

UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI" DIN IAȘI

Facultatea de Automatică și Calculatoare

Departamentul de Calculatoare

Concurs pentru ocuparea postului de conferențiar, poz. 14

Disciplinele postului: Fundamentele învățării automate, Învățare profundă, Sisteme de prelucrare grafică

## Tematica de concurs

privind

Prelegerea din aria tematică a postului

pentru ocuparea postului de conferențiar, poz. 14

din Statul de funcții al Departamentului de Calculatoare

pe anul universitar 2024-2025

### Fundamentele învățării automate

- **Învățare supervizată:** principii, definiții, concepte esențiale; metode fundamentale: K-Nearest Neighbors, Naive Bayes, arbori de decizie, regresie liniară/polinomială etc.
- **Învățare nesupervizată:** principii, definiții; metode de grupare: K-Means, grupare ierarhică, expectativă-maximizare (*expectation-maximization*), DBSCAN.
- **Prelucrarea trăsăturilor (*Feature Engineering*):** definiții; standardizare, normalizare, codificarea trăsăturilor; trăsături polinomiale, termeni de interacțiune (*interaction terms*); selecția și extragerea trăsăturilor.
- **Ansambluri:** introducere în învățarea bazată pe ansambluri; tipuri de ansambluri: bagging, boosting, stacking; Random Forest, AdaBoost.
- **Rețele neuronale:** rețele neuronale complet-conectate (*fully-connected*): principii, structură; propagare înainte, retropropagare; funcții de activare; metode de optimizare pentru antrenare; elemente de bază ale rețelelor convoluționale și recurente; arhitecturi de rețele neuronale profunde frecvent utilizate: U-Net, VGGNet, ResNet etc.
- **Modele encoder-decoder:** structura generală a unui encoder-decoder; arhitecturi bazate pe straturi recurente; aplicații pentru procesarea datelor de tip text.
- **Suprapotrivire (*Overfitting*) și regularizare:** definiții; cauze; efecte negative asupra antrenării și exploatării modelelor de învățare; tehnici de regularizare (L1, L2, dropout, oprire timpurie (*early stopping*) etc.).
- **Optimizarea hiperparametrilor:** motivație; metode populare: grid search, random search, hyperband.
- **Evaluarea modelelor de învățare automată:** metrici de evaluare: acuratețe, precizie, recall, scor F1; validare încrucișată; compromisul bias-varianță (*bias-variance tradeoff*).

### Învățare profundă

- **Bazele învățării profunde:** definiții, concepte esențiale; rețele neuronale clasice vs. rețele neuronale profunde; prezentare generală a unora dintre cele mai populare biblioteci de învățare profundă: PyTorch, TensorFlow + Keras.
- **Calculul bazat pe tensori:** definiții, proprietăți ale tensorilor; operații cu tensori: adunare, înmulțire, broadcasting, reshaping, slicing; diferențierea tensorilor.

- **Modele statice și dinamice:** antrenare online vs. offline; generarea de modele statice și dinamice; grafuri computaționale statice și dinamice – avantaje și dezavantaje.
- **Gestiunea seturilor de date:** seturi de date de diferite tipuri; tehnici de preprocesare a datelor; tehnici de partajare a datelor; gestiunea seturilor de date dezechilibrate; metode de augmentare a datelor; organizarea datelor în batch-uri.
- **Straturi convoluționale și recurente:** prezentare generală a rețelelor neuronale convoluționale; avantaje ale straturilor convoluționale în cadrul arhitecturilor de rețele neuronale; extragerea trăsăturilor în straturile convoluționale; propagarea datelor prin straturile convoluționale; straturi recurente – avantaje privind procesarea secvențelor; propagarea datelor prin straturile recurente; îmbunătățiri ale recurenței tradiționale: rețele LSTM, GRU.
- **Modele pentru serii de timp (*time series*):** definiții ale datelor ce formează serii de timp; provocările seriilor de timp: sezonabilitate, non-staționaritate, neregularitate; modele autoregresive și cu medie mobilă (*moving average*); rețele neuronale convoluționale temporale; rețele neuronale profunde pentru date ce formează serii de timp.
- **Modele Seq2Seq cu mecanisme de atenție:** arhitectura unui model Seq2Seq (*Sequence-to-Sequence*) tradițional; mecanisme de atenție în modelele Seq2Seq; aplicații de traducere automată.

## Sisteme de prelucrare grafică

- **Transformări grafice bidimensionale:** transformări geometrice: translație, rotație, scalare, oglindire.
- **Transformări de vizualizare:** transformări ale sistemelor de coordonate 2D; transformarea fereastră-poartă (*window-viewport transform*).
- **Pipeline-ul grafic OpenGL:** reprezentarea scenelor 2D, 3D în OpenGL; pipeline-ul OpenGL programabil; programe shader.
- **Programarea procesoarelor grafice:** limbajul GLSL; variabile specifice GLSL; vertex și fragment shader; vertex buffer objects (VBO) și vertex array objects (VAO).
- **Compunerea transformărilor geometrice:** stiva matricelor de transformare; modalități de gestiune a transformărilor într-o scenă grafică.
- **Modele de iluminare locală:** modelul Phong: iluminare ambientală, difuză și speculară; iluminare per-vertex și per-pixel.
- **Texturare:** definirea texturilor; coordonate de texturare; filtrarea texturilor; compunerea texturilor semi-transparente.
- **Metode de texturare prin ajustarea direcțiilor normalelor (*normal mapping*):** modalități de modificare a direcțiilor normalelor; normal mapping folosind texturi și/sau variabile aleatorii.

## Bibliografie

1. T. Jiang, J. L. Gradus, and A. J. Rosellini, "Supervised Machine Learning: A Brief Primer," *Behavior Therapy*, vol. 51, no. 5, pp. 675–687, Sep. 2020, doi: 10.1016/j.beth.2020.05.002.
2. J. E. van Engelen and H. H. Hoos, "A survey on semi-supervised learning," *Machine Learning*, vol. 109, no. 2, pp. 373–440, Nov. 2019, doi: 10.1007/s10994-019-05855-6.

3. G. James, D. Witten, T. Hastie, R. Tibshirani, and J. Taylor, "Unsupervised Learning," *An Introduction to Statistical Learning*, pp. 503–556, 2023, doi: 10.1007/978-3-031-38747-0\_12.
4. G. Matteucci, E. Piasini, and D. Zoccolan, "Unsupervised learning of mid-level visual representations," *Current Opinion in Neurobiology*, vol. 84, p. 102834, Feb. 2024, doi: 10.1016/j.conb.2023.102834.
5. E. Hancer, B. Xue, and M. Zhang, "A survey on feature selection approaches for clustering," *Artificial Intelligence Review*, vol. 53, no. 6, pp. 4519–4545, Jan. 2020, doi: 10.1007/s10462-019-09800-w.
6. X. He, K. Zhao, and X. Chu, "AutoML: A survey of the state-of-the-art," *Knowledge-Based Systems*, vol. 212, p. 106622, Jan. 2021, doi: 10.1016/j.knosys.2020.106622.
7. D. Mienye and Y. Sun, "A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects," *IEEE Access*, vol. 10, pp. 99129–99149, 2022, doi: 10.1109/access.2022.3207287.
8. X. Dong, Z. Yu, W. Cao, Y. Shi, and Q. Ma, "A survey on ensemble learning," *Frontiers of Computer Science*, vol. 14, no. 2, pp. 241–258, Aug. 2019, doi: 10.1007/s11704-019-8208-z.
9. Khan, A. Sohail, U. Zahoora, and A. S. Qureshi, "A survey of the recent architectures of deep convolutional neural networks," *Artificial Intelligence Review*, vol. 53, no. 8, pp. 5455–5516, Apr. 2020, doi: 10.1007/s10462-020-09825-6.
10. Y. Han, G. Huang, S. Song, L. Yang, H. Wang, and Y. Wang, "Dynamic Neural Networks: A Survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 11, pp. 7436–7456, Nov. 2022, doi: 10.1109/tpami.2021.3117837.
11. Saxe, S. Nelli, and C. Summerfield, "If deep learning is the answer, what is the question?," *Nature Reviews Neuroscience*, vol. 22, no. 1, pp. 55–67, Nov. 2020, doi: 10.1038/s41583-020-00395-8.
12. R. Miikkulainen et al., "Evolving deep neural networks," *Artificial Intelligence in the Age of Neural Networks and Brain Computing*, pp. 269–287, 2024, doi: 10.1016/b978-0-323-96104-2.00002-6.
13. J. A. Livezey and J. I. Glaser, "Deep learning approaches for neural decoding across architectures and recording modalities," *Briefings in Bioinformatics*, vol. 22, no. 2, pp. 1577–1591, Dec. 2020, doi: 10.1093/bib/bbaa355.
14. Y. Ji, H. Zhang, Z. Zhang, and M. Liu, "CNN-based encoder-decoder networks for salient object detection: A comprehensive review and recent advances," *Information Sciences*, vol. 546, pp. 835–857, Feb. 2021, doi: 10.1016/j.ins.2020.09.003.
15. C. Chen, D. Han, and J. Wang, "Multimodal Encoder-Decoder Attention Networks for Visual Question Answering," *IEEE Access*, vol. 8, pp. 35662–35671, 2020, doi: 10.1109/access.2020.2975093.
16. C. F. G. D. Santos and J. P. Papa, "Avoiding Overfitting: A Survey on Regularization Methods for Convolutional Neural Networks," *ACM Computing Surveys*, vol. 54, no. 10s, pp. 1–25, Jan. 2022, doi: 10.1145/3510413.
17. N. Syam and R. Kaul, "Overfitting and Regularization in Machine Learning Models," *Machine Learning and Artificial Intelligence in Marketing and Sales*, pp. 65–84, Mar. 2021, doi: 10.1108/978-1-80043-880-420211004.
18. B. Bischl et al., "Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges," *WIREs Data Mining and Knowledge Discovery*, vol. 13, no. 2, Jan. 2023, doi: 10.1002/widm.1484.
19. L. Yang and A. Shami, "On hyperparameter optimization of machine learning algorithms: Theory and practice," *Neurocomputing*, vol. 415, pp. 295–316, Nov. 2020, doi: 10.1016/j.neucom.2020.07.061.
20. K. Zhou, Z. Liu, Y. Qiao, T. Xiang, and C. C. Loy, "Domain Generalization: A Survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1–20, 2022, doi: 10.1109/tpami.2022.3195549.
21. S. Marschner and P. Shirley, *Fundamentals of Computer Graphics*. CRC Press, 2018.
22. V. Manta: *Grafică în C și OpenGL*, Ed. Politehnicum, Iași, 2006.
23. Introduction to Computer Graphics, Lecture notes, University Waterloo, 2023 <https://student.cs.uwaterloo.ca/~cs488/Winter2023/notes.pdf>
24. Computer Graphics, Lecture notes, Univ. Washington, MIT EECS 6.837, Cutler and Durand (MIT OpenCourseWare <http://ocw.mit.edu>)
25. *Computer Graphics & Image Processing 2020*, Cambridge
26. J. F. Hughes, A. van Dam, M. McGuire, D. Sklar, J. D. Foley, S. K. Feiner, and K. Akeley, *Computer Graphics: Principles and Practice*, 3rd ed. Addison-Wesley, 2013.
27. *Computer Graphics (CS 543)*, Worcester Polytechnic Institute (WPI)
28. V. S. Gordon and J. Clevenger, *Computer Graphics Programming in OpenGL with C++*. Walter de Gruyter GmbH & Co. KG, 2024.
29. S. Kosarevsky and V. Latypov, *3D Graphics Rendering Cookbook: A Comprehensive Guide to Exploring Rendering Algorithms in Modern OpenGL and Vulkan*. Packt Publishing Ltd., 2021.
30. D. Wolff, *OpenGL 4 Shading Language Cookbook: Build High-Quality, Real-Time 3D Graphics with OpenGL 4.6, GLSL 4.6 and C++ 17*. Packt Publishing Ltd., 2018.
31. S. Guha, *Computer Graphics Through OpenGL: From Theory to Experiments*. CRC Press, 2018.

Decan,  
Prof. Adrian Burlacu

Director de departament,  
Conf. Andrei Stan