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	Calculatoare şi Tehnologia Informaţiei
1.5 Ciclul de studii	Masterat
1.6 Specializarea	Sisteme Inteligente şi Vedere Artificială

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)				Inteligenţa computaţională II - Deep Learning			
2.2 Titularul activităţilor de curs				Prof. Dr. Victor Neagoe			
2.3 Titularul activităţilor 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		S	2.9 Codul disciplinei	1		2.10 Tipul de notare	Nota

3. Timpul total estimat (ore pe semestru al activităţilor 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 învăţământ	35.00	Din care: 3.5 curs	21	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					55
Tutorat					6
Examinări					4
Alte activităţi (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. Precondiţii (acolo unde este cazul)

4.1 de curriculum	Cunoştinţe generale de matematici speciale, statistică şi programarea calculatoarelor
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	Cursul se va desfăşura într-o sală cu videoproiector şi computer sau prin intermediul platformei Teams.
5.2 Seminar/ Laborator/Proiect	Aplicaţiile se vor desfăşura sub formă de proiect, tema fiind specifică fiecărui student, pentru proiect având fie o sală dotată cu computer şi videoproiector, fie folosind platforma Teams.

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.)*

Cursul are ca obiectiv principal prezentarea tehnicilor de DEEP LEARNING, care reprezintă un subdomeniu incitant in plină ascensiune al domeniului MACHINE LEARNING, ambele fiind subdomenii ale inteligenţei artificiale. Totodata, se urmăreşte ca majoritatea algoritmilor de DEEP LEARNING să fie ilustraţi prin generalizarea unor structuri de reţele neuronale artificiale . Al doilea obiectiv al cursului este evaluarea tehnicilor considerate de Deep Learning din punctul de vedere al aplicaţiilor lor de recunoaşterea formelor („pattern recognition”) în domeniul vederii artificiale (Computer Vision) şi Big Data Mining.

Aplicaţiile de proiect au ca obiectiv familiarizarea studenţilor cu implementarea tehnicilor de DEEP LEARNING pentru apicaţii de recunoaşterea formelor în aplicaţii de Computer Vision precum şi în aplicaţii de explorare a imaginilor de observaţie terestră (Earth Observation data mining); se doreşte folosirea unor medii de dezvoltare software dedicate (Matlab, Python), precum si dezvoltarea capacităţii studenţilor de evaluare şi interpretare a rezultatelor si optimizare a performanţelor.

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	- Aplicarea cunoştinţelor fundamentale şi de specialitate dezvoltate in cadrul acestei directii de master pentru identificarea si elaborarea unor strategii de rezolvare a unor probleme tehnice complexe, specifice domeniului Sisteme Inteligente si Vederea Artificială. - Capacitatea de a modela si proiecta sisteme software/hardware bazate pe tehnici de inteligenţă artificială pentru a rezolva probleme de recunoaşterea formelor din domeniul observării Pământului (Earth Observation) , roboticii , biologiei, medicinei, economiei, finanţelor, jocurilor, controlului calitatii; in cadrul inteligenţei artificiale, capacitatea de utilizare atât a unor tehnici inteligente recente de inspiratie naturală (cunoscute sub definiţia de inteligenţă computaţională , incluzând reţele neurale, sisteme „fuzzy”, calcul evoluţionist, „swarm intelligence”), cât şi a modelelor şi limbajelor clasice de inteligenţă artificială. - Abilitatea de a modela şi proiecta sisteme software/hardware de prelucrare şi analiză a imaginilor pentru aplicaţii specifice; capacitatea atat de a utiliza programe (software) deja existente pentru prelucrarea imaginilor, cat si de a proiecta si implementa sisteme noi, folosind interfete si limbaje specifice. - Capacitatea de a modela şi a proiecta sisteme bazate pe tehnici din domeniul vederii artificiale pentru a rezolva sarcini tipice de biometrie, teledetecţie, robotică vehiculară, supraveghere video. - Capacitatea de a aplica si dezvolta algoritmi si programe de mineritul datelor (data mining) si descoperirea cunoştintelor (knowledge discovery) ; capacitatea de a aborda aplicatii de data mining pentru imagistică satelitară şi multimedia

Transversale (generale)	- Îndeplinirea sarcinilor profesionale cu identificarea exactă a obiectivelor de realizat, a unor factori potenţiali de risc, a resurselor disponibile, a aspectelor economico-financiare, condiţiilor de finalizare a acestora, etapelor de lucru, timpului de lucru şi 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 si utilizarea eficientă a surselor informaţionale si a resurselor de comunicare si formare profesională asistată (portaluri Internet, aplicaţii software de specialitate, baze de date, cursuri on-line, etc.) atât in limba română cât şi într-o limbă de circulaţie internaţională.

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.)*

Cunoştinţe	*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.* -Enumeră principalele caracteristici ale domeniului Deep Learning (DL) şi principalele arhitecturi. -Defineşte conceptele principale ale domeniului DL: regularizarea, optimizarea parametrilor de învăţare, învăţarea cu întărire (Deep reinforcement learning), transferul învăţării (Transfer Learning) , DL cu reţele neurale feedforward, DL cu reţele neurale recurente etc. -Descrie arhitectura şi relaţiile fundamentale ale principalelor tipuri de sisteme neurale DL: reţele neurale convoluţionale (Convolutional Neural Networks-CNN), reţele Long Short-Term-Memory-LSTM), etc. -Sunt descrise şi aplicate metode de proiectare şi implementare a modeleleor DL pentru baze de date profesionale, cu folosirea unor medii de dezvoltare software dedicate. - Se evidenţiază indicii de evaluare a performanţelor sistemelor DL în domeniul „pattern recognition”.
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).* 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	*Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale.* •Selectează surse bibliografice potrivite şi le analizează. •Respectă principiile de etică academică, citând corect sursele bibliografice utilizate. •Demonstrează receptivitate pentru contexte noi de învăţare. •Manifestă colaborare cu ceilalţi colegi şi cadre didactice în desfăşurarea activităţilor 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. •Conştientizează 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 rămâneri în urmă și ce măsuri remediale se adoptă în astfel de cazuri.)*

-Pornindu-se de 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 directa 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 sau diferite filmuleţe care vor fi puse la dispoziţia studenţilor. Fiecare curs va debuta cu recapitularea capitolelor deja parcurse, cu accent asupra noţiunilor parcurse la ultimul curs.
-Prezentările utilizează imagini şi scheme, astfel încât informaţiile prezentate să fie uşor de înţeles şi asmilat.
-Această disciplină acoperă informaţii şi activităţi practice menite să-i sprijine pe studenţi în eforturile de învăţare şi de dezvoltare a unor relaţii optime de colaborare şi comunicare într-un climat favorabil învăţării prin descoperire.
-Se va avea în vedere exersarea abilităţilor de ascultare activă şi de comunicare asertivă, precum şi a mecanismelor de construcţie a feedback-ului, ca modalităţi de reglare comportamentală în situaţii diverse şi de adaptare a demersului pedagogic la nevoile de învăţare ale studenţilor.
-Se va exersa abilitatea de lucru în echipă pentru rezolvarea diferitelor sarcini de învăţare.

10. Conţinuturi

CURS		
Capitolul	**Conţinutul**	**Nr. ore**

1	Introducere 1.1.Definiţii şi state of the art (Deep Learning (DL) versus Machine Learning (ML) 1.2. Caracteristici, arhitecturi şi algoritmi pentru sistemele DL; clasificarea DL	01
2	Machine Learning (ML): fundamente 2.1. Conceptele de bază ale ML (Proiectare versus învăţare; criterii de optimizare; principiile învăţării) 2.2. Învăţare supervizată (algoritmul perceptron; regresie liniară adaptivă; Support Vector Machine -SVM) 2.3. Învăţare nesupervizată	02
3	Reţele neurale Deep Learning (DL) de tip Feedforward 3.1. Algoritmi de învăţare 3.2. Arhitecturi	01
4	Regularizarea DL 4.1.Regularizare sub constrângeri 4.2 Robusteţe la zgomot 4.3. Învăţare semi-supervizată	01
5	Optimizarea DL 5.1. Strategii de iniţializare a parametrilor 5.2 Rate de învăţare adaptivă (AdaGrad; RMSProp; Adam) 5.3. Strategii cu meta-algoritmi	02
6	Optimizarea DL 6.1. Strategii de iniţializare a parametrilor 6.2 Rate de învăţare adaptivă (AdaGrad; RMSProp; Adam) 6.3. Strategii cu meta-algoritmi	01
7	Reţele neuronale convoluţionale (CNN) 7.1. Strat de caracteristici aleatoare sau nesupervizate 7.2 Filtre şi hărţi de caracteristici; strat de convoluţie; strat de unificare maximă (MAX pooling); strat cu conexiune completă (fully connected) 7.3. Arhitectura completă a reţelelor convoluţionale 7.4. Algoritmi de învăţare eficienţi 7.5. Tipuri de CNN: LeNet, AlexNet; ZF Net; GoogLeNet; VGG Net; Res Net; Mobile Net; U Net. 7.6. Generative Adversarial Networks (GAN)	05
8	Încorporarea şi reprezentarea învăţării 8.1. Reducerea dimensionalităţii reprezentărilor 8.2 Arhitectura autocodificatorului 8.3. Cadrul Word2Vec 8.4. Implementarea unei arhitecturi Skip-G	02
9	Modelarea secvenţelor: reţele recurente şi recursive (RRN) 9.1. Reţele neuronale recurente (RNN) 9.2. Reţele recurente de tip DL (Deep Recurrent Networks) 9.3. Reţele neuronale recursive 9.4. Strategii pentru scale de timp multiple 9.5. Unităţi LSTM (Long Short-Term Memory)	03

10	DL cu întărire (Deep Reinforcement Learning) 10.1. Introducere 10.2 Decizie cu modele Markov 10.3. Explorare versus exploatare; ploitici de învățare 10.4. Învățare de tip Q și rețele Deep-Q (DQN) (ecuația Bellman, învățarea sistemului DQN; DQN și modelul Markov)	01
11	Metodologie practică și aplicații 11.1. Metrica performanțelor 11.2. Modele de bază 11.3. Selectarea hyper-parametrilor 11.4. Strategii de depanare 11.5. Transfer Learning 11.6. Aplicație DL pentru clasificarea imaginilor de observație terestră (EO) 11.7. Aplicație DL pentru identificarea stărilor emoționale	02
	Total:	21

Bibliografie:

Victor Neagoe, Inteligență Computațională II-Deep Learning, suport de curs electronic
I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016.

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. Proiectul are o temă specifică pentru fiecare student. Pentru fiecare proiect se vor interpreta și evalua rezultatele simulării software în sensul comparării performanțelor modelului Deep Learning cu o metodă de referință.	14
	Total:	14

Bibliografie:

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare	11.3 Pondere din nota finală

11.4 Curs	- Însuşirea noţiunilor 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
	- Cunoaşterea modului de aplicare a teoriei la probleme specifice	Examen scris în sesiunea de examene	20
	- Analiza diferenţială a principiilor şi 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	-Susținerea orală a proiectelor în sală, folosind un video proiector, sau pe platforma Teams	20
11.6 Condiții de promovare			
Obținerea a 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)

Programa cursului Inteligență computațională II: tehnici Deep Learning răspunde concret cerinţelor actuale de dezvoltare şi evoluţie, subscrise economiei europene a serviciilor din domeniul Calculatoare şii Tehnologia Informaţiei (CTI). În contextul progresului tehnologic actual, domeniile de activitate vizate de această disciplină sunt practic nelimitate : analiza inteligentă a imaginilor de observatie terestră (Earth Observation) pentru aplicatii civile şi militare (produse şi tehnologii de tip „remote sensing” de recunoastertea formelor pentru imagini satelitare), aplicații de securitate (sisteme de supraveghere şi sisteme biometrice), aplicaţii de “consum” (tehnologii inteligente pentru camere foto digitale sau smart phone), aplicații în domeniul medicinii (produse şi tehnologii inteligente de diagnoza medicala), aplicații din domeniul automatizărilor industriale (sisteme de inspecţie produse), robotică şi contextul aplicaţiilor de interacţiune om-maşină (sisteme de interfaţare om-maşină), aplicații financiare (predictia indicilor financiari), seismologie (predictia cutremurelor) şi altele. Se asigură astfel absolvenţilor competenţe adecvate cu necesităţile calificărilor actuale şi o pregătire ştiinţifică şi tehnică moderne, de calitate şi competitive, care să le permită angajarea rapidă după absolvire, disciplina ICII-Deep Learning fiind perfect încadrată în politica Universităţii Politehnica din Bucureşti, atât din punctul de vedere al conţinutului şi structurii, cât și din punctul de vedere al aptitudinilor și deschiderii internaţionale oferite studenţilor.

Data completării	Titular de curs	Titular(i) de aplicații
21.09.2026	Prof. Dr. Victor Neagoe	Prof. Dr. Victor Neagoe

Universitatea Naţională de Ştiinţă şi Tehnologie Politehnica Bucureşti
Facultatea de Electronică, Telecomunicaţii şi
Tehnologia Informaţiei

Data avizării în departament	Director de departament
Data aprobării în Consiliul Facultăţii	Decan
22.09.2026	Prof. Dr. Mihnea Udrea