

Ковалёв Сергей Протасович
Ведущий научный сотрудник, д.ф.-м.н.
Институт проблем управления им. В.А. Трапезникова РАН, г. Москва

Замена инженера компьютером: перспективы и проблемы машинного обучения

Аннотация. Рассматриваются подходы, перспективы и проблемы замены рутинной умственной инженерно-технической деятельности компьютерными средствами на базе машинного обучения. Обосновывается актуальность замены в контексте четвертой промышленной революции (Industry 4.0), в том числе в рамках технологий цифровых двойников (digital twin), порождающего проектирования (generative design), автоматического производства (automatic manufacturing). Проводится краткий сравнительный анализ символного (формального) и коннекционистского (нейросетевого) представления инженерных знаний. Демонстрируются примеры решения нетривиальных математических, физических и технических задач с применением глубоких нейронных сетей в лабораторных условиях. Приводится обзор архитектур и примеров нейросетевых средств решения ряда ключевых задач интеллектуального управления энергетическими системами.

Список литературы

1. *Madni A.M., Madni C.C., Lucero S.D.* Leveraging digital twin technology in model-based systems engineering // Systems. 2019. Vol. 7(1). P. 7. <https://doi.org/10.3390/systems7010007>
2. Ковалёв С.П. Применение онтологий при разработке распределенных автоматизированных информационно-измерительных систем // Автометрия. 2008. Т. 44, № 2. С. 41–49. <http://ccfit.nsu.ru/~kovalyov/publications/aiis-eng.pdf>
3. Волошин А. А., Волошин Е. А., Бусыгин Т. Г. Разработка системы автоматического синтеза тестовых сценариев и проверки правильности выполнения ПНР комплексов РЗА ЦПС // Вести в электроэнергетике. 2017. № 4 (90). С. 44–50.
4. Панов М., Хмелев И., Смирнов А. Нейронные сети на службе энергетиков // Открытые системы. СУБД. 2016. № 4. С. 39–41. <https://www.osp.ru/os/2016/04/13050997>
5. Szegedy C., Zaremba W., Sutskever I., Bruna J., Erhan D., Goodfellow I.J., Fergus R. Intriguing properties of neural networks // arXiv, 2013. <https://arxiv.org/abs/1312.6199>
6. Dai W.-Z., Muggleton S., Zhou Z.-H. Logical vision: meta-interpretive learning for simple geometrical concepts // Proc. 25th International Conference on Inductive Logic Programming (ILP-2015). Kyoto, 2015. http://www.ilp2015.jp/papers/ILP2015_submission_26.pdf
7. Iten R., Metger T., Wilming H., del Rio L., Renner R. Discovering physical concepts with neural networks // arXiv, 2018. <https://arxiv.org/abs/1807.10300>
8. Wang P., Ananya, Yan R., Gao R.X. Virtualization and deep recognition for system fault classification // Journal of Manufacturing Systems. 2017. Vol. 44. P. 310–316. https://www.researchgate.net/publication/316593019_Virtualization_and_deep_recognition_for_system_fault_classification
9. Kowalski J. CAD is a lie: generative design to the rescue. Autodesk, 2016. <https://www.autodesk.com/redshift/generative-design/>
10. Oh S., Jung Y., Kim S., Lee I., Kang N. Deep generative design: integration of topology optimization and generative models // arXiv, 2019. <https://arxiv.org/abs/1903.01548>
11. Kovalyov S.P. An approach to develop a generative design technology for power systems // Proc. VI International Workshop “Critical Infrastructures: Contingency Management, Intelligent, Agent-Based, Cloud Computing and Cyber Security” (IWCI 2019). Advances in Intelligent Systems Research. 2019. Vol. 169. P. 79–82. <https://www.atlantis-press.com/proceedings/iwci-19/125917306>
12. Ming M., Wang R., Zha Y., Zhang T. Multi-objective optimization of hybrid renewable energy system using an enhanced multi-objective evolutionary algorithm // Energies. 2017. Vol. 10. P. 674. <https://www.mdpi.com/1996-1073/10/5/674>