FIŞA DISCIPLINEI

1. Date despre program

1.1 Instituţia de învăţământ superior	Universitatea Babeș-Bolyai Cluj-Napoca
1.2 Facultatea	Facultatea de Matematică și Informatică
1.3 Departamentul	Departamentul de Informatică
1.4 Domeniul de studii	Informatică
1.5 Ciclul de studii	Licență
1.6 Programul de studiu / Calificarea	Informatică – limba de studiu engleză

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)	Metode inteligente de rezolvare a problemelor reale Intelligent Methods for solving real-world problems						
2.2 Titularul activităţilor de curs	Prof. Dr. Dioșan Laura						
2.3 Titularul activităţilor de seminar	Prof. Dr. Dioșan Laura						
2.4 Anul de studiu	3	2.5 Semestrul	5	2.6. Tipul de evaluare	C	2.7 Regimul disciplinei	Optional
2.8 Codul disciplinei	MLR5067						

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					10
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate şi pe teren					16
Pregătire seminarii/laboratoare, teme, referate, portofolii şi eseuri					24
Tutoriat					4
Examinări					4
Alte activităţi:					-

3.7 Total ore studiu individual	58
3.8 Total ore pe semestru	100
3.9 Numărul de credite	4

4. Precondiţii (acolo unde este cazul)

4.1 de curriculum	• Algoritmică, structuri de date, statistică
4.2 de competenţe	• Abilități medii de programare într-un limbaj de nivel înalt

5. Condiţii (acolo unde este cazul)

5.1 De desfăşurare a cursului	• Proiector
5.2 De desfăşurare a seminarului/laboratorului	• Pentru activitatea de laborator este nevoie de calculatoare cu o viteză de procesare cât mai mare.

6. Competenţele specifice acumulate

Competenţe profesionale	CE1.3 Folosirea metodelor, tehnicilor și algoritmilor din inteligența artificială pentru modelarea soluțiilor unor clase de probleme CE1.4 Identificarea şi explicarea tehnicilor și algoritmilor proprii inteligenței artificiale și folosirea acestora la rezolvarea unor probleme specifice CE1.5 Încorporarea modelelor și soluțiilor specifice inteligenţei artificiale în aplicații dedicate
Competenţe transversale	**CT1** Aplicarea regulilor de muncă organizată şi eficientă, a unor atitudini responsabile faţă de domeniul didactic-ştiinţific, pentru valorificarea creativă a propriului potenţial, cu respectarea principiilor şi a normelor de etică profesională **CT2** Desfăşurarea eficientă a activităţilor organizate într-un grup inter-disciplinar și dezvoltarea capacităţilor empatice de comunicare inter-personală, de relaţionare şi colaborare cu grupuri diverse **CT3** Utilizarea unor metode şi tehnici eficiente de învăţare, informare, cercetare şi dezvoltare a capacităţilor de valorificare a cunoştinţelor, de adaptare la cerinţele unei societăţi dinamice și de comunicare în limba română și într-o limbă de circulație internațională

7. Obiectivele disciplinei (reieşind din grila competenţelor acumulate)

7.1 Obiectivul general al disciplinei	• Cursul are drept obiectiv îmbunătăţirea automată a metodelor de rezolvare a problemelor
7.2 Obiectivele specifice	• Cursul trateaza aspecte teoretice si practice ale inteligenței artificiale. La sfârșitul cursului, studenții vor înțelege principiile de bază ale inteligenței artificiale și abordările algoritmice asociate și vor avea cunoștințe despre aplicații practice ale inteligenței artificiale.

8. Conţinuturi

8.1 Curs	Metode de predare	Observaţii
Instruire automată (Machine Learning - ML) - introducere în domeniul ML - tipuri de probleme	Expunerea Conversaţia Problematizarea	
- metodologia rezolvării unei probleme cu ajutorul unui algoritm de ML - aprecierea performanţelor unui algoritm de ML	Expunerea Conversaţia Demonstraţia didactică Algoritmizarea	
Principalele tipuri de algoritmi (descriere și instrumente) folosiţi în ML pentru - învăţare supervizată, ne-supervizată, - învățare semi-supervizată - învăţare multi-obiectiv	Expunerea Conversaţia Demonstraţia didactică Algoritmizarea Problematizarea	
Algoritmi de tip Deep Learning - retele neuronale convolutive (CNN) – elemente de bază o convoluții (clasice, transpuse, dilatate, spațial separabile, grupate) o agregări (maximizare, mediere, norme L1, L2) o straturi de dropout o funcții de cost (loss)	Expunerea Algoritmizarea Problematizarea	

Algoritmi de tip Deep Learning - retele neuronale convolutive (CNN) – arhitecturi consacrate - LeNet, AlexNet, VGG, ResNet, InceptionNet, DenseNet, Xception Net, MobileNet	Expunerea Algoritmizarea Problematizarea	
Algoritmi de tip Deep Learning - retele neuronale recurente (LSTM) - retele neuronale generative (GAN) - retele neuronale care prelucreaza grafe	Expunerea Conversaţia Algoritmizarea Problematizarea	

Analiza textelor cu ajutorul algoritmilor inteligenti
- reprezentarea textelor si extragerea de caracteristici cu ajutorul metodelor
  o clasice/manuale (BagOfWords, TF-IDF, n-grmas)
  o automate (Word2Vect, GloVe, tehnici de transfer)
- regăsirea informaţiei utile în texte cu ajutorul algoritmilor (statistici sau de învăţare)
  o modele clasice (LSA, LDA)
  o modele moderne (RNN, LSTM, Seq-to-seq, Attention, Memory-based nets)
	Expunerea
	Demonstraţia didactică
	Algoritmizarea
	Problematizarea	

Analiza textelor cu ajutorul algoritmilor inteligenti
- calcul afectiv în domeniul analizei de texte
  o identificarea polarității unor texte
  o identificarea sentimentelor în texte
- modele de traducere
  o dintr-o limbă în alta (Engleza vs. Franceza)
  o dintr-un domeniu în altul (limbaj medical vs. limbaj comun)
	Expunerea
	Conversaţia
	Demonstraţia didactică
	Algoritmizarea
	Problematizarea	

Procesarea imaginilor cu ajutorul algoritmilor inteligenți
- extragerea de caracteristici din imagini
  o descriptori “manuali” (e.g. HOG, SIFT, SURF, etc.)
  o descriptori “automati” (extrasi cu retele neuronale convolutive)
- recunoaşterea obiectelor in imagini
- detectia obiectelor in imagini (R-CNN, Yolo)
- segmentarea obiectelor in imagini
	Expunerea
	Conversaţia
	Algoritmizarea
	Problematizarea	

Recunoasterea obiectelor în imagini rezolvată ca
- problemă de clasificare (există sau nu există un anumit obiect în imagine)
- problemă de detecție (unde anume se află obiectul în imagine)
  o bounding-box-uri
  o contururi = segmentări semantice (la nivel de pixel)
- folosind algoritmi
  o clasici (SVM, Decision Tree)
  o moderni cu 2 etape (R-CNN, Fast R-CNN, Faster R-CNN)
  o moderni cu o singură etapă (YOLO, SSD, RetinaNet)
	Expunerea
	Conversaţia
	Demonstraţia didactică
	Algoritmizarea
	Problematizarea	

Calculul afectiv în domeniul procesării informațiilor vizuale - identificarea și recunoașterea feței - identificare și recunoașterea gesturilor (efectuate cu mâna sau pe baza mimicii) - identificarea și recunoașterea posturii	Expunerea Conversaţia Demonstraţia didactică Algoritmizarea Problematizarea	
Procesarea inteligentă avolumelor mari de informații vizuale în - domeniul asistenței auto (imagini și video) - domeniul medical (imagini RMN, CT, Echo, 2D, 3D, imagini spectrale)	Expunerea Conversaţia Demonstraţia didactică Algoritmizarea Problematizarea	
Calcul afectiv în domeniul procesării semnalelor audio - extragerea atributelor din semnalele vocale (atribute de frecvență, temporale, calitative, spectrale, TEO-based)	Expunerea Conversaţia Demonstraţia	

- clasificarea emoțiilor emise în timpul vorbirii - instrumente specifice (ex. Litebody) - procesarea muzicii și dezvoltarea de soluții inteligente muzicale	didactică Algoritmizarea Problematizarea	
Sisteme complexe - Automate celulare - Retele complexe (Small World, Scale Free)	Expunerea Conversaţia Demonstraţia didactică Algoritmizarea Problematizarea	
Bibliografie 1. S. Russell, P. Norvig, Artificial Intelligence: A Modern Approach, Prentice Hall, 1995 2. T. M. Mitchell, Machine Learning,McGraw-Hill Science, 1997 3. D. J. C. MacKey, Information Theory, Inference and Learning Algorithms, Cambridge University Press, 2003 4. C. Bishop, Pattern Recognition and Machine Learning, Springer, 2006 5. J. C. Burges. A tutorial on support vector machines for pattern recognition. In U. Fayyad, editor, Knowledge Discovery and Data Mining, volume 2, pages 121-167. Kluwer Academic, 1998 6. O. Chapelle. Support Vector Machines: Induction Principle, Adaptive Tuning and Prior Knowledge. PhD thesis, UPMC, 2004 7. T. Cormen, C. Leiserson, and R. Rivest. Introduction to Algorithms. MIT Press, 1990 8. I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016 https://www.deeplearningbook.org/		
8.2 Laborator	Metode de predare	Observaţii
L 1. Studiu de caz – instrumente utile în procesarea automată a informațiilor • Biblioteci specifice algoritmilor de AI (Weka, Keras, TensorFlow, PyTorch, etc)	Conversaţia Algoritmizarea Descoperirea Studiul individual Exerciţiul	Fiecare laborator dureaza 2 ore si se va desfasura o data la 2 sapta mani
L 2. Studiu de caz – demo folosire algoritmi inteligenți • prelucrarea imaginilor / textelor / semnalelor vocale folosind i. Modele inteligente preantrenate ii. Modele inteligente atrenate de la 0	Conversaţia Algoritmizarea Problematizarea Studiul de caz Cooperarea Studiul individual Exerciţiul	
L 3. Proiect – descriere problemă și studiul literaturii de specialitate	Conversaţia Algoritmizarea Problematizarea Descoperirea Simularea Studiul individual Exerciţiul	
L 4. Proiect – dezvoltare modele inteligente pentru rezolvarea problemei prin folosirea unor date sintetice	Conversaţia Algoritmizarea Problematizarea Studiul de caz Brainstorming-ul Studiul individual	

	Exerciţiul	
L 5. Proiect – dezvoltare modele inteligente pentru rezolvarea problemei prin folosirea unor date reale	Conversaţia Algoritmizarea Problematizarea Descoperirea Studiul de caz Studiul individual Exerciţiul	
L 6. Proiect – analiza performaței obținute în rezolvarea problemei și posibile îmbunătățiri	Conversaţia Algoritmizarea Studiul de caz Simularea Studiul individual Exerciţiul	
L 7. Proiect – integrarea modelelor inteligente în aplicații de sine stătătoare, destinate clientului	Conversaţia Algoritmizarea Problematizarea Studiul de caz Brainstorming-ul Studiul individual Exerciţiul	
Proiect: Alegerea unei probleme reale si rezolvarea ei cu ajutorul unei metode inteligente. Etapa 1 (saptamâna 1 şi 2) - expunerea (de către cadrul didactic) tipurilor de probleme care ar putea fi rezolvate cu ajutorul unei metode inteligente - expunerea (de către cadrul didactic) instrumentelor de rezolvare existente deja Etapa 2 (saptamâna 3 şi 4) - alegerea (de către student) problemei şi a instrumentului de rezolvare - discuţii asupra acestei alegeri Etapa 3 (saptamâna 5 şi 6) - metodologia rezolvării unei probleme concrete (paşi care trebuie urmaţi) Etapa 4 (saptamâna 7 şi 8) - alegerea datelor de testare Etapa 5 (saptamâna 9 şi 10) - rezolvarea problemei cu ajutorul instrumentului ales Etapa 6 (saptamâna 11 şi 12) - rezolvarea problemei cu ajutorul instrumentului ales Etapa 7 (saptamâna 13 şi 14) - prezentarea proiectului	Conversaţia Algoritmizarea Problematizarea Studiul de caz Brainstorming-ul Studiul individual Exerciţiul	

Bibliografie

9. S. Russell, P. Norvig, Artificial Intelligence: A Modern Approach, Prentice Hall, 1995
10. T. M. Mitchell, Machine Learning,McGraw-Hill Science, 1997
11. D. J. C. MacKey, Information Theory, Inference and Learning Algorithms, Cambridge University Press, 2003
12. C. Bishop, Pattern Recognition and Machine Learning, Springer, 2006
13. J. C. Burges. A tutorial on support vector machines for pattern recognition. In U. Fayyad, editor, Knowledge Discovery and Data Mining, volume 2, pages 121-167. Kluwer Academic, 1998
14. O. Chapelle. Support Vector Machines: Induction Principle, Adaptive Tuning and Prior Knowledge. PhD thesis, UPMC, 2004
15. T. Cormen, C. Leiserson, and R. Rivest. Introduction to Algorithms. MIT Press, 1990
16. I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016

https://www.deeplearningbook.org/
17. Francois Chollet, Deep Learning with Python, https://github.com/fchollet/deep-learning-with-python-notebooks
1. A. Geron, Hands-On Machine Learning with Scikit-Learn and TensorFlow, https://github.com/ageron/handson-ml

9. Coroborarea conţinuturilor disciplinei cu aşteptările reprezentanţilor comunităţii epistemice, asociaţiilor profesionale şi angajatori reprezentativi din domeniul aferent programului

- Cursul respecta recomandarile curicullare IEEE si ACM pentru studiile in informatica
- Cursul exista in programa de studiu a numeroase facultatilor de profil din intreaga lume
- Companiile de software considera continutul cursului ca fiind util in dezvoltarea abilitatilor de modelare si programare ale studentilor

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 metode de evaluare	10.3 Pondere din nota finală
10.4 Curs	• Cunoasterea conceptelor de baza ale domeniului • Aplicarea princiilor inteligente din continutul cursului pentru rezolvarea problemelor complexe si dificile	Realizare și susținere proiect	50%
10.5 Laborator	• Specificarea, proiectarea, implementarea si testarea metodelor inteligente • Rezolvarea efectiva a problemelor cu ajutorul metodelor anterior implementate	Observarea sistematică a studentului în timpul rezolvării temelor de laborator si realizarii proiectului	50%
10.6 Standard minim de performanță			

- Fiecare student trebuie să demonstreze ca a atins un nivel acceptabil de cunoastere si intelegere a domeniului, ca este capabil sa exprime cunostintele intr-o forma coerenta, ca are capacitatea de a stabili anumite conexiuni si de a utiliza cunostintele in rezolvarea unor probleme.

- Pentru a putea promova examenul studentul trebuie să:
  - Fie prezent la cel putin 6 laboratoare. Studenții care nu au prezență la minim 6 laboratoare nu se pot prezenta la examen nici în sesiunea de restanțe
  - Realizeze cel puțin 70% din proiect

Data completării	Semnătura titularului de curs	Semnătura titularului de seminar
23 aprilie 2023	Prof. Dr. Dioșan Laura	Prof. Dr. Dioșan Laura

Data avizării în departament — Semnătura directorului de departament

..... Prof. Dr. Dioșan Laura