

Kraków, 05.03.2024

Prof. dr hab. inż. Tomasz Szmuc
Katedra Informatyki Stosowanej
Akademii Górniczo-Hutniczej
Al. Mickiewicza 30, 30-059 Kraków
tel.: (+12) 617 28 32
e-mail: tsz@agh.edu.pl

RECENZJA OSIĄGNIĘCIA NAUKOWEGO I OCENA DOROBKU NAUKOWEGO

dr. Łukasza Struskiego

Recenzja niniejsza została przygotowana na zlecenie prof. dr. hab. inż. Macieja Ogorzałka, Przewodniczącego Rady Dyscypliny Informatyka Techniczna i Telekomunikacja UJ w związku z powołaniem przez Radę komisji habilitacyjnej dla przeprowadzenia postępowania o nadanie stopnia naukowego doktora habilitowanego nauk technicznych w dyscyplinie Informatyka Techniczna i Telekomunikacja. Recenzja dotyczy osiągnięć naukowych i działalności dr. Łukasza Struskiego

1. Recenzja osiągnięcia naukowego

Recenzja osiągnięcia naukowego została wykonana na podstawie dokumentacji, w tym załączonego cyklu dziewięciu publikacji podstawowych (opublikowanych w latach 2018-2023). Poniżej podano listę publikacji tworzących oceniane osiągnięcie naukowe: *Płytkie i głębokie modele uczenia maszynowego w eksploracji i interpretacji danych*. Poszczególne elementy listy uzupełniono punktacją według wykazu Ministerstwa Nauki i Edukacji.

1. **Ł. Struski**, J. Tabor, P. Spurek: *Lossy compression approach to subspace clustering*. Information Sciences (435), DOI: 10.1016/j.ins.2017.12.056, pp. 161-183, 2018. Punkty **MNiSzW: 200, IF:8.233**
2. **Ł. Struski**, P. Spurek, J. Tabor, M. Śmieja: *Projected memory clustering*. Pattern Recognition-Letters (123), DOI: 10.1016/j.patrec.2019.02.023, pp. 9-15, 2019. Punkty **MNiSzW:100, IF:4.757**.
3. **Ł. Struski**, M. Śmieja, J. Tabor: *Pointed Subspace Approach to Incomplete Data*. Journal of Classification (37), DOI: 10.1007/s00357-019-9304-3, pp. 42-57, 2020. Punkty **MNiSzW: 140, IF: 1.333**.
4. **Ł. Struski**, M. Sadowski, T. Danel, J. Tabor, I. T. Podolak: *Feature-Based Interpolation and Geodesics in the Latent Spaces of Generative Models*. IEEE Transactions on Neural Networks and Learning Systems, DOI: 10.1109/TNNLS.2023.3251848 ,p. 1–15, 2023. Punkty **MNiSzW: 200, IF: 14.255**.
5. M. Przewięźlikowski, M. Śmieja, **Ł. Struski**: *Estimating conditional density of missing values using deep Gaussian mixture model*. International Conference on Neural Information Processing (ICONIP), DOI: 10.1007/978-3-030-63836-8_19, pp. 220–231, 2020. Punkty **MNiSzW: 140, Core rank: B**.
6. **Ł. Struski**, M. Mazur, P. Batorski, P. Spurek, J. Tabor: *Bounding Evidence and Estimating Log-Likelihood in VAE*. Artificial Intelligence and Statistics Conference (AISTATS), pp. 5036–5051, 2023. Punkty **MNiSzW:140, Core rank: A**.
7. **Ł. Struski**, Sz. Knop, P. Spurek, W. Daniec, J. Tabor: *LocoGAN–Locally convolutional GAN*. Computer Vision and Image Understanding (221), DOI: 10.1016/j.cviu.2022.103462, pp. 103462(16), 2022. Punkty **MNiSzW: 100, IF:4.886**.
8. **Ł. Struski**, T. Danel, M. Śmieja, J. Tabor, B. Zieliński: *SONGs:Self-Organizing Neural Graphs*. Winter Conference on Applications of Computer Vision (WACV), DOI: 10.1109/WACV56688.2023.00384, pp. 3848–3857, 2023. Punkty **MNiSzW: 140, Core rank: A**.

9. D. Rymarczyk, **L. Struski**, M. Górszczak, K. Lewandowska, J. Tabor, B. Zieliński: *Interpretable Image Classification with Differentiable Prototypes Assignment*. European Conference on Computer Vision (ECCV), DOI:10.1007/978-3-031-197758_21, pp. 351–368, 2022. Punkty MNiSzW: 140, Core rank: A.

Prace te są powiązane tematycznie (*Ustawa z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce* (Dz.U. 2018 poz. 1668, z późniejszymi zmianami) ich zakres tematyczny jest komplementarny i tworzą spójną całość określającą recenzowane osiągnięcie naukowe.

1.1. Opis osiągnięcia naukowego

Oceniane osiągnięcie naukowe zatytułowane: *Płytke i głębokie modele uczenia maszynowego w eksploracji i interpretacji danych* koncentruje się na opracowaniu nowych metod/narzędzi wspierających eksplorację i interpretację danych. W ogólnym ujęciu, prace stanowiące osiągnięcie naukowe można tematycznie podzielić na trzy grupy. W pracach [1,2] zaproponowano nowe metody grupowania danych, w [3] podano reprezentację niekompletnych danych z użyciem nisko-wymiarowych podprzestrzeni. W kolejnych czterech [4,5,6,7] zaproponowano modele i metody poszukiwania wzorców w modelach generatywnych. Prace [8,9] opisują sposoby ulepszenia interpretowalnych sieci neuronowych lub struktur decyzyjnych do wyjaśniania danych. Bardziej szczegółowy opis rezultatów poszczególnych pracach zawarto poniżej.

Grupowanie danych [1,2]. Grupowanie danych jest ważnym zagadnieniem eksploracji danych i uczenia maszynowego. W bogatej kolekcji opracowanych metod wyróżnić należy algorytmy grupowania podprzestrzeni, traktujące każdą podprzestrzeń oddzielnie, tym samym umożliwiając dokładniejszą identyfikację klastrów na podstawie odpowiednich cech. W pracy [1] zaproponowano nowy algorytm (SuMC) opracowany z wykorzystaniem teorii informacji (entropia Shannona, złożoność Kolmogorowa) oraz stratnej wersji zasady minimalnej długości opisu (*Minimum Description Length Principle*). Sformułowano problem optymalizacji:– minimalizacja całkowitego błędu kwadratowego przy ograniczeniu, aby suma pamięci do opisu poszczególnych klastrów nie przekraczała pamięci przydzielonej do opisu całego zbioru danych. W zaproponowanym rozwiązaniu zastosowano losową generację klastrów oraz procedurę redukcji niepotrzebnych klastrów. Opracowany algorytm porównano z istniejącymi ORCLUS i 4C. Przeprowadzono eksperymenty na danych sztucznych i rzeczywistych. Algorytm SuMC uzyskiwał ogólnie lepsze wyniki. Złożoność obliczeniowa ogranicza zastosowanie algorytmu dla dużych zbiorów danych. Stosunkowo ogólne sformułowanie zagadnienia implikuje szerszy zakres zastosowań – oprócz dedykowanego klastrowania – także do segmentacji obrazów lub kompresji danych.

W pracy [2] zaproponowano model klastrowania PMC (*Projected Memory Clustering*) bazujący na podprzestrzeniach afinicznych równoległych do osi układu współrzędnych. Jest to modyfikacja metody SuMC, polegająca na ograniczeniu rozważań do wspomnianych podprzestrzeni, w odróżnieniu do szukania arbitralnej podprzestrzeni dla każdego klastra. W przypadku podprzestrzeni równoległych od osi współrzędnych nie trzeba obliczać macierzy kowariancji, co zwiększyło złożoność obliczeniową SuMC. Pozwoliło to zmodyfikować podstawowe twierdzenie (z pracy [1]) i tym samym poprawić jego efektywność i umożliwiło zastosowanie do klasteryzacji zbiorów danych wielowymiarowych. W celu oceny przeprowadzono eksperymenty na danych syntetycznych i rzeczywistych. Metoda PMC jest nieznacznie wolniejsza od najszybszej (PROCLUS), lecz charakteryzuje się lepszymi wynikami (wg Adjusted Rand Index).

Reprezentacja danych niekompletnych [3]. Niekompletne zbiory danych są istotnym zagadnieniem, szczególnie w praktycznych zastosowaniach eksploracji danych. Typowym rozwiązaniem jest reprezentowanie niekompletnych danych jako wektory, w których brakujące atrybuty uzupełniają się wartością statystyczną. W pracy [3] zaproponowano przedstawienie niekompletnych danych przez podprzestrzenie afiniczne. Podana reprezentacja niekompletnych danych okazała się użyteczna do definiowania odwzorowań afinicznych na takich danych. Typowe metody uczenia maszynowego wymagają jednak specyficznych danych wejściowych, tzn. wektorów lub macierzy jądra (podobieństw). W dalszej części podano sposób osadzenia macierzy afinicznych (reprezentujących uogólnione dane niekompletne) w przestrzeni wektorowej przez powiązanie punktowej podprzestrzeni z punktem bazowym połączonym z odpowiednią macierzą projekcji. Punkt bazowy jest wybierany jako najbardziej prawdopodobny

punkt z podprzestrzeni. Przeprowadzono szereg eksperymentów, w których wykazano lepszą dokładność klasyfikacji zaproponowanej metody względem istniejących.

Poszukiwanie wzorców w modelach generatywnych [4, 5,6,7]. Modele generatywne są intensywnie rozwijane w ostatnich latach. Wykorzystują rozkład danych w przestrzeni ukrytej, aby przez dekodowanie próbek generować nowe obiekty, pasujące do danych rzeczywistych. Stosując interpolację między różnymi obiektami można odkrywać nowe, łączące cechy obiektów pierwotnych. Interpolacja pozwala ocenić jakość modeli, może być zatem wykorzystana do określania geometrii przestrzeni ukrytej, lub w analizie zdolności generacji sieci. To kluczowe pojęcie dla generowania nowych obiektów było przedmiotem badań w pracy [4]. Zaproponowano ogólne podejście do interpolacji przez zdefiniowanie funkcji kosztu wykorzystującej odległość jądra oraz określenie Q- optymalności, odnoszące się do prowadzenia ścieżki przez obszary o wysokim prawdopodobieństwie danych. Skutkuje to obiektami bliższymi różnorodności danych. Dzięki tej definicji możliwe jest szybkie znalezienie ciągłej ścieżki przy użyciu dedykowanej sieci neuronowej. Opracowany model ma solidne podstawy teoretyczne. W twierdzeniu 1 udowodniono, że poszukiwanie optymalnej interpolacji może być określone przez znajdowanie krzywych geodezyjnych w odpowiedniej przestrzeni Riemanna. Tym samym maksymalizacja zaproponowanej miary jakości krzywej interpolacyjnej jest równoważna poszukiwaniu krzywej geodezyjnej. Przeprowadzono szereg eksperymentów na różnych modelach generatywnych oraz wykorzystaniem różnorodnych danych. Wykazano, że zaproponowany model przewyższa (niekiedy znacznie) liniową i sferyczną interpolację. Możliwe jest szerokie jego zastosowanie nie tylko do efektywnego odkrywania nowych obiektów i struktur danych, lecz również do kontroli procesu interpolacji.

Praca [5] skupia się na analizie i uzupełnianiu niekompletnych obrazów. W celu estymacji funkcji gęstości prawdopodobieństwa brakujących wartości opracowano metodę DMFA (*Deep Mixture of Factor Analyzers*). Metoda ta wykorzystuje głęboką sieć neuronową oraz techniki mieszaniny rozkładów normalnych GMM (*Gaussian Mixture Model*). Zastosowano metodę mieszaniny czynników składowych umożliwiającą zredukowanie liczby parametrów w macierzy kowariancji, co istotnie poprawiło efektywność. Otrzymana gęstość rozkładu normalnego brakujących danych charakteryzuje się lepszą jakością niż obliczona przez klasyczną GMM. Uzupełnienia (imputacje) obliczone przez zastąpienie brakujących danych wektorem średniej rozkładu wyliczonego przez DMFA charakteryzują się lepszą jakością niż wyniki klasycznej MFA. Powyższe wykazano eksperymentalnie.

Istniejące metryki porównywania wytrenowanych modeli generatywnych charakteryzują się pewnymi ograniczeniami. W szczególności modele (*Variational AutoEncoders* – VAE) wykorzystują dolne ograniczenie wiarygodności danych (ELBO), co utrudnia oszacowanie wpływu treningu między różnymi modelami. Znane jest bowiem dolne ograniczenie, a nie dokładna wiarygodność danych. W pracy [6] zaproponowano górne ograniczenie, umożliwiające lepsze porównywanie jakości danych generowanych przez różne modele. Podobnie jak w przypadku wcześniej omawianych prac, uzyskane wyniki są wsparte solidną bazą matematyczną. Jest to sekwencja twierdzeń poczynając od podania ogólnych warunków określających górne ograniczenie wiarygodności, poprzez twierdzenia wyznaczające szerokie klasy górnych ograniczeń wiarygodności, a skończywszy na wykazaniu, że istotna klasa rozkładów log-normalnych lokuje się w środku przedziału między dolnym a górnym ograniczeniem. Przeprowadzone liczne eksperymenty pozwoliły uzyskać lepsze (niekiedy znacznie) oszacowania w większości przypadków. Należy również zaznaczyć, że zaproponowana metody zapewnia zmniejszenie obliczonej luki wariacyjnej wraz ze wzrostem próbek.

W pracy [7] zaproponowano modyfikację sieci GAN (*Generative Adversarial Network*). W sieciach tego typu przestrzeń ukryta jest reprezentowana przez wektor losowych wartości, przekształcany w obraz o określonej rozdzielczości. Tym samym model jest trenowany dla jednej rozdzielczości, co skutkuje większymi kosztami obliczeniowymi i zapotrzebowaniem na pamięć w przypadkach budowania modeli dla większych rozdzielczości. Opracowany model LocoGAN umożliwia generowanie obrazów o dowolnej rozdzielczości. Idea polega na wykorzystaniu szumu w postaci trójwymiarowego tensora o strukturze przypominającej obraz i mogącego przyjąć dowolny rozmiar. Klatki obrazu podzielono na dwie grupy. Pierwsza zawiera globalny szum i koduje globalne cechy obrazu, np. kształt twarzy, kolor skóry itp. Druga odpowiada za generowanie lokalnych szczegółów (lokalny szum). Dwa dodatkowe kanały pozycyjne przechowują informacje współrzędnych piksela. Wykorzystanie konwolucyjnej sieci gene-

ratora zapewnia niezmienniczość translacji. Własność ta jest ważna przy przetwarzaniu obrazów o dowolnej rozdzielczości przy stałej liczbie kanałów. Przy trenowaniu zastosowano koncepcję uczenia lokalnego fragmentu obrazu. Zrezygnowano z wypełniania zerami warstw konwolucyjnych, generując w zamian większy szum przypominający strukturę obrazu. Umożliwia to generowanie spójnych i płynnych obrazów o dowolnej rozdzielczości. Ponadto można płynnie przenosić wybrane cechy między różnymi obrazami bez wykonywania dodatkowego dekodowania.

Interpretowalność i wyjaśnialność w modelach głębokich [8,9]. Przetwarzanie dużych zbiorów danych przez sieci głębokie najczęściej prowadzi do wyznaczenia złożonych modeli określających zależności między danymi wejściowymi a wyjściem sieci. Utrudnia to określenie syntetycznych reguł transformacji, które umożliwiłyby zrozumienie działania oraz mogłyby być wykorzystane do optymalizacji procesu uczenia. Interpretowalność i wyjaśnialność decyzji w głębokich modelach stanowią zatem jeden z ważniejszych obszarów badań. Wśród istniejących podejść i modeli (drzewa decyzyjne, prototypowanie, lasy losowe itp.) brak jest jednak zadawalającego rozwiązania. W szczególności stosunkowo popularne drzewa decyzyjne mają ograniczenia wynikające ze wzrostu złożoności wraz głębokością drzewa. W pracy [8] zaproponowano samoorganizujące się grafy neuronowe (SONG), nowy typ grafów decyzyjnych mających zastosowanie w dowolnym cyklu głębokiego uczenia. Nowa formuła treningu bazuje na procesach Markowa. Metoda pozwala na jednoczesne uczenie optymalnej struktury i prawdopodobieństw przejść. Propagacja wsteczna zapewnia stopniowe korygowanie struktury. W części teoretycznej (aneks) wykazano, że model jest zbieżny do rzadkiego binarnego skierowanego grafu acyklicznego. Połączenia między wierzchołkami wynikowego grafu są binarne, co ułatwia interpretowalność modelu. Przeprowadzone eksperymenty (dane MNIST i CIFAR) wykazały nieco lepszą lub porównywalną efektywność SONG względem drzew decyzyjnych przy istotnie mniejszej liczbie wierzchołków grafu.

Sieć ProtoPNet (*Prototypical Part Net*) porównuje kluczowe części obrazu z referencyjnymi wzorcami przypisanymi do poszczególnych klas. Porównanie jest realizowane z zastosowaniem metryki podobieństwa. Wyjaśnienie polega więc na określeniu listy wzorców i ich podobieństwa do obrazu wejściowego. Ta znana w literaturze metoda ma pewne ograniczenia – założenie że każda klasa ma unikalny zestaw prototypów, co powoduje wzrost liczby prototypów z liczbą klas. Duża liczba prototypów zaburza klarowność i tym samym użyteczność tej metody. W pracy [9] zaproponowano nowy model ProtoPool, który bazuje na miękkim przypisaniu, określonym przez rozkład prawdopodobieństwa dla zbioru prototypów. Tym samym model efektywnie wykorzystuje prototypy dostępne w puli. Ponadto wprowadzono dwa dodatkowe mechanizmy: zapobiegający przypisaniu tego samego prototypu do wielu slotów jednej klasy oraz eliminujący skupienie prototypów na tle. Eksperymenty weryfikujące efektywność przeprowadzono na zbiorach CUB-200-2011 i Stanford Cars. W obu przypadkach model ProtoPool wykazywał zauważalnie lepszą dokładność.

1.2 Ocena osiągnięcia naukowego

Oceniane osiągnięcie naukowe polega na opracowaniu nowych metod lub znaczącej modyfikacji istniejących w obszarze eksploracji i interpretacji danych z wykorzystaniem płytkich i głębokich modeli uczenia maszynowego. Badania koncentrowały się na poszukiwaniu nowych metod klastrowania i uzupełniania brakujących danych w metodach płytkich oraz analizie przestrzeni ukrytej i interpretacji wyników głębokich modeli klasyfikacyjnych. Wybór tego obszaru badawczego należy uznać jako właściwy, odpowiadający aktualnym wyzwaniom. Obserwowany w ciągu ostatnich kilkunastu lat gwałtowny rozwój tego obszaru sztucznej inteligencji charakteryzuje się eksplozją szczegółowych rozwiązań, które zazwyczaj są weryfikowane wyłącznie na istniejących zbiorach danych. Przestrzeń ukryta jest traktowana jako czarna/szara skrzynka, co może znacznie utrudniać trenowanie takiej sieci i często stawia pod znakiem zapytania wiarygodność uzyskanych wyników. Ten ostatni aspekt jest szczególnie ważny przy wykorzystaniu wyników w obszarach krytycznych – diagnostyka medyczna, rozpoznanie sceny w samochodach autonomicznych itp. Osiągnięcia Habilitanta pozytywnie wyróżniają się w tym względzie. Proponowane rozwiązania są obudowane rozważaniami teoretycznymi. Zapewnia to ogólność i klarowność (wiarygodność) proponowanych rozwiązań.

Szczegółowy opis rezultatów składających się na oceniane osiągnięcie naukowe przedstawiono w poprzednim punkcie recenzji. W poniższych punktach przedstawiono syntetyczne podsumowanie.



1. Opracowanie nowego, efektywnego algorytmu (SuMC) grupowania podprzestrzeni pozwalającego na dokładniejszą identyfikację klastrów. Algorytm wykorzystuje teorię informacji i stratną wersję zasady minimalnej długości opisu. W kolejnym kroku (model PMC) ograniczono rozważań do podprzestrzeni afinicznych równoległych do osi układu współrzędnych, co poprawiło efektywność, widoczną szczególnie dla danych wielowymiarowych.
2. Zaproponowanie reprezentacji danych niekompletnych przez podprzestrzenie afiniczne oraz nowej metody uzupełnienia brakujących danych przez odpowiednie rzutowanie. W wyniku uzyskano lepszą dokładność klasyfikacji.
3. Opracowanie nowych metod poszukiwania wzorców w modelach generatywnych – główne rezultaty wymienione poniżej.
 - a. Wprowadzenie ogólnego modelu interpolacji, w którym poszukiwanie optymalnej interpolacji jest określone przez znajdowanie krzywych geodezyjnych w przestrzeni Riemanna. W wyniku uzyskano efektywną metodę odkrywania nowych obiektów i możliwość kontroli procesu interpolacji.
 - b. Opracowanie efektywnej metody uzupełniania niekompletnych obrazów wykorzystującej głęboką sieć neuronową oraz techniki mieszaniny rozkładów normalnych.
 - c. Zaproponowanie górnego oszacowania wiarygodności pozwalającego na lepsze szacowanie jakości danych (obiektów) generowanych przez różne modele.
 - d. Zdefiniowanie sieci LocoGAN umożliwiającej efektywne generowanie spójnych i płynnych obrazów o dowolnej rozdzielczości.
4. Opracowanie nowych metod interpretowalności i wyjaśnialności w modelach głębokich wskazane poniżej wyniki.
 - a. Wprowadzenie nowego typu grafów decyzyjnych odpowiednio trenowanych z wykorzystaniem procesu Markowa. Prowadzi to do binarnego acyklicznego grafu o istotnie mniejszej liczbie wierzchołków. Tym samym istotnie polepsza się wyjaśnialność modeli głębokich.
 - b. Zaproponowanie modelu miękkiego przypisania prototypów do klas i dodatkowych mechanizmów usprawniających dopasowanie wzorców referencyjnych.

W wymienionych osiągnięciach pierwsza grupa (punkty 1 i 2) koncentruje się na badaniu płytkich metod, natomiast druga (punkty 3 i 4) skupia się na głębokich sieciach neuronowych. W badaniach grupy pierwszej zastosowano reprezentację danych przy pomocy skupisk podprzestrzeni, co umożliwia efektywną ekstrakcję informacji z dużych zbiorów danych. W badaniach drugiej grupy skupiono się na analizie struktury sieci, w tym warstwy ukrytej. Wyniki umożliwiły przyczyniły się do doskonalenia technik trenowania sieci, lepszego zrozumienia danych generowanych przez modele oraz wyjaśnienie predykcji.

Oprócz wspomnianych solidnych podstaw matematycznych zaproponowanych rozwiązań wyniki zostały zweryfikowane drogą testowania i porównania z istniejącymi. Potwierdziło to możliwości aplikacyjne tych rozwiązań.

W podsumowaniu oceny merytorycznej należy stwierdzić, że osiągnięte wyniki są oryginalne i wartościowe oraz otwierają nowe możliwości w obszarze eksploracji i interpretacji danych.

Przedstawiony cykl publikacji jest tematycznie spójny i dobrze opisuje oceniane osiągnięcie naukowe. Pozycje [1,2,3, 4,7] zostały opublikowane w czasopiśmie punktowanych odpowiednio 200, 100, 140, 200, 100. Pozostałe pozycje tworzące osiągnięcie [5,6,8,9] w materiałach renomowanych konferencji międzynarodowych – punktacja 140. Wszystkie publikacje są wieloosobowe. W poszczególnych pozycjach liczba współautorów zmienia się od 2 do 5. Procentowy udział Habilitanta jest szacowany w przedziale 30-70%. Złączone w dokumentacji deklaracja Habilitanta oraz oświadczenie współautorów potwierdzają znaczący merytoryczny wkład Habilitanta w prezentowane badania.



2. Ocena dorobku naukowego

Działalność naukowa Habilitanta zawiera się w obszarze sztucznej inteligencji i koncentruje się na wykorzystaniu różnych narzędzi, w tym płytkich i głębokich sieci neuronowych. W dostarczonej dokumentacji badania te podzielono na 5 obszarów Przetwarzanie danych niekompletnych, Częściowo nadzorowane grupowanie, Wykrywanie anomalii, Wyjaśnialne i interpretowalne uczenie maszynowe oraz Rzadkie reprezentacje.

Przetwarzanie danych niekompletnych. W tym obszarze Habilitant zaproponował szereg metod przetwarzania z wykorzystaniem: modelowania rozkładów brakujących wartości, aproksymacji gradientu gęstości logarytmicznej, przetwarzanej informacji grafowych sieci konwolucyjnych. Interesującymi rozwiązaniami są również modyfikacje jądra umożliwiające modelowanie brakujących współrzędnych korzystając z rozkładu danych.

Częściowo nadzorowane grupowanie. Zaproponowano dwa podejścia. W pierwszym zadanie grupowania jest rozkładane na dwa etapy – oznaczenie nieoznakowanych par punktów (konieczne/nieosiągalne połączenie) z zastosowaniem sieci syjamskich i następnie zastosowanie sieci neuronowej do nadzorowanego grupowania. W drugim podejściu zastosowano częściowo-nadzorowaną wersję mieszanki rozkładów do znajdowania klastrów w częściowo skategoryzowanych zbiorach danych.

Wykrywanie anomalii. Propozycje modyfikacji modeli typu *flow* opisano w dwóch publikacjach. W pierwszej (model OneFlow) wykorzystano model *flow* i estymator kwantyli Bernsteina, w drugim (model FlowSVDD) zastosowano zasadę SVDD (*Super Vector Data Description*).

Wyjaśnialne i interpretowalne uczenie maszynowe. W dwóch publikacjach zaproponowano rozszerzenie funkcjonalności modeli wykorzystujących prototypy części obrazu. W pierwszej podano nowy model semantycznej segmentacji obrazu, natomiast w drugiej zaproponowano model wydajniej zarządzający prototypowymi częściami między klasami.

Rzadkie reprezentacje. W tym obszarze można wyróżnić dwie propozycje: modyfikację funkcji *softmax* generującej rozkłady prawdopodobieństwa z regulowanym współczynnikiem rzadkości oraz sieć konwolucyjną grafów przestrzennych, wykorzystującą cechy przestrzenne do uczenia grafów.

Scharakteryzowane powyżej badania stanowią cenne otoczenie tematyki opisywanego wcześniej osiągnięcia naukowego. Świadczy to o konsekwentnie prowadzonych badaniach, które zaowocowały wartościowymi wynikami.

W ujęciu ilościowym dorobek Habilitanta scharakteryzowano poniżej. W poszczególnych podkategoriach wyróżniono okresy przed i po uzyskaniu stopnia doktora.

1. Artykuły w czasopismach – łącznie 13 w tym 2 przed uzyskaniem stopnia doktora oraz 11 po doktoracie
2. Prace w materiałach konferencyjnych - 10
3. Recenzowane materiały prezentowane na konferencjach typu workshop – 2
4. Wykłady/warsztaty zaproszone – 3
5. Pozostałe wystąpienia na konferencjach – 5.

Sumaryczny współczynnik *Impact Factor* (IF) dla całego dorobku publikacyjnego wynosi 111,261, średni IF dla 16 publikacji w czasopismach – 6,954. Całkowita liczba punktów MNiSzW – 4410.

Liczba cytowań (w nawiasach bez autocytowań): Google Scholar – 395(367), Web of Science – 75(69), Scopus – 175(155).

Indeks Hirscha wg poszczególnych baz: Google Scholar – 9(8), Web of Science – 5(5), Scopus – 8(7).

Nieco niższa od spodziewanej liczba cytowań oraz wartości indeksu Hirscha wynikają zapewne ze stosunkowo krótkiego okresu po opublikowaniu najważniejszych prac.

Habilitant był trzykrotnie członkiem komitetu organizacyjnego konferencji: *International Conference on Theoretical Foundations of Machine Learning* i jednokrotnie był członkiem komitetu programowego

tej konferencji. Wyrazem uznania dla osiągnięć było zlecenie wykonania recenzji (łącznie 39) w ramach uznanych konferencji międzynarodowych – głównie sklasyfikowanych w Core rank A.

Na uznanie zasługuje działalność w realizacji projektów badawczych. Dr Ł. Struski brał udział jako wykonawca w 3 zakończonych projektach NCN oraz uczestniczył w 3 aktualnie realizowanych – w tym 2 projektach NCN odpowiednio jako kierownik i wykonawca oraz w projekcie Team-Net (FNP). Tematyka wymienionych projektów jest powiązana z ocenianą działalnością naukową.

Habilitant realizował również projekty naukowo-badawcze dla prywatnych przedsiębiorstw w formie 3-6 miesięcznych staży dwukrotnie w Samsung R&D (Warszawa) oraz Reliability Solutions Sp. z o.o. (Kraków). Od ponad roku realizuje projekt dla UES Sp. z o.o. (Rzeszów).

Dr Ł. Struski odbył na krótkie staże podoktorskie na Politechnice Wrocławskiej (2 tygodnie) oraz w Uniwersytecie Autonomicznym w Barcelonie (niecały miesiąc). Warto wspomnieć o krótkiej wizycie na Uniwersytecie w Helsinkach. Przez jeden rok pracował również jako asystent na Wydziale Informatyki, Elektroniki i Telekomunikacji AGH.

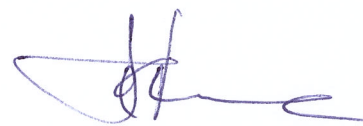
Działalność naukowa, dydaktyczna i organizacyjna Habilitanta była wyróżniona przez Rektora Uniwersytetu Jagiellońskiego: Nagroda Zespołowa III stopnia za osiągnięcia naukowe (2021), Nagroda zespołowa III stopnia za osiągnięcia organizacyjne (2019), Nagroda zespołowa II stopnia za osiągnięcia dydaktyczne i organizacyjne.

3. Wniosek końcowy

W przedstawionym osiągnięciu naukowym opracowano nowe metody lub znaczące modyfikacje istniejących w obszarze eksploracji i interpretacji danych z wykorzystaniem płytkich i głębokich modeli uczenia maszynowego. Dotyczy to klastrowania i uzupełniania brakujących danych w modelach płytkich oraz poszukiwania wzorców, uzupełniania brakujących fragmentów obrazów, interpretacji i wyjaśnialności wyników w modelach głębokich. Zaproponowane metody i algorytmy są obudowane solidnymi rozważaniami teoretycznymi, co pozwala uzyskać ogólne, pozwalające na szerokie zastosowania rozwiązania. Uzyskane wyniki wpisują się w główny nurt aktualnych badań i stanowią ważny i wartościowy wkład w tym obszarze sztucznej inteligencji. Otwierają również nowe możliwości badawcze.

Wyniki badań nie wchodzących w skład osiągnięcia naukowego stanowią jego uzupełnienie zarówno w kontekście wcześniejszych etapów badań, jak również ich rozszerzenie. Łącznie z osiągnięciem naukowym tworzą zatem wartościową i spójną całość. Świadczy to o dojrzałości badawczej Habilitanta.

Podsumowanie oceny osiągnięcia naukowego, dorobku po uzyskaniu stopnia doktora oraz działalności około-naukowej pozwala na jednoznaczne stwierdzenie, że spełnione są wymagania dotyczące uzyskania stopnia naukowego doktora habilitowanego (Ustawa z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce - Dz.U. 2018 poz. 1668, z późniejszymi zmianami), co prowadzi do wniosku o dopuszczenie dr. Łukasza Struskiego do kolejnego etapu postępowania w celu nadania stopnia naukowego doktora habilitowanego nauk inżynieryjno-technicznych w dyscyplinie Informatyka techniczna i telekomunikacja.



Tomasz Szmuc