



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 | Calculatoare și Tehnologia Informației |
| 1.5 Ciclul de studii | Masterat |
| 1.6 Specializarea | Sisteme Inteligente și Vedere Artificială |

2. Date despre disciplină

| | | | | | | | |
|--|----|---|-------------------|------------------------|------|-------------------------|----|
| 2.1 Denumirea disciplinei (ro) | | Inteligența computațională II - Deep Learning | | | | | |
| 2.2 Titularul activităților de curs | | Prof. Dr. Victor Neagoe | | | | | |
| 2.3 Titularul activităților de seminar / laborator | | Prof. Dr. Victor Neagoe | | | | | |
| 2.4 Anul de studiu | 1 | 2.5 Semestrul | II | 2.6. Tipul de evaluare | E | 2.7 Regimul disciplinei | Ob |
| 2.8 Tipul disciplinei | DA | 2.9 Codul disciplinei | UPB.04.M2.O.16-08 | 2.10 Tipul de notare | Nota | | |

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

| | | | | | |
|--|-------|--------------------|------|-----------------------|-----|
| 3.1 Număr de ore pe săptămână | 2.5 | Din care: 3.2 curs | 1.50 | 3.3 seminar/laborator | 1 |
| 3.4 Total ore din planul de învățământ | 35.00 | Din care: 3.5 curs | 21 | 3.6 seminar/laborator | 14 |
| Distribuția fondului de timp: | | | | | ore |
| Studiul după manual, suport de curs, bibliografie și notițe | | | | | 54 |
| 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 | 65.00 | | | | |
| 3.8 Total ore pe semestru | 100 | | | | |
| 3.9 Numărul de credite | 4 | | | | |

4. Precondiții (acolo unde este cazul)

| | |
|--------------------------------|---|
| 4.1 de curriculum | Cunoștințe generale de matematici speciale, statistică și programarea calculatoarelor |
| 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 | Cursul se va desfășura într-o sală cu videoproiector și computer |
|----------|--|



| | |
|-----------------------------------|---|
| 5.2 Seminar/ Laborator/Proiect | Laboratorul se va desfășura într-o sală cu dotare specifică; această sală trebuie să conțină calculator individual pentru fiecare student, internet, videoproiector Pentru desfășurarea activităților de laborator sunt necesare următoarele soluții software instalate pe computere: Matlab, Python și Office |
|-----------------------------------|---|

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.)*

Cursul are ca obiectiv principal prezentarea tehnicilor de DEEP LEARNING, care reprezintă un subdomeniu incitant în plină ascensiune al domeniului MACHINE LEARNING, ambele fiind subdomenii ale inteligenței artificiale. Totodată, se urmărește ca majoritatea algoritmilor de DEEP LEARNING să fie ilustrați prin generalizarea unor structuri de rețele neuronale artificiale. Al doilea obiectiv al cursului este evaluarea tehnicilor considerate de Deep Learning din punctul de vedere al aplicațiilor lor de recunoașterea formelor („pattern recognition”) în domeniul vederii artificiale (Computer Vision) și Big Data Mining.

Aplicațiile de proiect au ca obiectiv familiarizarea studenților cu implementarea tehnicilor de DEEP LEARNING pentru aplicații de recunoașterea formelor în aplicații de Computer Vision precum și în aplicații de explorare a imaginilor de observație terestră (Earth Observation data mining); se dorește folosirea unor medii de dezvoltare software dedicate (Matlab, Python), precum și dezvoltarea capacității studenților de evaluare și interpretare a rezultatelor și optimizare a performanțelor.

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">- Aplicarea cunoștințelor fundamentale și de specialitate dezvoltate în cadrul acestei direcții de master pentru identificarea și elaborarea unor strategii de rezolvare a unor probleme tehnice complexe, specifice domeniului Sisteme Inteligente și Vederea Artificială.- Capacitatea de a modela și proiecta sisteme software/hardware bazate pe tehnici de inteligență artificială pentru a rezolva probleme de recunoașterea formelor din domeniul observării Pământului (Earth Observation), roboticii, biologiei, medicinei, economiei, finanțelor, jocurilor, controlului calitatii; în cadrul inteligenței artificiale, capacitatea de utilizare atât a unor tehnici inteligente recente de inspirație naturală (cunoscute sub definiția de inteligență computațională, incluzând rețele neurale, sisteme „fuzzy”, calcul evoluționist, „swarm intelligence”), cât și a modelelor și limbajelor clasice de inteligență artificială.- Abilitatea de a modela și proiecta sisteme software/hardware de prelucrare și analiză a imaginilor pentru aplicații specifice; capacitatea atât de a utiliza programe (software) deja existente pentru prelucrarea imaginilor, cât și de a proiecta și implementa sisteme noi, folosind interfețe și limbaje specifice.- Capacitatea de a modela și a proiecta sisteme bazate pe tehnici din domeniul vederii artificiale pentru a rezolva sarcini tipice de biometrie, teledetecție, robotică vehiculară, supraveghere video.- Capacitatea de a aplica și dezvolta algoritmi și programe de mineritul datelor (data mining) și descoperirea cunoștințelor (knowledge discovery); capacitatea de a aborda aplicații de data mining pentru imagistică satelitară și multimedia |
|-----------|--|

| | |
|---------------------------------------|---|
| <p>Transversale (generale)</p> | <ul style="list-style-type: none"> - Îndeplinirea sarcinilor profesionale cu identificarea exactă a obiectivelor de realizat, a unor factori potențiali de risc, a resurselor disponibile, a aspectelor economico-financiare, condițiilor de finalizare a acestora, etapelor de lucru, timpului de lucru și termenelor de realizare aferente. - Executarea responsabilă a unor sarcini de lucru în echipă pluridisciplinară, cu asumarea de roluri pe diferite paliere ierarhice. - Identificarea nevoii 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. |
|---------------------------------------|---|

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.)

| | |
|--------------------------|--|
| <p>Cunoștințe</p> | <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"> -Enumeră principalele caracteristici ale domeniului Deep Learning (DL) și principalele arhitecturi. -Definește conceptele principale ale domeniului DL: regularizarea, optimizarea parametrilor de învățare, învățarea cu întărire (Deep reinforcement learning), transferul învățării (Transfer Learning), DL cu rețele neurale feedforward, DL cu rețele neurale recurente etc. -Descrie arhitectura și relațiile fundamentale ale principalelor tipuri de sisteme neurale DL: rețele neurale convoluționale (Convolutional Neural Networks-CNN), rețele Long Short-Term-Memory-LSTM), etc. -Sunt descrise și aplicate metode de proiectare și implementare a modelelor DL pentru baze de date profesionale, cu folosirea unor medii de dezvoltare software dedicate. - Se evidențiază indicii de evaluare a performanțelor sistemelor DL în domeniul „pattern recognition”. |
| <p>Aptitudini</p> | <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 un model de Deep Learning (DL) pentru o aplicație concretă de data mining, clasificare, recunoașterea formelor, predicție etc. Utilizează argumentat principii specifice pentru proiectarea unei sarcini specifice.. Lucrează productiv în echipă. Elaborează un text științific Verifică experimental soluții identificate, prin implementarea software a unor modele inteligente Rezolvă aplicații practice Interpretează adecvat relații de cauzalitate Analizează comparativ modelul selectat cu alte modele de referință publicate în literatura de specialitate Formulează concluzii prin interpretarea rezultatelor obținute la experimentele realizate |



| | |
|--|--|
| 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 situației/contextului de învățare sau a situației problemă de rezolvat•Manifestă responsabilitate socială prin implicarea activă în viața socială studențească/implicare în evenimentele din comunitatea academică•Promovează/contribuie prin soluții noi, aferente domeniului de specialitate pentru a îmbunătăți calitatea vieții sociale.•Conștientizează valoarea contribuției sale în domeniul ingineriei la identificarea de soluții viabile/sustenabile care să rezolve probleme din viața socială și economică (responsabilitate socială).•Aplică principii de etică/deontologie profesională în analiza impactului tehnologic al soluțiilor propuse în domeniul de specialitate asupra mediului înconjurător.•Analizează și valorifică oportunități de afaceri/de dezvoltare antreprenorială în domeniul de specialitate.•Demonstrează abilități de management al situațiilor din viața reală (gestionarea timpului colaborare vs. conflict). |
|--|--|

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 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 sau diferite filmulețe care vor fi puse la dispoziția studenților. Fiecare curs va debuta cu recapitularea capitolelor deja parcurse, cu accent asupra noțiunilor parcurse la ultimul curs.

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

-Această disciplină acoperă informații și activități practice menite să-i sprijine pe studenți în eforturile de învățare și de dezvoltare a unor relații optime de colaborare și comunicare într-un climat favorabil învățării prin descoperire.

-Se va avea în vedere exersarea abilităților de ascultare activă și de comunicare asertivă, precum și a mecanismelor de construcție a feedback-ului, ca modalități de reglare comportamentală în situații diverse și de adaptare a demersului pedagogic la nevoile de învățare ale studenților.

-Se va exersa abilitatea de lucru în echipă pentru rezolvarea diferitelor sarcini de învățare.

10. Conținuturi

| CURS | | |
|-----------|--|---------|
| Capitolul | Conținutul | Nr. ore |
| 1 | Introducere 1.1. Definiții și state of the art (Deep Learning (DL) versus Machine Learning (ML)) 1.2. Caracteristici, arhitecturi și algoritmi pentru sistemele DL; clasificarea DL | 01 |



| | | |
|----|---|----|
| 2 | Machine Learning (ML): fundamente 2.1. Conceptele de bază ale ML (Proiectare versus învățare; criteriile de optimizare; principiile învățării) 2.2. Învățare supervizată (algoritmul perceptron; regresie liniară adaptivă; Support Vector Machine -SVM) 2.3. Învățare nesupervizată | 02 |
| 3 | Rețele neuronale Deep Learning (DL) de tip Feedforward 3.1. Algoritmi de învățare 3.2. Arhitecturi | 02 |
| 4 | Regularizarea DL 4.1. Regularizare sub constrângeri 4.2. Robustețe la zgomot 4.3. Învățare semi-supervizată | 02 |
| 5 | Optimizarea DL 5.1. Strategii de inițializare a parametrilor 5.2. Rate de învățare adaptivă (AdaGrad; RMSProp; Adam) 5.3. Strategii cu meta-algoritmi | 02 |
| 6 | Optimizarea DL 5.1. Strategii de inițializare a parametrilor 5.2. Rate de învățare adaptivă (AdaGrad; RMSProp; Adam) 5.3. Strategii cu meta-algoritmi | 02 |
| 7 | Rețele neuronale convoluționale (CNN) 6.1. Strat de caracteristici aleatoare sau nesupervizate 6.2. Filtre și hărți de caracteristici; strat de convoluție; strat de unificare maximă (MAX pooling); strat cu conexiune completă (fully connected) 6.3. Arhitectura completă a rețelelor convoluționale 6.4. Algoritmi de învățare eficienți 6.5. Tipuri de CNN: LeNet, AlexNet; ZF Net; GoogLeNet; VGG Net; Res Net; Mobile Net; U Net. 6.6. Generative Adversarial Networks (GAN) | 02 |
| 8 | Încorporarea și reprezentarea învățării 7.1. Reducerea dimensionalității reprezentărilor 7.2. Arhitectura autocodificatorului 7.3. Cadrul Word2Vec 7.3. Implementarea unei arhitecturi Skip-G | 02 |
| 9 | Modelarea secvențelor: rețele recurente și recursive (RRN) 8.1. Rețele neuronale recurente (RNN) 8.2. Rețele recurente de tip DL (Deep Recurrent Networks) 8.3. Rețele neuronale recursive 8.4. Strategii pentru scale de timp multiple 8.5. Unități LSTM (Long Short-Term Memory) | 02 |
| 10 | DL cu întărire (Deep Reinforcement Learning) 9.1. Introducere 9.2. Decizie cu modele Markov 9.3. Explorare versus exploatare; ploiți de învățare 9.4. Învățare de tip Q și rețele Deep-Q (DQN) (ecuația Bellman, învățarea sistemului DQN; DQN și modelul Markov) | 02 |



| | | |
|---------------|--|----|
| 11 | Metodologie practică și aplicații 10.1. Metrica performanțelor 10.2. Modele de bază 10.3. Selectarea hyper-parametrilor 10.4. Strategii de depanare 10.5. Transfer Learning 10.6. Aplicație DL pentru clasificarea imaginilor de observație terestră (EO) 10.7. Aplicație DL pentru identificarea stărilor emoționale | 02 |
| Total: | | 21 |

Bibliografie:

PROIECT

| Nr. crt. | Conținutul | Nr. ore |
|---------------|---|---------|
| 1 | Proiectarea, implementarea software (Python/Matlab) și evaluarea performanțelor unui clasificator bazat pe un model de Deep Learning pentru baze de date clasice. Perechea (DeepCNN -bază de date) este specifică fiecărui student. Pentru fiecare proiect se vor interpreta și evalua rezultatele simulării în sensul comparării performanțelor modelului Deep Learning cu o metodă de referință. | 14 |
| Total: | | 14 |

Bibliografie:

Victor Neagoie, Inteligență Computațională II-Deep Learning, suport de curs electronic, <https://curs.upb.ro/2021/course/view.php?id=9502>
I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016.

11. Evaluare

| Tip activitate | 11.1 Criterii de evaluare | 11.2 Metode de evaluare | 11.3 Pondere din nota finală |
|----------------|---|-------------------------------------|------------------------------|
| 11.4 Curs | - Însușirea noțiunilor teoretice fundamentale; studenții vor răspunde la un număr de întrebări formulate astfel încât să se testeze faptul că au înțeles noțiunile predate. | Examen scris în sesiunea de examene | 20 |
| | - Cunoașterea modului de aplicare a teoriei la probleme specifice | Examen scris în sesiunea de examene | 20 |
| | - Analiza diferențială a principiilor și metodelor teoretice. | Examen scris în sesiunea de examene | 10 |



| | | | |
|--------------------------------------|--|----------------------------------|----|
| 11.5 Seminar/laborator/proiect | -Proiect: capacitatea masterandului de a proiecta, de a implementa software și de a evalua performanțele unui clasificator bazat Deep Learning | -Prezentare scrisă a proiectelor | 30 |
| | -Proiect: capacitatea masterandului de a proiecta, de a implementa software și de a evalua performanțele unui clasificator bazat Deep Learning | -Prezentare scrisă a proiectelor | 20 |
| | -Proiect: capacitatea masterandului de a proiecta, de a implementa software și de a evalua performanțele unui clasificator bazat pe inteligență computațională | -Prezentare scrisă a proiectelor | |
| 11.6 Condiții de promovare | | | |
| Obținerea a 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 (SEIS)

Programa cursului Inteligență computațională 1I: tehnici Deep Learning răspunde concret cerințelor actuale de dezvoltare și evoluție, subscrise economiei europene a serviciilor din domeniul Calculatoare și Tehnologia Informației (CTI). În contextul progresului tehnologic actual, domeniile de activitate vizate de această disciplină sunt practic nelimitate : analiza inteligentă a imaginilor de observație terestră (Earth Observation) pentru aplicații civile și militare (produse și tehnologii de tip „remote sensing” de recunoașterea formelor pentru imagini satelitare), aplicații de securitate (sisteme de supraveghere și sisteme biometrice), aplicații de “consum” (tehnologii inteligente pentru camere foto digitale sau smart phone), aplicații în domeniul medicinei (produse și tehnologii inteligente de diagnoza medicală), aplicații din domeniul automatizărilor industriale (sisteme de inspecție produse), robotică și contextul aplicațiilor de interacțiune om-mașină (sisteme de interfațare om-mașină), aplicații financiare (predicția indicilor financiari), seismologie (predicția cutremurelor) și altele. Se asigură astfel absolvenților competențe adecvate cu necesitățile calificărilor actuale și o pregătire științifică și tehnică moderne, de calitate și competitive, care să le permită angajarea rapidă după absolvire, disciplina IC1 fiind perfect încadrată în politica Universității Politehnica din București, atât din punctul de vedere al conținutului și structurii, cât și din punctul de vedere al aptitudinilor și deschiderii internaționale oferite studenților.

Data completării

Titular de curs

Titular(i) de aplicații

Prof. Dr. Victor Neagoe

Prof. Dr. Victor Neagoe

Data avizării în departament

Director de departament



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



29.10.2024

Conf. Dr. Bogdan Cristian FLOREA

Data aprobării în Consiliul Facultății

Decan

29.10.2024

Prof. Dr. Mihnea Udrea