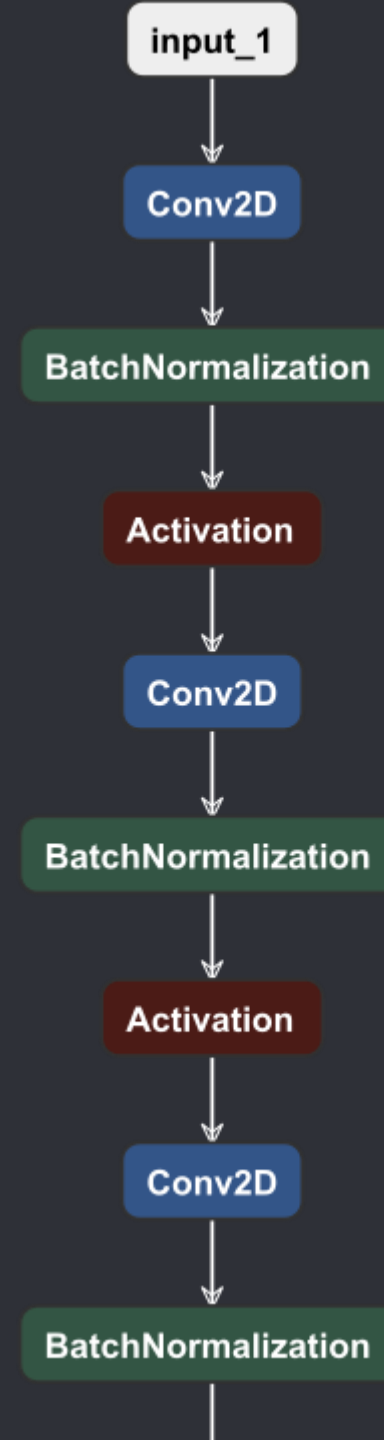
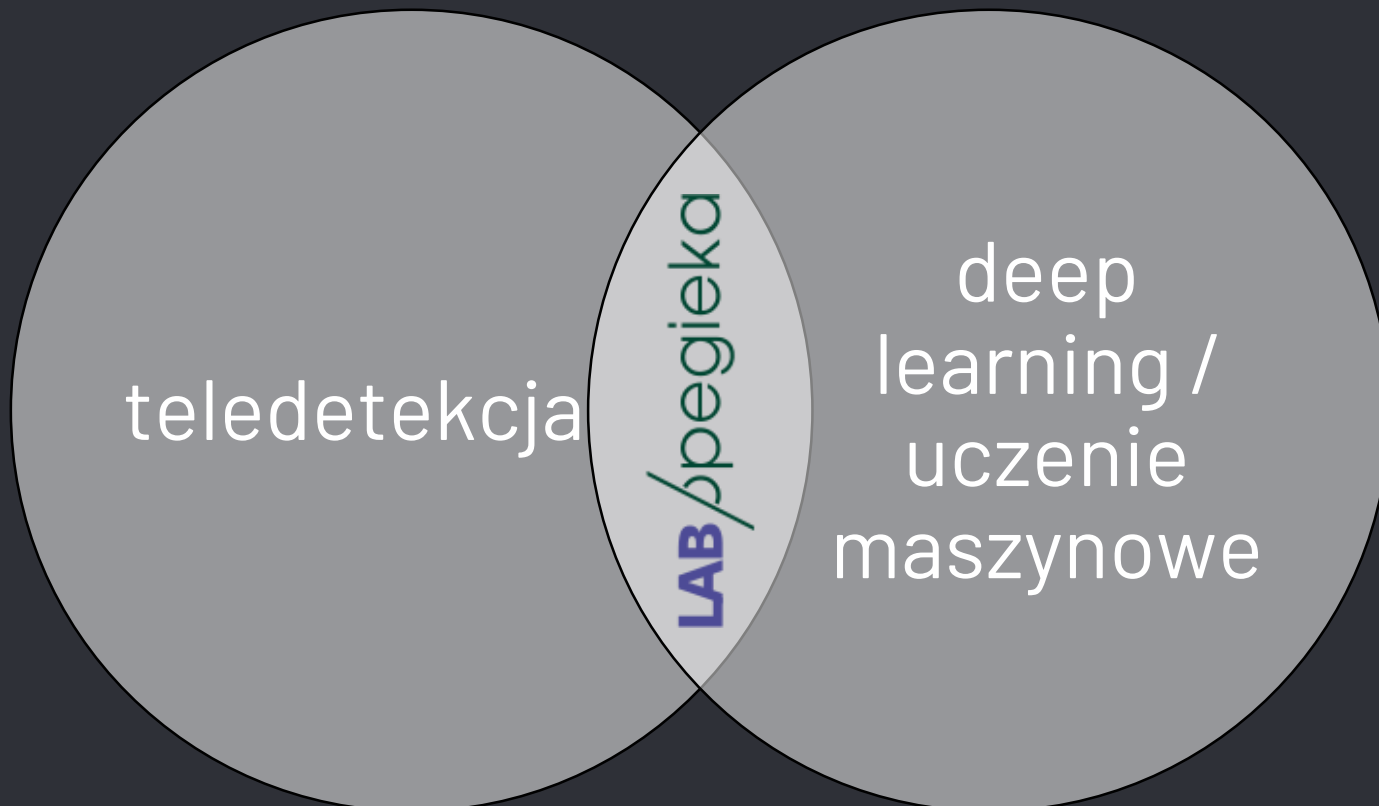
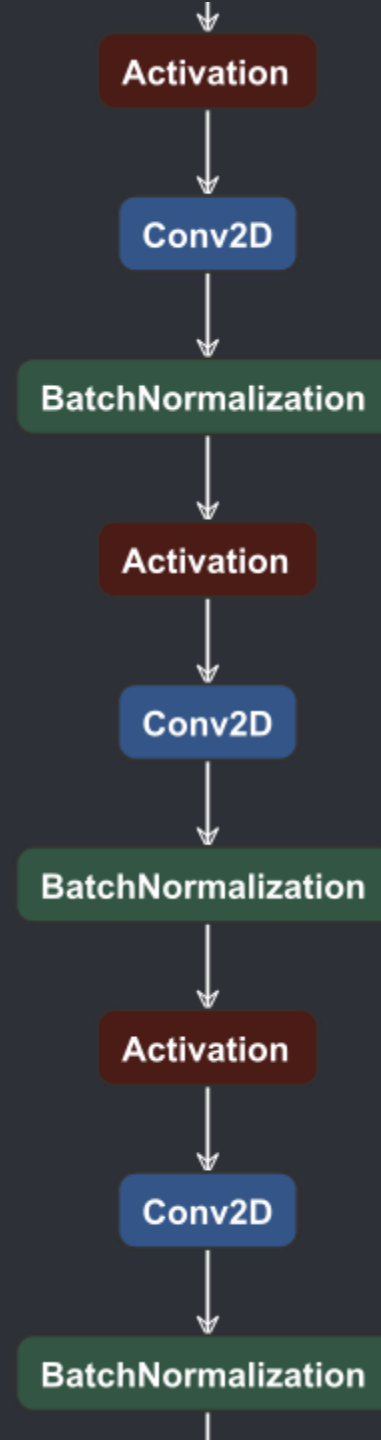


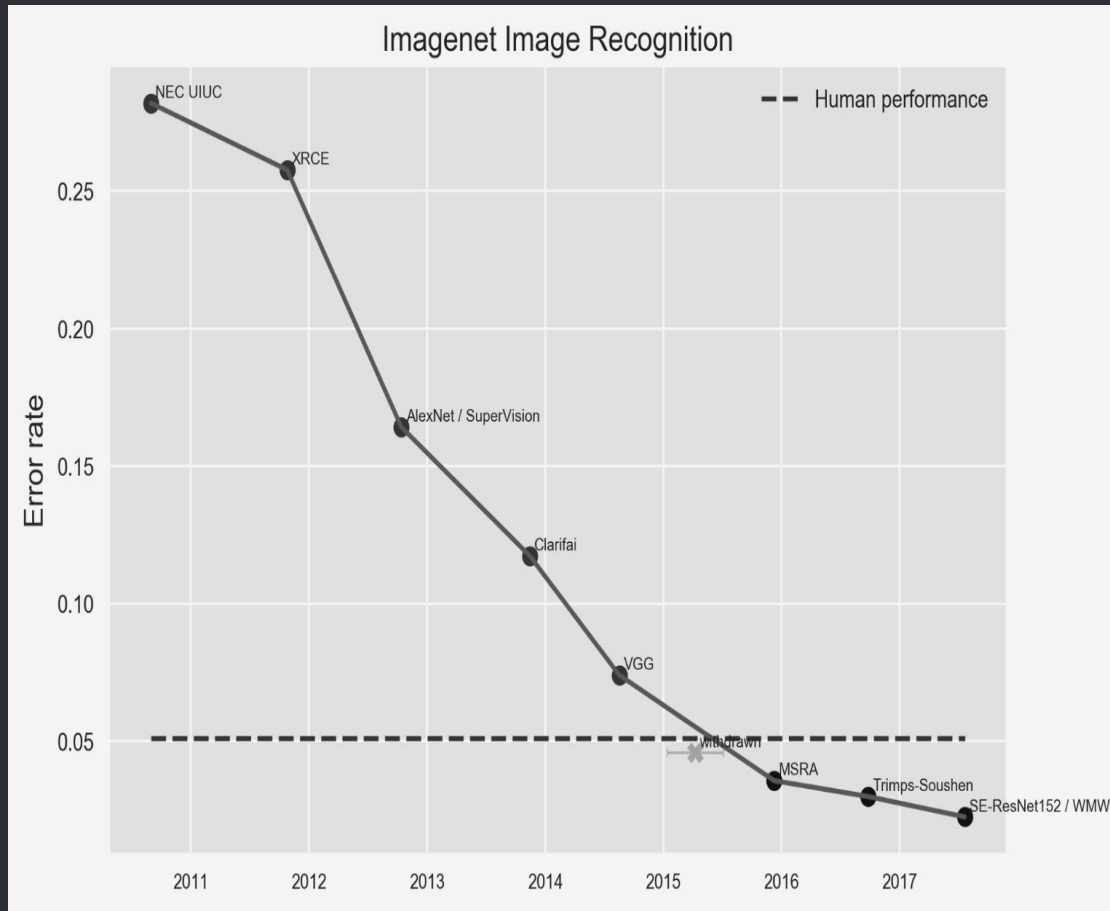
o nas



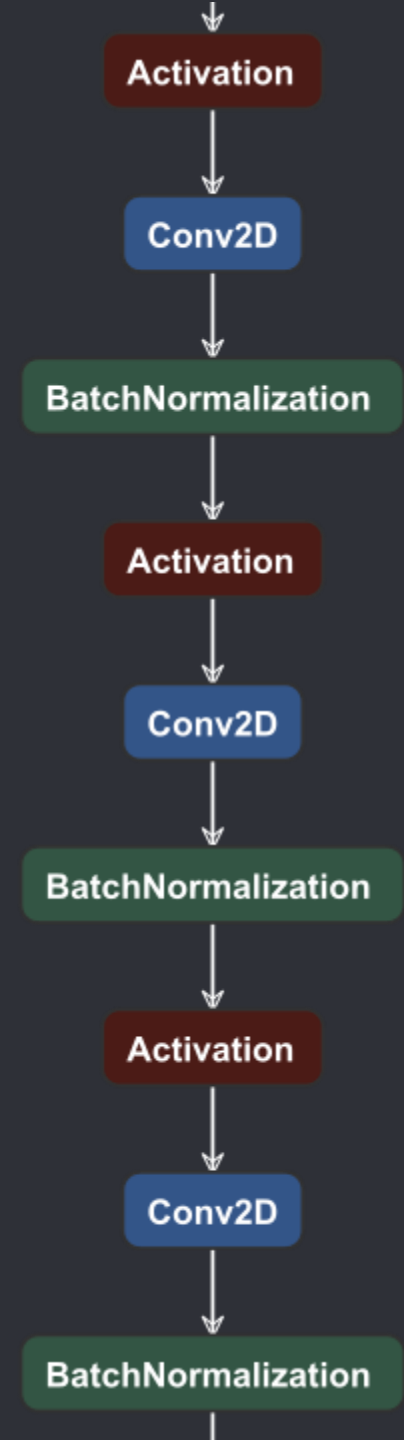
motywacja - ilość danych



motywacja - uczenie maszynowe




Poziom błędy w corocznym konkursie ImageNet w latach 2011 - 2017. Źródło: Electronic Frontier Foundation




problemy badawcze

- automatyczna klasyfikacja chmur punktów
- automatyczne generowanie NMT
- wyznaczanie szkód w uprawach ozimych
- mapy drzew

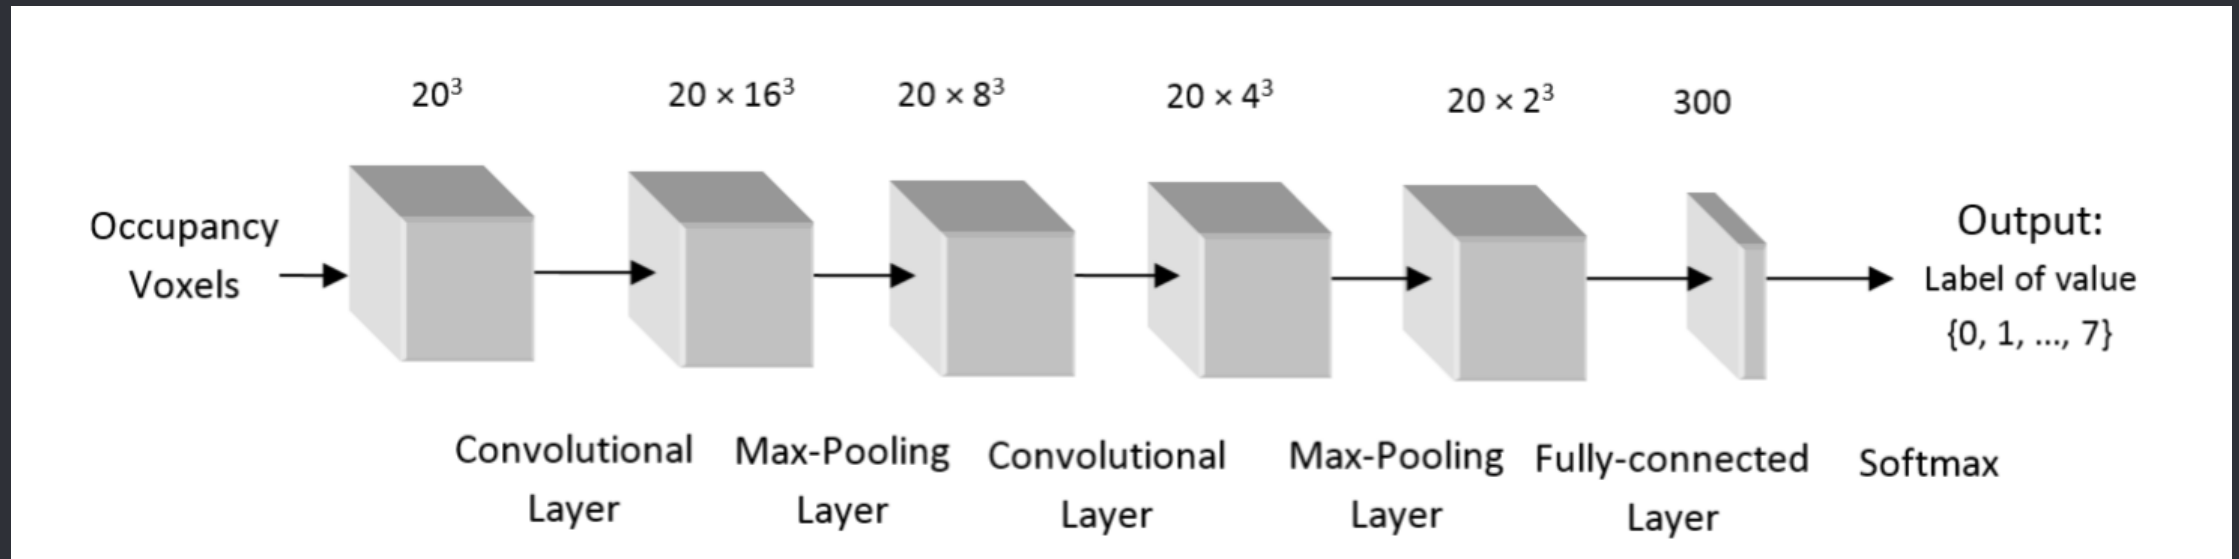


klasyfikacja - problemy

- do 40% kosztów projektów związanych z klasyfikacją chmur punktów to koszty klasyfikacji manualnej
- dodanie nowych klas znacznie zwiększa czas przetwarzania

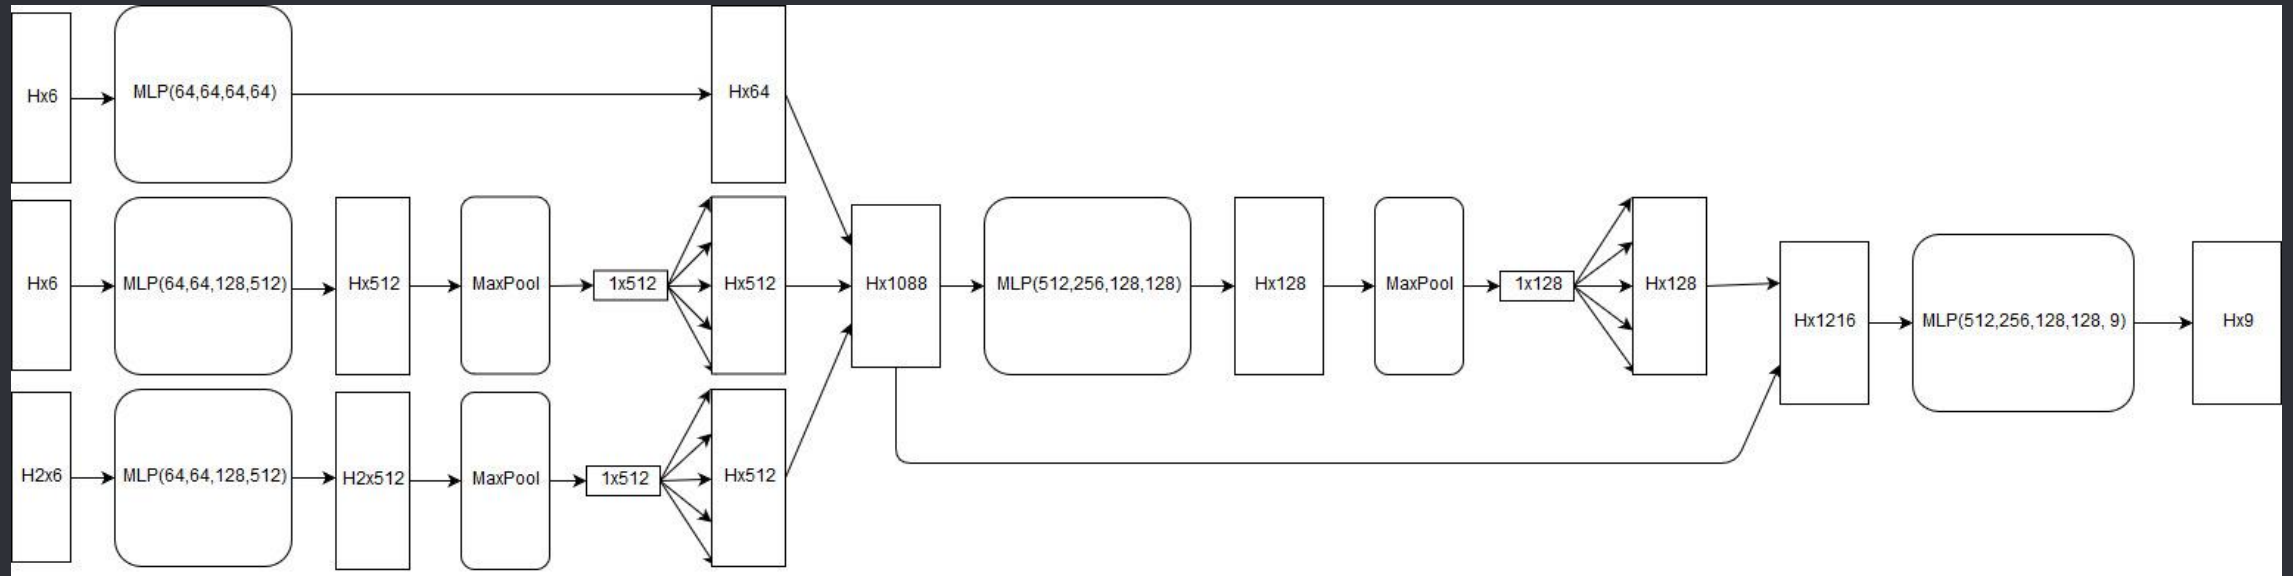


konwolucje 3D



Jing Huang and Suya You, "Point cloud labeling using 3D Convolutional Neural Network," *2016 23rd International Conference on Pattern Recognition (ICPR)*, Cancun, 2016, pp. 2670-2675

pointnet/poinet ++

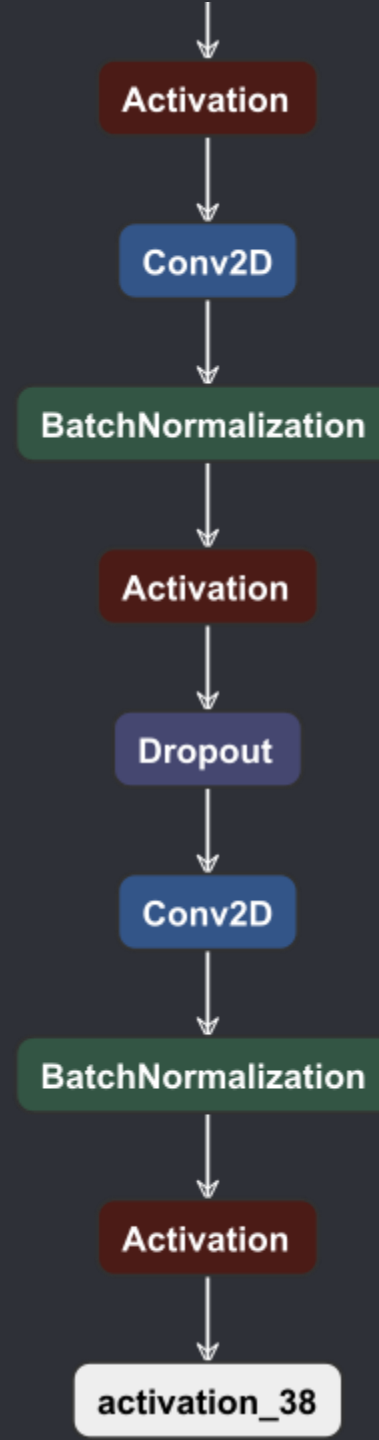


R. Q. Charles, H. Su, M. Kaichun and L. J. Guibas, "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, 2017, pp. 77-85.

Qi, Charles Ruizhongtai et al. "PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space." *NIPS (2017)*.

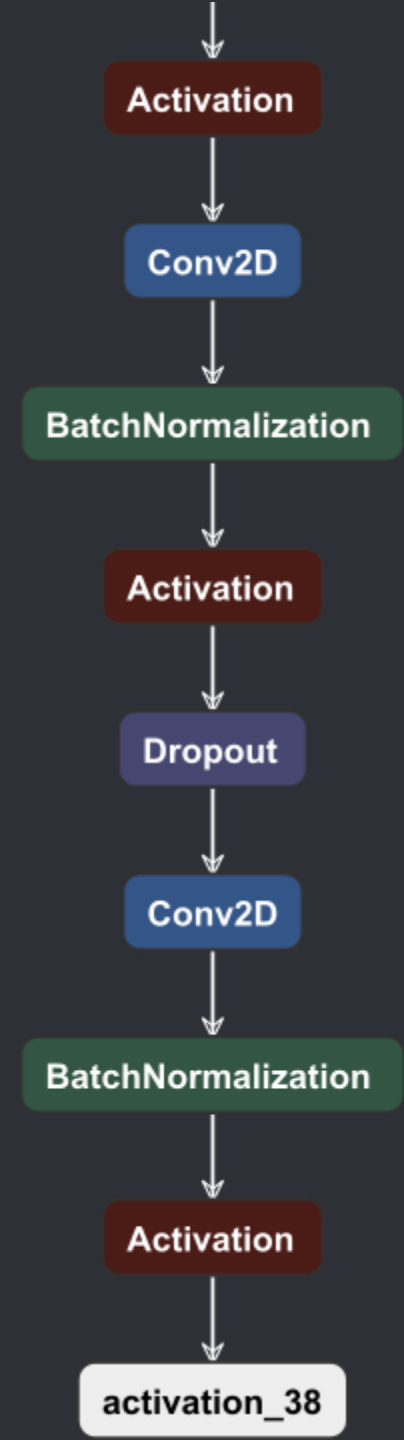
klasyfikacja – przykładowe wyniki

	unclass	ground	lveg	mveg	hveg	build	low_point
unclass	36.64%	1.75%	1.15%	24.11%	6.36%	29.99%	0.00%
ground	0.00%	98.38%	1.39%	0.21%	0.01%	0.01%	0.00%
lveg	0.03%	34.97%	63.20%	1.59%	0.04%	0.17%	0.00%
mveg	0.59%	0.14%	1.36%	93.47%	1.61%	2.84%	0.00%
hveg	0.01%	0.00%	0.00%	0.39%	98.14%	1.46%	0.00%
build	0.50%	2.91%	0.95%	1.50%	3.72%	90.41%	0.01%
low_point	0.00%	51.49%	0.00%	0.00%	0.00%	25.00%	23.51%

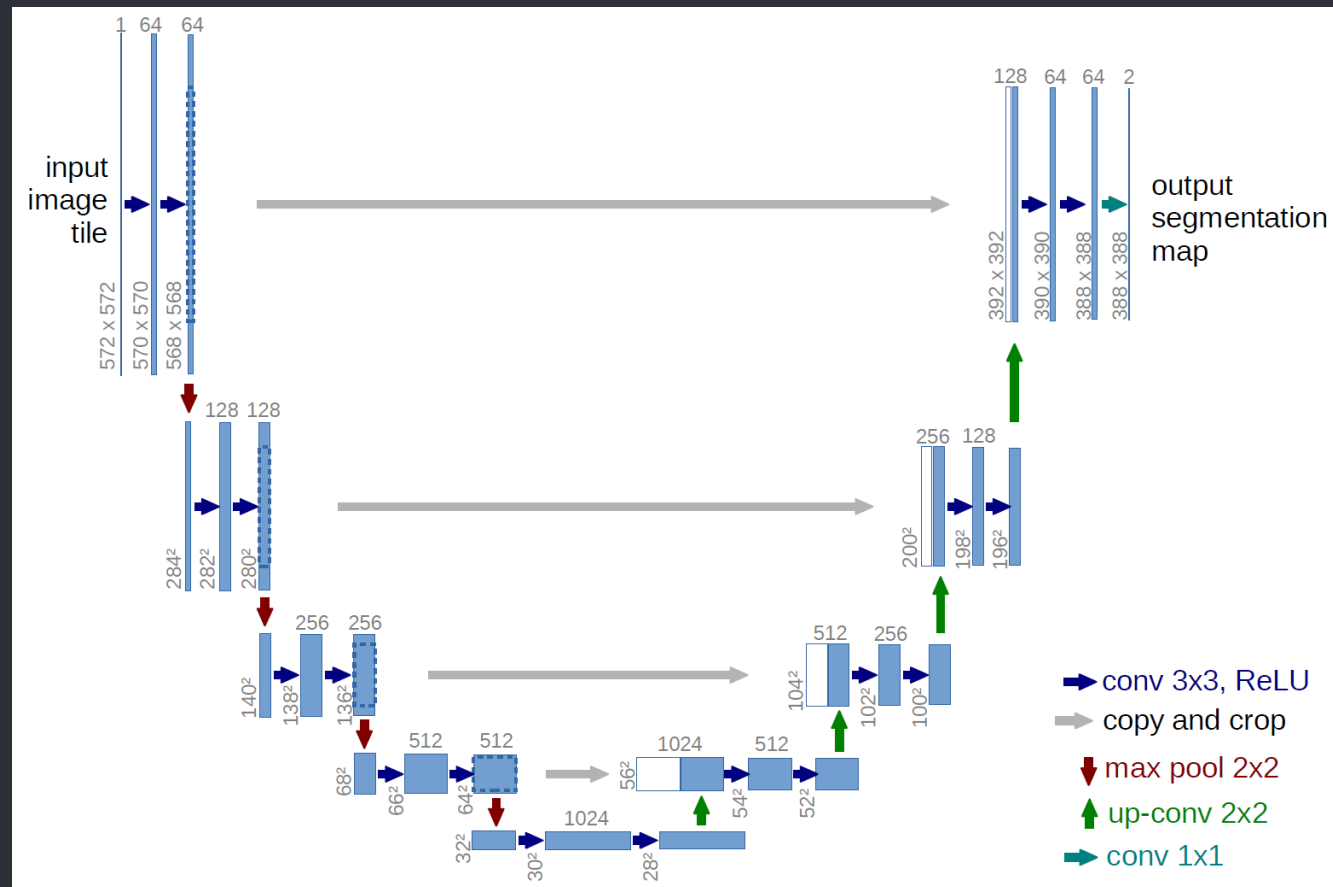


NMT - problemy

- czy zawsze potrzebujemy pełnej klasyfikacji?
- skomplikowanie obliczeniowe w przypadku chmur punktów
- czy możemy generować NMT z chmur punktów praktycznie w czasie rzeczywistym?


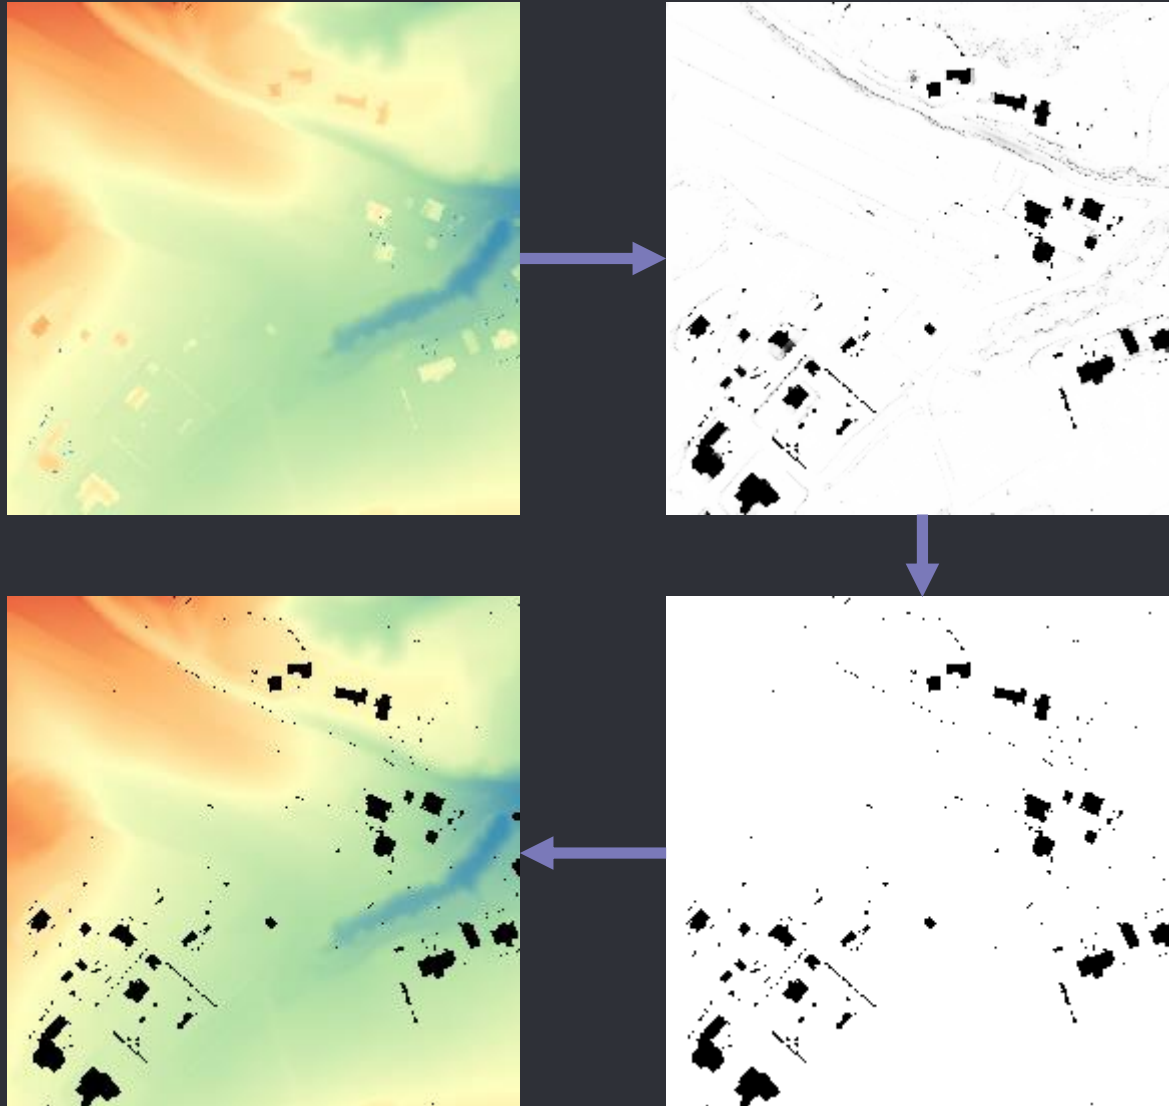


u-net



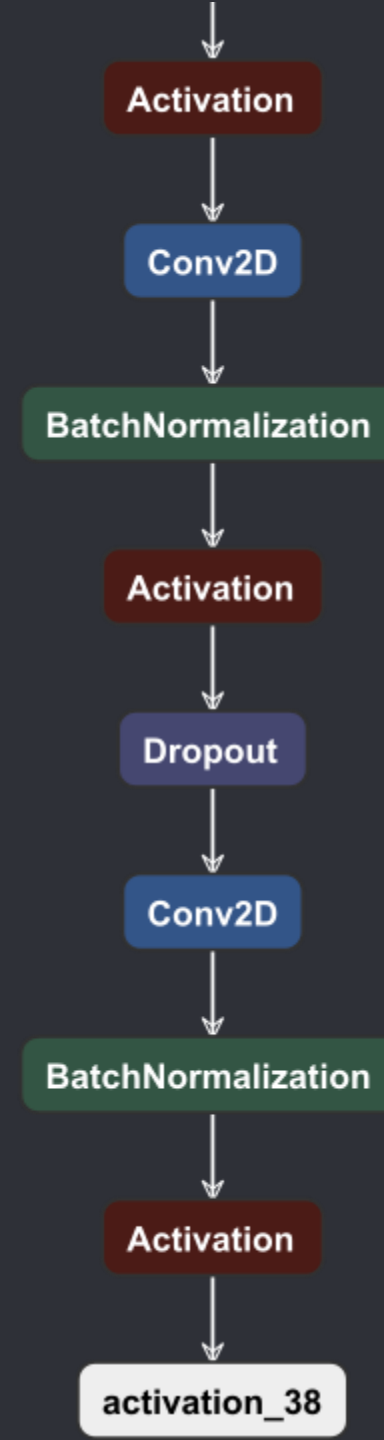
U-Net: Convolutional Networks for Biomedical Image Segmentation; Olaf Ronneberger, Philipp Fischer, Thomas Brox; Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, Vol.9351: 234--241, 2015

NMT – proces generowania

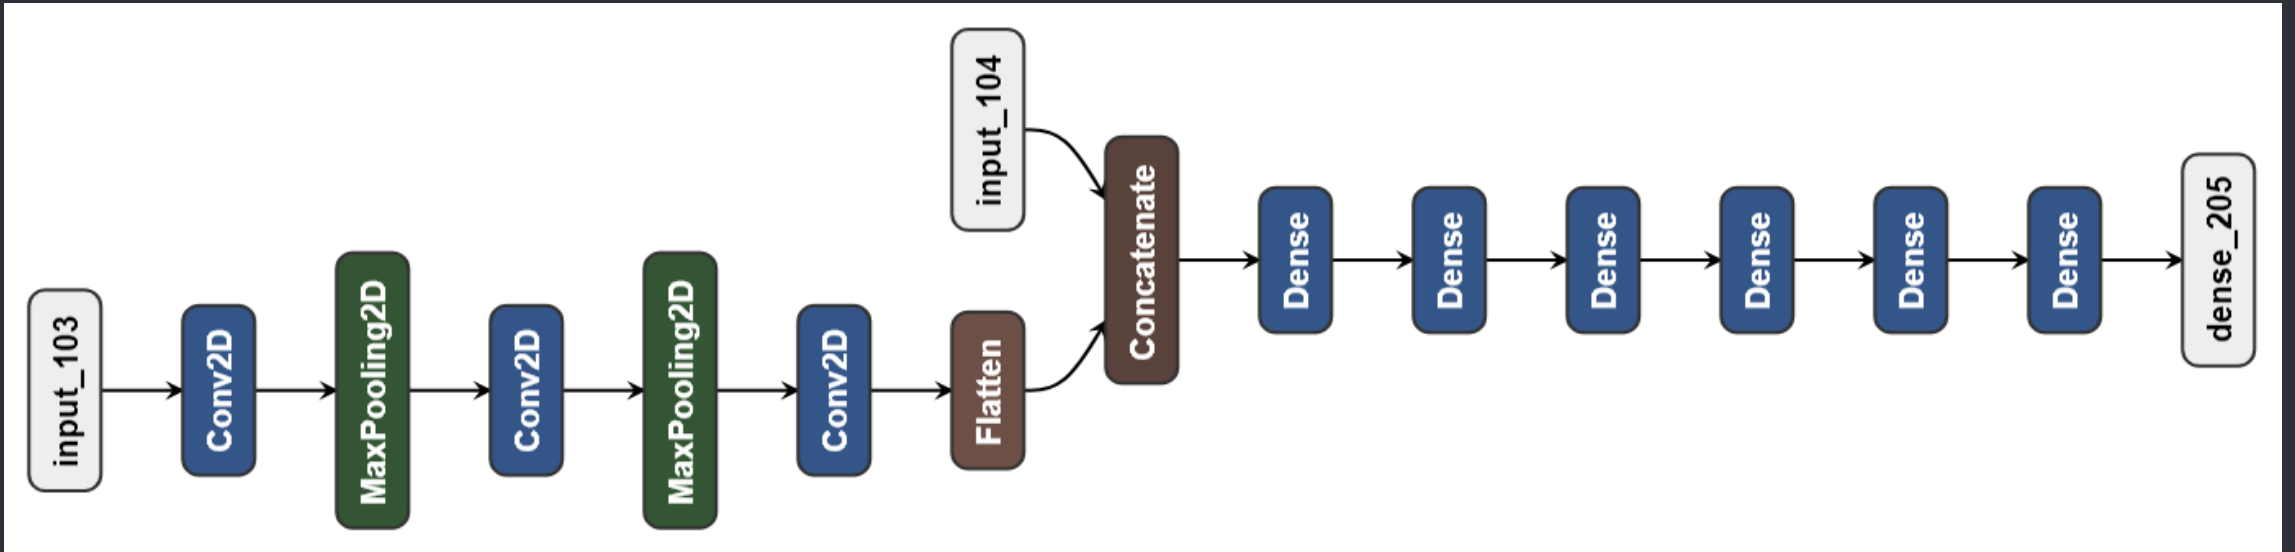


szkody - problemy

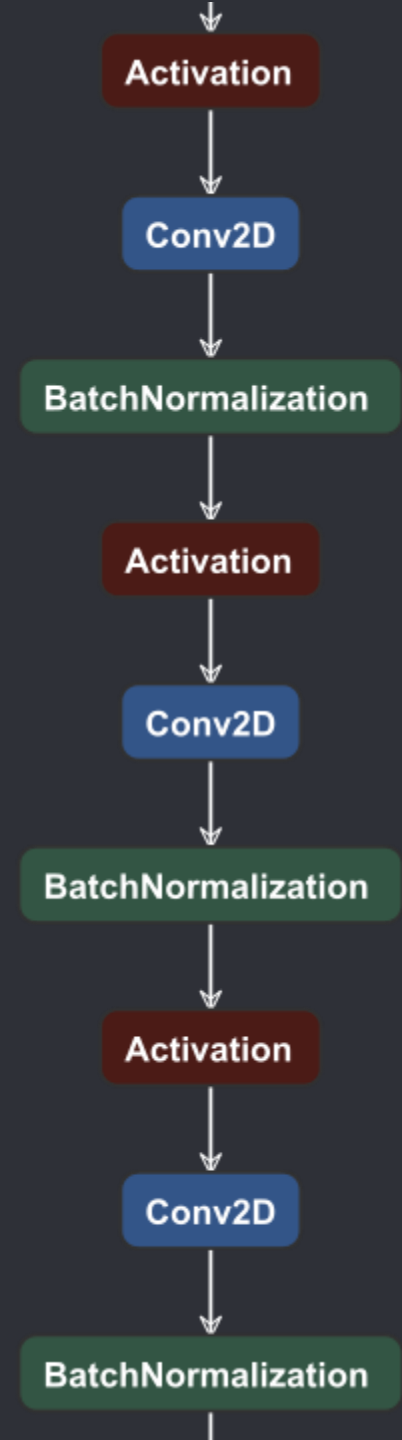
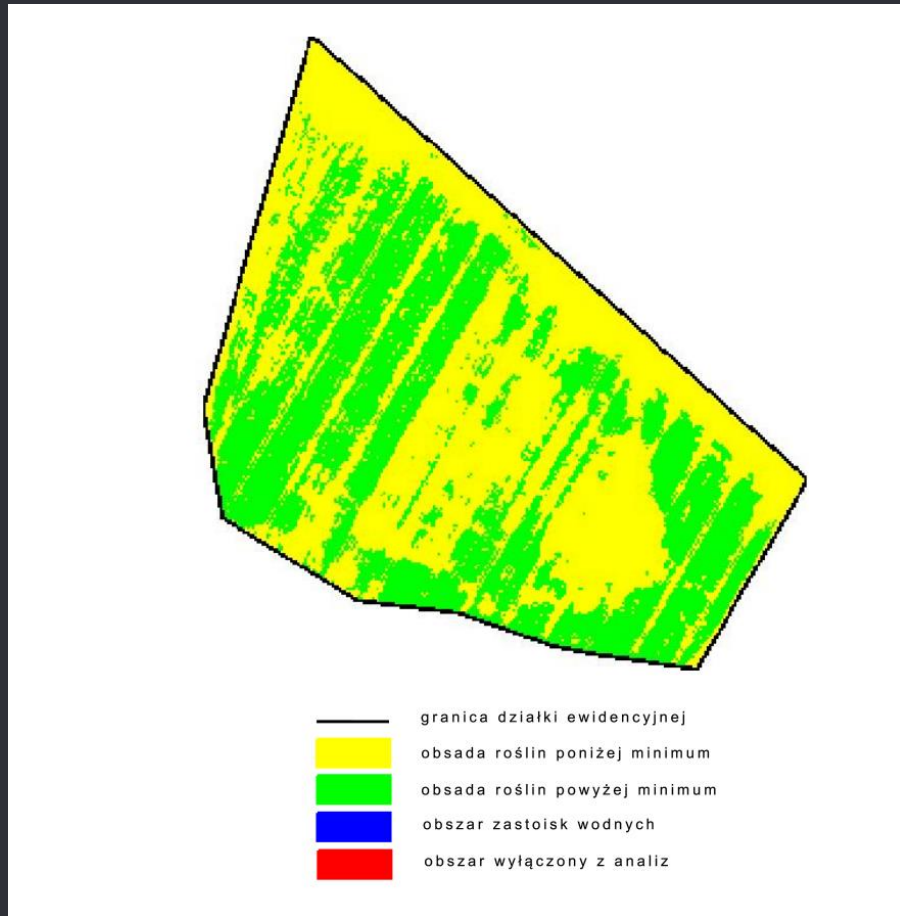
- pojedyncze obserwacje to zbyt mało
- integracja różnych źródeł danych



zasięg szkód złego przezimowania

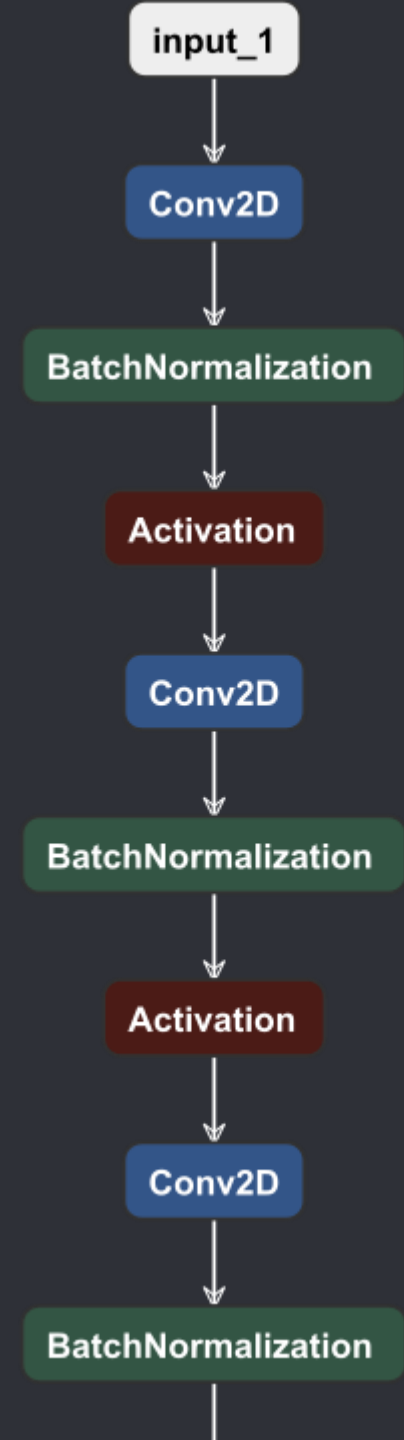


zasięg szkód złego przezimowania

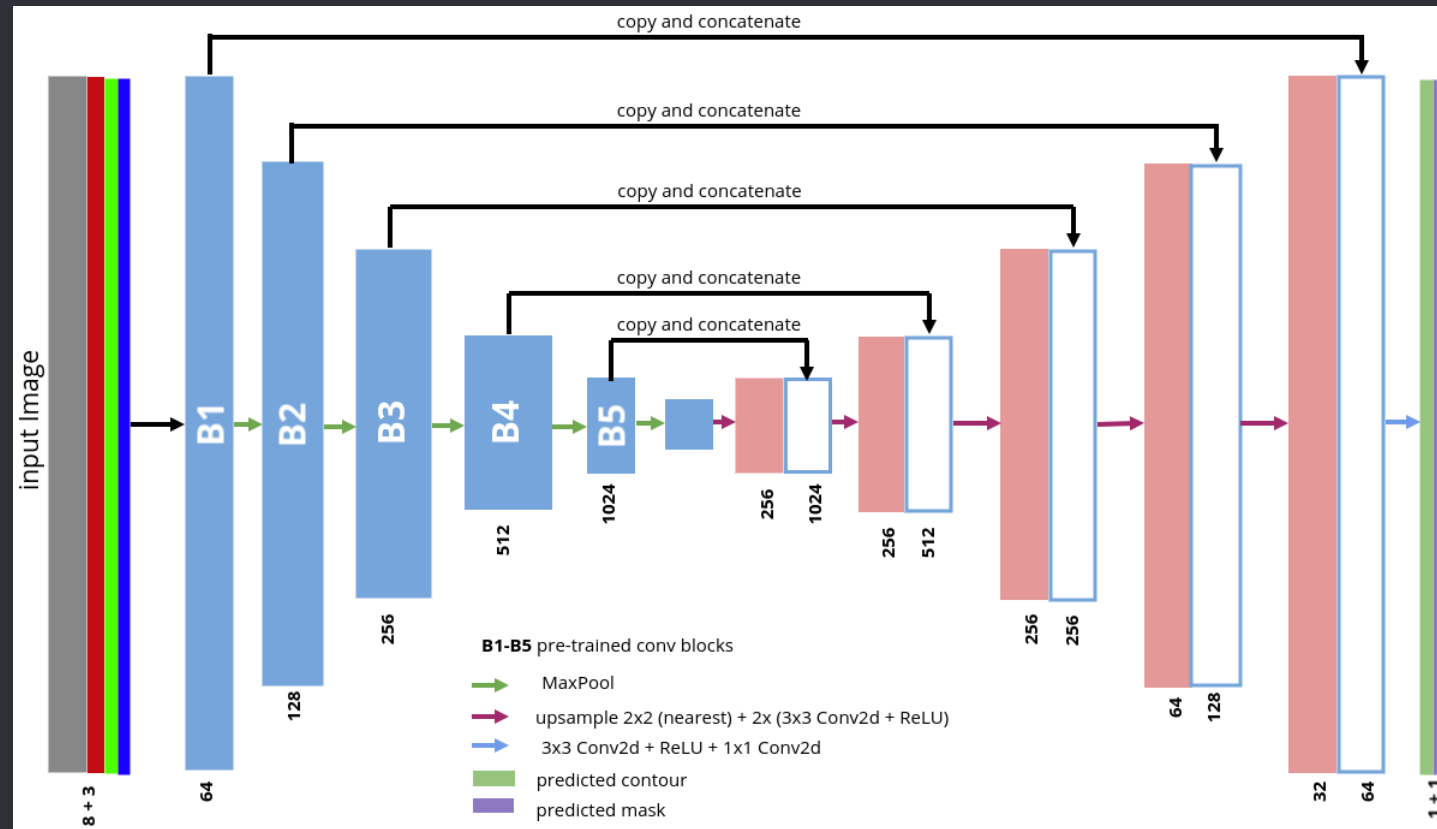


mapy drzew - problemy

- skomplikowanie obliczeniowe
- algorytmy potrzebują dużo pracy manualnej nad dobraniem parametrów

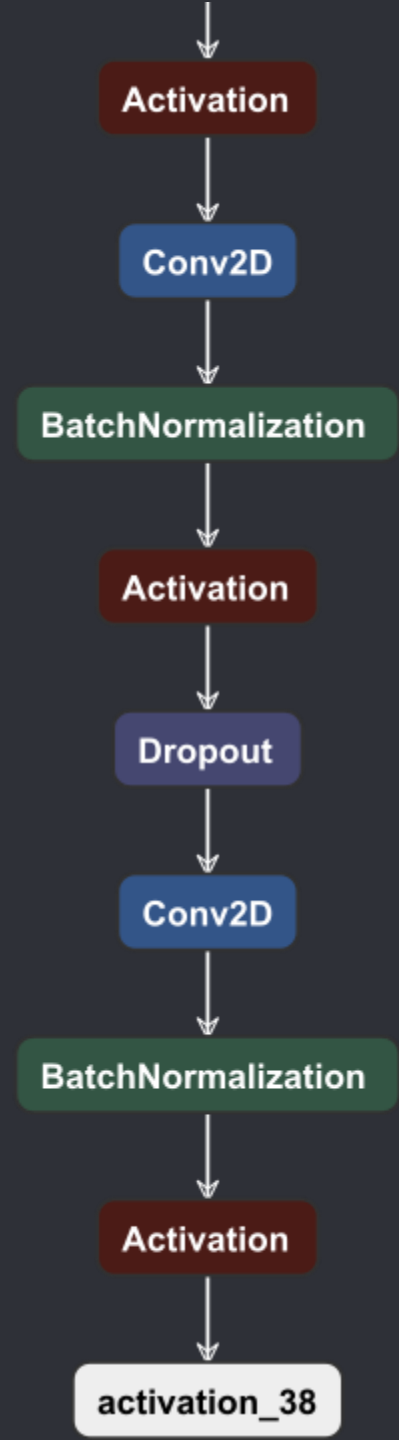


TernausNetV2


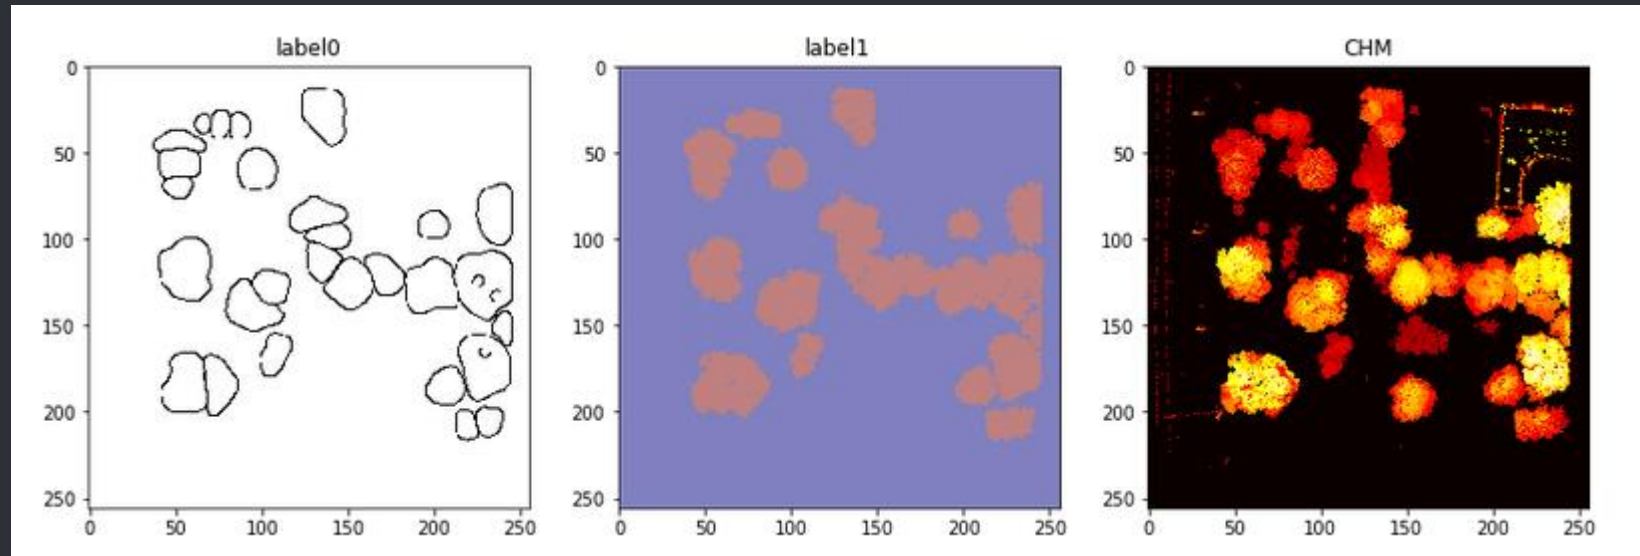


Iglovikov, Vladimir I. et al. "TernausNetV2: Fully Convolutional Network for Instance Segmentation." CoRR abs/1806.00844 (2018): n. pag.


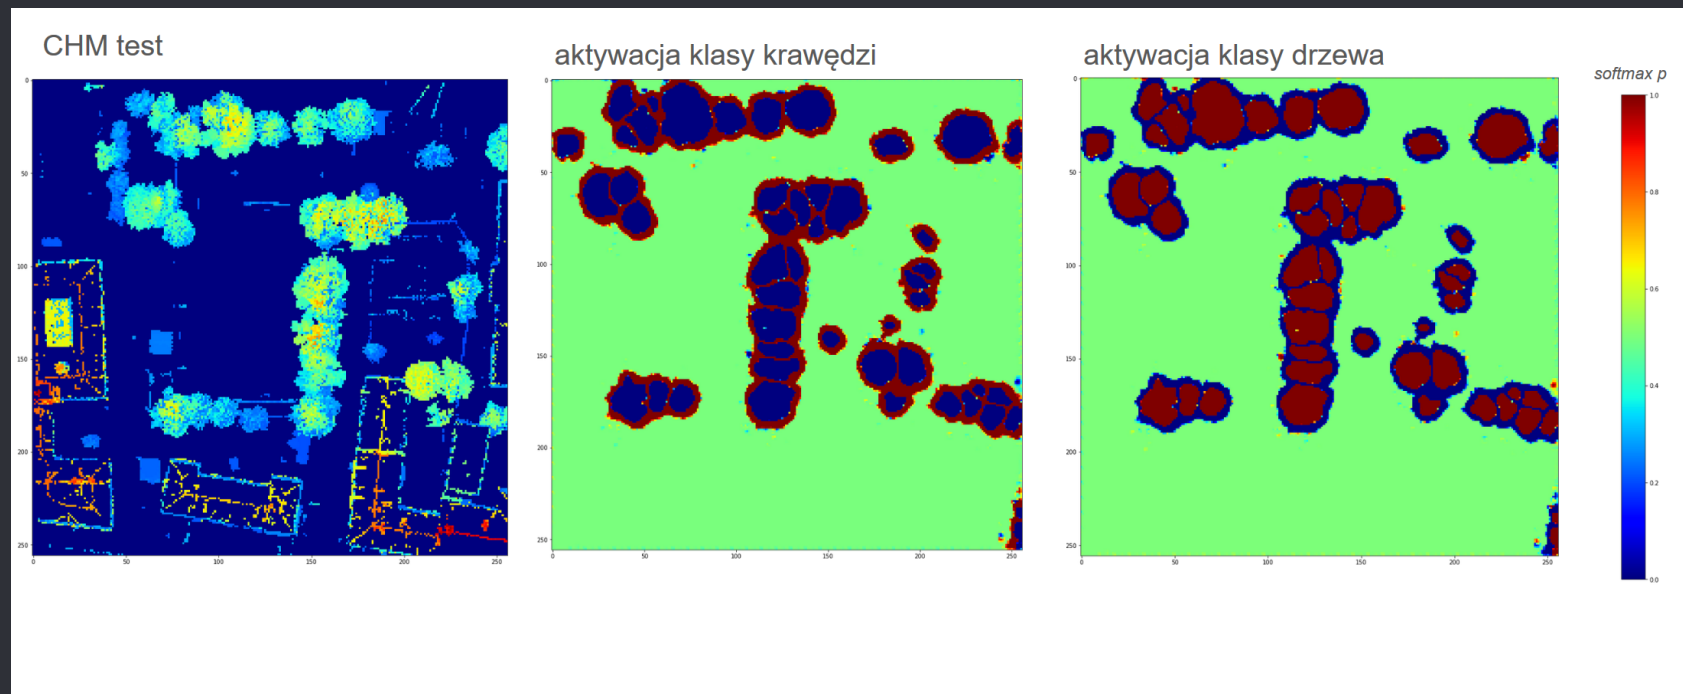
mapy drzew - dane terenowe



mapy drzew – dane uczące




mapy drzew – wynik predykcji



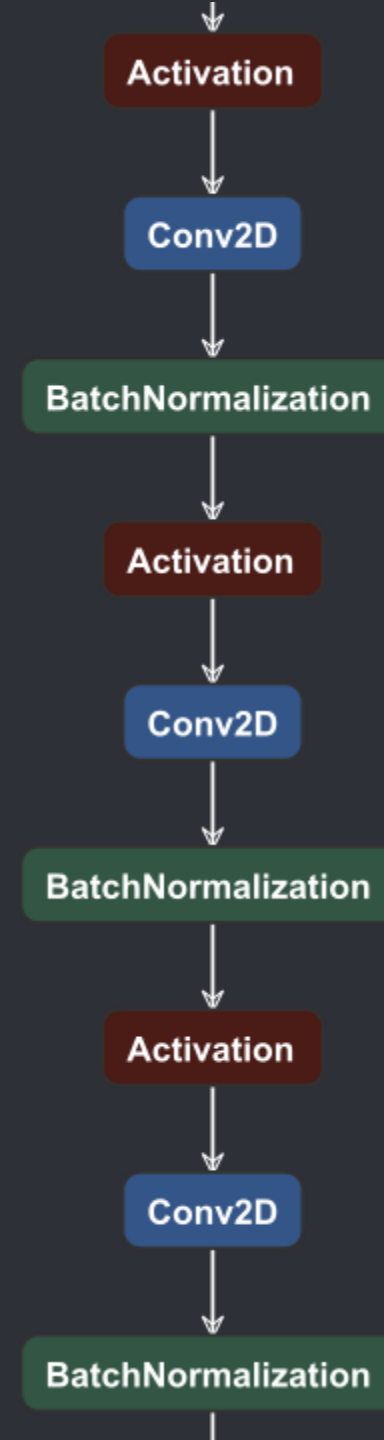
wnioski

- sieci neuronowe to bardzo przydatne narzędzie do analiz danych przestrzennych, zazwyczaj dają wyniki lepsze od standardowych technik
- konieczna odpowiednia infrastruktura
- system do zarządzania eksperymentami




podziękowania

- Opracowanie samouczącej się informatycznej platformy analitycznej wspomagającej proces zarządzania lasami w oparciu o dane obrazowe z kamer fotogrametrycznych oraz chmury punktów multi-spektralnego skanera laserowego RPO Województwa Warmińsko-Mazurskiego na lata 2014-2020, oś priorytetowa 1 inteligentna gospodarka, warmii i mazur
działanie 1.2 innowacyjne firmy
poddziałanie 1.2.1 działalność b+r przedsiębiorstw




podziękowania

- Powszechny Zakład Ubezpieczeń Spółka Akcyjna
- Urząd Miasta w Elblągu



zespół

- Anna Białczak, Gabriela Kuc, Barbara Marcinkowska, Paulina Ściana, Piotr Czubek, Wojciech Dominik, Dominik Mielczarek, Karol Szymański, Adam Wasilewski, Artur Wiosna



Dziękuję za uwagę
jakub.krawczyk@opegieka.pl

