

Recenzja rozprawy doktorskiej  
*Andriia Krutsylo*  
zatytułowanej:  
*Continual Learning with Experience Replay*

## 1. Problem badawczy i jego znaczenie

W pracy rozważane są problemy ciągłego uczenia, głównie dla w scenariusza *class incremental learning*. Praca ma charakter naukowy - doktorant proponuje w pracy autorskie algorytmy dla rozważanego zadania oraz dokonuje ich ewaluacji na drodze eksperymentu komputerowego. Dodatkowo, w ramach pracy zaproponowano nową metrykę, która może być przydatna w ocenie jakości metod ciągłego uczenia. Opracowane metody mogą znaleźć szerokie zastosowanie praktyczne.

## 2. Wkład autora

W rozprawie nie sformułowano tezy, jednakże dość precyzyjnie określono główny cel badań, tj. opracowanie metod zwiększających jakość algorytmów ciągłego uczenia bazujących na powtórkach, a także potrzebę ujednolicenia protokołów oceny tego typu algorytmów. Cele szczegółowe określono w ramach trzech obszarów badawczych:

- (i) Opracowanie strategii tworzenia bufora danych z już prezentowanych zadań (klas).
- (ii) Opracowanie metod wykorzystywania danych zawartych w buforze w przypadku pojawienia się nowych zadań.
- (iii) Ocena jakości metod ciągłego uczenia.

Postawione cele i pytania uważam za ciekawe, dobrze sformułowane i ważne dla dziedziny ciągłego uczenia maszynowego.

Do najważniejszych osiągnięć rozprawy zaliczam:

- 1. Zaproponowanie algorytmu *Deep Features Buffer*, zapewniającego różnorodność przechowywanych próbek poprzez analizę ich reprezentacji cech.
- 2. Zaproponowanie nadzorowanej i nienadzorowanej wersji algorytmu HebbCL (*Hebbian Continual Learning*) umożliwiającego przechowywanie reprezentacji w wagach synaptycznych.
- 3. Opracowanie metody CVM (*Continual Visual Mapping*), która *de facto* eliminuje bufor pamięci poprzez zastosowanie zamrożonych dużych modeli językowych (LLM) jako semantycznych kotwic przypisanych do nowych klas.
- 4. Pokazanie, że wybór między jednoczesnym łączeniem, a oddzielaniem danych z poprzednich zadań od danych z bieżącego zadania zmienia dynamikę optymalizacji i może istotnie wpływać na skuteczność heurystyk wyboru danych do bufora.
- 5. Zaproponowane metody *Replay Batch Sampling* z zaproponowaną metryką *Batch Cosine Distance*, która służy do zidentyfikowania porcji danych, która wpłynie na największą zmianę reprezentacyjną w stosunku do obecnego modelu.

6. Zaproponowanie autorskiej metryki *Knowledge Retention*, która pozwala na oddzielenie rzeczywistego zachowania zgeneralizowanych reprezentacji od zjawiska ponownego uczenia się parametrów wprost z bufora.
7. Ocenę zaproponowanych metod na drodze eksperymentu komputerowego.

Wyniki rozprawy w dużej mierze bazują na sześciu artykułach doktoranta opublikowanych w materiałach konferencyjnych pięciu konferencji międzynarodowych (m.in. ESANN, ICANN, SAC) oraz czasopiśmie *Neurocomputing*. Oprócz tego, doktorant jest autorem trzech prac prezentowanych w trakcie warsztatów konferencji AAAI i *NeurIPS* oraz dwóch preprintów. Do prac współautorskich dostarczono oświadczenia współautorów, które potwierdzają dominujący wkład mgra Krutysło w ich powstanie. Na tym etapie kariery naukowej należy uznać dorobek doktoranta za dobry, choć wybór miejsc publikowania mógłby być ambitniejszy. Wiele zawartych w rozprawie dokonań zasługuje na prezentację w trakcie bardziej renomowanych konferencji.

### 3. Poprawność

Jak wspomniano tekst rozprawy bazuje na wspomnianym zbiorze artykułów, wręcz niektóre rozdziały, jak choćby związany z proponowaną metryką, są ich kopią. Często też zachowują one strukturę artykułu, co nie jest pożądane w przypadku opracowania dysertacji jako spójnego dzieła, a nie cyklu publikacji. Opis zaproponowanych algorytmów poprzedza krótkie wprowadzenie oraz omówienie najważniejszych wyników rozprawy. Poziom edytorski manuskryptu oceniam dobrze.

Z punktu widzenia warsztatu badawczego, autor formułuje propozycje swoich metod na podstawie solidnej analizy literatury, dostrzegając możliwości poprawy opisanych tam metod. Jako narzędzie ewaluacji przyjęto podejściu oparte głównie na eksperymencie komputerowym, jednakże część własności została także oceniona na drodze analitycznej.

Lektura rozprawy prowadzi do sformułowania kilku uwag.

1. Doktorant wykorzystuje jako jedną z metod referencyjnych znaną modyfikację algorytmu DER (*Dark Experience Replay*) DER++. W pracy zauważa on także pojawienie się metody X-DER, która zgodnie z wynikami zawartymi w publikacji nr 8 (zgodnie ze spisem literatury) uzyskuje zdecydowanie lepsze wyniki niż DER++. Dlaczego w eksperymentach nie wykorzystano X-DER?
2. Dlaczego zamiast MIR (*Maximally Interfered Retrieval*) nie zastosowano innych strategii np. stosowanej w opisanym iCaRL herding, gdzie wybiera się przykłady, których wektory w przestrzeni ukrytej najlepiej przybliżają średnią reprezentacji danej klasy. Wydaje się też, że ciekawą alternatywą jest też LARS (*Loss-Aware Reservoir Sampling*) (P. Buzzega et al., *Rethinking Experience Replay: a Bag of Tricks for Continual Learning*, ICPR2020, 10.1109/ICPR48806.2021.9412614).
3. Algorytm HebbCL, inspirowany m.in. przez CURL (*Continual Unsupervised Representation Learning*), prowadzi do rozbudowy struktury sieci w trakcie pojawiania się nowych zadań. Czy nie należałoby zatem jako algorytmów referencyjnych wybrać metod inspirowanych PNN (Progressive Neural Network), np. PackNet (<https://arxiv.org/abs/1711.05769>), czy HAT (<https://arxiv.org/pdf/1801.01423>). W trakcie takiego eksperymentu warto porównać nie tylko jakość, ale też wielość budowanej struktury związanej z nowym zadaniem.
4. *Continual Visual Mapping* zakłada mapowanie modelu na zamrożoną przestrzeń ukrytą LLM. Czy takie podejście nie będzie miało problemu w przypadku np. *fine-grained classification*, tj., gdy mamy do czynienia z bardzo dużą liczbą bardzo do siebie podobnych klas (np. gatunki ptaków)?

5. Poprzez sformułowanie tematu rozprawy jako *Continual Learning with Experience Replay*, doktorant sugeruje, że praca koncentruje się na metodach z buforem. Należy jednak zauważyć, że ani HebbCL, ani CVM do tej grupy nie należą. HebbCL bazuje na swojego rodzaju izolacji parametrów, a drugiej ze wspomnianych metod bliżej jest raczej do metod bazujących na regularyzacji. Nie jest to poważny zarzut, jednakże wydaje się, że być może temat rozprawy, a także jej cele powinny być inaczej sformułowane. Jest to także istotne ze względu na dobór metod referencyjnych. W przypadku CVM porównano się m.in. z EWC, co należy uznać za prawidłowe, natomiast dobór metod referencyjnych w przypadku nadzorowanej wersji HebbCL wymaga szerszego komentarza ze strony doktoranta. Warto tu wspomnieć, że problem odpowiedniego doboru metod i danych referencyjnych jest zadaniem niebanalnym. W literaturze poświęconej ciągłemu uczeniu problem ten był wielokrotnie sygnalizowany, stąd warto wspomnieć np. pracę Mundt M. et al., *CLEVA-Compass: A Continual Learning Evaluation Assessment Compass to Promote Research Transparency and Comparability*, ICLR 2022 (<https://arxiv.org/abs/2110.03331>), gdzie autorzy podjęli próbę uporządkowania tego obszaru, jednakże bez powodzenia.
6. Jako że praca poświęcona jest uczeniu ciągłemu, to analizując zachowanie poszczególnych algorytmów należy z jednej strony pokazywać jakość na kolejnych zadaniach, ale także zwracać uwagę na retencję wiedzy. W eksperymentach doktorant wykorzystuje uśrednioną dokładność oraz zapominanie dla ostatnich pięciu klas (dla DFB), z kolei przy opisie HebbCL rezygnuje z metryki zapominania i wykorzystuje 10NN, natomiast w przypadku CMV oraz strategii próbkowania ogranicza się już jedynie do średniej dokładności. Co ciekawe, w pracy zaproponowano metrykę KR (*Knowledge Retention*), która nie jest stosowana w rozdziałach 4 i 5, ani też zaproponowane algorytmy nie posłużyły jako ilustracja tej propozycji w rozdziale 6.

#### 4. Wiedza kandydata

Doktorant posługuje się sprawnie zaawansowanym aparatem matematycznym, a także potrafi zaplanować eksperyment komputerowy w celu oceny jakości zaproponowanych metod. Przegląd literaturowy dotyczący zagadnień przedstawionych w rozprawie pozwala stwierdzić, że doktorant posiada aktualną wiedzę z zakresu tematyki rozprawy, a także potrafi dokonać krytycznego przeglądu źródeł w celu wskazania ciekawych kierunków badań. Zawarty w dysertacji spis źródeł literaturowych, zawierających 97 pozycji, jest aktualny i kompletny. Należy zatem stwierdzić, że doktorant posiada wiedzę z zakresu informatyki technicznej i telekomunikacji, w szczególności w zakresie metod uczenia maszynowego i ciągłego uczenia.

#### 5. Podsumowanie

Doktorant wykazał się w recenzowanej rozprawie właściwie stosowanym podejściem eksperymentalnym oraz dobrą znajomością aktualnej problematyki związanej z uczeniem modeli głębokich, szczególnie w scenariuszu uczenia ciągłego. Zostało to poparte dobrymi studiami literaturowymi, obejmującymi aktualne piśmiennictwo związane z problematyką rozprawy, co świadczy o bardzo dobrej wiedzy doktoranta z tego zakresu. Dla poruszanych problemów doktorant sformułował kilka ciekawych i użytecznych metod i obserwacji oraz wskazał możliwości dalszego rozwoju metod w obszarze związanym z rozprawą, a także zwrócił uwagę na zidentyfikowane ograniczenia przeprowadzonych badań.

Recenzowana dysertacja przedstawia rozwiązanie ważnego i oryginalnego problemu, wzbogacając naszą wiedzę dotyczącą wykorzystania metod ciągłego uczenia. Zawarte w niej wyniki badań eksperymentalnych wskazują również na możliwość wykorzystania otrzymanych metod w praktyce. Przedstawione w punkcie 3 recenzji uwagi nie wpływają na pozytywne wrażenie o przedłożonej rozprawie. Jestem także przekonany, że doktorant zdaje sobie sprawę z możliwości kontynuowania rozpoczętej w pracy tematyki.

Reasumując, biorąc pod uwagę powyższe opinie stwierdzam, że rozprawa mgr Andriia Krutsylo pt. „*Continual Learning with Experience Replay*” spełnia wymagania stawiane pracom doktorskim, w szczególności:

- Rozprawa zawiera oryginalne rozwiązanie problemu naukowego.
- 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 mgr Andriia Krutsylo do publicznej obrony.

Podpis jest prawidłowy  
Dokument podpisany przez Michał  
Wojciech Wozniak  
Data: 2026.02.26 11:53:01 CET

---

*Podpis*