

Laboratory of Bioinformatics and Computational Genomics LB!GO
Faculty of Mathematics and Information Science, Warsaw University of Technology
ul. Koszykowa 75, 00-662 Warsaw, Poland

Warszawa,
11.11.2023

Laboratory of Functional and Structural Genomics LFSG
Centre of New Technologies, University of Warsaw
Banacha 2c Street, 02-097 Warsaw, Poland

mobile: [+48504726203](tel:+48504726203), e-mail: Dariusz.Plewczynski@pw.edu.pl, www: <https://plewczynski-lab.org>

Warszawa, 11/11/2023

Prof. dr hab. Dariusz Plewczyński
Laboratorium Bioinformatyki i Genomiki Obliczeniowej,
Wydział Matematyki i Nauk Informatycznych,
Politechnika Warszawska
Laboratorium Genomiki Funkcjonalnej i Strukturalnej
Centrum Nowych Technologii
Uniwersytet Warszawski

RECENZJA rozprawy doktorskiej mgr Macieja Wołczyka

Adaptiveness in Deep Learning Models

wykonanej w Katedrze Uczenia Maszynowego
Instytutu Informatyki i Matematyki Komputerowej
na Wydziale Matematyki i Informatyki
Uniwersytetu Jagiellońskiego

pod kierunkiem promotora
profesora doktora habilitowanego Jacka Tabora

złożonej do Rady Dyscypliny Naukowej
Informatyka Techniczna i Telekomunikacja (ITT)
Uniwersytetu Jagiellońskiego

Przedstawiona mi do recenzji praca doktorska jest wynikiem udanego rozwoju teoretycznego metod uczenia maszynowego, a dokładniej uczenia głębokiego, w zakresie procesu adaptacji, w tematyce badawczej rozwijanej w paradygmacie opartym na danych treningowych (uczenie pod nadzorem).

Uczenie głębokie to specjalistyczna i wysoce efektywna gałąź uczenia maszynowego, która polega na zastosowaniu skomplikowanych sieci neuronowych z wieloma warstwami przetwarzającymi, by analizować i interpretować duże ilości danych. Inspiracją dla tych sztucznych sieci są biologiczne procesy zachodzące w ludzkim mózgu, które pozwalają na rozpoznawanie wzorców i podejmowanie decyzji. W uczeniu głębokim, informacje przepływają przez hierarchię warstw, gdzie każda warstwa automatycznie i sukcesywnie wydobywa coraz to bardziej złożone i abstrakcyjne cechy z danych wejściowych. Dzięki algorytmowi wstecznej propagacji błędów, wspartemu przez techniki optymalizacyjne takie jak spadek gradientu, modele są w stanie dostosowywać swoje wewnętrzne parametry w celu zminimalizowania błędu predykcji, co prowadzi do coraz lepszej dokładności i wydajności w zadaniach takich jak rozpoznawanie obrazów, przetwarzanie języka naturalnego, samodzielne prowadzenie pojazdów czy zastosowania medyczne. Postęp w tej dziedzinie jest ściśle związany z dostępnością dużych zbiorów danych do treningu oraz zwiększoną mocą obliczeniową, dokonany dzięki rozwojowi nowych technologii sprzętowych, w tym jednostek przetwarzania graficznego (GPU) i jednostek przetwarzania tensorowego (TPU). Te przełomy technologiczne nie tylko przyspieszyły obliczenia, ale również umożliwiły bardziej złożone i głębokie architektury sieci, przyczyniając się do szybkiego rozwoju całej dziedziny.

Adaptacja w uczeniu głębokim odzwierciedla zdolność modeli do samodzielnego dostosowywania się do zmieniających się warunków i danych, co jest kluczowe w dynamicznych środowiskach. Ta adaptacja przyjmuje kilka form. *Transfer learning* umożliwia modelom wykorzystywanie wcześniej nabytej wiedzy do nowych, ale podobnych zadań, przyspieszając proces uczenia i poprawiając wydajność. *Domain adaptation* to proces, w którym model jest dostosowywany do nowego, często znacznie różnego, rozkładu danych, co jest ważne, gdy dane treningowe i testowe się różnią. *Continuous learning* pozwala modelowi na ciągłe przyswajanie wiedzy i rozwiązywanie nowych zadań przez cały czas jego działania, co jest odpowiedzią na problem katastroficznego zapominania, gdzie nowa nauka negatywnie wpływa na wcześniej nabyte umiejętności. *Meta-learning* rozwiązuje problem adaptacji poprzez nauczanie modeli najbardziej efektywnych sposobów uczenia się, aby mogły one

efektywnie przyswajając nowe zadania po niewielu przykładach. *Few-shot learning* skupia się na osiągnięciu wysokiej wydajności modelu przy bardzo ograniczonej liczbie przykładów, co jest ważne w sytuacjach, gdzie dane są skąpe. *Self-supervised learning* pozwala modelom generować własne etykiety do nauki z nieoznaczonych danych, co rozszerza ich zdolności adaptacyjne. Powyższe różnorodne metody adaptacji w uczeniu głębokim są kluczowe dla rozwoju modeli, które mogą skutecznie radzić sobie z szerokim zakresem zadań i środowisk bez konieczności projektowania nowych od podstaw za każdym razem, kiedy napotkają nowe dane lub wyzwania.

Uczenie ciągłe w uczeniu głębokim opisuje zdolność modelu do przyswajania, zachowania i wykorzystywania wiedzy nabytej przez cały okres jego działania, zamiast uczenia się tylko w izolacji podczas jednorazowego procesu treningowego. Jest to podejście, które umożliwia modelowi zachowanie i rozwój wiedzy nabytej w przeszłości, jednocześnie ucząc się nowych zadań, co jest istotne w dynamicznie zmieniających się środowiskach. Uczenie ciągłe pozwala na zachowanie elastyczności modelu, umożliwiając mu adaptację do nowych sytuacji bez zapominania poprzednich umiejętności, co odpowiada na wyzwanie katastroficznego zapominania – zjawiska, gdzie w procesie uczenia nowych rzeczy model traci wcześniej nabyte informacje. Proces ten obejmuje transfer wiedzy, gdzie model wykorzystuje wiedzę z poprzednich zadań do szybszego i bardziej efektywnego rozwiązywania nowych problemów, oraz strategie zapobiegające zapominaniu, takie jak specjalne techniki regularyzacji, adaptacyjne rozszerzanie modelu, czy selektywne zachowywanie istotnych informacji. Uczenie ciągłe oznacza też, że model jest w stanie nieustannie uczyć się przez swój 'cykl życia', co implikuje potrzebę sekwencyjnego i inkrementalnego uczenia, gdzie model jest systematycznie aktualizowany na podstawie nowych danych. Rozwijanie modeli uczenia ciągłego w uczeniu głębokim wymaga innowacji w zakresie architektury sieci neuronowych i algorytmów, które mogą skutecznie zarządzać stale rosnącymi i ewoluującymi zbiorami danych.

Uczenie ze wzmocnieniem w kontekście uczenia głębokiego, znane jako głębokie uczenie ze wzmocnieniem (*Deep Reinforcement Learning*, DRL), jest zaawansowaną metodą uczenia maszynowego, która umożliwia agentom komputerowym nauczenie się optymalnych strategii działania poprzez interakcję ze środowiskiem i otrzymywanie informacji zwrotnej w formie nagród. Ta metoda łączy klasyczne elementy uczenia ze wzmocnieniem, takie jak agenci, stany, akcje, nagrody, polityki działania oraz funkcje wartości i funkcja Q, z głębokimi sieciami neuronowymi, które mogą przetwarzać wysokowymiarowe

dane sensoryczne i generować złożone reprezentacje środowiska. W DRL, agent próbuje maksymalizować sumę przyszłych nagród, podejmując decyzje, które są podyktowane nie tylko bezpośrednim zyskiem, ale również długoterminowymi konsekwencjami swoich działań. Dzięki zdolności do przetwarzania złożonych danych wejściowych, DRL znalazło zastosowanie w różnych dziedzinach, od gier strategicznych i symulacji, przez autonomiczne systemy sterowania, np. w pojazdach samojezdnych, po zaawansowaną robotykę. Wyzwaniami w DRL są między innymi eksploracja przestrzeni akcji, równowaga między eksploracją a eksploatacją, skalowanie do dużych przestrzeni stanów i akcji, a także zapewnienie stabilności i konwergencji treningu. Rozwój w tej dziedzinie kontynuuje rozszerzanie granic możliwości automatyzacji i inteligentnych systemów decyzyjnych.

Praca doktorska Macieja Wołczyka dotyczy właśnie tych czterech podstawowych pojęć: uczenia głębokiego, adaptacji, uczenia ciągłego, uczenie ze wzmocnieniem i ich zastosowań w różnych dziedzinach. Praca składa się z pięciu publikacji, podzielonych na dwie części:

1. Uczenie Ciągłe: Pierwsza część skupia się na uczeniu ciągłym, ważnym w sieciach neuronowych, gdzie model musi adaptować się do zmieniających się danych bez zapominania wcześniej nabytej wiedzy. W tej części przedstawione są trzy publikacje autorskie:

- *Publikacja I*: Wprowadza środowisko i protokół ewaluacji dla ciągłego uczenia ze wzmocnieniem.

- *Publikacja II*: Skupia się na transferze wiedzy, identyfikując kluczowe aspekty architektoniczne i algorytmiczne, proponując wytyczne do efektywniejszych rozwiązań.

- *Publikacja III*: Przedstawia metodę ciągłego uczenia z mechanizmami ograniczającymi zapominanie.

2. Adaptacja Modeli: Druga część rozprawy koncentruje się na adaptacji istniejących modeli do różnych paradygmatów, co Doktorant przedstawia w dwóch publikacjach autorskich:

- *Publikacja IV*: Pokazuje, jak przekształcić model do dynamicznej adaptacji ścieżki obliczeniowej dla każdego przykładu, wprowadzając klasyfikatory wczesnego wyjścia.

- *Publikacja V*: Wykorzystuje technikę normalizujących przepływów do wprowadzenia warunkowania we wcześniej wytrenowanych modelach generatywnych.

Prace te zostały zaprezentowane na czołowych konferencjach i są wynikiem współpracy międzynarodowej. Dodatkowo, Kandydat publikował prace dotyczące innych zagadnień głębokiego uczenia i brał udział w stażach naukowych w renomowanych instytucjach.

Praca doktorska składa się z cyklu pięciu prac opublikowanych w materiałach konferencyjnych renomowanych konferencji międzynarodowych, z listy CORE A ocenianych na 200 punktów ministerialnych. Dodatkowo doktorantowi udało się uczestniczyć w wielu grantach badawczych, współorganizować konferencje, inicjować i realizować prace we współpracy międzynarodowej, realizować staże zagraniczne.

Przesłany mi do recenzji doktorat składany jest w dyscyplinie informatyki technicznej i telekomunikacji (ITT), co w moim mniemaniu jest uprawnione, ponieważ doktorant opracował zaawansowane modele głębokie, realizujące uczenie ciągłe i potrafiące się adaptować, które to metody umożliwiają istotny postęp zarówno w informatyce, ale również zastosowaniach w wielu dyscyplinach.

Przedmiotem mojej oceny, jest rozprawa doktorska, w tym przypadku zszywka dziewięciu prac współautorskich. Rozprawa w moim przekonaniu w pełni spełnia warunki określone w art. 187 ustawy z dnia 20 lipca 2004 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. z 2014 r., poz. 665 ze zm.). Rozprawa ta, a raczej publikacje i dokonania naukowe doktoranta, prezentują oryginalność rozwiązanego unikalnego problemu naukowego, ogólną wiedzę teoretyczną, ale również aplikacyjną (specyficzną dla dziedziny uczenia głębokiego) kandydata w dyscyplinie informatyki technicznej, a także umiejętność prowadzenia pracy naukowej na wysokim poziomie.

Rozprawa doktorska mgr Macieja Wolczyka pt. pt. “*Adaptiveness in Deep Learning Models*” została przygotowana w Katedrze Uczenia Maszynowego Instytutu Informatyki i Matematyki Komputerowej na Wydziale Matematyki i Informatyki Uniwersytetu Jagiellońskiego pod kierunkiem prof. dr hab. Jacka Tabora. Badania zostały zrealizowane w ramach stypendium wielu grantów: NCN, FNP, UJ oraz POB co umożliwiło Doktorantowi skorzystanie z unikalnej ścieżki rozwoju, wzbogacając tym samym zakres rozprawy doktorskiej. Ponadto, kontakt z partnerami zagranicznymi umieścił doktoranta w interdyscyplinarnym i międzynarodowym otoczeniu i dostarczył mu unikalnych i przydatnych pojęć, narzędzi i technik, które zastosował w swojej pracy badawczej.

Autor prezentuje tezy swojej rozprawy doktorskiej na 41 stronach w autoreferacie, w którym podkreśla znaczenie zaimplementowanych metod informatycznych oraz opracowanych narzędzi i algorytmów. Zapropozowane przez autora metody uczenia głębokiego są na wysokim, światowym poziomie. Dorobek naukowy doktoranta jest godny uwagi, wyróżniający się i nie budzi żadnych wątpliwości recenzenta.

W dwustronicowym streszczeniu Doktorant prezentuje skrótowo swój dorobek. Rozprawa doktorska skupia się na adaptacji modeli głębokiego uczenia do różnych zadań i warunków, stawiając czoła wyzwaniom, jakie niesie za sobą specyficzne zastosowanie tych modeli. Pierwsza część pracy zawiera publikacje skoncentrowane na ciągłym uczeniu i przeciwdziałaniu katastroficznemu zapominaniu w sieciach neuronowych, w tym metody na efektywne wykorzystanie wiedzy z przeszłości do nauki nowych zadań. Druga część bada metody adaptacji istniejących modeli do różnych paradygmatów, np. przez modyfikację ścieżek obliczeniowych dla indywidualnych przykładów i wprowadzenie warunkowania do nienadzorowanych modeli generatywnych.

Następnie zaprezentowany jest wstęp i motywacja Doktoranta. Omawiane są znaczące osiągnięcia w dziedzinie głębokiego uczenia w ostatnich 15 latach, podkreślając rozwój dzięki dostępności GPU, skalowalnym architekturom sieci neuronowych, oraz poprawie w dostępności danych. Mimo że modele głębokiego uczenia osiągają nad-ludzka wydajność w dziedzinach takich jak przetwarzanie języka naturalnego, widzenie komputerowe i uczenie ze wzmocnieniem, nadal mają ograniczenia w generalizacji, odporności i efektywności energetycznej. Rozprawa koncentruje się na adaptacji tych modeli, co jest wyzwaniem ze względu na ich małą elastyczność w założeniach dotyczących danych i procesu treningowego. Podkreślona jest popularność metody fine-tuning, pozwalającej na adaptację dużych modeli do nowych zadań, lecz nadal z ograniczeniami w adaptowaniu wiedzy z zadań podrzędnych do modelu pierwotnego. Praca ta bada sposoby ulepszenia właściwości adaptacyjnych modeli głębokiego uczenia, szczególnie w kontekście ciągłego uczenia i zmieniających się rozkładów danych, oferując nowe podejścia do adaptacji w obliczu tych wyzwań. Rozprawa jest podzielona na dwie części i składa się z pięciu publikacji prezentujących różne aspekty adaptacyjności, opublikowanych na czołowych konferencjach. Skupia się na ciągłym uczeniu, w tym na algorytmach wymuszających zapominanie oraz na zaawansowanych technikach adaptacji, takich jak zmiana paradygmatów obliczeniowych i warunkowania w modelach generatywnych.

Następnie zaprezentowane są dwa rozdziały obejmujące cykl pięciu prac wraz z opisami wkładu autorskiego:

- [PI] **Wołczyk, Maciej**, Michał Zając, Razvan Pascanu, Łukasz Kuciński, and Piotr Miłoś. “Continual World: A robotic benchmark for continual reinforcement learning.” *Advances in Neural Information Processing Systems (NeurIPS)*, pp. 28496-28510, 2021, CORE A*, 200 MEiN points.
- [PII] **Wołczyk, Maciej**, Michał Zając, Razvan Pascanu, Łukasz Kuciński, and Piotr Miłoś. “Disentangling Transfer in Continual Reinforcement Learning.” *Advances in Neural Information Processing Systems (NeurIPS)*, pp. 6304-6317, 2022, CORE A*, 200 MEiN points.
- [PIII] **Wołczyk, Maciej**, Karol J. Piczak, Bartosz Wójcik, Łukasz Pustelnik, Paweł Morawiecki, Jacek Tabor, Tomasz Trzciniński, and Przemysław Spurek. “Continual Learning with Guarantees via Weight Interval Constraints.” *International Conference on Machine Learning (ICML)*, pp. 23897-23911, 2022, CORE A*, 200 MEiN points.
- [PIV] **Wołczyk, Maciej**, Bartosz Wójcik, Klaudia Bałazy, Igor T. Podolak, Jacek Tabor, Marek Śmieja, and Tomasz Trzciniński. “Zero Time Waste: Recycling Predictions in Early Exit Neural Networks.” *Advances in Neural Information Processing Systems (NeurIPS)*, pp. 2516-2528, 2021, CORE A*, 200 MEiN points.
- [PV] **Wołczyk, Maciej**, Magdalena Proszewska, Łukasz Maziarka, Maciej Zięba, Patryk Wielopolski, Rafał Kurczab, and Marek Śmieja. “PluGeN: Multi-Label Conditional Generation From Pre-Trained Models.” *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI)*, pp. 8647-8656. 2022, CORE A*, 200 MEiN points.

Praca pierwsza „Continual World: A robotic benchmark for continual reinforcement learning” przedstawia badania nad problemem ciągłego uczenia ze wzmocnieniem, skupiając się na efektywnej transferze wiedzy. Głównym motywem jest adaptacja do zmieniających się strumieni danych w uczeniu ze wzmocnieniem, które jest istotne w kontekście robotyki i innych dynamicznych środowisk. Publikacja wprowadza benchmark robotyczny dla ciągłego uczenia ze wzmocnieniem, który jest niedrogi obliczeniowo, łatwy do interpretacji, ale jednocześnie złożony i rozszerzalny. Zaproponowano zestaw zadań

robotycznych, których każde ma jasno określony cel i warunki sukcesu, umożliwiając stworzenie użytecznych metryk. Metodyka ta pozwala na analizę średniego wskaźnika sukcesu i katastroficznego zapomnienia oraz ocenę transferu wiedzy do nowych zadań. Przeprowadzono ponad 45 000 eksperymentów, testując różne metody ciągłego uczenia, w tym konsolidację wag elastycznych (EWC), PackNet i powtórzenie doświadczeń. Wyniki wykazały istotne różnice między uczeniem ze wzmocnieniem a uczeniem nadzorowanym, zaskakująco słabe wyniki metod opartych na powtórzeniu doświadczeń oraz skuteczność metody PackNet. Publikacja analizuje także problem transferu wiedzy do przodu, pokazując, że w Continual World zapomnienie jest w dużej mierze ograniczone, ale transfer wiedzy do przodu nie zawsze jest skuteczny. Autorzy, w tym pierwszy autor pracy, przeprowadzili szczegółowe badania ablatywne i optymalizację hiperparametrów, co przyczynia się do głębszego zrozumienia i identyfikacji nowych problemów badawczych w ciągłym uczeniu ze wzmocnieniem. Praca ta została dobrze przyjęta przez społeczność i jest szeroko cytowana, co pokazuje użyteczność zaproponowanego benchmarku.

Praca druga „Disentangling Transfer in Continual Reinforcement Learning” skupia się na dalszym badaniu i proponowaniu rozwiązań problemów związanych z transferem wiedzy w ciągłym uczeniu ze wzmocnieniem. Badania skupiają się na tym, jak efektywnie wykorzystać zdobytą wiedzę do szybkiego uczenia się nowych zadań, co jest kluczowe w dziedzinach interaktywnych z rzeczywistym światem, takich jak robotyka. W pracy tej zbadano, które komponenty algorytmu Soft Actor-Critic (SAC) przyczyniają się do transferu wiedzy, analizując różne kombinacje zadań z Continual World oraz dłuższe sekwencje zadań. Autorzy stwierdzili, że krytyk (część algorytmu oceniająca wartość stanu) jest najważniejszym elementem transferu, ponieważ dobre reprezentacje dla oszacowania wartości stanu ułatwiają proces szkolenia. Inne komponenty, takie jak aktor i polityka eksploracji, również mają znaczący wpływ, sugerując, że te komponenty przyspieszają uczenie na różne sposoby. Następnie zbadano wpływ różnych strategii eksploracji oraz wpływ schematów regularyzacji i zamrażania warstw na transfer. Na podstawie tych badań autorzy skompilowali zalecane wybory projektowe dla algorytmu SAC w środowiskach ciągłego uczenia i wprowadzili podejście ClonEx-SAC. Wydajność ClonEx-SAC na benchmarku Continual World pokazuje, że dokładne zrozumienie problemu pozwala znaleźć proste podejście, które działa lepiej niż bardziej skomplikowane metody.

Podsumowując, w tej pracy dokładnie zbadano właściwości transferu wiedzy, zarówno w prostym ustawieniu dwóch zadań, jak i w scenariuszu

ciągłego uczenia ze złożonymi sekwencjami zadań i długoterminowymi zależnościami. Opracowany ClonEx-SAC jest podejściem, które działa lepiej niż gotowe rozwiązania z ciągłego uczenia nadzorowanego. Praca ta wnosi wkład w dziedzinę ciągłego uczenia, uczenia transferowego i uczenia ze wzmocnieniem. Autor pracy, będący pierwszym autorem, przyczynił się do 40% jej treści.

Praca trzecia „Continual Learning with Guarantees via Weight Interval Constraints” skupia się na zagadnieniu zapewniania gwarancji w ciągłym uczeniu. Autorzy zauważają, że większość rozwiązań w ciągłym uczeniu koncentruje się na łagodzeniu katastroficznego zapominania bez ustanawiania twardych ograniczeń, co jest problematyczne w krytycznych sytuacjach. Proponują metodę ciągłego uczenia, która gwarantuje, że wydajność na poprzednich zadaniach nie spadnie poniżej określonego progu. Metoda ta używa formuły określającej ciągłe uczenie jako problem znalezienia przecinających się regionów przestrzeni parametrów, które dobrze radzą sobie z konkretnymi zadaniami. Autorzy przedstawiają tę ideę poprzez reprezentację wykonalnych regionów przestrzeni parametrów jako hiperprostokątów, co redukuje złożoność problemu. Wprowadzono formułę interwałową sieci neuronowej, gdzie parametry sieci są postrzegane jako interwały, tworząc hiperprostokąt w przestrzeni parametrów. Przy tej formułowaniu, możliwe jest obliczenie zbioru przewidywań dla każdego wejścia, wybierając dowolne parametry z tego hiperprostokąta. Podczas treningu na sekwencji zadań wymagane jest, aby hiperprostokąt reprezentujący dobre rozwiązania dla bieżącego zadania był podzbiorem regionu parametrów reprezentujących rozwiązania dla poprzednich zadań. Zastosowano tę ideę w ustawieniu ciągłego uczenia, używając arytmetyki interwałowej do obliczenia najgorszej możliwej wydajności na hiperprostokącie. Ponieważ parametry nie opuszczą hiperprostokąta podczas reszty treningu, ta wartość będzie dolnym ograniczeniem najgorszej wydajności. Metoda ta, znana jako InterContiNet, została zaimplementowana w praktyce w sieciach neuronowych składających się z warstw liniowych i konwolucyjnych i przetestowana na standardowych benchmarkach ciągłego uczenia nadzorowanego, takich jak Split-MNIST i Split-CIFAR. Wyniki wykazały, że metoda ta osiąga podobną wydajność jak standardowe metody regularyzacji, jednocześnie zapewniając gwarancje na zapominanie.

Podsumowując, praca ta zaproponowała pierwszą metodę ogólnego ciągłego uczenia, która nakłada twarde ograniczenia na zapominanie. Przez parametryzację wag sieci neuronowej jako hiperprostokąta i wykorzystanie arytmetyki interwałowej do znalezienia najgorszej dokładności na bieżącym zadaniu, zapewniono, że dokładność nie spadnie poniżej obliczonego progu

podczas kontynuowania treningu na kolejnych zadaniach. Metoda ta wykazała podobną lub lepszą wydajność niż poprzednie podejścia, zapewniając jednocześnie gwarancje na zapominanie.

Praca czwarta „Zero Time Waste: Recycling Predictions in Early Exit Neural Networks” proponuje metodę adaptacji wytrenowanego modelu do warunkowego obliczenia. W pracy tej skupiono się na metodach wczesnego wyjścia, popularnych w kontekście warunkowych obliczeń, które zmieniają ścieżkę obliczeniową w zależności od przykładu. W modelach klasyfikacyjnych standardowe sieci neuronowe mają zazwyczaj pojedynczy klasyfikator na końcu sieci, który jest aktywowany po sekwencyjnym przetworzeniu wejścia przez wszystkie warstwy. Metody wczesnego wyjścia wprowadzają dodatkowe klasyfikatory, tzw. wewnętrzne klasyfikatory (IC), po wybranych ukrytych warstwach sieci neuronowej. Pozwala to na zatrzymanie przetwarzania przy każdym wewnętrznym klasyfikatorze i podjęcie decyzji, czy odpowiedzieć na podstawie jego przewidywań. Jeśli zdecydujemy się na wczesną odpowiedź, oszczędzamy koszty obliczeniowe, ponieważ przykład nie jest przetwarzany przez pozostałe warstwy sieci.

W pracy IV skupiono się na problemie marnotrawstwa w metodach wczesnego wyjścia w kontekście adaptacji istniejących wytrenowanych modeli. Badano kwestię ponownego wykorzystania informacji między wewnętrznymi klasyfikatorami. Wprowadzono metrykę *Hindsight Improvability*, która pokazuje, ile błędów można by uniknąć, efektywnie wykorzystując przewidywania poprzednich klasyfikatorów. Odkryto, że potencjalne korzyści z ponownego wykorzystania wiedzy są znaczące. W celu zmniejszenia marnotrawstwa wiedzy i wykorzystania potencjalnych poprawek, wprowadzono dwie techniki do ponownego wykorzystania obliczeń z poprzednich klasyfikatorów wewnętrznych. Po pierwsze, zaproponowano kaskadowanie, czyli dodanie połączeń rezydualnych między kolejnymi wewnętrznymi klasyfikatorami, co umożliwi bezpośrednie wykorzystanie informacji. Po drugie, wprowadzono agregację, czyli agregowanie przewidywań wszystkich poprzednich klasyfikatorów wewnętrznych za pomocą ważonej średniej geometrycznej. Łącząc te dwa podejścia, stworzono metodę Zero Time Waste (ZTW), która minimalizuje marnotrawstwo obliczeniowe w metodach wczesnego wyjścia.

W Publikacji [IV] pokazano, że to podejście działa bardzo dobrze na standardowych benchmarkach wczesnego wyjścia w porównaniu z poprzednimi pracami. Badano kilka standardowych zestawów danych i architektur wizji komputerowej, pokazując, że poprawki oferowane przez ZTW są znaczące.

Ponadto, przeprowadzono eksperymenty w paradygmacie uczenia transferowego i przeprowadzono dokładne badania ablatywne, również pokazując znaczne ulepszenia. Pokazano również, że ZTW może być stosowane w uczeniu ze wzmocnieniem, co, według autorów, było pierwszym zastosowaniem metod wczesnego wyjścia w tym ustawieniu.

Podsumowując, praca IV pokazuje, że modele z wczesnym wyjściem dostosowane z architektur o statycznej ścieżce obliczeniowej są marnotrawne. Klasyfikatory wczesnego wyjścia często przewidują poprawnie, ale bez wystarczającej pewności, dlatego ich wkład jest odrzucany. Metoda Zero Time Waste łączy połączenia kaskadowe i agregację wczesnych wyjść, aby zwalczyć tę nieefektywność. Zaproponowane podejście przewyższa poprzednie prace w tej dziedzinie i może być z powodzeniem stosowane w scenariuszach uczenia ze wzmocnieniem, stanowiąc znaczący osiągnięcie w problemie adaptacji w warunkowych obliczeniach.

Praca piąta „PluGeN: Multi-Label Conditional Generation From Pre-Trained Models” przedstawia problem kontrolowania procesu generacji w nienadzorowanych modelach generatywnych. Autorzy zauważają, że modele generatywne, chociaż skuteczne w modelowaniu złożonych rozkładów, często mają ograniczoną zdolność do kontrolowania procesu generacji, zwłaszcza w odniesieniu do konkretnych cech czy atrybutów. Rozwiązaniem może być ponowne trenowanie modelu z wprowadzeniem czynników warunkujących, lecz jest to podejście kosztowne i skomplikowane.

W pracy V wprowadzono PluGeN (Plugin Generative Network), metodę umożliwiającą generację warunkową w nienadzorowanych modelach generatywnych. PluGeN działa na przestrzeni modeli ukrytych (latent), która zwykle nie jest uporządkowana w stosunku do dostępnych atrybutów. Autorzy proponują odwracalną operację, pozwalającą przejść od nieustrukturyzowanej przestrzeni ukrytej do specjalnie skonstruowanej, rozłącznej przestrzeni ukrytej. W tej przestrzeni każdy atrybut odpowiada określonemu wymiarowi, co ułatwia modyfikację i próbkowanie konkretnych atrybutów. Do osiągnięcia rozłączenia wykorzystano przepływ normalizujący (normalizing flow), model generatywny zdolny do modelowania danych poprzez odwracalną operację z łatwo obliczalnym wyznacznikiem macierzy Jacobiego.

Dzięki zaproponowanej metodzie możliwe jest swobodne przejście między tymi dwiema przestrzeniami ukrytymi, co umożliwia próbkowanie lub modyfikowanie przykładów w uporządkowanej przestrzeni, a następnie

przetwarzanie ich za pomocą głównego modelu generatywnego. Autorzy zastosowali PluGeN z trzema różnymi modelami podstawowymi, demonstrując jego użyteczność w wizji komputerowej i chemoinformatyce, np. w trudnym zadaniu generowania cząsteczek. Przeprowadzone eksperymenty pokazują wysoką zdolność podejścia do zadań takich jak warunkowa generacja nowych próbek, modyfikacja istniejących przykładów oraz interpolacja między różnymi wartościami atrybutów. Dodatkowo, pokazano, że zaproponowana formuła struktury przestrzeni ukrytej prowadzi do znakomitych wyników w trudnych zadaniach generalizacji.

Podsumowując, praca V proponuje sposób na efektywną adaptację i kontrolę procesu generacji istniejących modeli. PluGeN wykorzystuje przepływy normalizujące do nadzorowanego rozłączenia przestrzeni ukrytej wytrenowanego modelu generatywnego. Zmieniając kody ukryte w rozłączonej przestrzeni, można modyfikować generowane próbki i generować nowe o pożądanych właściwościach. Metoda ta osiąga bardzo dobre wyniki w tych zadaniach oraz w ekstrapolacji i generowaniu próbek z rzadkimi kombinacjami atrybutów, stanowiąc znaczący wkład w modelowanie generatywne.

Poniżej postaram się w skrócie podsumować kluczowe osiągnięcia badawcze doktoranta, które zostały przedstawione przez autora i streszczone powyżej przez recenzenta:

- *Adaptacja Modeli Głębokiego Uczenia:* mgr Maciej Wołczyk bada adaptację modeli głębokiego uczenia do zmieniających się strumieni danych i nowych zadań, co jest kluczowe dla rozwoju sztucznej inteligencji, szczególnie w kontekście ciągłego uczenia i uczenia ze wzmocnieniem.
- *Benchmarki dla Ciągłego Uczenia Ze Wzmocnieniem:* Opracował benchmarki dla ciągłego uczenia ze wzmocnieniem z zastosowaniem w robotyce, w tym metryki pozwalające na ocenę zapominania i transferu wiedzy, co ma znaczenie dla praktycznego wykorzystania modeli w zmieniających się warunkach.
- *Strategie Przeciwdziałania Zapominaniu:* Zaproponował metody gwarantujące ograniczenie zapominania w ciągłym uczeniu, co jest istotne w krytycznych zastosowaniach takich jak autonomiczna jazda czy aplikacje medyczne.
- *Optymalizacja Wykorzystania Zasobów Obliczeniowych:* Przedstawił metody, takie jak Zero Time Waste, które efektywniej wykorzystują zasoby obliczeniowe przez recykling przewidywań w sieciach neuronowych z wczesnym wyjściem, co pozwala na oszczędności i przyspieszenie procesu uczenia.

- *Kontrolowanie Procesu Tworzenia Danych w Modelach Generatywnych:* Opracował metodę PluGeN, która pozwala na kontrolę procesu generacji w nienadzorowanych modelach generatywnych, umożliwiając tworzenie danych z pożądanymi cechami.
- *Publikacje i Wpływ na Społeczność Naukową:* Prace Doktoranta zostały opublikowane na prestiżowych konferencjach i zyskały uznanie w społeczności naukowej, co świadczy o ich znaczącym wkładzie w dziedzinę uczenia maszynowego.
- *Współpraca Międzynarodowa i Aktywność Naukowa:* mgr. Maciej Wołczyk współpracował międzynarodowo i miał istotny udział w badaniach, co przyczyniło się do stworzenia innowacyjnych rozwiązań w obszarze uczenia głębokiego.

Na koniec przedstawiony są inne dokonania doktoranta oraz lista publikacji nie wchodząca w skład przedstawionych szczegółowo doniesień konferencyjnych. Kandydat zasygnalizował różne własne osiągnięcia badawcze, niezwiązane bezpośrednio z problemem adaptacyjności, ale stanowiące znaczący wkład w dziedzinę głębokiego uczenia. Chciałbym wymienić kilka z nich: (i) badania nad modelami generatywnymi, np. nad reprezentacją obrazów za pomocą hiper-sieci; (ii) praca nad rozłącznymi reprezentacjami i ich związkiem z uczeniem wielozadaniowym; (iii) staż Badawczy w Lyft, gdzie pracował nad modułami planowania dla autonomicznych pojazdów, co zaowocowało współautorstwem dwóch publikacji; (iv) opublikowanie jako współautor podręcznika "*Głębokie uczenie. Wprowadzenie*", który obejmuje tematy od klasycznego uczenia maszynowego po złożone architektury oparte na uczeniu głębokim; (v) współautorstwo artykułów opublikowanych w takich czasopismach jak IEEE Transactions on Neural Networks and Learning Systems oraz konferencjach CORE A i B; (vi) współpraca badawcza w ramach grantów NCN Opus i innych; (vii) współpraca z ekspertami z ETH Zurich, Google Deepmind, Know-Center GmbH, a także z zespołami badawczymi z IMPAN i Politechniki Warszawskiej oraz międzynarodowe staże badawcze ETH Zurich i Woven Planet/Lyft Level-5.

Należy również wspomnieć aktywne recenzowanie manuskryptów w konferencjach o randze A* jak ICML, NeurIPS, ICLR i innych; współorganizację szkół letnich i warsztatów z zakresu uczenia maszynowego i wiele innych osiągnięć osobistych i naukowych.

Pytania do doktoranta:

Opracowane metody prezentują interesujące i innowacyjne koncepcje, które oczywiście wymagają dalszych badań. Prosiłbym o skomentowanie w trakcie obrony następujących ogólnych kwestii dla wybranych przykładów z całości cyklu publikacji:

- *Zastosowania Praktyczne*: Jakie są potencjalne praktyczne zastosowania dla opracowanych metod adaptacji w ciągłym uczeniu ze wzmocnieniem? Czy mogą one być bezpośrednio stosowane w przemyśle, na przykład w robotyce lub autonomicznej jeździe?
- *Ograniczenia*: Jakie są główne ograniczenia opracowanych przez Pana metod i jak mogą one wpływać na ich efektywność w realnych warunkach?
- *Porównanie z Istniejącymi Rozwiązaniami*: Jak nowe metody, takie jak PluGeN czy Zero Time Waste, wypadają na tle istniejących podejść pod względem efektywności, dokładności i kosztów obliczeniowych?
- *Wytyczne dla Przyszłych Badań*: Patrząc w przyszłość, jakie wytyczne dla przyszłych prac można zaproponować, jakie są kolejne najbliższe kroki w dalszym rozwoju tych metod?
- *Staż Przemysłowy*: Doceniając staż przemysłowy Doktoranta chciałbym zapytać jakie wnioski można wyciągnąć z sześciomiesięcznego stażu w Lyft Level-5 i czy przełożyły się, a jeśli tak to jak na rozwój metod teoretycznych w doktoracie?
- *Proces Zapominania*: Jakie są praktyczne implikacje zapewnienia gwarancji przeciwdziałania zapominaniu w modelach ciągłego uczenia i czy istnieją scenariusze, w których te gwarancje mogą być ograniczone?
- *Ryzyka implementacyjne*: Jakie są potencjalne ryzyka związane z szerokim wdrożeniem modeli adaptacyjnych w rzeczywistych aplikacjach i jak można im zapobiegać? W szczególności w przypadku dużych modeli głębokich - jakie są ograniczenia w zakresie skalowalności i wydajności zaproponowanych metod w kontekście rosnących wymagań dotyczących wielkości i złożoności danych?

Wnioski końcowe

W podsumowaniu oceny rozprawy doktorskiej pana mgr Macieja Wolczyka pt. "*Adaptiveness in Deep Learning Models*", pragnę wyrazić moje wysokie uznanie dla przedstawionej pracy. Suma punktów ministerialnych w Polsce wynosi 1000. Jest to wynik wyjątkowy, nawet jeśli uwzględnimy współautorskość zamieszczonych publikacji.

Podsumowując, osiągnięcia mgr. Macieja Wołczyka odzwierciedlają głębokie zrozumienie i innowacyjne podejście do problemów adaptacji, ciągłego uczenia oraz efektywności w dziedzinie sztucznej inteligencji i głębokiego uczenia. Osiągnięcia Macieja Wołczyka świadczą o jego aktywnym i znaczącym udziale w badaniach naukowych w dziedzinie głębokiego uczenia.

Biorąc pod uwagę wartość naukową rozprawy doktorskiej, udane połączenie starannie opisanych narzędzi uczenia głębokiego, a także istotnych eksperymentów benchmarkowych i zadawanych fundamentalnych pytań badawczych, uważam rozprawę doktorską pana mgr Macieja Wołczyka za znaczący wkład w dyscyplinę Informatyki Technicznej i Telekomunikacji.

Rozprawa doktorska spełnia warunki określone w Art. 187 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz. U. z 2021 r. poz. 478, 619, 1630). Ponadto uważam, że rozprawa ta przewyższa powszechne i ustawowe wymagania stawiane rozprawom doktorskim, stanowi oryginalne rozwiązanie problemu naukowego, wykazuje ogólną wiedzę informatyczną, oraz demonstuje zdolność do samodzielnego prowadzenia pracy naukowej.

W związku z powyższym, mam przyjemność przedłożyć Radzie Dyscypliny Naukowej Informatyki Technicznej i Telekomunikacji Uniwersytetu Jagiellońskiego wniosek o dopuszczenie pana mgr Macieja Wołczyka do dalszych etapów przewodu doktorskiego.

Ponadto, zważywszy na wysoki poziom merytoryczny i obszerność rozprawy, jej staranne przygotowanie oraz klarowny sposób prezentacji tematyki badawczej, metodyki i wyników, wnioskuję o wyróżnienie rozprawy odpowiednią nagrodą.



Dariusz Plewczynski, PhD, Professor of Exact and Natural Sciences; Principal Investigator
Phone: +48 22 554 36 54 or +48 22 234 7219

e-mail: d.plewczynski@cent.uw.edu.pl or Dariusz.Plewczynski@pw.edu.pl www: <https://plewczynski-lab.org>

Laboratory of Functional and Structural Genomics LFSG

Centre of New Technologies, University of Warsaw; Banacha 2c Street, 02-097 Warsaw, Poland

Laboratory of Bioinformatics and Computational Genomics LB!GO

Faculty of Mathematics and Information Science, Warsaw University of Technology; ul.

Koszykowa 75, 00-662 Warsaw, Poland