orală și în scris în limba română: utilizează vocabularul științific specific domeniului studiat, în vederea comunicării eficiente și corecte, în scris și oral.– Comunicare orală și în scris într-o limbă străină (engleză): demonstrează înțelegerea și aplicarea corectă a vocabularului aferent domeniului studiat, într-o limbă străină. |
| Transversale (generale) | <ul style="list-style-type: none">– Comunică eficient, în special în timpul orelor de aplicații, coordonându-și eforturile cu ceilalți pentru rezolvarea de situații problemă de complexitate medie.– Autonomie și gândire critică: abilitatea de a gândi în termeni științifici, de a căuta și analiza date în mod independent, de a identifica soluții, precum și de a desprinde și prezenta concluzii.– Capacitate de analiză și sinteză: prezintă în mod sintetic cunoștințele dobândite, ca urmare a unui proces de analiză sistematică.– Respectă principiile de etică academică: în activitatea de documentare citează corect sursele bibliografice utilizate.– Pune în practică elemente de inteligență emoțională în gestionarea socio-emoțională adecvată a unor situații din viața academică, demonstrând stăpânire de sine și obiectivitate în luarea deciziilor sau în situații de stres. |

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 | <p><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></p> <ul style="list-style-type: none">– Definește corect noțiunile de bază ale domeniului inteligenței artificiale și învățării automate: învățare supervizată, învățare nesupervizată, învățare susținută, metodologii experimentale, validare încrucișată, modele clasice de clasificare și regresie, trăsături și parametri de semnal etc.– Descrie în mod corespunzător conceptele și aspectele particulare legate de modelele de învățare automată clasică (modelul celor K medii, algoritmul celor K vecini, modele cu mixturi de Gaussiene, modele Markov ascunse, arbori de decizie și ansambluri de arbori de decizie, regresie liniară și logistică, mașini cu vectori suport, rețele neuronale artificiale simple), precum și avantajele și limitările individuale ale acestora.– Evidențiază metodologiile și tehnicile de antrenare și de testare pentru modelele de învățare automată clasică.– Înțelege principiile de împărțire a seturilor de date și de evaluare a capabilității de generalizare a modelelor de învățare automată clasică.– Definește și utilizează elementele de bază legate de analiza și prelucrarea semnalului vocal (reprezentări în domeniile timp și frecvență).– Este capabil să utilizeze corect principalele modalități de extragere a trăsăturilor semnalului vocal (în domeniul timp, spectrale și cepstrale). |
| Aptitudini | <p><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></p> <ul style="list-style-type: none">– Selectează și grupează informații relevante într-un context dat, putând astfel să descrie corespunzător diverse aspecte teoretice sau practice ale domeniului inteligenței artificiale și învățării automate.– Utilizează argumentat conceptele specifice domeniului inteligenței artificiale și învățării automate, în vederea abordării corecte a unor probleme.– Verifică experimental soluțiile identificate pentru rezolvarea practică a unor aplicații legate de prelucrarea datelor și a semnalelor.– Formulează concluzii corecte asupra rezultatelor experimentele realizate.– Argumentează modul de rezolvare și soluțiile utilizate pentru rezolvarea unor probleme. |
| Responsabilitate și autonomie | <p><i>Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale.</i></p> <ul style="list-style-type: none">– Selectează surse bibliografice potrivite și le analizează.– Respectă principiile de etică academică, citând corect sursele bibliografice utilizate.– Demonstrează receptivitate pentru contexte noi de învățare.– Manifestă colaborare cu ceilalți colegi și cadre didactice în desfășurarea activităților didactice.– Demonstrează autonomie în organizarea contextului de învățare și a problemelor de rezolvat.– Conștientizează valoarea contribuției sale în domeniul ingineriei la identificarea de soluții viabile care să rezolve probleme din viața socială și economică.– Analizează oportunități de afaceri sau de dezvoltare antreprenorială, pornind de la cunoștințele dobândite în domeniul inteligenței artificiale și învățării automate clasice.– Demonstrează abilități de management ale situațiilor din viața reală (de exemplu gestionarea corectă a timpului de învățare). |

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 rămăneri în urmă și ce măsuri remediale se adoptă în astfel de cazuri.)



– Cursurile sunt predate într-o manieră interactivă, fiind încurajată participarea activă a studenților. Sunt folosite atât metode clasice de predare (prelegerea și expunerea), utilizând prezentări PowerPoint prin intermediul mijloacelor multimedia, cât și interactive, bazate pe întrebări – răspunsuri și feedback-ul studenților, adaptând permanent demersul pedagogic la posibilitățile de asimilare și învățare a studenților (prin repetarea suplimentară a anumitor noțiuni și concepte, dacă acest lucru se dovedește necesar).

Fiecare curs debutează cu recapitularea succintă a capitolelor anterioare, cu accent asupra noțiunilor parcurse la ultimul curs. Prezentările utilizează numeroase imagini și scheme, astfel încât informațiile prezentate să fie cât mai ușor de înțeles și asimilat. Se lucrează împreună cu studenții un număr de exerciții sau probleme.

Materialele complete de curs sunt disponibile în format electronic pe platforma Moodle a facultății.

– Predarea cunoștințelor în cadrul orelor de laborator se bazează pe comunicarea orală și explicarea detaliată a metodelor utilizate și a rezultatelor obținute, într-o manieră permanent interactivă. Studenții implementează și evaluează independent aceleași probleme prin utilizarea calculatorului și a mediului software. Aplicațiile realizate îi ajută pe studenți în dezvoltarea unor relații optime de comunicare într-un climat favorabil învățării prin descoperire.

Materialele de laborator sunt disponibile studenților sub formă electronică pe platforma Moodle a facultății.

10. Conținuturi

| CURS | | |
|-----------|--|---------|
| Capitolul | Conținutul | Nr. ore |
| 1 | “Introducere” – Scurt istoric și momente cheie în evoluția domeniului. Stadiul domeniului în prezent. Rezultate remarcabile. Probleme și aspecte etice | 2 |
| 2 | “Concepte fundamentale. Paradigme” – Definiții. Paradigme de învățare automată (supervizată, nesupervizată, susținută) și analiza comparativă a acestora. Supraantrenarea. Metodologii experimentale și tehnici de antrenare și de testare. Principii de divizare ale seturilor de date. Hiperparametrii modelelor de învățare automată și optimizarea acestora. Normalizarea datelor de intrare. Măsuri de performanță. Problema complexității datelor de intrare | 4 |
| 3 | “Modelul celor K medii (KMM). Algoritmii celor mai apropiați K vecini (KNN)” – Concepte teoretice. Modelare matematică. Funcții pentru măsurarea distanțelor. Alegerea hiperparametrilor. Avantaje și limitări. Problema complexității datelor de intrare. Exemple | 2 |
| 4 | “Modele cu mixturi de Gaussiene (GMM)” – Concepte teoretice. Modelare matematică. Distribuții Gaussiene de ordin superior. Forme pentru matricele de covarianță. Algoritmii de maximizare a valorilor așteptate (expectation-maximization, EM). Alegerea hiperparametrilor. Avantaje și limitări. Utilizarea în cadrul învățării supervizate și în cadrul învățării nesupervizate. Exemple | 2 |
| 5 | “Regresie liniară. Regresie logistică” – Concepte teoretice. Modelare matematică. Soluția analitică și soluții numerice. Algoritmii LMS. Avantaje și limitări. Exemple | 2 |
| 6 | “Arbori de decizie (DT). Ansambluri de arbori de decizie (RF)” – Concepte teoretice. Terminologie specifică. Modelare matematică. Funcții criteriu. Avantaje și limitări. Tehnici de clasificare în ansamblu – eșantionare și agregare (bagging), ponderare și agregare (boosting). Exemple | 2 |



| | | |
|---|---|----|
| 7 | “Mașini cu vectori suport (SVM)” – Concepte teoretice. Modelare matematică. Maximizarea marginii de separare. Funcții de transformare (kernel functions). Regularizarea mașinilor cu vectori suport – variabile de relaxare, parametrul C. Avantaje și limitări. Probleme de clasificare – strategii de clasificare în ansamblu (una-vs-una, una-vs-restul). Exemple | 4 |
| 8 | “Modele Markov ascunse (HMM)” – Concepte teoretice. Modelare matematică. Problema evaluării – algoritmul de propagare directă. Problema decodării – algoritmul Viterbi. Problema antrenării – algoritmul de propagare inversă și algoritmul Baum-Welch. Avantaje și limitări. Exemple | 4 |
| 9 | “Rețele neurale complet-conectate (FCNN)” – Concepte teoretice. Principii fundamentale. Modelare matematică. Neuronul artificial. Funcții de activare. Teorema de aproximare universală. Antrenarea FCNN – funcții cost, algoritmul de minimizare după gradient (gradient descent, GD), algoritmul de propagare inversă a erorilor (backpropagation), antrenare pe loturi de date și algoritmul GD stocastic (stochastic gradient descent, SGD). Avantaje și limitări. Problema dispariției/exploziei gradientului. Hiperparametrii FCNN. Exemple | 6 |
| | Total: | 28 |

Bibliografie:

1. Ș. Mihalache, *Inteligență artificială I: sisteme clasice de învățare automată*, suport de curs electronic pe platforma Moodle a facultății de ETTI: <https://curs.upb.ro/>
2. D. Burileanu, Ș. Mihalache, *Prelucrarea digitală a semnalelor: concepte fundamentale, tehnici avansate, aplicații*, Editura MATRIX ROM, București, 2022, ISBN: 978-606-25-0767-1.
3. C.M. Bishop, *Pattern Recognition and Machine Learning*, Springer International Publishing, 2006, ISBN: 978-0387-31073-2.
4. M. Kubat, *An Introduction to Machine Learning*, Ed. a 2-a, Springer International Publishing, 2017, ISBN: 978-3-319-63912-3.
5. T. Hastie, R. Tibshirani, J. Friedman, *The Elements of Statistical Learning*, Ed. a 2-a, Springer International Publishing, 2009, ISBN: 978-0-387-84857-0.
6. I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, MIT Press, 2016, ISBN: 978-0-262-03561-3.

LABORATOR

| Nr. crt. | Conținutul | Nr. ore |
|----------|--|---------|
| 1 | Protecția muncii. Introducere în utilizarea limbajului de programare Python și a pachetelor adiționale (numpy, scipy, pandas, matplotlib etc.) | 4 |
| 2 | Aplicații de clasificare nesupervizată: modelul celor K medii (KMM), modele cu mixturi de Gaussiene (GMM). Aplicații de clasificare supervizată: algoritmul celor mai apropiați K vecini (KNN) | 4 |
| 3 | Aplicații de regresie și clasificare supervizată: regresie liniară, regresie logistică | 4 |
| 4 | Aplicații de clasificare: arbori de decizie (DT) și ansambluri de arbori de decizie (RF) | 4 |
| 5 | Aplicații de clasificare supervizată: mașini cu vectori suport (SVM) | 4 |
| 6 | Aplicații de clasificare supervizată și regresie: rețele neurale complet-conectate (FCNN) | 4 |
| 7 | Colocviu final | 4 |
| | Total: | 28 |



Bibliografie:

1. Ș. Mihalache, *Inteligență artificială I: sisteme clasice de învățare automată – Platforme de laborator*, disponibile în format electronic pe platforma Moodle a facultății de ETTI: <https://curs.upb.ro/>
2. ***, *scikit-learn – Machine Learning in Python*, documentație și manual de utilizare, disponibile în format electronic: <https://scikit-learn.org/stable/>
3. ***, *Keras API documentation*, documentație și manual de utilizare, disponibile în format electronic: <https://keras.io/2.17/api/>
4. ***, *NumPy*, documentație și manual de utilizare, disponibile în format electronic: <https://numpy.org/doc/>
5. ***, *pandas documentation*, documentație și manual de utilizare, disponibile în format electronic: <https://pandas.pydata.org/docs/>

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 legate de inteligență artificială și sisteme clasice de învățare automată. Cunoașterea modului de aplicare a teoriei la rezolvarea unor probleme specifice domeniului. | Examen scris în sesiunea de examene. | 50% |
| 11.5 Seminar/laborator/proiect | Înțelegerea modelelor și tehnicilor fundamentale de inteligență artificială și învățare automată clasică. Cunoașterea modului de simulare și de implementare practică (pe calculator) a metodelor și tehnicilor studiate, cu ajutorul unor medii de programare evaluate. | Colocviu final de laborator (test pe calculator). | 50% |
| 11.6 Condiții de promovare | | | |
| <ul style="list-style-type: none"> – Obținerea a 50% din punctajul total. – Realizarea obligațiilor caracteristice activității de laborator (participarea la lucrările planificate). | | | |

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)

În ultimele decenii, domeniul de inteligență artificială (IA) a înregistrat o creștere spectaculoasă, devenind o forță motrice în progresul tehnologic global. Instituții de învățământ superior din întreaga lume își revizuiesc programele de studiu pentru a incorpora cunoștințele și abilitățile necesare pentru a face față acestui trend emergent. Utilitatea profundă a domeniului de IA se reflectă în multiplele sale aplicații practice, de la sisteme de recomandare în comerțul electronic la asistență medicală, vehicule autonome, și multe altele. Studiul domeniului de IA la nivel universitar nu doar că permite studenților să obțină o înțelegere profundă a conceptelor tehnice, ci îi pregătește și pentru a fi competitivi pe piața muncii, într-un peisaj profesional în continuă schimbare. Capacitatea de a înțelege și de a dezvolta tehnologii de inteligență artificială devine o abilitate esențială în era digitală, deschizând porți către o gamă largă de oportunități de carieră în companii de tehnologie, cercetare și dezvoltare, start-up-uri inovatoare și multe altele. În plus, integrarea studiului IA în instituțiile de învățământ superior stimulează cercetarea și inovația. Cercetarea în acest domeniu poate



Universitatea Națională de Știință și Tehnologie Politehnica București

**Facultatea de Electronică, Telecomunicații și
Tehnologia Informației**



duce la descoperiri remarcabile, îmbunătățind semnificativ calitatea vieții și rezolvând provocări complexe. Prin colaborarea cu industria, universitățile pot crea punți solide între teorie și aplicații practice, pregătind astfel tinerii pentru a face față provocărilor tehnologice ale viitorului.

Se 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, disciplina fiind perfect încadrată în politica Universității Naționale de Știință și Tehnologie 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 de cercetare-dezvoltare din instituțiile de stat și private care utilizează (sau intenționează să folosească) sisteme bazate pe inteligență artificială.

| Data completării | Titular de curs | Titular(i) de aplicații |
|------------------|-----------------|-------------------------|
|------------------|-----------------|-------------------------|

| | | |
|--|-----------------------------------|--|
| | Ș.L. dr. ing. Șerban MIHALACHE | |
|--|-----------------------------------|--|

| | | |
|--|--|-----------------------------------|
| | | Ș.L. dr. ing. Șerban MIHALACHE |
|--|--|-----------------------------------|

| | |
|------------------------------|-------------------------|
| Data avizării în departament | Director de departament |
|------------------------------|-------------------------|

| | |
|------------|-----------------------|
| 31.10.2024 | Prof. Dr. Claudiu DAN |
|------------|-----------------------|

| | |
|---|-------|
| Data aprobării în Consiliul Facultății | Decan |
|---|-------|

| | |
|------------|------------------------|
| 01.11.2024 | Prof. Dr. Mihnea Udrea |
|------------|------------------------|