

Prof. dr hab. Włodzisław Duch
Katedra Informatyki Stosowanej i Laboratorium Neurokognitywne
Uniwersytet Mikołaja Kopernika, Toruń

Recenzja osiągnięć naukowych doktora Dariusza Jamróza,
w związku z ubieganiem się o stopień doktora habilitowanego, w dziedzinie
nauk inżyniersko-technicznych, dyscyplinie Informatyka Techniczna i Teleko-
munikacja, opracowana na prośbę Instytutu Biocybernetyki i Inżynierii Biome-
dycznej

Toruń, 5 grudnia 2021

Dr Dariusz Jamróż ukończył studia magisterskie z informatyki na Wydział Matematyki i Fyzyki Uniwersytetu Jagiellońskiego w 1997 roku. Doktorat z nauk technicznych w dyscyplinie informatyka obronił z wyróżnieniem w 2001 roku na podstawie rozprawy: „Wizualizacja obiektów w przestrzeniach wielowymiarowych”. Po ukończeniu doktoratu pracował w Katedrze Automatyki AGH Wydziału Elektrotechniki, Automatyki, Informatyki i Elektroniki jako asystent, a następnie adiunkt. Do 2012 roku zatrudniony był też w Wyższej Szkole Turystyki i Ekologii w Suchej Beskidzkiej, a od 2012 roku jest adiunktem w Katedrze Informatyki Stosowanej AGH. Obecnie ubiega się o stopień doktora habilitowanego na podstawie cyklu 7 publikacji pod wspólnym hasłem „Wprowadzenie wielowymiarowej rzeczywistości wirtualnej oraz metod analizy wielowymiarowych danych wraz z badaniami potwierdzającymi ich skuteczność”.

Wśród siedmiu publikacji przedstawionych jako osiągnięcie habilitacyjne jedna jest w czasopiśmie w pierwszym kwartyle Q1, dwie w Q2, dwie w Q3 i dwie to prace konferencyjne. Sześć z tych publikacji nie ma współautorów. Tylko jedna ma trzech współautorów, których wkład, zgodnie z zamieszczonym oświadczeniem, dotyczył „strony przeróbczej”, a cały wkład od strony informatycznej przypisano dr Jamróżowi. Jedna publikacja jest z roku 2017, dwie z 2018, jedna z 2019 i trzy z 2020.

Tematem przewodnim cyklu artykułów przedstawionych jako osiągnięcie naukowe są metody wizualizacji wielowymiarowych danych: metoda MVR, metoda tuneli obserwacyjnych z perspektywą, i wizualizacja jako kryterium uczenia sieci neuronowych. To bardzo interesujące zagadnienia o potencjalnie ważnych zastosowaniach. Metody wizualizacji danych stano-

Sekretarz
Informatyka Techniczna i Telekomunikacja

09-12-2021

data wpływu

wią obecnie ważną gałąź eksploracyjnej analizy danych. Powstało wiele wyrafinowanych metod tego rodzaju, łatwo dostępnych w toolboxach Matlaba lub w takich narzędziach do uczenia maszynowego jak scikit-learn.

Pierwsza publikacja dr Jamróza dotycząca wizualizacji wielowymiarowych danych z 2017 roku to „The perspective-based observational tunnels method: A new method of multidimensional data visualization”, w czasopiśmie *Information Visualization*. Jest to wersja metody opisanej w jego doktoracie w 2001 roku, rozszerzona o zastosowanie perspektywy, czyli wybór punktu z którego obserwowane są odległości w wielowymiarowej przestrzeni. Jest to więc prosta metoda projekcyjna uwzględniająca perspektywę. Efekty związane ze zmianą punktu, względem którego dokonywana jest wizualizacja, można osiągnąć w różnych metodach, np. w skalowaniu wymiarowym zależnie od przyjętej miary podobieństwa (stresu) reprezentowane są bardziej wiernie bliskie sobie odległości a mniej dokładnie odległe. W metodzie rozmytej dynamiki symbolicznej (fuzzy symbolic dynamics) ustawia się dwa lub trzy punkty odniesienia względem których tworzona jest nieliniowa mapa w przestrzeni 2D lub 3D.

W omawianej publikacji porównano wizualizacje oparte na projekcji z perspektywą z wizualizacją opartą na kilku znanych metodach: współrzędnych równoległych, ortogonalnych projekcji, PCA, SOM i MDS, analizując 5-wymiarową reprezentację drukowanych znaków zeskanowanego tekstu. Czemu wybrano takie dane? Znacznie ciekawsze porównania można zrobić na standardowej bazie MNIST ręcznie pisanych znaków, dla której jest wiele wyników klasyfikacji jak i wizualizacji. Do porównania nie użyto żadnej z metod redukcji wymiarowości obecnie stosowanych w realnych zagadnieniach, takich jak t-distributed Stochastic Neighbor Embedding (tSNE), Isomap, kernel PCA, różnych wariantów metody locally linear embedding (LLE), UMAP czy wielu innych metod używanych do wizualizacji złożonych danych, dostępnych w postaci łatwych do użycia programów w Pythonie np. na stronie scikit-learn. Są tam przykłady mapowania obrazów cyfr z 64 wymiarów za pomocą tych metod. W publikacji dr Jamróza analizowano też próbki węgla, ale nie ma w niej wyników klasyfikacji, jedynie ocena liczby punktów przegięcia krzywych po redukcji wymiarów danych do dwóch. Nie bardzo wiadomo do czego taka metoda miałaby służyć.

Druga publikacja na ten sam temat to „Multidimensional virtual reality-MVR method: a new method of visualization of multidimensional worlds” z czasopisma *The Visual Computer*

z 2019 roku. W odróżnieniu od metod wizualizacji wielowymiarowych danych celem jest wizualizacja wielowymiarowej rzeczywistości, w której zanurzone są obiekty rozciągłe, a nie chmury punktów. To ciekawy pomysł, który może znaleźć zastosowania praktyczne w grach komputerowych. W pracy zdefiniowane są wypukłe bryły i oceniana jest jasność projekcji ścian tych obiektów na płaszczyznę obserwacji, oraz współczynniki mające określać perspektywę. Testy przeprowadzono na grupie 97 studentów, których zadaniem było szukanie wyjścia z 4 lub 5-wymiarowego labiryntu. Dodanie informacji na temat perspektywy zwiększa szansę na znalezienie drogi wyjścia z labiryntu, czego należy się spodziewać. Trudno jest uznać jednak ten artykuł za istotne osiągnięcie z punktu widzenia informatyki.

Artykuł z 2020 roku w czasopiśmie „Knowledge and Information Systems” testował różne pomysły uczenia sieci autoasocjacyjnej, w której wewnętrzna warstwa miała tylko dwa neurony. Jeśli używać takich sieci jako autoenkoderów, wymagając odtworzenia informacji wejściowej na wyjściu, to można je wykorzystać do wizualizacji. Artykuł porównuje tak otrzymane wyniki do sieci, które mają jeden neuron wyjściowy, dwa reprezentujące dwie klasy, jeden reprezentujący dwie klasy i jeden, który ma się nauczyć przypadkowych wartości przypisanych wejściowym danym. Wykreślenie aktywacji dwóch neuronów dla wielowymiarowych danych wejściowych pozwala na wizualizację wyników. Porównanie jakości wizualizacji oparte tu na ocenie, czy przypadkowo wybrana klasa daje się oddzielić w wyniku takiej wizualizacji od pozostałych. Nie jest to żadne nowe kryterium uczenia sieci neuronowych. Problem z taką oceną wyników polega na tym, że wyniki trudno odnieść do innych publikacji, które używają standardowych metod oceny. Dla dyskretnych danych niektóre klasy czasami dają się oddzielić od reszty, ale nic z tego nie wynika dla oceny samej metody wizualizacji. Przypadkowe wartości przypisane do różnych próbek dadzą oczywiście najgorsze wyniki. Autoenkodery można uczyć na wiele sposobów, więc nie można z przedstawionych wyników wyciągnąć jednoznacznych wniosków dotyczących różnych metod wizualizacji. Porównanie wyników oparte na jakości klasyfikacji po redukcji wymiarowości można było łatwo zrobić metodą jedna klasa vs. pozostałe dla każdego zbioru, zamiast wybierać w przypadkowy sposób jedną z klas. Jest wiele ciekawych metod wizualizacji, takich jak zastosowanie metody SVM do wizualizacji i redukcji wymiarowości danych, czy różnych publikacji opartych na metodzie szukania projekcji (projection pursuit) i ocenie jakości rzutowanych klastrów, które dały by w tym przypadku dobre wyniki.

Jedną z metod stosowanych do porównania wizualizacji wielowymiarowych danych były mapy Kohonena, nazywane też samoorganizującymi się sieciami SOM. W publikacji z 2020 w *Neural Computing and Applications* dr Jamróz opisał eksperymenty oceniające jakość wizualizacji map SOM i sieci autoasocjacyjnych w zastosowaniu do oceny podatności różnego rodzaju próbek węgla na fluidalne zgazowanie. Te dane używane były w wielu jego publikacjach. Praca jest bardzo podobna do poprzednich, jest tu ranking kilku używanych od dawna metod zastosowanych do 7-wymiarowych danych, ale nie metod najnowszych i szeroko obecnie stosowanych. Praktyczne zastosowanie takiej wizualizacji jest wątpliwe. W szczególności bez krosswalidacji nie wiadomo jak można zastosować takie metody do klasyfikacji, jak na mapach stworzonych na podzbiorze danych umieszczone zostaną nowe próbki.

Praca nr 5 na liście osiągnięć jest nieco okrojona, konferencyjną wersją publikacji omówionej powyżej. Praca nr 6 jest też pracą konferencyjną i jedyna różnica to zastosowanie sześciu opisanych metod wizualizacji do danych fraktalnych. Widzimy więc wizualizację 5-wymiarowego fraktala, ale nie bardzo wiadomo co z tego ma wynikać. Takie dane można wrzucić do scikit-learn i otrzymać jeszcze 10 kolejnych obrazków.

Mamy więc 6 prac, które z punktu widzenia używanych algorytmów niewiele się od siebie różnią, wszystkie dotyczą prostej metody projekcji w zastosowaniu do wizualizacji danych 4-7-wymiarowych. Z punktu widzenia informatyki metoda tuneli obserwacyjnych jest trywialna a zaprezentowane wyniki nie uzasadniają jej wyższości nad innymi.

W ostatniej publikacji z listy osiągnięć w czasopiśmie „Applied Sciences” z 2020 roku dr Jamróz przy współpracy trzech osób zajął się analizą danych procesu flotacji rud miedzi opisanych za pomocą 5 parametrów odnoszących się do rodzaju rudy, wielkości drobin i parametrów flotacji, oraz 3 parametrów oceniających rezultaty zawartości miedzi w produktach tego procesu. Najpierw utworzono sieć neuronową, która mapowała 5 parametrów wejściowych na 3 wyjściowe, takie jak koncentracja miedzi w otrzymanym koncentracie, w oparciu o rzeczywiste dane pomiarowe. Następnie zmieniano parametry wyjściowe poszukując optymalnych wartości pozwalających zmaksymalizować kombinację parametrów wyjściowych, minimalizując różnice jednego z nich względem sumy pozostałych dwóch parametrów. Model budowano w oparciu o testy wykonane na dwóch maszynach, na jednej było ich 72, a na drugiej tylko 12. Model powinien uwzględniać więcej parametrów wejściowych, ale nie wszystkie dają się mierzyć.

To proste zastosowanie znanych metod nie zostało niestety przeprowadzone poprawnie. Jest wiele dobrych narzędzi do tworzenia modeli neuronowych jak i algorytmów genetycznych, po co więc było tworzyć własne oprogramowanie w C++? Uzasadnienie wyboru architektury sieci nie można oprzeć na twierdzeniu, że więcej neuronów zbyt wolno się uczyło. Sieć neuronowa składająca się z 4 warstw po 50 neuronów i warstwy wyjściowej uczona była na całych dostępnych danych i mogła się łatwo przeuczyć, ale nie wspomniano nic o walidacji modelu. To elementarny błąd, tak utworzony model nie ma wartości. Rys. 3 z tej pracy pokazuje jakieś krzywe, ale nie ma oznaczeń na osiach i nie wiadomo co te krzywe znaczą. Tabela 8 pokazuje zbieżność 3 wartości na wyjściu sieci neuronowych w zależności od liczby iteracji. Jaki sens ma łączenie wartości całkiem różnych parametrów prostymi liniami? Z punktu widzenia metodologii analizy danych ta praca nie powinna zostać opublikowana, a przyjęta została po miesiącu od złożenia – niedobrze to świadczy o jakości czasopisma.

Nie wspomniano nigdzie o dostępności oprogramowania pozwalającego na wizualizację wielowymiarowych danych za pomocą metody MVR – wystarczy kilka linijek w Matlabie. Dostępność oprogramowania pozwalającego na niezależną ocenę jest w dzisiejszych czasach standardem w informatyce.

Pozostały dorobek nie wchodzący w skład omawianego cyklu prac to 12 publikacji w czasopismach, którym przypisano nie więcej niż 25 punktów. Większość z nich jest czasopiśmie Politechniki Wrocławskiej „Physicochemical Problems of Mineral Processing” związanych z konferencją geologów. Informatyka techniczna nie jest dyscypliną przypisaną do tego czasopisma, chociaż należy uznać, że zastosowania metod klasyfikacji do analizy próbek węgla można tu autorom zaliczyć. 10 z tych publikacji jest współautorskich i dotyczy zastosowań metod informatyki.

Habilitant nie odbył żadnego naukowego stażu za granicą, a w tej dyscyplinie jest to pewien standard. Liczba cytowań wszystkich publikacji wg Web of Science przy końcu listopada 2021 wynosi 162, bez autocytowań 56. Jak na 20 lat pracy po doktoracie to naprawdę niskie wskaźniki. Czynniki Hirscha według Scopus z wyłączeniem autocytowań wynosi 5, a Web of Science wynosi 8, ale z autocytowaniami. Sprawdziłem cytowania publikacji za pomocą Google Scholar, gdzie można znaleźć również cytowania w pracach konferencyjnych. Najczęściej cytowana była praca „Application of multidimensional data visualization by means of self-organizing Kohonen maps to evaluate classification possibilities of various coal ty-

pes; Archives of Mining Sciences, 2015, ale tylko jedno cytowanie pochodziło z publikacji zagranicznych autorów. Podobnie było z innymi publikacjami.

To są niestety bardzo słabe wyniki. O ile same cytowania mogą być w wąskich specjalnościach niskie to pozostałą aktywność trudno jest uznać za wystarczającą. Mamy tu udział w Komitecie zaledwie jednej konferencji, CCIE 2021 w Chinach (żadnej krajowej). Na stronie tej konferencji (<http://www.ccieconf.com/Committee.html>) nie ma jednak wśród członków komitetu nazwiska dr Jamróza, nie jest to też konferencja wymieniona na liście MEiN. Recenzje dla 3 czasopism, udział w dwóch grantach badawczych, brak kierowania własnym grantem, dwa zlecenia wewnętrzne z innych Katedr AGH, to nie są osiągnięcia wystarczające by zostać doktorem habilitowanym tak dobrej uczelni badawczej, jaką jest AGH. Brakuje również konkretnych osiągnięć dydaktycznych. Ogólnikowe stwierdzenie „Był promotorem oraz recenzentem prac dyplomowych” wskazuje na brak opieki nad magistrantami, nie mówiąc o byciu promotorem pomocniczym jakiegoś doktoratu. Działalność organizacyjna sprowadzała się do bycia członkiem Wydziałowej Komisji Rekrutacyjnej i Komisji Wyborczej.

Podsumowując, przedstawiony mi materiał dotyczący osiągnięć naukowych, dydaktycznych i organizacyjnych nie jest w mojej opinii wystarczający, by spełnić wymagania ustawowe, zawarte w art. 219 Ustawy „Prawo o szkolnictwie wyższym i nauce”, jak i wymagania zwyczajowe dotyczące nadania stopnia doktora habilitowanego.



Toruń, 6.12.2021