

Łódź, dn. 11 lipca 2022 r.

Prof. dr hab. inż. **Anna Fabijańska**
Politechnika Łódzka
Wydział Elektrotechniki, Elektroniki,
Informatyki i Automatyki
Instytut Informatyki Stosowanej
Ul. Stefanowskiego 18
90-537 Łódź

RECENZJA

wniosku w postępowaniu o nadanie
dr. Przemysławowi Spurkowi
stopnia doktora habilitowanego w dziedzinie nauk inżynieryjno-technicznych
w dyscyplinie informatyka techniczna i telekomunikacja

1. Podstawa sporządzenia recenzji

Podstawę opracowania niniejszej recenzji stanowiło pismo Pani dr hab. inż. Agnieszki Mykowieckiej, Zastępcy Dyrektora Instytutu Informatyki Polskiej Akademii Nauk (IPI PAN) z dnia 9 maja 2022 r., wystosowane w związku z Uchwałą nr 3/2022 Rady Naukowej IPI PAN z dnia 20 kwietnia 2022 r., powołującą mnie na recenzenta w postępowaniu o nadanie dr. Przemysławowi Spurkowi stopnia doktora habilitowanego w dziedzinie nauk inżynieryjno-technicznych, w dyscyplinie informatyka techniczna i telekomunikacja.

Recenzja sporządzona została na podstawie przekazanej mi dokumentacji przygotowanej przez Habilitanta, która obejmowała:

- elektroniczną wersję wniosku o przeprowadzenie postępowania habilitacyjnego,
- dane wnioskodawcy,
- kopię dokumentu potwierdzającego posiadanie stopnia doktora,
- autoreferat,
- wykaz osiągnięć naukowych,
- oświadczenia współautorów publikacji,
- kopie prac składających się na cykl publikacji stanowiących osiągnięcie naukowe,
- dokumenty potwierdzające istotną działalność naukową,
- dokument potwierdzający przyjęcie do druku pracy A9, wchodzącej w skład osiągnięcia.

2. Sylwetka habilitanta

Pan dr Przemysław Spurek ukończył w 2009 roku studia magisterskie na Wydziale Matematyki i Informatyki Uniwersytetu Jagiellońskiego, uzyskując tytuł zawodowy magistra. Od roku 2013 jest związany z tym wydziałem zawodowo, gdzie aktualnie pracuje na stanowisku adiunkta (od marca 2015 roku). Stopień doktora nauk matematycznych w dyscyplinie informatyka dr Przemysław Spurek uzyskał na macierzystym wydziale w czerwcu 2014 roku, po

przedłożeniu i obronie rozprawy nt.: „Kompresja pamięci oparta na zmianie układu współrzędnych”. W okresie po uzyskaniu stopnia doktora, Habilitant skoncentrował się głównie na zagadnieniach związanych z szeroko pojętym uczeniem maszynowym, w szczególności pracując nad rozwojem i zastosowaniem metod klasteryzacji danych oraz, w ostatnim czasie, zastosowań uczenia głębokiego. Kandydat konsekwentnie działa więc naukowo w obszarach tematycznych zaliczanych do m.in. dyscypliny informatyka techniczna i telekomunikacja, w której ubiega się o stopień doktora habilitowanego.

Pan dr Przemysław Suprek jest autorem bądź współautorem 44 publikacji zaindeksowanych w bazie Scopus, z czego 23 to artykuły w czasopismach, w tym 18 w czasopismach posiadających IF (*Expert Systems With Applications, Information Sciences, Neurocomputing, Pattern Analysis and Applications, Pattern Recognition, Aequationes Mathematicae, Computer Vision and Image Understanding, IEEE Access, IEEE Transactions on Pattern Analysis and Machine Intelligence, Journal of Machine Learning Research, Knowledge Based Systems, Pattern Recognition Letters, PLoS One*). Warto również zwrócić uwagę na zauważalną aktywność publikacyjną dra Przemysława Spurka również w okresie po złożeniu wniosku o przeprowadzenie postępowania o nadanie stopnia doktora habilitowanego. Wg. bazy Scopus prace dra Przemysława Spurka były cytowane łącznie 271 razy, a wskaźnik Hirsha Habilitanta wynosi 8. Zdecydowana większość tych prac wpisuje się w obszar tematyczny *computer science*. Ponadto, dr Przemysław Spurek uczestniczy lub uczestniczył w realizacji dziesięciu projektów finansowanych ze środków krajowych przez NCN (7 projektów), NCBiR, FNP oraz POIG. W trzech projektach finansowanych przez NCN pełnił rolę kierownika.

W ramach działalności dydaktycznej Pan dr Przemysław Spurek prowadził trzy autorskie wykłady związane m.in. z obszarem swojej aktywności naukowej (podstawy sztucznej inteligencji, p grafiki i muzyki, ruby on rRails) oraz szereg zajęć laboratoryjnych i ćwiczeniowych z dziedziny informatyki i matematyki dla studentów kierunku informatyka. Wypromował 15 magistrów. Jest też promotorem pomocniczym dwóch doktorantów.

3. Stwierdzenie spełnienia przesłanki, o której mowa w art. 219 ust. 1, pkt. 1 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce dotyczącej posiadania stopnia doktora

Pan Przemysław Spurek posiada stopień doktora nauk matematycznych w zakresie informatyki, który uzyskał 26 czerwca 2014 r. na Wydziale Matematyki i Informatyki Uniwersytetu Jagiellońskiego w Krakowie. Kopia dyplomu stanowi załącznik do recenzowanego wniosku.

4. Ocena osiągnięcia naukowego wskazanego przez Habilitanta zgodnie z art. 219 ust. 1 pkt. 2 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce

4.1. Temat i publikacje wchodzące w skład osiągnięcia

Jako osiągnięcie naukowe wynikające z art. 219, pkt. 2 Ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce Pan dr Przemysław Spurek przedstawił cykl powiązanych tematycznie artykułów naukowych w czasopismach naukowych lub w recenzowanych materiałach z konferencji międzynarodowych nt.: **Uczenie reprezentacji w metodach**

nienadzorowanych. Na cykl ten składa się 10 artykułów naukowych opublikowanych w latach 2014-2021, czyli w okresie po uzyskaniu przez Habilitanta stopnia doktora.

W skład ww. cyklu publikacji wchodzi następujące artykuły naukowe (w nawiasach podano deklarowany wkład Habilitanta w powstanie poszczególnych publikacji, potwierdzony oświadczeniami współautorów załączonymi do recenzowanego wniosku):

- [A1] Jacek Tabor, **Przemysław Spurek (50%)**, *Cross-Entropy Clustering*, Pattern Recognition 47, 3046–3059, 2014. (MEiN₂₀₂₁: 140 pkt., **IF: 7.74**)
- [A2] **Przemysław Spurek (60%)**, Jacek Tabor, Krzysztof Byrski, *Active Function Cross Entropy Clustering*, Expert Systems with Applications 72, 49–66, 2017. (MEiN₂₀₂₁: 140 pkt., **IF: 6.954**)
- [A3] **Przemysław Spurek (50%)**, Jacek Tabor, Krzysztof Byrski, *Online updating of active function cross-entropy clustering*, Pattern Analysis Applications 22 (4), 1409–1425, 2019. (MEiN₂₀₂₁: 70, **IF: 2.580**)
- [A4] **Przemysław Spurek (80%)**, Wiesław Pałka, *Clustering of Gaussian distributions*, International Joint Conference on Neural Networks (IJCNN) 22 (4), 3346–3353, 2016. (MEiN₂₀₂₁: 140, Core rank: A).
- [A5] **Przemysław Spurek (100%)**, *General split gaussian Cross-Entropy clustering* Expert Systems with Applications 68, 58–68, 2017. (MEiN₂₀₂₁: 140, **IF: 6.954**)
- [A6] **Przemysław Spurek (60%)**, Jacek Tabor, Przemysław Rola, Michał Ociepka. *ICA based on asymmetry* Pattern Recognition 67, 230–244, 2017. (MEiN₂₀₂₁: 140, **IF: 7.74**)
- [A7] Szymon Knop, **Przemysław Spurek (30%)**, Jacek Tabor, Igor Podolak, Marcin Mazur, Stanisław Jastrzebski. *Cramer-wold autoencoder* Journal of Machine Learning Research (JMLR) 21, 1-28 2020 (MEiN₂₀₂₁: 140, **IF: 3.989**)
- [A8] **Przemysław Spurek (50%)**, Szymon Winczowski, Jacek Tabor, Maciej Zamorski, Maciej Zieba, Tomasz Trzcinski *Hypernetwork approach to generating point clouds*, International Conference on Machine Learning (ICML) 2020:119, 9099–9108, 2020. (MEiN₂₀₂₁: 200, Core rank: A*).
- [A9] **Przemysław Spurek (40%)**, Maciej Zieba, Jacek Tabor, Tomasz Trzcinski *General hypernetwork framework for creating 3D point clouds*. IEEE Transactions on Pattern Analysis and Machine Intelligence, doi: 10.1109/TPAMI. (MEiN₂₀₂₁: 200, **IF: 16.389**)
- [A10] Tomasz Danel, **Przemysław Spurek (30%)**, Jacek Tabor, Marek Smieja, Łukasz Struski, Agnieszka Słowik, Łukasz Maziarka. *Spatial Graph Convolutional Networks*. International Conference on Neural Information Processing (ICNIP) 2020. (MEiN₂₀₂₁: 140, Core rank: A).

4.2. Charakterystyka ilościowa osiągnięcia

Skład publikacji przedstawionych przez Habilitanta do oceny w ramach powiązanego tematycznie cyklu kształtuje się więc następująco:

- 7 artykułów w czasopismach posiadających współczynnik IF i uwzględnionych w bazie Journal Citation Reports (JCR);
- 3 referaty na konferencjach międzynarodowych uwzględnionych w bazie CORE Conference Ranking i posiadających rankingi A* (1 artykuł) oraz A (2 artykuły).

Zgodnie z informacją zawartą we wniosku, sumaryczny współczynnik *impact factor* (IF) publikacji wchodzących w skład osiągnięcia z uwzględnieniem wartości z roku 2020 wynosi 52.340. Wartości współczynnika IF poszczególnych czasopism, w których opublikowano artykuły wchodzące w skład osiągnięcia wahają się w zakresie od 2.580 do 16.389. Sumaryczna liczba punktów MEiN przypisanych do publikacji wchodzących w skład cyklu wynosi 1450, przy czym punktacja poszczególnych prac waha się w zakresie od 70 do 200, osiągając średnią na poziomie 145 punktów.

Od strony bibliometrycznej, ocena przedstawionego przez dra Przemysława Spurka osiągnięcia naukowego **wypada więc bardzo dobrze**. Czasopisma, w których opublikowane zostały prace wchodzące w skład cyklu to wydawnictwa o dużym prestiżu, uznane przez środowisko naukowe (np. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *Pattern Recognition*, *Expert Systems with Applications*). Również, międzynarodowe konferencje na których przedstawiono prace wchodzące w skład cyklu (np. *International Joint Conference on Neural Networks*, *International Conference on Machine Learning*, *International Conference on Neural Information Processing*) mają dużą renomę.

Pan dr Przemysław Spurek jest samodzielnym autorem jednej z publikacji wchodzących w skład cyklu. W pozostałych pracach (mających od dwóch do siedmiu współautorów) Jego zadeklarowany udział waha się w zakresie 30-80%, osiągając średnią na poziomie 50%. W sześciu pracach Habilitant jest pierwszym autorem, a Jego udział jest wiodący. Z załączonych do wniosku oświadczeń wynika, że Habilitant jest autorem przedstawionych w pracach algorytmów (zarówno na poziomie koncepcji, jak i implementacji), lub uczestniczył w opracowaniu zasadniczych koncepcji przedstawionych w pracach algorytmów (np. zdefiniowaniu funkcji kosztu). Umieścił część proponowanych rozwiązań w aktualnym stanie wiedzy. Przeprowadzał samodzielnie, bądź planował eksperymenty. Choć liczba samodzielnich publikacji Habilitanta jest mała, **indywidualny wkład merytoryczny dra Przemysława Spurka w prace wchodzące w skład cyklu jest wiodący, jasno zdefiniowany i nie budzi wątpliwości**.

Tematyka prac wchodzących w skład osiągnięcia naukowego przedstawionego do oceny w ogólnym ujęciu dotyczy uczenia maszynowego i znajdowania reprezentacji danych nieposiadających etykiet. Ten obszar tematyczny zaliczany jest do dyscyplin informatyka i informatyka techniczna i telekomunikacja. Wszystkie prace zamieszczone w cyklu opublikowane zostały w czasopismach lub seriach wydawniczych uwzględnionych w bazie bibliograficznej DBLP indeksującej publikacje z obszaru informatyki. Według bazy Scopus, wszystkie prace zamieszczone w cyklu również należą do obszaru tematycznego *computer science*. Z tego też powodu, **nie budzi wątpliwości przynależność osiągnięcia przedstawionego przez dra Przemysława Spurka do dyscypliny informatyka techniczna i telekomunikacja**, w której prowadzone jest postępowanie o nadanie stopnia doktora habilitowanego.

4.3. Podsumowanie osiągnięcia

W przedstawionym do oceny cyklu artykułów naukowych, Habilitant podejmuje problem znajdowania reprezentacji danych (tj. cech opisujących ich strukturę) w nienadzorowanym uczeniu maszynowym. W szczególności, proponuje różne podejścia, które w ogólnym ujęciu można podzielić na dwie zasadnicze grupy: (i) metody niewykorzystujące sieci neuronowych [A1-A6] oraz (ii) metody wykorzystujące szeroko rozumiane uczenie głębokie [A7-A10]. Taki podział,

z uwzględnieniem czasu powstawania publikacji wchodzących w skład cyklu wpisuje się w trendy naukowe obowiązujące w obszarze uczenia maszynowego.

W pracach z pierwszego obszaru tematycznego [A1-A6] Habilitant podejmuje problem grupowania danych o skomplikowanej strukturze, tj. takich, które w przestrzeni cech tworzą zakrzywione, podłużne, nieliniowe skupienia, zlokalizowane wzdłuż krzywych (a w wyżej wymiarowych przestrzeniach – wzdłuż rozmaitości). W klasycznym podejściu, dokładne grupowanie takich danych wymaga wykorzystania dużej liczby komponentów, najczęściej reprezentowanych przez mieszaninę rozkładów normalnych. Habilitant natomiast proponuje metodę analizy skupień CEC (ang. *Cross-entropy clustering*) [A1], którą konsekwentnie rozwija w kolejnych artykułach, adaptując do krzywoliniowych układów współrzędnych [A2-A4] oraz danych reprezentowanych przez rozkłady niegaussowskie (np. skośne lub posiadające grube ogony) [A5-A6].

W szczególności, algorytm CEC (ang. *Cross-entropy clustering*) przedstawiony w pracy [A1] modyfikuje metodę EM (ang. *Expectation Maximization*) poprzez zastąpienie w funkcji kosztu mieszaniny gęstości rozkładów, maksimum prawdopodobieństwa. W konsekwencji punkt danych trafia do klastra, który maksymalizuje wartość prawdopodobieństwa. Optymalizacja tak zdefiniowanej funkcji straty powoduje naturalną redukcję liczby klastrów. Ponadto, gęstości są niezależne od siebie, więc parametry każdego z klastrów mogą być aproksymowane oddzielnie. Metoda uogólnia się też do rozkładów prawdopodobieństwa innych niż Gaussowskie dzięki uwzględnieniu w funkcji kosztu entropii krzyżowej pomiędzy zbiorem danych, a parametryczną rodziną rozkładów. Do znajdowania minimum funkcji kosztu proponowane jest zastosowanie metody Hartigana z losowym przypisaniem początkowej przynależności do klastrów. Warto odnotowania jest również, że Habilitant udostępnił środowisku naukowemu autorską implementację algorytmu CEC w postaci dedykowanego pakietu w języku R.

Metoda CEC w dalszym ciągu posiada jednak pewne ograniczenia z dopasowaniem do danych leżących wokół wyżej wymiarowych (nieliniowych) rozmaitości. W takim przypadku bowiem do dokładnego opisu danych potrzebnych jest wiele składowych rozkładów normalnych. Aby rozwiązać ten problem, w pracy [A2] Habilitant zaproponował rozwinięcie algorytmu CEC do postaci afCEC (ang. *active function Cross-Entropy Clustering*), który modeluje poszczególne klastry za pomocą nowego rozkładu prawdopodobieństwa, który Autor określa mianem *f*-adapted Gaussian. Rozkład ten uogólnia rozkład normalny do rozkładu rozmaitości reprezentowanej przez funkcję *f*, przez co może zostać wykorzystany do modelowania klastrów danych elipsami w krzywoliniowych układach współrzędnych. W konsekwencji, możliwe jest opisanie danych mniejszą liczbą komponentów o bardziej skomplikowanych kształtach, a poprzez to uzyskanie lepszego dopasowania, aniżeli w przypadku klasycznych algorytmów. Potwierdziły to eksperymenty porównujące metodę afCEC z konkurencyjnymi metodami, takimi jak: k-średnich, GMM, AcaGMM, oraz CEC, przeprowadzone na danych syntetycznych, oraz rzeczywistych (pochodzących z systemu monitorowania turbin wiatrowych). Algorytm afCEC jest efektywny numerycznie i łatwo adaptowalny do przestrzeni wielowymiarowych. Podejście pozwala na modelowanie rozmaitości występujących np. w przypadku chmur punktów 3D. Analogicznie, jak w przypadku algorytmu CEC, pakiet z implementacją algorytmu afCEC jest dostępny dla na otwartej licencji dla środowiska naukowego.

W pracy [A3] Habilitant skupia się na optymalizacji algorytmu afCEC mającej na celu wykonanie klasteryzacji i redukcji klastrów w trybie on-line, tj. wraz z nowo pojawiającymi się danymi. Tego typu podejście może być przydatne przykładowo w przypadku klastrowania

strumieni danych. W szczególności, zaproponowano wydajny obliczeniowo algorytm bazujący na podejściu Hartigana i pozwalający na szybkie aktualizowanie parametrów rozkładów jedynie na podstawie nowo pojawiających się punktów danych. Przy takim podejściu metoda afCEC wykazała większą tendencję do redukcji liczby klastrów. Pozwoliła też znaleźć lepsze minimum funkcji kosztu, a co za tym idzie zwiększyć dokładność wyodrębnienia klastrów.

Algorytm CEC wykorzystany został również w pracy [A4], w której Habilitant w dalszym ciągu rozważa problem klastrowania punktów danych układających się w zakrzywiony kształt w wielowymiarowej przestrzeni. Ideą proponowanego podejścia jest klastrowanie poprzez grupowanie rozkładów. W szczególności, Habilitant proponuje, aby klastry uzyskane metodą CEC i reprezentowane za pomocą rozkładu Gaussowskiego scalać z wykorzystaniem aglomeracyjnych metod grupowania z uwzględnieniem odległości pomiędzy gęstościami rozkładów. W procesie scalania, do grupowania rozkładów Habilitant proponuje alternatywne wykorzystanie dwóch metod tj. klastrowania hierarchicznego oraz metody Warda. Do pomiaru odległości pomiędzy rozkładami, proponowane jest wykorzystanie klasycznych miar, tj. dywergencji Kullbacka-Leiblera, dywergencji Cauchy'ego-Schwarza lub odległości Bhattacharya. Skuteczność obu metod została zweryfikowana w odniesieniu zarówno do danych syntetycznych, jak i rzeczywistych – w tym danych obrazowych (do binaryzacji obrazu) oraz grupowania stanów USA odpowiednio do rozmieszczenia ludności. W porównaniu do wcześniejszych prac, weryfikacja eksperymentalna obu metod oraz ich odniesienie do konkurencyjnych rozwiązań są jednak dość ubogie.

W pracy [A5] Habilitant kontynuuje rozważania dotyczące wykorzystania metody CEC w połączeniu z innymi niż normalne rozkłady danych, do modelowania danych o rozkładach niegaussowskich. W szczególności proponuje metodę General Split Gaussian Cross-Entropy Clustering (GSGCEC) będącą rozszerzeniem CEC o wykorzystanie rozkładu General Split Gaussian (GSG). Rozkład GSG, będący połączeniem dwóch części rozkładów normalnych o różnych parametrach, pozwala na modelowanie danych o rozkładach skośnych lub posiadających grube ogony w sposób dokładniejszy, aniżeli metoda GMM lub oryginalna metoda CEC. Dodatkowo, dzięki specjalnemu zapisowi funkcji kosztu, GSGCEC posiada mniejszą liczbę parametrów, więc złożoność numeryczna procesu ich znajdowania w porównaniu z GMM jest wyraźnie niższa. GSGCEC jest również mniej podatny na inicjalizację. W dalszym ciągu zachowuje jednak zdolność do redukcji liczby klastrów – podobnie jak źródłowa metoda CEC. Skuteczność metody GSGCEC została przetestowana została w kilku scenariuszach tj. w odniesieniu do danych medycznych, danych pochodzących z systemu monitoringu turbin wiatrowych, binaryzacji obrazów oraz progowania wielopoziomowego. Przeprowadzono również testy porównawcze z klasycznymi algorytmami, takimi jak GMM, CEC, EMMIXuskew, mixsmsn (wszystkie o zbliżonej liczbie parametrów).

Rozkład General Split Gaussian (GSG) został również wykorzystany w pracy [A6] w problemie separacji sygnałów składowych. W szczególności Habilitant zaproponował rozszerzenie metody składowych niezależnych (ang. *Independent Component Analysis*, ICA) w taki sposób, aby zapewnić lepsze rozdzielanie sygnałów o skośnych rozkładach. Nowa metoda, określana mianem ICA_{sc} zamiast aproksymować dane rozkładami z ciężkimi ogonami, do aproksymacji wykorzystuje rozkład danych powstały w wyniku sklejenia połówek dwóch asymetrycznych rozkładów gęstości. Algorytm wykorzystuje drugi moment centralny (inaczej niż klasyczne podejścia wykorzystujące momenty trzeci i czwarty) do opisanie skośności rozkładu danych. Drugi moment jest w tym przypadku wystarczający, gdyż GSG powstaje w wyniku sklejenia dwóch połówek rozkładu normalnego. W konsekwencji metoda posiada zwiększoną

odporność na zakłócenia i lepiej niż konkurencyjne metody dopasowuje się do danych o skośnych rozkładach. Skuteczność metody ICA_{SG} została zweryfikowana w problemach rozdzielania składowych informacji obrazowej, hiperspektralnej, dźwiękowej oraz sygnałów EEG. Dzięki wykorzystaniu metody ICA_{SG} możliwe było skuteczniejsze rozdzielanie sygnałów w ww. problemach, aniżeli z wykorzystaniem metod konkurencyjnych, takich jak: ICA, FastICA, ProDenICA, PearsonICA, infomax oraz JADE. Ponadto, wpasowanie rozkładu GSG do danych wymaga znalezienia zaledwie dwóch parametrów, co czyni metodę ICA_{SG} bardziej efektywną obliczeniowo, niż rozważone metody konkurencyjne.

Prace [A7-A10] reprezentują drugi nurt badań Habilitanta nad poszukiwaniem reprezentacji danych – tym razem z wykorzystaniem metod zaliczanych do obszaru uczenia głębokiego. Jest on bardziej heterogeniczny niż nurt „klasyczny”, w dalszym ciągu jednak wpasowuje się w tematykę cyklu.

W pracach [A7-A9] Habilitant skupia uwagę na problemie uczenia reprezentacji danych z wykorzystaniem autoenkoderów. W szczególności, praca [A7] proponuje nowy model autoenkodera generatywnego CWAE (ang. *Cramer-Wold Auto-Encoder*). Bazuje on na odległości Cramer-Wolda pomiędzy rozkładami, która wykorzystuje odległość MMD oraz nową funkcję jądrową (ang. *kernel function*) Cramera-Wolda. Proponowana metoda sprowadza problem liczenia odległości pomiędzy wielowymiarowymi rozkładami do sytuacji jednowymiarowej, wymagającej wyznaczenia odległości Cramera-Wolda między dwoma próbkami. W szczególności, odległość pomiędzy rozkładami otrzymywana jest w wyniku pomiaru odległości L2 pomiędzy estymacjami jądrowymi (wygładzeniami) próbek na wszystkich jednowymiarowych podprzestrzeniach (rzutach). Dla jądra Gaussowskiego taka odległość ma jawny wzór, nie ma więc potrzeby znajdowania optymalnego transportu, ani próbkowania podprzestrzeni. Logarytm odległości Cramera-Wolda pomiędzy reprezentacją w przestrzeni osadzeń (ang. *latent vector*) i rozkładem normalnym uwzględniona jest w funkcji kosztu CWAE. W konsekwencji model CWAE uczy się szybciej i stabilniej niż konkurencyjne metody wykorzystujące odległość Wassersteina, (w tym WAE-MMD oraz SWAE). Potwierdziły to eksperymenty porównawcze przeprowadzone na popularnych zbiorach obrazowych MNIST, Fashion MNIST, CIFAR-10 oraz CELEB A, w których uwzględniono architekturę autoenkodera bazującą na tradycyjnej (perceptronowej) sieci neuronowej, jak i modelu splotowej sieci neuronowej. Również jakość uzyskanych z CWAE wyników mierzona odległością FID (ang. *Fréchet Inception Distance*) w większości była lepsza, aniżeli w przypadku metod konkurencyjnych. Kod źródłowy aplikacji jest dostępny publicznie.

Praca [A8] kontynuuje problem nienadzorowanego uczenia reprezentacji z wykorzystaniem sieci o architekturze autoenkoder. W szczególności rozważa problem reprezentacji obiektów 3D określonych chmurą punktów oraz siatką. W tym celu proponuje rozwiązanie o nazwie HyperCloud, którego zasadniczą ideą jest połączenie generatywnego modelu kontradiktoryjnego autoenkodera (ang. *adversarial autoencoder*) chmur punktów 3D z podejściem typu HyperNetwork, w którym jedna sieć neuronowa, generuje wagi dla drugiej – docelowej sieci, w tym przypadku sieci neuronowej wytrenowanej do mapowania punktów z jednostajnego rozkładu na kuli jednostkowej na określony kształt 3D. W szczególności, w modelu HyperCloud sieć HyperNetwork bazująca na architekturze PointNet zastępuje dekodery w autoenkoderze. Jej zadaniem jest transformowanie „skondensowanej” reprezentacji chmury punktów (ang. *latent vector*) w wagi sieci docelowej, która następnie mapuje punkty z założonego rozkładu na punkty reprezentujące określony kształt 3D. W przeciwieństwie do innych metod, podejście HyperCloud nie zakłada z góry wynikowej liczby punktów. Ponadto, ponieważ HyperNetwork opiera się na

architekturze autokodera nauczonej rekonstrukcji realistycznych kształtów 3D, wagi sieci docelowej można uznać za parametryzację powierzchni kształtu 3D, a nie standardową reprezentację chmury punktów, zwykle zwracaną przez konkurencyjne podejścia. Podejście pozwala również na generowanie siatek, co jest przewagą w odniesieniu do innych metod i pozwala uniknąć postprocessingu chmur punktów. Metoda HyperCloud jest znacznie łatwiejsza do nauczenia niż konkurencyjne algorytmy, ponieważ posiada mniejszą liczbę parametrów i nie nakłada żadnych ograniczeń na rozkład prawdopodobieństwa wejściowego i jego Jakobian.

Praca [A9] rozszerza podejście HyperNetwork do postaci HyperFlow, zwiększając jednocześnie jakość rekonstruowanych chmur punktów i siatek. Efekt został osiągnięty dzięki wykorzystaniu CNF (ang. *Continuous Normalizing Flow*) jako sieci docelowej oraz zastosowaniu nowego, zaproponowanego przez Habilitanta, rozkładu prawdopodobieństwa bez zwartego suportu określonego mianem spherical log-normal, który może być użyty w modelach typ flow. Praca proponuje również zabieg, określony mianem „triangulation trick”, którego ideą jest bezpośrednia generacja siatki poprzez pobieranie wierzchołków triangulacji z rozkładu źródłowego i transformowanie ich na nowe pozycje w rozkładzie wynikowym z zachowaniem połączeń pomiędzy wierzchołkami. Transformacji dokonuje sieć docelowa. Ponieważ ta ostatnia przekształca próbkę z rozkładu Spherical Log-Normal w chmurę punktów 3D, to sfera jest przekształcana na powierzchnię obiektu. Podejście HyperFlow sprawdzone zostało w kilku scenariuszach. W problemie generowania chmur punktów 3D okazało się porównywalne z metodami konkurencyjnymi (raw-GAN, latent-GAN, PC-GAN, PointFlow) w kontekście jakości. Jako jedyne posiada jednak zdolność do generowania siatek bez dedykowanego postprocessingu chmur punktów. Ponadto, wykazało przewagę podczas uczenia, wymagając mniej zasobów, niż metody konkurencyjne.

Cykl publikacji zamyka praca [A10], poświęcona uczeniu reprezentacji z wykorzystaniem grafowych sieci neuronowych. Praca ta wydaje się jednak mniej związana z tematyką wcześniejszych prac. W szczególności, proponuje rozwiązanie SGCN (ang. *Spatial Graph Convolutional Network*), które rozszerza standardową sieć grafową o informację dot. przestrzennego położenia poszczególnych węzłów. Dzięki takiemu podejściu możliwe jest zastosowanie sztucznej augmentacji danych poprzez obrót grafu w przestrzeni, a to z kolei przekłada się na możliwość rozszerzenia danych uczących w przypadku małych zbiorów danych. Podejście przetestowano w dwóch scenariuszach, tj. w odniesieniu do danych obrazowych z uwzględnieniem współrzędnych pikseli oraz danych reprezentujących związki chemiczne z uwzględnieniem informacji o położeniu atomów. Wykazano, że przy takim założeniu można uogólnić sieć grafową do typowej sieci splotowej.

Podsumowując, oryginalne osiągnięcia dra Przemysława Spurka przedstawione w ocenianym cyklu publikacji obejmują (zgodnie z załączonymi oświadczeniami Habilitanta i współautorów):

- tworzenie specjalizowanych dedykowanych modeli oraz implementacja algorytmu CEC (ang. *Cross-entropy clustering*) [A1];
- autorstwo algorytmu afCEC (ang. *active function Cross-Entropy Clustering*) i jego implementacji, wykazanie oraz dowiedzenie jego właściwości [A2], a także autorstwo wersji on-line algorytmu afCEC [A3];

- autorstwo algorytmu klastrowania hierarchicznego bazującego na wynikowych klastrach wygenerowanych przez algorytm CEC (w dwóch wariantach) [A4];
- autorstwo algorytmu General Split Gaussian Cross-Entropy Clustering (GSGCEC) będącego rozszerzeniem algorytmu CEC o wykorzystanie rozkładu General Split Gaussian [A5];
- autorstwo algorytmu ICA_{SG} będącego rozszerzeniem metody składowych niezależnych wykorzystującym rozkład General Split Gaussian oraz autorstwo implementacji algorytmu [A6];
- sformułowanie funkcji kosztu oraz wyprowadzenie i udowodnienie części właściwości modelu autoenkodera generatywnego CWAE (ang. Cramer-Wold Auto-Encoder) [A7];
- autorstwo rozwiązania HyperCloud oraz współautorstwo jego implementacji [A8];
- autorstwo rozkładu Spherical Log-Normal oraz podbudowy teoretycznej wykorzystującego go modelu HyperFlow [A9];
- sformułowanie funkcji kosztu algorytmu SGCN (ang. *Spatial Graph Convolutional Network*), udział w wyprowadzaniu teoretycznych własności model oraz autorstwo jego implementacji [A10].

Powyższe rozwiązania stanowią oryginalny wkład w rozwój metod znajdowania reprezentacji danych nieposiadających etykiet. **Wszystkie rozwiązania wchodzące w skład recenzowanego osiągnięcia są silnie motywowane teoretycznie.** W zdecydowanej większości, posiadają również **szeroką, rzetelną i przekonującą weryfikację eksperymentalną**, która wskazuje na przewagę proponowanych rozwiązań w stosunku do wybranych metod konkurencyjnych bądź w kontekście dokładności, bądź aspekcie obliczeniowym. Warto zwrócić uwagę również na fakt, iż implementacje większości metod uczenia reprezentacji danych wchodzących w skład osiągnięcia naukowego dra Przemysława Spurka zostały udostępnione w publicznych repozytoriach kodu źródłowego i udostępnione do pobrania środowisku naukowemu.

W związku z powyższymi faktami, moja **ocena osiągnięcia naukowego dra Przemysława Spurka** pt. *Uczenie reprezentacji w metodach nienadzorowanych* **jest pozytywna**, gdyż samo osiągnięcie **stanowi oryginalny i wartościowy wkład naukowy**, poszerzający aktualny stan wiedzy.

5. Ocena aktywności naukowej Habilitanta zrealizowanej w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej zgodnie z art. 219 ust. 1 pkt. 3 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce

W okresie przed uzyskaniem stopnia doktora (tj. w roku 2013), afiliując do Uniwersytetu Jana Kochanowskiego w Kielcach Habilitant opublikował na konferencji CORES 2013 artykuł poświęcony problemowi identyfikacji kulistych nanostruktur granitu w obrazach z transmisyjnej mikroskopii elektronowej. W tym czasie dr Przemysław Spurek był pracownikiem naukowo-technicznym w projekcie POIG pn. *"Opracowanie technologii nowej generacji czujnika wodoru i jego związków do zastosowań w warunkach ponadnormatywnych"* realizowanym w tej uczelni.

W późniejszym okresie dr Przemysław Spurek odbył dwa trzymiesięczne staże naukowe, w tym jeden w zagranicznej uczelni. Odpowiednio były to staż podoktorski (*postdoctoral researcher*) na Uniwersytecie Technicznym w Ostrawie (w okresie styczeń-marzec 2022), oraz staż naukowy w Instytucie Podstaw Informatyki (IPI) Polskiej Akademii Nauk (w okresie listopad 2018-styczeń 2019). Z dokumentacji nie wynika jednak bezpośrednio, jaką istotną aktywnością naukową wykazał się w ich czasie Habilitant. W swoim dorobku dr Przemysław Spurek posiada dwie publikacje konferencyjne we współautorstwie z opiekunem stażu odbytego w IPI PAN (*Adversarial Examples Detection and Analysis with Layer-wise Autoencoders*, 33rd IEEE International Conference on Tools with Artificial Intelligence, ICTAI 2021, oraz *Fast and stable interval bounds propagation for training verifiably robust models*, 28th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2020), które mogą świadczyć o aktywności naukowej Kandydata w tej jednostce. Natomiast, nie znalazłam w Jego dorobku publikacji współautorskich z pracownikami Uniwersytetu Technicznego w Ostrawie, ani innych faktów wskazujących na Jego istotną aktywność naukową w tej jednostce. W autoreferacie (pkt. 5, s. 60) Habilitant wskazuje również na ok. dziesięciomiesięczny staż podoktorski w Polskiej Akademii Nauk w latach 2014-2015. Nie dołączył jednak dokumentów z nim z związanych (jak to miało miejsce w przypadku pozostałych staży).

Warto natomiast zwrócić uwagę, na szeroką współpracę naukową dra Przemysława Spurka (potwierdzoną wspólnymi publikacjami oraz projektami) z naukowcami reprezentującymi jednostki naukowe i badawcze w kraju oraz zagranicą (m.in.: New York University, University of Cambridge, Delft University of Technology, CERN, AGH, Politechnika Łódzka, Politechnika Białostocka, Politechnika Warszawska, Politechnika Wrocławska, Uniwersytet Ekonomiczny w Krakowie, Uniwersytet Medyczny w Białymstoku). W szczególności, wg. bazy Scopus (narzędzie Scival) 12% publikacji Kandydata powstało we współpracy międzynarodowej, natomiast 34% procent – we współpracy z innymi instytucjami naukowymi w Polsce. W mojej ocenie świadczy to o tym, że dr Przemysław Spurek chętnie podejmuje współpracę z innymi naukowcami i skutecznie ją realizuje.

Uważam również, że wszystkie ww. aktywności są wystarczające, aby uznać, że dr Przemysław Spurek wykazuje się istotną aktywnością naukową albo artystyczną realizowaną w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej.

6. Podsumowanie

W podsumowaniu niniejszej recenzji stwierdzam, że zarówno osiągnięcie naukowe dra Przemysława Spurka w postaci cyklu powiązanych tematycznie artykułów naukowych, jak i Jego aktywność naukowa zrealizowana w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej **spełniają wymagania stawiane kandydatom do stopnia naukowego doktora habilitowanego** nauk inżyneryjno-technicznych w dyscyplinie informatyka techniczna i telekomunikacja. W związku z powyższym, wniosek dra Przemysława Spurka o nadanie stopnia doktora habilitowanego uznaję za zasadny.

Anne Falejczyk