



FIȘA UNITĂȚII DE CURS/MODULULUI

1. Date despre program

1.1. Instituția de învățământ superior	Universitatea de Stat din Moldova
1.2. Facultatea	Matematică și Informatică
1.3. Departamentul	Informatică
1.4. Domeniul de formare profesională	0613 Dezvoltarea produselor program și a aplicațiilor
1.5. Ciclul de studii	Studii superioare de master, ciclul II
1.6. Programul de studii	Inteligența Artificială și Știința Datelor

2. Date despre unitatea de curs/modul

2.1. Denumirea disciplinei	Învățare Profundă						
2.2. Titularul activităților de curs	?						
2.3. Titularul activităților de laborator	?						
2.4. Anul de studii	2	2.5. Semestrul	1	2.6. Tipul de evaluare	E	2.7. Categoria formativă	SA

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. laborator	1
3.4. Total ore în planul de învățământ	45	din care: 3.5 curs	30	3.6. laborator	15
Distribuția fondului de timp pentru studiul individual:					ore
Studiu după manual, suport de curs, bibliografie și notițe					40
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate					30
Pregătire laboratoare, teme, referate, portofolii					65
3.7. Total ore studiu individual	135				
3.8. Total ore pe semestru	180				
3.9. Număr de credite	6				

4. Precondiții de acces la unitatea de curs/modul

4.1. de curriculum	Baze de date, programare(Python), statistică pentru știința datelor, analiza și vizualizarea datelor, învățarea automată.
4.2. de competențe	Cunoștințe de programare, statistică și învățare automată.

5. Condiții de desfășurare

5.1. a cursului	Sală de curs cu tablă mare și proiector, laptop(cu aplicații instalate – biblioteci Python).
5.2. a laboratorului	Sală de laborator, calculatoare care au instalate Python.

6. Obiectivele disciplinei – rezultate așteptate ale învățării la formarea cărora contribuie parcurgerea și promovarea disciplinei

Cunoștințe	(C1) Dobândirea unor cunoștințe profunde cu privire la conceptele esențiale de Deep Learning, diferențele față de învățarea automată tradițională, și familiarizarea cu contextul istoric și reperele cheie (C2) Dobândirea unor cunoștințe fundamentale cu privire la diversele arhitecturi de rețele neuronale, cum ar fi rețelele neuronale convoluționale (CNN), rețelele neuronale recurente (RNN), LSTM, autoencodere, și
------------	--



	rețele generative adversariale (GANs). (C3) Familiarizarea cu cadrele de lucru populare, cum ar fi TensorFlow, Keras și PyTorch, și cunoașterea principiilor de alegere a cadrelor potrivite pentru diverse proiecte.
Abilități	(A1) Abilitatea de a implementa și antrena diverse tipuri de rețele neuronale folosind cadre de lucru moderne (A2) Abilitatea în ajustarea hiperparametrilor și utilizarea tehnicilor de optimizare pentru îmbunătățirea performanței modelelor. (A3) Abilitatea de a de a utiliza modele pre-antrenate și aplicare a tehnicilor de fine-tuning pentru sarcini noi.
Responsabilitate și autonomie	(R1) Capacitatea de a iniția, proiecta și dezvolta proiecte de învățare profundă de la zero.. (R2) Capacitatea de a alege arhitectura rețelei, tehnicile de prelucrare a datelor și a metodologiilor de antrenare.

7. Conținutul unității de curs/modulului

7.1. Curs	Numărul de ore
<i>C1. Introducere în Deep Learning.</i> Prezentarea generală a Deep Learning și distincția față de învățarea automată.Context istoric și repere cheie în învățarea profundă.Concepte fundamentale: neuroni, ponderi, funcții de activare și funcții de pierdere.	2
<i>C2. Bazele Rețelelor Neuronale.</i> Arhitectura rețelelor neuronale.Propagarea directă și propagarea inversă.Algoritmi de optimizare și coborârea gradientului.	2
<i>C3. Lucrul cu Datele.</i> Prelucrarea datelor pentru învățarea profundă.Împărțirea seturilor de date: antrenament, validare și testare.Tehnici de augmentare a datelor.	2
<i>C4. Cadre de Lucru pentru Învățarea Profundă.</i> Introducere în TensorFlow și Keras.Prezentarea PyTorch și ecosistemul său.Alegerea cadrelor de lucru potrivite pentru proiectul tău.	2
<i>C5. Rețele Neuronale Convolaționale (CNN).</i> Înțelegerea convoluțiilor și pooling-ului.Arhitectura CNN și aplicațiile acestora în recunoașterea imaginilor.Implementarea unui proiect bazat pe CNN.	2
<i>C6. Rețele Neuronale Recurente (RNN) și LSTM.</i> Bazele RNN și problemele pe care le rezolvă.Rețelele Neuronale cu Memorie pe Termen Lung (LSTM).Cazuri de utilizare: analiza seriilor temporale și prelucrarea limbajului natural.	2
<i>C7. Autoencoders.</i> Introducere în autoencoders și arhitectura lor.Aplicații ale autoencoders în învățarea caracteristicilor și denoising.Autoencodere Variationali (VAE).	2
<i>C8. Rețele Generative Adversariale (GANs).</i> Înțelegerea conceptului de modele generative.Arhitectura și principiul de funcționare al GANs.Aplicații și provocări ale GANs.	2
<i>C9. Prelucrarea Limbajului Natural (NLP) cu Învățare Profundă.</i> Embedding-uri de cuvinte și word2vec.Modele de învățare profundă pentru NLP (RNN, LSTM,	2



Transformatori).Construirea unui model de analiză a sentimentelor.	
<i>C10. Modele Secvențiale și Mecanismul de Atenție.</i> Introducere în modele secvență-la-secvență.Înțelegerea mecanismului de atenție.Aplicații: traducere automată, recunoașterea vorbirii.	2
<i>C11. Transfer Learning și Fine-tuning.</i> Principiile transfer learning.Utilizarea modelelor pre-antrenate pentru sarcini noi.Strategii de fine-tuning și cele mai bune practice.	2
<i>C12. Învățarea prin Întărire cu Învățare Profundă.</i> Bazele învățării prin întărire.Rețele Neuronale cu Q-Profund (DQN).Metode de gradient al politicilor și modele actor-critic.	2
<i>C13. Scalabilitatea și Implementarea Modelelor de Învățare Profundă.</i> Strategii pentru scalarea modelelor de învățare profundă.Arhitecturi și platforme de implementare.Monitorizarea și întreținerea modelelor implementate.	4
<i>C14. Etica și Echitatea în Învățarea Profundă.</i> Considerații etice în IA și învățarea profundă.Abordarea părtinirii și echității în modele.Practici responsabile de IA.	2
<i>Total prelegeri:</i>	30
Bibliografie:	
<ol style="list-style-type: none">1. AI Publishing, Python Machine Learning for Beginners: Learning from scratch NumPy, Pandas, Matplotlib, Seaborn, Scikitlearn, and TensorFlow for Machine Learning and Data Science, AI Publishing, 2021.2. BUDUMA, Nikhil. Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms, O'Reilly Media, 2017.3. CHARNIAK, Eugene. Introduction to Deep Learning, The MIT Press Cambridge, Massachusetts, London, England, 2018.4. GLASSNER Andrew. Deep Learning: From Basics to Practice. Volume 1, 2, The Imaginary Institute, Seattle, WA, 2018.5. GURNEY, Kevin. An introduction to neural networks , UCL Press, 2004.6. ROTHMAN, Denis, Transformers for Natural Language Processing: Build innovative deep neural network architectures for NLP with Python, PyTorch. BERT, RoBERTa, T5, GPT-2, architecture of GPT-3, and much more, Packt Publishing, 2021.	
7.2. Laborator	
	Numărul de ore
L1. Implementarea rețelelor neurale profunde în TensorFlow sau PyTorch.	3
L2. Învățarea profundă aplicată în seturi de date complexe.	3
L3. Transfer learning și fine-tuning în practică.	3
L4. Aplicarea rețelelor neurale convoluționale în recunoașterea de obiecte .	3
L5. Generarea de conținut cu modele de deep learning .	3
<i>Total laborator:</i>	15
Bibliografie:	
<ol style="list-style-type: none">1. GÉRON, Aurélien. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, 2019.2. LONG, Liangqu, ZENG, Xiangming. Beginning Deep Learning with TensorFlow: Work with Keras, MNIST Data Sets, and Advanced Neural Networks, Apress, 2022.3. LOY, James. Neural Network Projects with Python: The ultimate guide to using Python to explore the true power of neural networks through six projects, Packt Publishing, 2019.	

8. Evaluare



Universitatea de Stat din Moldova



Nota semestrială			
Atestarea 1	Atestarea 2	Evaluare curentă	Lucrul individual
25%	25%	25%	25%

Nota finală	
Nota semestrială	Nota la examen
60%	40%

Standard minim de performanță
<p>Standard minim (cunoștințe și aptitudini necesare pentru nota 5)</p> <ul style="list-style-type: none">• prezența la cursuri și seminarii conform cerințelor generale ale facultății• cunoașterea conceptelor de bază din Deep Learning• abilitatea de a crea o rețea neuronală în TensorFlow/PyTorch• capacitatea de a implementa fine-tuningul rețelelor neuronale <p>Evaluarea în cadrul disciplinei „Învățare Profundă” se realizează formativ - activitatea la orele de laborator, verificarea orală sau scrisă curentă, două lucrări de atestare (la mijloc și la sfârșit de semestru), și sumativ (final) – 4 lucrări independente, realizate pe parcursul semestrului și examenul final la disciplină. Nota generală la disciplină însumează nota de la examen și cea semestrială, în proporție de 40 și, respectiv, 60 la sută, și apreciază gradul de corespundere cu finalitățile scontate: cunoștințele și competențele acumulate, abilitatea de a aplica cunoștințele, gradul de integrare a cunoștințelor de către studenți etc.</p>

Data completării

25.08.2024

Titular de disciplină

Dr., conf. univ. ?

Data avizării în departament

Șef departament