

INFORMACJA O PROPONOWANEJ DO OTWARCIA ROZPRAWIE DOKTORSKIEJ

Metody ekstrakcji cech z danych wielowymiarowych przy użyciu głębokich sieci neuronowych

Doktorant: **mgr inż. Maciej ZAMORSKI**

Promotor: **prof. dr hab. inż. Jerzy ŚWIĄTEK**

Promotor pomocniczy: **dr inż. Maciej ZIĘBA**

Uzasadnienie podjęcia tematu

Zagadnienie ekstrakcji cech z wielowymiarowych danych to ważny i aktywnie rozwijany temat badań w obszarze uczenia maszynowego. Poprawna, niskowymiarowa reprezentacja wysokowymiarowych danych w znacznym stopniu odpowiada za poprawne wyuczone modele uczenia maszynowego [1] i jest jednym z elementów umożliwiających stosowanie sieci głębokich [2, 3]. Hipotetyzuje się [1], że odpowiednio dobrana niskowymiarowa reprezentacja danych umożliwia odkrycie cech objaśniających wysokopoziomowe zależności w danych. Często sytuacją jednak jest posiadanie wyekstrahowanych cech zapisanych jako wektor liczb rzeczywistych, który nie jest w łatwy sposób interpretowalny przez człowieka [1].

Wzrost dostępnych danych oraz zasobów obliczeniowych umożliwia dynamiczny rozwój uczenia maszynowego, w tym zwłaszcza uczenia głębokiego, pozwalając na przetwarzanie i odkrywanie struktur danych nie tylko w ustrukturyzowanych obrazach, ale również w wysoce złożonych danych, takich jak dźwięk, język naturalny, czy modele trójwymiarowe [2]. Szczególny rodzaj modeli trójwymiarowych, chmury punktów, jest istotny z punktu widzenia nauki i inżynierii, gdyż jest on jednym ze standardowych sposobów modelowania rzeczywistości widzianej przez kamery trójwymiarowe, takie jak LiDAR, stosowane w autonomicznych samochodach.

Jednak z powodu nieregularnego formatu w jakich rejestrowane są chmury punktów, ich przetwarzanie stanowi wyzwanie dla tradycyjnych metod uczenia maszynowego i uczenia głębokiego. Jedno z pierwszych podejść [7] stosowanych dla chmur punktów nie poddanych obróbce wstępnej opierało się o klasyczne sieci jednokierunkowe, przy czym obecnie [8] coraz częściej wykorzystuje się podejścia stosujące sieci typu GAN [4] oraz Adversarial [5] Autoencoder lub Variational Autoencoder [6]. Jednak żaden z obecnie zaproponowanych modeli nie bierze pod uwagę interpretowalności cech lub możliwości uproszczenia reprezentacji wykorzystując do tego celu kodowania binarne. Ostatnia cecha jest szczególnie istotna w zastosowaniach takich jak autonomiczne samochody, gdzie dane przetwarzane są w czasie rzeczywistym i szybkość oraz prostota przetwarzania reprezentacji obiektów jest o kluczowym znaczeniu.

Cel rozprawy

Celem rozprawy jest zbudowanie generatywnego modelu typu GAN [4] lub Adversarial Autoencoder [5] z regularyzowaną przestrzenią cech w celu osiągnięcia interpretowalności wydobytych informacji wraz z doбором odpowiedniego dla nich rozkładu danych.

Metodyka badań

Zbudowany model zostanie oceniony dwoma podejściami: wizualnym oraz numerycznym. Ocena wizualna pozwala stwierdzić, czy stworzone przez model chmury punktów i reprezentacji wyglądają poprawnie, co pozwala wyeliminować możliwość tworzenia przez model przypadków zdegenerowanych. Ocena numeryczna dotyczyć będzie przedstawienia jakości działania modelu w zadaniach klasyfikacji, wyszukiwania oraz interpretowalności cech wydobytych z danych.

Zakres rozprawy

1. Wybór zbiorów danych do badań
2. Zbudowanie modelu GAN lub AAE do wyuczania reprezentacji chmur punktów
3. Opracowanie metody optymalizacji prior'a określającego rozkład reprezentacji
4. Zdefiniowanie regularyzacji umożliwiającej interpretowalność otrzymanych cech
5. Przeprowadzenie eksperymentów potwierdzających jakość proponowanego podejścia

Uzyskane wyniki

Dotychczas zaprezentowano możliwość dostosowania modeli typu Bidirectional GAN do problemu uczenia z częściowym nadzorem[9] oraz zastosowania w nim regularyzacji wydobywanych cech, później stosowanych w zadaniach klasyfikacji oraz wyszukiwania. Drugim zaprezentowanym rezultatem jest zastosowanie modelu typu Adversarial Autoencoder dla danych trójwymiarowych[10] opisanych jako chmury punktów, uzyskujących dotychczas najlepsze rezultaty w zakresie generowania, wyszukiwania oraz rekonstrukcji danych.

Literatura

1. Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.
2. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436.
3. Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1). Cambridge: MIT press.
4. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. In *Advances in neural information processing systems* (pp. 2672-2680).
5. Makhzani, A., Shlens, J., Jaitly, N., Goodfellow, I., & Frey, B. (2015). Adversarial autoencoders. *arXiv preprint arXiv:1511.05644*.
6. Kingma, D. P., & Welling, M. (2013). Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*.
7. Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. *Proc. Computer Vision and Pattern Recognition (CVPR), IEEE*, 1(2), 4.
8. Achlioptas, P., Diamanti, O., Mitliagkas, I., & Guibas, L. (2017). Representation learning and adversarial generation of 3D point clouds. *arXiv preprint arXiv:1707.02392*.
9. Zamorski, M., & Zięba, M. (2018). Semi-supervised learning with Bidirectional GANs. *arXiv preprint arXiv:1811.11426*.
10. Zamorski, M., Zięba, M., Nowak, R., Stokowiec, W., & Trzeciński, T. (2018). Adversarial Autoencoders for Generating 3D Point Clouds. *arXiv preprint arXiv:1811.07605*.

mgr inż. Maciej Zamorski