

DOKTORANTŪROS STUDIJŲ DALYKO SANDAS

Dalyko pavadinimas	Mokslo kryptis, kodas	Fakultetas	Katedra
Gilieji neuroniniai tinklai	Informatikos inžinerija (T 007)	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, pastaruju metu, išaugus skaičiuojamiesiems resursams, jie ypač išpopuliarėjo. Dirbtiniai neuroniniai tinklai yra priskiriami prie skaitmeninio intelekto (angl. <i>computational intelligence</i>) metodų. Kurso metu doktorantams suteikiamos 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. Faktoriai 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, parametrų 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. Konvoliuciniai neuroniniai tinklai: <ol style="list-style-type: none"> 3.1. Konvoliucijos operacija. Konvoliucinis 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. Parametrų erdvės tikimybinis tankis (Bayes tinklai). 4. Gilieji generaciniai modeliai: <ol style="list-style-type: none"> 4.1.1. Bolemano mašinos, giliosios ir konvoliucinės Bolemano 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

Aston Zhang, Zachary C. Lipton, Mu Li, and Alexander J. Smola, "Dive into Deep Learning", 2021.

<https://d2l.ai/index.html>

Ian Goodfellow, Yoshua Bengio and Aaron Courville, "Deep Learning", MIT Press, 2016

<http://www.deeplearningbook.org>

Aston Zhang, Zachary C. Lipton, Mu Li, and Alexander J. Smola, "Dive into Deep Learning", 2021.

<https://d2l.ai/index.html>

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, paskelbti per pastaruosius 5 metus
Povilas Treigys	dr.	http://www.elaba.mb.vu.lt/dmsti/?aut=Povilas+Treigys
Olga Kurasova	dr.	http://www.elaba.mb.vu.lt/dmsti/?aut=Olga+Kurasova
Viktor Medvedev	dr.	http://www.elaba.mb.vu.lt/dmsti/?aut=Viktor+Medvedev