

DOKTORANTŪROS STUDIJŲ DALYKO SANDAS

Dalyko pavadinimas	Mokslo kryptis (šaka) kodas	Fakultetas	Katedra
Gilieji neuroniniai tinklai	Informatikos inžinerija 07 T	MIF	Duomenų mokslo ir skaitmeninių technologijų institutas

Studijų būdas	Kreditų skaičius ECTS	Studijų būdas	Kreditų skaičius
paskaitos	1 (pavasario)	konsultacijos	1
individualus	4	seminarai	1

Dalyko anotacija			
<p>Nepaisant to, kad dirbtiniai neuroniniai tinklai pradėti kurti ir nagrinėti daugiau nei prieš 50 metų, pastaruoju metu, išaugus skaičiuojamiesiems resursams, jie ypač išpopuliariėjo. Dirbtiniai neuroniniai tinklai yra priskiriami prie skaitmeninio intelekto (angl. <i>computational intelligence</i>) metodų. Kurso metu doktorantams suteikiamas žinios ne tik apie paprastesnių struktūrų neuroninius tinklus, bet didžiausias dėmesys skiriamas giliesiems neuroniniams tinklams, kurie pajėgūs išspręsti gana sudėtingus duomenų klasifikavimo, vaizdo, garso ir kitų signalų atpažinimo bei kitus uždavinius.</p>			
<p><i>Pagrindinės temos:</i></p> <ol style="list-style-type: none"> 1. Įvadas į dirbtinius neuroninius tinklus; <ol style="list-style-type: none"> 1.1. Dirbtinis neuronas ir jo ryšis su biologiniu. Pagrindinės sąvokos; 1.2. Mašininio mokymosi pagrindai. Mokymas, validavimas ir testavimas. Mokymo su mokytoju ir mokymo be mokytojo paradigmos; 1.3. Vienasluoksnis ir daugiasluoksnis perceptronai. Aktyvacijos funkcijos. Mokymo algoritmai. „Klaidos sklidimo atgal“ algoritmas. Stochastinis gradientinis nusileidimas. Hiperparametrai ir jų nustatymas; 1.4. Tiesinės ir logistinės regresijų ryšys su neuroniniais tinklais. Atsitiktinės reikšmės, tikimybės, informacijos teorija, Bayes statistika. 2. Autoenkoderiai: <ol style="list-style-type: none"> 2.1. Faktoriniai modeliai ir faktorinė analizė; 2.2. Enkoderiai, dekoderiai, latentiniai kintamieji („butelio kaklelis“); 2.3. Triukšmo šalinimas, regionų atstatymas (angl. <i>neural inpainting</i>); 2.4. Variaciniai autoenkoderiai: <ol style="list-style-type: none"> 2.4.1. Latentinių vektorių atskyrimas, parametru parinkimas atsižvelgiant į skirstinius, reparameterizacija ir stochastika. 2.5. Nepainūs (angl. <i>disentangled</i>) variaciniai autoenkoderiai: nekoreliuotas latentinis skirstinys ir tinklo neuronai, ryšys su sustiprintu mokymusi (angl. <i>reinforcement learning</i>). 3. Konvoluciiniai neuroniniai tinklai: <ol style="list-style-type: none"> 3.1. Konvoluciujos operacija. Konvoluciunis jungumas ir kaukės žingsnis (angl. <i>pooling, strides</i>). 3.2. Optimizavimo algoritmai ir tikslumo matavimo metrikos; 3.3. Reguliarizacija, neuronų įjungimas/išjungimas (angl. <i>dropout</i>), paketo normalizavimas; 3.4. Parametru erdvės tikimybinis tankis (Bayes tinklai). 4. Gilieji generaciniai modeliai: <ol style="list-style-type: none"> 4.1.1. Bolcmano mašinos, giliuosios ir konvoluciunės Bolcmano mašinos; 4.1.2. Diskriminatoriai, generaciniai ir sąlyginiai stochastiniai neuroniniai tinklai. 			

5. Gilusis sustiprintas mokymasis
- 5.1. Markovo procesai, Q-mokymasis, sutartiniai (angl. *policy*) gradientai, Paslaugos į priekį (angl. *credit*) suteikimo problema, atlygio nustatymas ir veiksmų erdvė (angl. *reward shaping and sparsity*), pritaikomumo problema (angl. *alignment problem*).
6. Rekurentiniai (grįžtamojo ryšio) ir rekursiniai neuroniniai tinklai:
- 6.1. Dvikrypčiai, gilieji rekurentiniai tinklai,
- 6.2. Rekursiniai tinklai, laiko modeliavimas, laikinis atsakas, kintančios laiko skalės, ilgalaikės trumpalaikės-atmintis (angl. *long short-term memory*), klaidos sklidimas atgal laiko ir struktūros atžvilgiais.

Praktinė užduotis: išspręsti nurodytus uždavinius pasitelkus dirbtinius neuroninius tinklus.

Pagrindinė literatūra

- Higgins, I., Matthey, L., Pal, A., Burgess, C., Glorot, X., Botvinick, M., Mohamed, S. & Lerchner, A. (2016). beta-VAE: Learning basic visual concepts with a constrained variational framework. <https://openreview.net/forum?id=Sy2fzU9gl>
- Liu, X., Li, Y., & Wang, Q. (2018). Multi-View Hierarchical Bidirectional Recurrent Neural Network for Depth Video Sequence Based Action Recognition. International Journal of Pattern Recognition and Artificial Intelligence. <https://doi.org/10.1142/S0218001418500337>
- Olabiyi, O., & Martinson, E. (2018). U.S. Patent Application No. 15/362,720. <https://patents.google.com/patent/US20180053108A1/en>
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5-6), 602-610. <https://doi.org/10.1016/j.neunet.2005.06.042>
- Mikolov, T., Kombrink, S., Burget, L., Černocký, J., & Khudanpur, S. (2011, May). Extensions of recurrent neural network language model. In *Acoustics, Speech and Signal Processing (ICASSP), 2011 IEEE International Conference on* (pp. 5528-5531). IEEE. <https://doi.org/10.1109/ICASSP.2011.5947611>
- Zaremba, W., Sutskever, I., & Vinyals, O. (2014). Recurrent neural network regularization. arXiv preprint arXiv:1409.2329. <https://arxiv.org/abs/1409.2329>
- Masci, J., Meier, U., Cireşan, D., & Schmidhuber, J. (2011, June). Stacked convolutional auto-encoders for hierarchical feature extraction. In *International Conference on Artificial Neural Networks* (pp. 52-59). Springer, Berlin, Heidelberg. https://link.springer.com/chapter/10.1007%2F978-3-642-21735-7_7
- Liu, Y., Feng, X., & Zhou, Z. (2016). Multimodal video classification with stacked contractive autoencoders. *Signal Processing*, 120, 761-766. <https://doi.org/10.1016/j.sigpro.2015.01.001>
- Xie, J., Xu, L., & Chen, E. (2012). Image denoising and inpainting with deep neural networks. In *Advances in neural information processing systems* (pp. 341-349). <http://papers.nips.cc/paper/4686-image-denoising-and-inpainting-with-deep-neural-networks>
- Karpathy, A. (2016). Deep reinforcement learning: Pong from pixels. <http://karpathy.github.io/2016/05/31/rl/>

Konsultuojančiųjų dėstytojų vardas, pavardė	Mokslo laipsnis	Svarbiausieji darbai mokslo kryptyje (šakoje) paskelbti per pastaruosius 5 metus
Povilas Treigys	dr.	<p>Morkūnas, M.; Treigys, P.; Bernatavičienė, J.; Laurinavičius, A.; Korvel, G. Machine learning based classification of colorectal cancer tumour tissue in whole-slide images. <i>Informatica</i>. Vilnius: Vilniaus universiteto Matematikos ir informatikos institutas. ISSN 0868-4952. 2018, Vol. 29, no. 1, p. 75-90. DOI: 10.15388/Informatica.2018.158.</p> <p>Jucevičius, J.; Treigys, P.; Bernatavičienė, J.; Briedienė, Rūta; Naruševičiūtė, Ieva; Dzemyda, Gintautas; Medvedev, Viktor. Automated 2D segmentation of prostate in T2-weighted MRI scans // International journal of computers communications & control. Oradea : Universitatea Agora. ISSN 1841-9836. eISSN 1841-9844. 2017, Vol. 12, No. 1, p. 53-60. Prieiga per internetą:</p>

		< http://univagora.ro/jour/index.php/ijccc/article/view/2783/1059 >.
Olga Kurasova	dr.	<p>Medvedev, V.; Kurasova, O.; Bernatavičienė, J.; Treigys, P.; Marcinkevičius, V.; Dzemyda, G. A new web-based solution for modelling data mining processes. <i>Simulation Modelling Practice and Theory</i>. Amsterdam : Elsevier Science. ISSN 1569-190X. eISSN 1878-1462. 2017, Vol. 76, p. 34-46. DOI: 10.1016/j.smpat.2017.03.001.</p> <p>Bernatavičienė, J.; Dzemyda, G.; Kurasova, O.; Marcinkevičius, V.; Medvedev, V.; Treigys, P. Cloud computing approach for intelligent visualization of multidimensional data. <i>Advances in stochastic and deterministic global optimization</i>. Ser.: Springer optimization and its applications. ISSN 1931-6828. Vol. 107. Cham: Springer International Publishing Switzerland, 2016. ISBN 9783319299730. p. 73-85. DOI: 10.1007/978-3-319-29975-4_5.</p>
Viktor Medvedev	dr.	<p>Medvedev, V.; Kurasova, O. Cloud technologies: a new level for Big Data Mining // Resource management for Big Data platforms: algorithms, modelling, and high-performance computing techniques / Editors: Florin Pop, Joanna Kołodziej, Beniamino Di Martino. Ser.: Computer communications and networks. ISSN 1617-7975. Cham: Springer International Publishing AG, 2016. ISBN 9783319448800. p. 55-68. DOI: 10.1007/978-3-319-44881-7_3</p> <p>Bernatavičienė, J; Dzemyda, G.; Bazilevičius, G.; Medvedev, V.; Marcinkevičius, V.; Treigys, P. 2015. Method for visual detection of similarities in medical streaming data // International journal of computers communications & control. Oradea: Universitatea Agora. ISSN 1841-9836. 2015, Vol. 10, no. 1, p. 8-21</p>