

dr hab. inż. Maciej Zięba, prof. PWr
Katedra Sztucznej Inteligencji
Wydział Informatyki i Telekomunikacji
Politechnika Wrocławska
maciej.zieba@pwr.edu.pl

Wrocław, 31 stycznia 2026 r.

Recenzja rozprawy doktorskiej

Andriia Krutsylo

zatytułowanej:

Continual Learning with Experience Replay

1. Problem badawczy i jego znaczenie

Obszar badawczy doktoranta obejmuje opracowanie metod uczenia ciągłego z mechanizmami powtarzania. Tematyka ta wpisuje się w jeden z głównych nurtów uczenia maszynowego nad którym pracują wiodące zespoły na całym świecie. Mimo to, w moim przekonaniu istnieją problemy związane z uczeniem ciągłym, które dalej nie zostały w pełni rozwiązane. Autor koncentruje się na konkretnej grupie podejść z mechanizmem powtarzania, proponując szereg nowych metod agregacji przykładów oraz nową metodykę testowania. Praca niestety nie zawiera wprost zdefiniowanej hipotezy badawczej, natomiast posiada jasno zdefiniowany cel:

The overarching goal of this dissertation is to advance the understanding and effectiveness of replay-based approaches for continual learning in the supervised online class-incremental setting.

W moim przekonaniu jest on jasny, ambitny i odpowiada wymogom stawianym rozprawom doktorskim. Efektem realizacji celu jest szereg kontrybucji, które autor kategoryzuje jako teoretyczne, algorytmiczne, metodyczne oraz ewaluacyjne. Wkład pracy jest znaczący, klarowny, poparty w treści pracami wynikami które realizują postawiony cel badawczy.

Podsumowując, uważam że problem badawczy rozwiązywany przez doktoranta jest bardzo istotny i aktualny. Cel pracy jest dobrze postawiony, a proponowane rozwiązania wpisują się w główny nurt badań dotyczący metod uczenia maszynowego.

2. Wkład autora

W ramach pracy autor proponuje trzy techniki agregacji danych na potrzeby powtarzania w zadaniach uczenia ciągłego. Pierwsza z technik zakłada wykorzystanie informacyjnych reprezentacji obserwacji z autorską techniką podmiany danych w buforze. Drugie podejście wykorzystuje uczenie Hebb'a i agregację danych bezpośrednio w wagach modelu. Ostatni z modeli wykorzystuje reprezentację współdzieloną z semantycznym odpowiednikiem klas, aby osadzić dane w odseparowanej semantycznie przestrzeni bez konieczności przechowywania danych wizyjnych podczas inferencji. Opracowane rozwiązania są ciekawe i nowatorskie, zostały przebadane w metodycznie poprawny sposób, wykorzystując znane i dostępne zbiory danych. Otrzymane wyniki wskazują wysoką jakość na tle rozwiązań referencyjnych.

W dalszej kolejności autor proponuje dwie techniki próbkowania na potrzeby douczania modeli w trybie powtarzania. Szczególnie interesująca w tym obszarze badań jest przeprowadzona przez autora teoretyczna analiza konstrukcji minibatchy na potrzeby douczania modeli w zależności od tego czy dane próbki pochodzą z bieżącego, czy z danych dotyczących poprzednich zdań przechowywanych w buforze. Na koniec doktorant wprowadza nową miarę do oceny stopnia zapamiętywania modeli w uczeniu ciągłym. Wkład autora w dziedzinę jest w pracy dobrze opisany i klarowny, koncentruje się zarówno na opracowywaniu nowych architektur uczenia ciągłego, jak i kompleksowej analizie porównawczej z metodami istniejącymi w literaturze. Przedstawione rozwiązania są spójne tematycznie, klarownie i stanowią ważny wkład w dziedzinę. Wkład autora poparty jest publikacjami pokrywającymi się z zakresem doktoratu, na które składa się sześć publikacji, z tego trzech, dla których doktorant jest jedynym autorem. Wśród publikacji warto wyróżnić publikacje 140-punktowe, na konferencji HICSS oraz w czasopiśmie Neurocomputing. Dorobek kandydata związany z tematem uzupełniają liczne wystąpienia na warsztatach towarzyszących renomowanym konferencjom, takim jak AAAI, czy NeurIPS. Mimo iż prace z takich wydarzeń często nie są punktowane, to podlegają one rzetelnemu procesowi oceny przez renomowanych recenzentów dziedzinowych i często stanowią ważny wkład w dziedzinę. Warto nadmienić iż dużo publikacji i wystąpień jest jednoautorskich co pozwala obiektywnie stwierdzić, że wkład Doktoranta był tutaj wiodący i niepodważalny.

Do najważniejszych osiągnięć rozprawy zaliczam:

1. Opracowanie metody HebbCL, która w sprytny sposób wykorzystuje uczenie Hebba do agregacji danych w wagach modelu. Technika ta nie wymaga zewnętrznego przechowywania danych w buforze, co wpisuje się w obecne trendy uczenia ciągłego. Podejście to umożliwia zarówno uczenie w trybie nienadzorowanym, jak i trybie nienadzorowanym co znacznie poszerza możliwy aspekt aplikacyjny. Podejście jest ciekawe od strony teoretycznej, a jakość jego jest potwierdzona na tle rozwiązań referencyjnych.
2. Opracowanie metody CVM, która wykorzystuje reprezentacje semantyczne do budowy osadzeń danych. Metoda proponuje sprytnie wykorzystanie LLMów do uczenia się dyskryminujących reprezentacji dzielących modalność tekstu i danych. Dzięki generalizacji reprezentacji semantycznej wynikającej z różnorodności danych wykorzystanych do uczenia modelu językowego obserwacje z nowych zadań są alokowane do zarezerwowanych odseparowanych obszarów. Opracowany model dobrze wkomponowuje się w obecne trendy uczenia ciągłego, które podejmują się wykorzystania współczesnych modeli językowych do tego typu zadań.
3. Opracowanie technik wyboru obserwacji w ramach procesu douczania modeli. Autor podnosi dosyć istotny, często pomijany temat, proponując kompleksową, uzasadnioną teoretycznie analizę tego zjawiska w odniesieniu do łączenia próbek z bufora z przykładami z bieżącego zadania. Wyniki przeprowadzonej analizy pokazują że tego rodzaju separacja danych ma istotny wpływ na jakość działania modelu. W konsekwencji istniejące metody uczenia ciągłego z powtarzaniem powinny być ewaluowane biorąc pod uwagę każde z podejść do próbkowania. Ciekawym elementem pracy jest również metoda Batch Sampling, która wykorzystuje techniki aktywnego uczenia do konstrukcji batchy treningowych.

Podsumowując, autor w swojej rozprawie zaproponował szereg metod które wzbogacają w znacznym stopniu rodzinę modeli dedykowanych do problemu uczenia ciągłego. Większość dorobku doktoranta koncentruje się na opracowaniu nowych i ciekawych rozwiązań algorytmicznych. Wkład autora, jak i jakość, innowacyjność i kompletność opracowanych rozwiązań oceniam wysoko.

3. Poprawność

Rozprawa zredagowana została poprawnie i starannie, rozdziały zorganizowane są w logiczny i uporządkowany sposób. Autor rozprawy posiada silny warsztat badacza, proponowane nowe podejścia są uzasadnione teoretycznie i poparte licznymi eksperymentami, które są przeprowadzone metodycznie poprawnie. Praca napisana w j. angielskim poprawnym językiem, bez większych błędów gramatycznych i stylistycznych.

Lektura rozprawy prowadzi jednak do kilku pytań i uwag krytycznych:

1. Metoda Deep Features Buffer wykorzystuje reprezentację pochodzącą z modelu głębokiego do wyboru przykładów, które mają być zagregowane w buforze. Nie jest dla mnie jasne jakie jest kryterium wyboru modelu głębokiego, który wykorzystany został do reprezentacji. Istotną wartością dodaną w tym przypadku byłoby przeanalizowanie kilku różnych architektur głębokich w badaniach eksperymentalnych. Lekkim ograniczeniem jest również wykorzystanie obrazów o niskiej wymiarowości, co może poddawać w wątpliwość stosowanie rozwiązania we współczesnych problemach uczenia ciągłego.

2. W algorytmie HebbCL w trybie nienadzorowanym autor zdecydował się porównać wyniki podejścia z modelem CURL, który wykorzystuje procedurę generatywnego powtarzania. Prosiłbym o uzasadnienie wyboru tej metody jako podejścia referencyjnego. Cemu doktorant nie wziął pod uwagę innych podejść generatywnych dla powtarzania w uczeniu ciągłym?

3. Algorytm HebbCL jest bardzo interesującym i nowatorskim rozwiązaniem. Wydaje się natomiast, że ze względu na specyfikę uczenia Hebba może być nieefektywny i ciężki do zastosowania dla danych złożonych, wielowymiarowych danych. Wyniki badań empirycznych potwierdzają jakość podejścia na tle metod referencyjnych, natomiast badania zostały przeprowadzone na obrazach o niskiej rozdzielczości. Interesujące jest również jak jakość podejścia zachowuje się wraz ze wzrostem liczby zadań w uczeniu ciągłym. Czy fakt, iż wiedza z poprzednich zadań przechowywana jest w wagach modelu nie jest w tym przypadku dużym ograniczeniem?

4. Metoda Continual Visual Mapping wykorzystuje trenowalny enkoder dla obrazów i nietrenowalny komponent LLM do reprezentowania konceptów tekstowo. Nasuwa się pytanie, czemu autor rozprawy nie skorzystał z rozwiązania pozwalającego na reprezentowanie tych dwóch modalności jednocześnie, takiego jak CLIP. Ponadto, porównanie się do takiego modelu referencyjnego znacznie wzbogaciłoby wyniki proponowanego podejścia.

5. Podejście Batch Sampling wykorzystuje proces aktywnego uczenia w którym liczone odległości między obserwacjami w batchach. W moim przekonaniu ten proces może znacznie spowalniać uczenie, gdyż ta operacja jest wykonywana w każdym kroku operacji gradientowej. Czy autor analizował te opóźnienia w zależności od liczby obserwacji w batchu i długości reprezentacji osadzeń?

6. Wydaje się, że podejścia opisane w pracy charakteryzują się wyższym potencjałem publikacyjnym, niż miejsca w których zostały opublikowane. Interesuje mnie jakie kwestie zadecydowały o tych decyzjach publikacyjnych?

4. Podsumowanie

Doktorant wykazał się w recenzowanej rozprawie właściwie stosowanym podejściem eksperymentalnym oraz dobrą znajomością aktualnej problematyki związanej z opracowywaniem metod uczenia głębokiego dla uczenia ciągłego z powtarzaniem. Dla poruszanych problemów doktorant sformułował kilka ciekawych i użytecznych architektur, które mogą mieć szerokie zastosowania praktyczne. Bardzo doceniam też spójność i kompletność pracy.

Przedstawione w punkcie 3 recenzji uwagi nie wpływają na pozytywne wrażenie o przedłożonej rozprawie. Jestem przekonany, że doktorant zdaje sobie sprawę z możliwości kontynuowania rozpoczętej w pracy tematyki, czemu dał wyraz prezentując dość ciekawy plan potencjalnych kierunków badań.

Reasumując, biorąc pod uwagę powyższe opinie i wymagania zawarte w Ustawie - Prawo o szkolnictwie wyższym i nauce (t.j. Dz. U. z 2024 r. poz. 1571), stwierdzam, że rozprawa mgra Andriia Krutysylo pt. *Continual Learning with Experience Replay* **spełnia wymagania** stawiane pracom doktorskim, w szczególności:

- Rozprawa zawiera szereg nowatorskich metod z obszaru uczenia maszynowego, w szczególności metod uczenia ciągłego.
- Kandydat posiada ugruntowaną, głęboką wiedzę w dyscyplinie Informatyka Techniczna i Telekomunikacja.
- Doktorant posiada umiejętność samodzielnego prowadzenia pracy naukowej.

Stąd, wnoszę o jej przyjęcie i dopuszczenie mgra Andriia Krutysylo do publicznej obrony.

Podpis jest prawidłowy

Dokument podpisany przez
Maciej Mateusz Zięba
Data: 2026.02.03 11:30:04 CET

Podpis