Dr hab. inż. Wojciech Kotłowski, prof. PP
Instytut Informatyki
Politechnika Poznańska
ul. Piotrowo 2, 60-965 Poznań
tel: (+48) 61 665 2936
wkotlowski@cs.put.poznan.pl

Poznań, 8 marca 2021 roku

Recenzja osiągnięcia naukowego

dr. inż. Macieja Zięby

p.t.: *Metody i algorytmy rozwiązujące podstawowe problemy z jakością i strukturą danych w zadaniach uczenia maszynowego*

będącego podstawą ubiegania się o nadanie stopnia doktora habilitowanego

Niniejsza recenzja została przygotowana w odpowiedzi na uchwałę (nr 87/04/KSND03/2020-2024) Komisji ds. Stopni Naukowych w Dyscyplinie Informatyka Techniczna i Telekomunikacja z dnia 16 grudnia 2020 r., powołującej mnie na recenzenta w ramach komisji habilitacyjnej, w postępowaniu w sprawie nadania stopnia doktora habilitowanego dr. inż. Maciejowi Ziębie w dziedzinie nauk inżynieryjno-technicznych w dyscyplinie informatyka techniczna i telekomunikacja.

1 Sylwetka habilitanta

Dr inż. Maciej Zięba ukończył w 2009 r. studia magisterskie na kierunku Informatyka na Politechnice Wrocławskiej, uzyskując jednocześnie podobny dyplom z Blekinge Institute of Technology w Szwecji w ramach programu *Double Diploma Programme*. W roku 2011 r. ukończył kolejne studia magisterskie w dziedzinie Nauk o Zarządzaniu, również na Politechnice Wrocławskiej. W roku 2014 uzyskał z wyróżnieniem tytuł doktora nauk technicznych w dyscyplinie Informatyka na Wydziale Informatyki i Zarządzania Politechniki Wrocławskiej. Rozprawa doktorska nosiła tytuł „Zespoły klasyfikatorów SVM dla danych niezbalansowanych" i była pisana pod opieką prof. dr. hab. inż. Jerzego Świątka. Patrząc na wymienione w autoreferacie tytuły prac dyplomowych, zainteresowania metodami uczenia maszynowego towarzyszyły dr. Ziębie już na etapie studiów magisterskich, a następnie dalej na etapie studiów doktoranckich: rozpoczynając od wieloetapowych sieci neuronowych, poprzez rodziny drzew decyzyjnych, kończąc na wspomnianych zespołach klasyfikatorów typu SVM.

Dr inż. M. Zięba był z Politechniką Wrocławską silnie związany zawodowo przez większość swojej kariery: rozpoczynając w 2009 r. od pracy w projekcie jako samodzielny informatyk, poprzez asystenta naukowego w latach 2012-2013, asystenta naukowo-dydaktycznego w latach 2013-2016, aż do adiunkta od roku 2016 do chwili obecnej. Równocześnie pracował też jako

WPŁYNĘŁO
19-04-2021
RDN IT.T/71/2021

wykładowca akademicki w Wyższej Szkole Horyzont (2015-2016) oraz Akademii Leona Koźmińskiego (od 2019) w Warszawie. Z pewnością warto również podkreślić staż podoktorski („post doc"), jaki habilitant odbył na University of Wollongong w Australii w półrocznym okresie na przełomie 2016 i 2017 roku.

Recenzowany wniosek jest efektem siedmiu lat dalszego rozwoju naukowego kandydata od czasu uzyskania przez niego stopnia doktora nauk technicznych. Pod względem zainteresowań naukowych, habilitant pozostał w dziedzinie uczenia maszynowego, skupiając się przede wszystkim na współczesnych problemach z danymi.

2 Ocena osiągnięcia naukowego stanowiącego podstawę wniosku habilitacyjnego

Osiągnięciem naukowym przedłożonym przez dr. Ziębę jest cykle powiązanych tematycznie publikacji p.t. „Metody i algorytmy rozwiązujące podstawowe problemy z jakością i strukturą danych w zadaniach uczenia maszynowego". W obrębie cyklu znajduje się aż 11 prac, z czego 6 prac opublikowanych w czasopismach z ministerialnej listy A, 4 prace w materiałach konferencji i warsztatów, oraz jeden rozdział w książce.

2.1 Tematyka i opis cyklu publikacji

Tematem przedłożonego cyklu publikacji są współczesne problemy z danymi w uczeniu maszynowym. Z jednej strony zauważalny od pewnego czasu wzrost dostępności dużych wolumenów danych daje niezwykłe możliwości trenowania coraz bardziej złożonych i zaawansowanych algorytmów sztucznej inteligencji, z drugiej strony uwypuklają się coraz bardziej pewne problemy niesione przez dane, utrudniające ich wykorzystanie. Stąd habilitant skoncentrował się w ostatnich latach na rozwiązywaniu wspomnianych problemów tak, aby można było na podstawie danych budować efektywne modele uczenia maszynowego.

Tematyka cykl publikacji w sposób naturalny dzieli się na trzy wątki, podejmujące trzy problemy z danymi, których rozwiązania podjął się dr Zięba:

- Niekompletność danych uczących,
- Niezbalansowanie danych uczących,
- Struktura danych uczących.

Poniżej szczegółowo opisuję przyczynki w poszczególnych wątkach.

Niekompletność danych uczących. Wątek ten dotyczy sytuacji, gdy dane zawierają wartości brakujące. Problem niekompletności danych jest bardzo znanym zagadnieniem badawczym, obecnym w statystyce już od kilkudziesięciu lat, co zresztą zostało oczywiście zauważone przez habilitanta. Istniejące metody można zgrubnie podzielić na wewnętrzne – dostosowujące sam algorytm do możliwości napotkania brakujących danych, jak i zewnętrzne – starające się uzupełnić brakujące dane za pomocą mniej lub bardziej wyrafinowanych metod wstępnego przetwarzania, lub zwyczajnie usuwające obserwacji mające braki. Dr. inż. M. Zięba w ramach swoich prac badawczych [P1,P2] rozwijał oba kierunki.

W pracy [P1] wprowadził metody konstrukcji zespołu klasyfikatorów w obecności danych brakujących poprzez podział zbioru uczącego na kompletne podzbiory, które następnie były przedstawiane klasyfikatorom bazowym z zespołu. Podział na podzbiory bazuje na autorskim

Uki

algorytmie badającym zależności pomiędzy występowaniem wartości brakujących i identyfikującym podgrupy atrybutów dające kompletne podzbiory danych. Podejście jest niezależne od konkretnego modelu klasyfikatora bazowego.

Z kolei w pracy [P2] wprowadzona została metoda zewnętrzna do uzupełniania brakujących wartości w sekwencyjnych danych, bazująca na przewidywaniu kolejnych elementów za pomocą procesu Gaussa. Powyższa metodyka zastosowana została z sukcesem do problemu śledzenia sygnałów NMR.

Niezbalansowanie danych uczących. Wątek ten dotyczy zagadnień klasyfikacji, gdy liczność poszczególnych klas w obrębie danych jest bardzo niezrównoważona (np. klasa pozytywna stanowiąca zaledwie kilka procent całości obserwacji, głównie pochodzących z klasy negatywnej). Tak jak w poprzednim przypadku, zagadnienie niezrównoważonych zbiorów danych doczekało się licznych prac zarówno w dziedzinie statystyki, jak i uczenia maszynowego. Jest szereg metod – takich jak ważenie obserwacji, zmiana funkcji błędu, nadpróbkowanie (*oversampling*) klasy mniejszościowej czy niedopróbkowanie (*undersampling*) klasy większościowej – znanych już od dłuższego czasu, pozwalających na radzenie sobie z niezbalansowanymi klasami. Temat ten nadal nie wydaje się jednak rozwiązany i właściwe są dalszej badania w tym zakresie, jakich podjął się habilitant.

W pracy [P3] habilitant zmodyfikował znany algorytm SMOTE, który oryginalnie generuje syntetyczne obserwacje aby wzbogacić klasę mniejszościową (*oversampling*). Zauważona została wada algorytmu polegająca na generowaniu interpolacji punktów danych, które niekoniecznie muszą być sensowne. Proces ten zastąpiono dużo bardziej zaawansowaną metodą generacji danych opartą na Ograniczonej Maszynie Boltzmanna, znacznie lepiej reprezentującą rzeczywisty rozkład danych.

Tematyka pracy [P4] to algorytmy klasyfikacyjne dla problemów niezbalansowanych, oparte na tzw. miękkich regułach decyzyjnych, zwracających rozkład prawdopodobieństwa na decyzjach, a następnie opracowanie wnioskowanie na ich podstawie używając reguły Bayesa. Niezbalansowanie klas zostało tutaj uwzględnione poprzez użycie odpowiedniego estymatora prawdopodobieństw klas. Wynikowy algorytm został przetestowany na licznych zbiorach benchmarkowych oraz na danych z obszaru diagnostyki medycznej.

Z kolei praca [P5] dotyczy metody „uczenia się we własnym tempie", która dokonuje wyboru kolejności przedstawienia obserwacji, rozpoczynając od obserwacji prostych (z trudnością ocenianą przez algorytm na bieżąco). W autorskim podejściu habilitanta trudność przykładów oceniana jest na podstawie funkcji straty (błędu) na obiekcie, a w problemach niezbalansowanych pojawia się tutaj niesymetryczna macierz kosztów. Dzięki temu tempo uczenia obserwacji z obu klas (mniejszościowej i większościowej) może być odpowiednio dostosowane.

Na koniec, w pracy [P6] dr Zięba opracował nowy algorytm konstruujący zespoły klasyfikatorów o nazwie *BetaBoost*, wykorzystujący metodą próbkowania danych w oparciu o rozkład Beta-dwumianowy (dla każdej z klas z osobna). Rozważone zostały dwie strategie doboru parametrów rozkładu: zakładająca silny klasyfikator bazowy i niewielkie zaufanie do jakości danych (rozkład dobrany tak, aby z wyższym prawdopodobieństwem wybierać obserwacje klasyfikowane jako najbardziej prawdopodobnie należące do danej klasy), lub zakładająca słaby klasyfikator bazowy i duże zaufanie do jakości danych (z wyższym prawdopodobieństwem wybierane obserwacje „trudne", których klasyfikacja do danej klasy jest niejednoznaczna).

Struktura danych uczących. W obrębie tego wątku habilitant skupił się na uczeniu się reprezentacji danych, co można interpretować jako uczenie się ekstrakcji cech, bardziej informatywnych niż cechy bazowe, lub uczenie się rozkładu danych na pewnej ukrytej podprzestrzeni (rozmaitości).

Ufler

Praca [P7] konstruuje interpretowalny model klasyfikacji oparty na Ograniczonej Maszynie Boltzmanna. Pomysł dyplomanta (w zespole) polega na przypisywaniu wartości cech do przestrzeni cech, która podległa dyskretyzacji, a także przypisaniu wartości funkcji scoringowej tym cechom. W odróżnieniu od poprzednich prac bazujących na regresji logistycznej, tutaj odbywa się to poprzez wytrenowany model (generatywny) w postaci maszyny Boltzmanna.

W pracy [P8] opracowany został algorytm do automatycznej ekstrakcji cech przy użyciu metod ewolucyjnych. W kolejnych iteracjach wybierane są najistotniejsze cechy, które następnie podlegają krzyżowaniu się i mutacji. Wybór cech wykorzystuje algorytm lasów losowych, a ostateczny klasyfikator agreguje modele przy użyciu ważonego głosowania. Opracowana metoda została wykorzystana do przewidywania upadłości przedsiębiorstw.

W pracy [P9] habilitant podejmuje problem uczenia się reprezentacji z częściowym nadzorem poprzez zastosowanie modeli generatywnych typu GAN (w celu wyuczenia się reprezentacji na warstwach pośrednich dyskryminatora). Wprowadza się dodatkowo tzw. trójkową funkcję straty jako regularyzatora uczenia się reprezentacji. Użycie łącznie obu mechanizmów pozwoliło na polepszenie jakości otrzymanej reprezentacji.

Uczenie się reprezentacji w sposób nienadzorowany było z kolei temat pracy [P10], w której również wykorzystano model GAN, używając dodatkowo dwóch metod regularyzacji warstwy pośredniej sieci dyskryminującej. Były to: skalowanie odległości Hamminga między reprezentacjami obiektów z wysoko wymiarowej przestrzeni do przestrzeni o niskim wymiarze, a także maksymalizację entropii binarnych reprezentacji dla warstwy docelowej w sieci dyskryminującej.

Ostatnia z prac w cyklu [P11] dotyczy konstrukcji modelu generatywnego dla obiektów reprezentowanych w postaci chmury punktów 3D poprzez użycie architektury *adversarial autoencoder*, a także dobór architektury sieci (typu *PointNet*) celem wymuszenia jej niezmienniczości ze względu na permutacje punktów, wraz z zastosowaniem sieci typu GAN na przestrzeni ukrytej. Dzięki zaproponowaniu rozkładu typu Beta dla przestrzeni ukrytej, możliwe było wyuczenie się przez model reprezentacji binarnej.

2.2 Ocena osiągnięcia naukowego

W ramach osiągnięcia naukowego rozważano szereg problemów związanych z danymi w uczeniu maszynowym, za każdym razem proponując nowatorskie rozwiązanie i skrupulatnie je weryfikując w eksperymentach obliczeniowych, nie rzadko również przedstawiając rzeczywiste zastosowanie nowej metody. Wśród prac znalazła się jedna opublikowana na najbardziej prestiżowej konferencji uczenia maszynowego *Neural Information Processing Systems* (NeurIPS, dawniej: NIPS), na której procent akceptowanych prac (*acceptance rate*) jest rzędu 20%. Pojawiła się również praca w jednym z czołowych czasopism dziedziny *Machine Learning Journal* (choć tu habilitant występuje jako drugi współautor), a także szereg prac opublikowanych w innych prestiżowych czasopismach z dziedzinie uczenia maszynowego, sztucznej inteligencji i analizy danych: *Applied Soft Computing*, *Expert Systems with Applications*, *Computer Vision and Image Understanding* czy *IEEE Journal of Biomedical and Health Informatics*. Poza pracą [P1], wszystkie pozostałe przedłożone w cyklu publikacje mają wielu autorów, ale w większości z nich habilitant miał największy, często wręcz dominujący udział. Chciałbym tu zaznaczyć, że w dziedzinie uczenia maszynowego obecność współautorów jest powszechna i prace indywidualne pojawiają się stosunkowo rzadko. Co więcej, do wszystkich artykułów ze współautorami habilitant przedstawił bardzo precyzyjne zestawienia (w formie podpisanych przez współautorów deklaracji, a także w postaci zbiorczych tabeli) procentowego udziału w poszczególnych etapach tworzenia publikacji, począwszy od zdefiniowania problemu i studiów nad literaturą, poprzez konstrukcję metod, przeprowadzanie eksperymentu, skończywszy na samym pisaniu pracy.

Vgli

Cykl prac ma charakter spójny, a poszczególne prace są ze sobą wystarczająco blisko powiązane tematycznie. Trudno nie docenić istotności osiągniętych wyników zarówno dla rozwoju dziedziny uczenia maszynowego, jak i potencjalnych zastosowań. Obecność wartości brakujących w dużych wolumenach danych jest zjawiskiem powszechnym, a znaczna większość prac badawczych wciąż pomija ten problem. Na szczególną uwagę zasługuje też tutaj propozycja metody uzupełniania wartości brakujących w danych sekwencyjnych [P2], których znaczenie coraz bardziej rośnie (*data stream mining*). Również niezbalansowane dane licznie pojawiają się w wielu zastosowaniach (daleko nie szukając, wystarczy choćby spojrzeć na proporcje przypadków pozytywnych i negatywnych w danych epidemiologicznych dotyczących pandemii COVID-19) i każda przynosząca poprawę jakości modyfikacja istniejących rozwiązań (np. zastąpienie interpolacji w metodzie SMOTE bardziej inteligentnym modelowaniem rozkładu [P3]) może przełożyć się na znaczne zyski praktyczne z ich użycia. Uczenie się reprezentacji, czyli trzecie z zadań w cyklu, ma kluczowe znaczenie dla problemów uczenia się w dziedzinach, w których bazowa reprezentacja, pomimo zawierania pełnej informacji o wyjściu, jest bezpośrednio trudna do użycia, np. reprezentacja obrazu w postaci jasności pikseli. Tutaj również w ramach osiągnięcia habilitacyjnego został wykonany istotny wkład badawczy, np. poprzez użycie modeli GAN z pomysłowo dobraną regularyzacją [P9,P10]. Ciekawym i istotnym praktycznie problem jest również tworzenie reprezentacji dla obiektów opisanych za pomocą chmur punktów [P11]. Habilitant pochylił się również (pośrednio) nad dbałością o interpretowalność modeli uczących, szczególnie istotnej w zastosowaniach metodycznych (wnioskowanie na podstawie reguł decyzyjnych [P4] czy konstrukcja tablic scoringowych [P7]).

Przedłożone przez dr. inż. Macieja Ziębę prace stanowią istotny i nowatorski wkład w dziedzinę uczenia maszynowego. Charakteryzuje je wysoki poziom zaawansowania metodycznego, konkurencyjność względem najlepszych światowych rozwiązań algorytmicznych, nowatorskość w podejściu do rozwiązania postawionych problemów badawczych, a także poprawna i staranna weryfikacja eksperymentalna. Zwróciło moją uwagę, że habilitant potrafi kreatywne łączyć istniejące technologie i metody w synergiczną całość, np. w przypadku wspólnego zastosowania metody GAN i trójkowej funkcji straty w pracy [P9], czy maszyny Boltzmanna i algorytmu SMOTE w pracy [P3]. Wyraźnie widać, że płynnie porusza się między najnowszymi wynikami badawczymi, które potrafi pomysłowo zmodyfikować i zaprząc do własnych celów. Biorąc pod uwagę powyższe, uważam, że przedłożony cykl prac **stanowi osiągnięcie naukowe spełniające wymogi stosownej ustawy dotyczącej ubiegania się o nadanie stopnia doktora habilitowanego**.

3 Pozostałe osiągnięcia kandydata i ocena dorobku publikacyjnego

3.1 Pozostałe osiągnięcia naukowo-badawcze

Dr inż. Maciej Zięba pracował po doktoracie nad szeregiem ciekawych problemów badawczych, które nie zostały włączone do cyklu publikacji stanowiącego osiągnięcie naukowe, zapewne z powodu pewnej odrębności tematycznej, ale są również bardzo wartościowym wkładem w dziedzinę uczenia maszynowego. W prestiżowym czasopiśmie *Bioinformatics* (w chwili obecnej *Impact Factor* 5.610) opublikował artykuł dotyczący detekcji sygnałów w widmach NMR. Pracował również szerzej nad problemami uczenia się chmur punktów 3D przy użyciu modeli generatywnych (tematyka pojawiła się również w pracy [P11]), efektem czego są prace na warsztacie przy konferencji NeurIPS 2019, a także na głównym *tracku* prestiżowej konferencji ICML 2020. Ta druga praca zasługuje na szczególną uwagę, ponieważ ICML, obok NeurIPS, jest moim zdaniem najważniejszą konferencją w uczeniu maszynowym, z trudnym i bardzo selektywnym procesem recenzyjnym.

Vfli

W ramach doktoratu habilitant skupił się na modelach uczących typu SVM, włączanych jako bazowe klasyfikatory do zespołu trenowanego techniką *boosting*, przede wszystkim w kontekście problemów z niezrównoważoną licznością klas. Efektem badań były dwa artykuły opublikowane w czasopismach *Soft Computing* i *Applied Soft Computing*.

3.2 Wskaźniki publikacyjne

Dr inż. Maciej Zięba wymienia łącznie 44 opublikowane prace, z czego 22 przed doktoratem i 22 po doktoracie. Z tego 9 prac zostało opublikowane w czasopismach z bazy *Journal Citation Report*, w tym 7 po doktoracie i 6 w obrębie cyklu prac stanowiącego osiągnięcie habilitacyjne.

Liczba opublikowanych prac robi wrażenie, ale warto się przed wszystkim przyjrzeć innym wskaźnikom publikacyjnym, które zwykle lepiej oddają jakoś dorobku naukowego. Zgodnie z wnioskiem habilitacyjnym, dorobek naukowy dr. Zięby może zostać podsumowany następującymi wskaźnikami:

- Sumaryczny współczynnik *Impact Factor*: 26.557, w tym 4.44 przed doktoratem i 22.11 po doktoracie
- Liczba cytowań w *Google Scholar*: 521 oraz w *Web of Science*: 210 (202 bez autocytowań).
- Indeks Hirscha: 7 (*Web of Science*) lub 11 (*Google Scholar*)

Wymienione wyżej wskaźniki odzwierciedlają jakość osiągnięć i świadczą o intensywnej pracy naukowej habilitanta (szczególnie po uzyskaniu stopnia doktora), a także o tym, że jego prace są często zauważane w kraju i za granicą. Sumaryczny *Impact Factor* po doktoracie na poziomie 22.11 uważam za bardzo wysoki jak na tę dziedzinę badań, a dochodzą do tego dwie prace opublikowane na konferencjach kategorii A^* rankingu CORE (NeurIPS 2018 i ICML 2020), które w bazie *Journal Citation Report* się nawet nie znajdują.

W ramach przedłożonego cyklu publikacji stanowiącego osiągnięcie naukowe, sumaryczny *Impact Factor* wynosi 17.586 z liczbą (nowych) punktów MNiSW 1060, a same prace doczekały się w międzyczasie 307 cytowań na *Google Scholar*. Są to wartości wysokie, wyraźnie świadczące o jakości przedłożonych prac, w szczególności robi wrażenie liczba cytowań zważywszy na to, że są to prace zaledwie z ostatnich kilku lat.

3.3 Projekty badawcze, granty i nagrody naukowe

Habilitant uczestniczył w łącznie sześciu projektach badawczych, z czego dwóch jako kierownik i czterech jako wykonawca. Projekty mają silne podłoże praktyczne (np. optymalizacja procesów biznesowych, poszukiwanie leków, szacowanie ryzyka kredytowego), ale również istotny pierwiastek badawczy (nowe metody uczenia maszynowego). Prócz tego, habilitant był również beneficjentem grantu „Młoda Kadra" dla młodych naukowców w latach 2016-2019.

Podczas swojej kariery naukowej, dr Zięba uzyskał również wiele nagród i stypendiów: zarówno wyróżnień lokalnych, uczelnianych (wyróżnienie rozprawy doktorskiej, stypendia naukowe Politechniki Wrocławskiej, nagroda Rektora Politechnik Wrocławskiej, itd.), jaki i regionalnych czy ogólnokrajowych (stypendia w ramach programów „Mozart", „Od Innowacji do Zysku", Dolnośląski Grant Plus, itd.)

W podsumowaniu dorobku habilitacyjnego pojawiają się również stypendia wyjazdowe: Erasmus w Blekinge Institute of Technology w Szwecji, które później zaowocował podwójnym dyplomem magisterskim, staż podoktorski na Uniwersytecie w Wollongong, a także kolejny staż podoktorski w INRIA we Francji w 2020 r.

Wzlei

Podsumowując całość sekcji 3 stwierdzam, że habilitant wykazuje się bogatym dorobkiem naukowym, o wysokich wskaźnikach bibliograficznych, brał również czynny udział w licznych projektach badawczych. Stąd moja opinia o dorobku naukowym jest całościowo pozytywna.

4 Ocena dorobku dydaktycznego, popularyzatorskiego, współpracy międzynarodowej

4.1 Dorobek dydaktyczny

We wniosku habilitant przedstawia listę kursów prowadzonych przez niego na Politechnice Wrocławskiej, która zawiera aż 164 pozycje. Ponieważ powtarzają się nazwy kursów, nawet w obrębie tego samego semestru, zakładam, że poszczególne pozycje z listy odpowiadają zajęciom z pojedynczymi grupami studentów; wyszczególnione są również nadzorowane prace dyplomowe. Nawet biorąc to pod uwagę, dorobek dydaktyczny nadal robi wrażenie. Do powyższej listy dochodzą jeszcze kursy prowadzone poza Politechniką Wrocławską – na Wyższej Szkole Informatyki Stosowanej Horyzont oraz w Akademii Leona Koźmińskiego w Warszawie. Dr Zięba opracował też dwa skrypty dydaktyczne do swoich przedmiotów, współorganizował dwa warsztaty dla studentów.

W ramach pracy dydaktycznej habilitant wypromował aż 11 prac magisterskich i 10 prac inżynierskich. W jego dorobku pojawia się 6 prac, których współautorami są studenci – zakładam, że wielu z nich to jego dyplomanci. Do tego opiekował się trójką doktorantów w charakterze promotora pomocniczego.

4.2 Międzynarodowe i krajowe konferencje

Habilitant wymienia tutaj 18 konferencji, na których wygłosił referat, z czego większość to wydarzenia międzynarodowe. Dodatkowo, deklaruje on aktywny udział w kolejnych czterech konferencjach, jako współautor pracy opublikowanej na samej konferencji lub warsztacie przykonferencyjnym, prezentujący wyniki badań na sesjach posterowych.

4.3 Udział w komitetach organizacyjnych konferencji i recenzowanie w czasopismach naukowych

Dr Zięba by członkiem komitetów programowych 9 konferencji, co wiązało się między innymi z recenzowaniem zgłaszanych tam prac. Na liście pojawiają się najbardziej prestiżowe konferencje w uczeniu maszynowym, takie jak ICML 2020 czy NeurIPS 2020. Dodatkowo, recenzował on prace do wielu czasopism naukowych, z czego do 10 czasopism z listy JCR.

4.4 Współpraca krajowa i międzynarodowa

Na uwagę zasługuje również fakt, że habilitant intensywnie współpracuje z innymi badaczami w dziedzinie uczenia maszynowego, zarówno z Polski jak i spoza kraju: dr. hab. Tomaszem Trzcińskim z Politechniki Warszawskiej, dr. Karolem Kurachem z Google Brain, prof. Lei Wangiem z University of Wollongong w Australii (u którego spędził staż podoktorski), prof. Wolfgangiem Heardlem z Uniwersytetu Humboldta w Berlinie, dr. Yaroslawem Nikolaevem z ETH w Zurichu, dr. Przemysławem Spurkiem i prof. dr. hab. Jackiem Taborem z Uniwersytetu Jagiellońskiego,

czy dr. hab. Janem Chorowskim z Uniwersytetu Wrocławskiego. Jest to moim zdaniem modelowy przykład tego, jak powinna wyglądać praca naukowa: poprzez szukanie współpracy na zewnątrz macierzystej uczelni, w najlepszych ośrodkach krajowych i zagranicznych.

Podsumowując, moja opinia o dorobku dydaktycznym, popularyzatorskim i współpracy międzynarodowej habilitanta jest w pełni pozytywna.

5 Konkluzja końcowa

Dorobek naukowy habilitanta jest obszerny, wysoki jakościowo i dojrzały. Wnosi istotny wkład do dyscypliny naukowej, którą habilitant się zajmuje. Jego prace są rozpoznawane w Polsce i za granicą, o czym świadczą liczne cytowania. Wysoko oceniam również jego dorobek dydaktyczny, aktywność w zakresie organizacyjnym i popularyzatorskim, realizację i kierowanie projektami badawczymi, a także intensywną współpracę międzynarodową.

Ocena przedłożonego cyklu publikacji stanowiącego osiągnięcie habilitacyjne, całościowego dorobku naukowego, a także dorobku dydaktycznego, popularyzatorskiego i współpracy międzynarodowej habilitanta pozwala mi stwierdzić, że pan dr inż. Maciej Zięba spełnia wymogi ustawowe stawiane kandydatom do stopnia naukowego doktora habilitowanego. W związku z tym wnioskuję o nadanie dr. inż. Maciejowi Ziębie stopnia naukowego doktora habilitowanego w dziedzinie nauk inżynieryjno-technicznych w dyscyplinie informatyka techniczna i telekomunikacja.

Dr hab. inż. Wojciech Kotłowski, prof. PP

Wojciech Kotłowski