



APPLICATION OF DEEP LEARNING TECHNIQUES IN IDENTIFICATION OF THE STRUCTURE OF SELECTED ROAD MATERIALS

ZASTOSOWANIE TECHNIKI GŁĘBOKIEGO UCZENIA DO IDENTYFIKACJI STRUKTURY WYBRANYCH MATERIAŁÓW DROGOWYCH

Grzegorz Mazurek*, Małgorzata Durlej
Kielce University of Technology, Poland
Juraj Šrámek
University of Zilina, Slovakia

Abstract

In research, there is a growing interest in using artificial intelligence to find solutions to difficult scientific problems. In this paper, a deep learning algorithm has been applied using images of samples of materials used for road surfaces. The photographs showed cross-sections of random samples taken with a CT scanner. Historical samples were used for the analysis, located in a database collecting information over many years. The deep learning analysis was performed using some elements of the VGG16 network architecture and implemented using the R language. The learning and training data were augmented and cross-validated. This resulted in the high level of 96.4% quality identification of the sample type and its selected structural features. The photographs in the identification set were correctly identified in terms of structure, mix type and grain size. The trained model identified samples in the domain of the dataset used for training in a very good way. As a result, in the future such a methodology may facilitate the identification of the type of mixture, its basic properties and defects.

Keywords: deep learning, tomograph, R programming language, classification, road surfaces, correlation, digital image

Streszczenie

W badaniach naukowych obserwuje się coraz większe zainteresowanie wykorzystaniem sztucznej inteligencji do poszukiwania rozwiązań trudnych problemów naukowych. W niniejszym artykule został zastosowany algorytm głębokiego uczenia z użyciem obrazów próbek materiałów wykorzystywanych do budowy nawierzchni drogowych. Fotografie przedstawiały przekroje losowych próbek wykonane za pomocą tomografu komputerowego. Do analizy wykorzystano próbki historyczne, znajdujące się w bazie danych zbierającej informacje z wielu lat. Analizę głębokiego uczenia wykonano przy użyciu niektórych elementów architektury sieci VGG16 i zaimplementowano, stosując język R. Dane uczące oraz treningowe poddano augmentacji oraz walidacji krzyżowej. W rezultacie uzyskano wysoki poziom 96,4% jakości identyfikacji rodzaju próbki oraz jej wybranych cech strukturalnych. Fotografie w zbiorze identyfikacyjnym zostały poprawnie zidentyfikowane pod względem struktury, typu mieszanek oraz uziarnienia. Wytrenowany model w bardzo dobry sposób zidentyfikował próbki w obszarze dziedziny trenowanego zbioru danych. W rezultacie taka metodyka może w przyszłości ułatwić identyfikację rodzaju mieszanek, jej podstawowych właściwości oraz defektów.

Slowa kluczowe: głębokie uczenie, tomograf, język programowania R, klasyfikacja, nawierzchnie drogowe, korelacja, obraz cyfrowy

REFERENCES

- [1] Katalog typowych konstrukcji nawierzchni podatnych i półsztywnych. 2014.
- [2] Mazurek G., Buczyński P., Mackiewicz P., Iwański M.: *Field investigation of a deep recycled base course layer containing dedicated three component hydraulic and bituminous binder*, Construction and Building Materials, t. 390, s. 131685, sie. 2023, doi: 10.1016/j.conbuildmat.2023.131685.
- [3] Wirtgen Group, *Cold Recycling Technology*, First edition. Windhagen: Wirtgen GmbH, 2012.
- [4] Mazurek G., Durlej M., Iwański M., *Numerical modelling of interlayer adhesion in the layer of recycled material with the use of the leutner apparatus and computed tomography scanning*”, SAE, t. 13, nr 4, grudz. 2021, doi: 10.30540/sae-2021-011.
- [5] Rebelo F.J.P., Martins F.F., Silva H.M.R.D., Oliveira J.R.M., *Use of data mining techniques to explain the primary factors influencing water sensitivity of asphalt mixtures*, Construction and Building Materials, t. 342, s. 128039, sie. 2022, doi: 10.1016/j.conbuildmat.2022.128039.
- [6] Gong H., Sun Y., Mei Z., Huang B.: *Improving accuracy of rutting prediction for mechanistic-empirical pavement design guide with deep neural networks*, Construction and Building Materials, t. 190, s. 710-718, lis. 2018, doi: 10.1016/j.conbuildmat.2018.09.087.
- [7] Guo X., Hao P.: *Using a Random Forest Model to Predict the Location of Potential Damage on Asphalt Pavement*, Applied Sciences, t. 11, nr 21, p. 10396, lis. 2021, doi: 10.3390/app112110396.
- [8] Fakhri M., Dezfoolian R.S.: *Pavement structural evaluation based on roughness and surface distress survey using neural network model*, Construction and Building Materials, t. 204, s. 768-780, kwi. 2019, doi: 10.1016/j.conbuildmat.2019.01.142.
- [9] Gopalakrishnan K., Agrawal A., Ceylan H., Kim S., Choudhary A.: *Knowledge discovery and data mining in pavement inverse analysis*, Transport, t. 28, nr 1, s. 1-10, mar. 2013, doi: 10.3846/16484142.2013.777941.
- [10] Bashar M.Z., Torres-Machi C.: *Performance of Machine Learning Algorithms in Predicting the Pavement International Roughness Index*, Transportation Research Record, t. 2675, nr 5, s. 226-237, maj 2021, doi: 10.1177/0361198120986171.
- [11] Tong Z., Gao J., Sha A., Hu L., Li S.: *Convolutional Neural Network for Asphalt Pavement Surface Texture Analysis: Convolutional neural network*, Computer-Aided Civil and Infrastructure Engineering, t. 33, nr 12, s. 1056-1072, grudz. 2018, doi: 10.1111/mice.12406.
- [12] Tran K.A., Kondrashova O., Bradley A., Williams E.D., Pearson J.V., Waddell N.: *Deep learning in cancer diagnosis, prognosis and treatment selection*, Genome Med, t. 13, nr 1, s. 152, grudz. 2021, doi: 10.1186/s13073-021-00968-x.
- [13] Arya D. et al.: *Deep learning-based road damage detection and classification for multiple countries*, Automation in Construction, t. 132, s. 103935, grudz. 2021, doi: 10.1016/j.autcon.2021.103935.
- [14] Jóźwiak Z., Pożarycki A., Górnáś P.: *Diagnostyka nawierzchni drogowej przy zastosowaniu metod sieci neuronowych – studium przypadku*, Drogownictwo, t. 2, nr 3, s. 65-72, 2022.
- [15] Freund Y., Schapire R.E.: *A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting*, Journal of Computer and System Sciences, t. 55, nr 1, pp. 119-139, sie. 1997, doi: 10.1006/jcss.1997.1504.
- [16] Nazemi M., Heidaripanah A.: *Support vector machine to predict the indirect tensile strength of foamed bitumen-stabilised base course materials*, Road Materials and Pavement Design, t. 17, nr 3, pp. 768-778, lip. 2016, doi: 10.1080/14680629.2015.1119712.
- [17] Chollet F., Allaire J., Matuk K.: *Deep learning: praca z językiem R i biblioteką Keras*. Gliwice: Helion, 2019.
- [18] Simonyan K., Zisserman A.: *Very Deep Convolutional Networks for Large-Scale Image Recognition*, 2014, doi: 10.48550/ARXIV.1409.1556.
- [19] Zelelew H.M., Almuntashri A., Agaian S., Papagiannakis A.T.: *An improved image processing technique for asphalt concrete X-ray CT images*, Road Materials and Pavement Design, t. 14, nr 2, pp. 341-359, cze. 2013, doi: 10.1080/14680629.2013.794370.
- [20] Report TECHMATSTRATEG I, *The innovative technology used the binding agent optimization that provides the long service life of the recycled base course*, National Centre for Research and Development (NCBR), TECHMATSTRATEG1/349326/9/NCBR/2017, 2018.
- [21] Selvaraju R.R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D.: *Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization*, 2016, doi: 10.48550/ARXIV.1610.02391.