



Rada Naukowa Dyscypliny
INFORMATYKA TECHNICZNA
I TELEKOMUNIKACJA

Sekretariat

Data wpływu.....23.06.2026.

Numer.....

dr hab. inż. Paweł Morawiecki, prof. IPI PAN

Warszawa, 08.06.2026

Paweł Morawiecki

Recenzja rozprawy doktorskiej „Continual Learning without Access to Past Data” autorstwa Grzegorza Rypeścia

Tematyka rozprawy

Tematyka rozprawy doktorskiej skupia się na problemie uczenia ciągłego (ustawicznego) w kontekście sztucznych sieci neuronowych. Ogólnie rzecz ujmując, problem podjęty przez Doktoranta polega na tym, że podczas uczenia nowego zadania model często „nadpisuje” wcześniejszą wiedzę co prowadzi do zjawiska zwanego katastroficznym zapominaniem. Model traci nabyte wcześniej zdolności np. poprawne klasyfikowanie uprzednio nauczonych klas obiektów. W rozprawie badany jest najtrudniejszy wariant tego problemu, gdzie zakładamy brak dostępu do wcześniej widzianych próbek/przykładów ze zbioru uczącego.

W autoreferacie sformułowano pięć hipotez badawczych, które Autor weryfikuje w swoich pracach.

1. W jaki sposób izolacja architektoniczna i selektywne aktualizacje parametrów (wag) mogą zostać wykorzystane do ograniczenia zapominania bez zwiększania narzutu pamięciowego?
2. W jaki sposób można zrównoważyć dylemat stabilności i plastyczności w scenariuszach częściowo nadzorowanych, w których występuje niedobór etykiet?
3. Jak ewoluują reprezentacje wcześniejszych klas podczas przyswajania nowych zadań i czy można dokładnie przewidywać te przesunięcia?
4. Czy można zastosować korekty statystyczne (adaptacja kowariancji) do rozkładów dawnych klas, aby przywrócić ich trafność i poprawić granice decyzyjne?

5. W jakim stopniu załamanie wymiarowości w przestrzeniach ukrytych (ang. latent space) przyczynia się do preferowania najnowszych zadań i za pomocą jakich mechanizmów można temu zapobiegać?

Odpowiedzi na powyższe pytania zostały przedstawione w zwięzłej formie w końcowej części Autoreferatu, natomiast po szczegółowe badania i wyniki Doktorant odsyła do cyklu publikacji.

Cykl publikacji

Praca składa się z cyklu trzech publikacji. Poniżej przedstawiam krótką charakterystykę prac.

1. „Divide and not forget: Ensemble of selectively trained experts in Continual Learning” The Twelfth International Conference on Learning Representations (ICLR), (2024).

Zaproponowana w pracy metoda SEED (Selection of Experts for Ensemble Diversification) wykorzystuje zespół ekspertów, ale nie trenuje wszystkich modeli jednocześnie. Dla każdego nowego zadania wybierany jest tylko jeden ekspert, ten, którego douczenie powinno spowodować najmniejszy dryf reprezentacji i najmniejsze zapominanie. Wybór eksperta opiera się na reprezentowaniu klas jako wielowymiarowych rozkładów Gaussa. Dzięki temu metoda łączy plastyczność (możliwość uczenia nowych klas) ze stabilnością, czyli ochroną wcześniejszej wiedzy. Praca odpowiada na pierwsze pytania badawcze dotyczące izolacji parametrów i selektywnej aktualizacji.

2. „Category Adaptation Meets Projected Distillation in Generalized Continual Category Discovery”, The European Conference on Computer Vision (ECCV), (2024).

Publikacja dotyczy trudniejszego i bardziej realistycznego scenariusza: model dostaje kolejne porcje danych, ale część danych jest nieetykietowana, a wśród nich mogą pojawiać się nowe, wcześniej nieznanne kategorie. Metoda CAMP łączy dwa mechanizmy. Pierwszy to destylacja wiedzy, która pomaga zachować wcześniejsze umiejętności modelu. Drugi to adaptacja kategorii, czyli korekta reprezentacji wcześniejszych klas po tym, jak model nauczył się nowych danych. Autorzy wskazują, że sama destylacja może zbyt mocno „usztyniać” model, przez co trudniej mu odkrywać nowe klasy. CAMP próbuje rozwiązać ten konflikt przez zastosowanie projektowanej destylacji i sieci adaptującej centroidy kategorii.

3. „Task-recency bias strikes back: Adapting covariances in Exemplar-Free Class Incremental Learning”, (NeurIPS), (2024)

Autorzy skupiają się na następującym problemie: podczas gdy model uczy się kolejnych zadań, jego przestrzeń reprezentacji się zmienia, a zapamiętane statystyki dawnych klas (średnie i kowariancje) przestają pasować do aktualnego modelu.

Wprowadzona metoda AdaGauss adaptuje zarówno średnie, jak i macierze kowariancji dawnych klas, żeby przywrócić ich zgodność z aktualną przestrzenią cech. Publikacja identyfikuje też ważny mechanizm błędu: task-recency bias, czyli tendencję modelu do faworyzowania najnowszych klas. Autorzy wiążą ją z „dimensionality collapse”, który prowadzi do problemów z macierzami kowariancji i zaburzonych granic decyzyjnych.

Redakcja Tekstu

Autoreferat i publikacje są napisane starannie, poprawnym angielskim. Wprowadzenie w tematykę badań i podkreślenie kluczowych problemów i wyzwań jest pomocne. Znalazłem tylko kilku drobnych uchybień:

- brakuje konsekwencji w stosowaniu łącznika w wyrazach (zbitkach wyrazów): exemplar-free, trade-off, task-recency. Czasem na jednej stronie są dwie różne wersje.

- zdanie „This section provides a short summary of each one of them, what aforementioned research questions and contributions they address.” (strona 30) nie brzmi jak angielski.

Uwagi i pytania

Podczas lektury rozprawy nasunęły mi się następujące pytania:

1. Czy któreś z przedstawionych metod mogłyby zostać zaaplikowane do treningu LLM'ów (gdzie nie ma jasno postawionych zadań, a wyzwanie uczenia ciągłego wciąż zostaje)?
2. Czy w pracy 2 i 3 w istocie nie jest eksploatowany ten sam pomysł? Tj. użycie mniejszej sieci adaptującej cechy rozkładu? Czy praca nr 3 powstała jako naturalne rozwinięcie pomysłu z wcześniejszej publikacji (już nie centroidy ale średnie i kowariancje)?
3. Jeśli faktycznie potraktować pracę nr 3 jako pewne uogólnienie/rozwinięcie wcześniejszego pomysłu, to czy można pójść jeszcze dalej (np. mieszanka gaussowska czy coś bogatszego niż średnia i kowariancja)?

Konkluzja

Przedłożony cykl prac oceniam wysoko, prace dotyczą ważnego problemu z dużym potencjałem naukowo-aplikacyjnym, a uzyskane wyniki są przekonujące. Uważam, że złożona rozprawa mgr Grzegorza Rypeścia spełnia wymagania ustawowe i zwyczajowe stawiane pracom doktorskim i może stanowić podstawę nadania stopnia doktora.

Biorąc pod uwagę uzyskane wyniki i miejsca publikacji, wnioskuję o wyróżnienie rozprawy.

Prof. dr hab. Andrzej Kuczyński