

**Recenzja**  
**rozprawy doktorskiej mgr. inż. Sylwestra Czmiła**  
**pt. *Algorytmy nadzorowanego inkrementalnego uczenia maszynowego***  
**oraz ocena jakości ich klasyfikacji**

Niniejsza recenzja została przygotowana w odpowiedzi na pismo Przewodniczącego Rady Dyscypliny *Informatyka Techniczna i Telekomunikacja* (ITiT) Politechniki Rzeszowskiej, dr. hab. inż. Mariusza Oszusta, prof. uczelni (pismo nr RE.530/43/2024/RDITiT z dn. 11 grudnia 2024r.), zawierające informację, że zostałem powołany przez wymienioną wyżej Radę Dyscypliny na recenzenta w postępowaniu w sprawie nadania stopnia doktora mgr. inż. Sylwestrowi Czmiłowi. Wspomniane wyżej pismo, wraz z egzemplarzem rozprawy, zostało wysłane z Rzeszowa w dn. 27 stycznia 2025r. (data stempla pocztowego). Postępowanie prowadzone jest w dziedzinie nauk inżynieryjno-technicznych, w dyscyplinie ITiT. Promotorem rozprawy jest prof. dr hab. inż. Jacek Kluska.

Recenzowana rozprawa doktorska koncentruje się wokół ważnej i aktualnej problematyki projektowania klasyfikatorów w drodze ciągłego (nieograniczonego w czasie) uczenia z danych, z wykorzystaniem tzw. inkrementalnych (przyrostowych) algorytmów uczenia nadzorowanego. Rozprawa liczy 113 stron i zawiera (w następującej kolejności): wykaz symboli, oznaczeń i skrótów, 9 rozdziałów (w tym wprowadzenie i podsumowanie), dwa dodatki A i B, spisy rysunków, tabel i literatury (71 pozycji) oraz streszczenia w języku polskim i angielskim.

Pierwszy rozdział ma charakter wstępny i zawiera zarówno usystematyzowany przegląd zagadnień dotyczących klasycznych algorytmów uczenia nadzorowanego oraz algorytmów inkrementalnych, jako odpowiedzi na wady podejść klasycznych. Rozważane w rozprawie podejście do uczenia klasyfikatorów z danych określane jest w literaturze jako uczenie typu *online* (lub alternatywnie *continuous / continual / lifelong learning*). Proces uczenia odbywa się bez ograniczeń w czasie, w środowisku otwartym na napływ nowych danych uczących. W trakcie trwania procesu uczenia, klasyfikator adaptuje się na bieżąco do nowych danych, przy czym może zarówno uczyć się nowej wiedzy (zachowując uprzednio nabytą) o przynależności danych do znanych kategorii, jak również może identyfikować nowe kategorie danych. Są to niezwykle ważne i pożądane obecnie cechy, których brakuje tradycyjnemu podejściu do uczenia – znanemu pod nazwą *offline* – które odbywa się w skończonym czasie, w środowisku zamkniętym przed napływem nowych danych uczących (tzn. z wykorzystaniem



danych uczących ustalonych z góry i nie podlegających żadnym zmianom w trakcie trwania całego procesu uczenia). Badania nad algorytmami uczenia w trybie *online* są obecnie jak najbardziej aktualne i ważne. W ich nurt wpisuje się również praca Doktoranta, wnosząc zauważalny wkład w postaci nowego, oryginalnego algorytmu inkrementalnego.

Doktorant dokonał przeglądu literatury światowej (37 pozycji; 26 we wprowadzeniu i 11 w rozdziale 3), prezentującej różnorodne podejścia do projektowania klasyfikatorów z danych. Przegląd obejmuje 17 algorytmów, w tym osiem podejść klasycznych (las losowy, SVM,  $k$ -NN, XGBoost, naiwny klasyfikator Bayesa, drzewo decyzyjne, AdaBoost i regresję logistyczną), cztery algorytmy inkrementalne (sieci ART, drzewo Hoeffdinga, Additive Expert Ensemble i Oza Bagging) oraz pięć podejść z rodziny algorytmów kwantyzacji wektorowej (LVQ1, LVQ2, LVQ3, EVQ i SFAM). Przedstawiony przegląd literatury zarówno świadczy o głębokiej wiedzy Doktoranta w reprezentowanej przez niego dyscyplinie naukowej jak i stanowi logiczny punkt wyjścia do zaproponowanych przez niego rozwiązań będących odpowiedzią na określone mankamenty podejść dotychczas stosowanych.

W rozdziale 2 Doktorant formułuje główny cel pracy, pięć celów szczegółowych oraz trzy hipotezy badawcze. Doktorant stawiając sobie jako cel rozprawy opracowanie nowego algorytmu inkrementalnego o minimalnej liczbie parametrów, zbudowanie profesjonalnego środowiska programistycznego do wszechstronnego testowania algorytmu i analizy porównawczej oraz implementacji sprzętowej algorytmu, podjął się zadania trudnego, o dużym znaczeniu zarówno poznawczym jak i aplikacyjnym. Praktyczny wymiar tego zadania jest ważny również ze względu na znaczenie nowoczesnych algorytmów klasyfikacji danych w szeroko rozumianych problemach decyzyjnych. Ponadto, w ostatnich latach intensywnie rozwija się rynek narzędzi AI w formie implementacji programowych (w szczególności, w języku Python).

Na uwagę zasługuje nieformalna teza badawcza (sformułowana na str. 10; akapit „*Głównym ograniczeniem klasycznych klasyfikatorów jest brak mechanizmu pozwalającego na ciągle integrowanie nowych danych z już istniejącym modelem*”), którą można rozwinąć następująco: klasyczne algorytmy uczenia klasyfikatorów nie posiadają zdolności adaptacji do nowych danych napływających w trakcie procesu uczenia oraz nie posiadają zdolności do identyfikacji nowych klas podczas uczenia. Podsumowując, Doktorant stwierdza, że odpowiedzią na te ograniczenia są algorytmy inkrementalne, w szczególności proponowane przez Niego rozwiązanie. Należy podkreślić, że powyższa teza rozprawy jest oryginalna i ważna zarówno z naukowego jak i praktycznego punktu widzenia. Przedstawienie metod i algorytmów oraz wyników praktycznych eksperymentów pozwalających na wykazanie jej prawdziwości wniesie wkład w rozwój zarówno teorii jak i praktyki budowy szeroko



rozumianych systemów decyzyjnych.

W rozdziale 3 Doktorant omawia szczegółowo algorytmy LVQ1, LVQ2, LVQ3, EVQ i SFAM, gdyż jak sam wskazał były one inspiracją do zaprojektowania proponowanego przez Niego rozwiązania. W rozdziale 4 Doktorant krótko charakteryzuje wybrane narzędzia teoretyczne wykorzystane w części eksperymentalnej pracy, tzn.: miary oceny jakości klasyfikatorów (dokładność, precyzja, czułość, uogólnioną miarę F-beta i miarę geometryczną – tzw. pole pod krzywą), procedurę walidacji krzyżowej, tzw. wykres pudełkowy do analizy rozkładu cechy statystycznej, algorytm hierarchicznego grupowania danych Scotta-Knotta oraz test Wilcoxona.

W rozdziale 5 Doktorant przedstawia szczegóły proponowanego algorytmu *Simple Evolving Vector Quantization* (SEVQ). Algorytm ten jest rozszerzeniem znanej metody kwantyzacji wektorowej (LVQ). Metoda LVQ operuje na określonej z góry liczbie tzw. prototypów (centroidów) w przestrzeni danych uczących. W ramach współzawodnictwa prototypów – zgodnie z regułą WTA (ang. *Winner Takes All*) – prototyp zwyciężający jest „przyciągany” do próbki danych wejściowych jeżeli próbka i prototyp należą do tej samej klasy. W przeciwnym przypadku, prototyp jest „odpychany” od próbki danych. Modyfikacja Doktoranta polega na zastąpieniu mechanizmu „odpychającego” nowym mechanizmem, który umożliwia dodawanie nowych prototypów w trakcie trwania procesu uczenia. W przypadku braku zgodności klas prototypu zwyciężającego i próbki danych wejściowych, próbka ta jest dodawana do struktury klasyfikatora jako nowy prototyp (ewentualnie z nową, dotąd nieznaną klasą). Doktorant przedstawił funkcjonowanie algorytmu SEVQ z wykorzystaniem czterech syntetycznych, dwuwymiarowych zbiorów danych. Następnie omówił podobieństwa i różnice pomiędzy SEVQ, a wybranymi algorytmami z rozdziału 3 (LVQ1, EVQ i SFAM).

W rozdziale 6 Doktorant przedstawia bardzo rozbudowaną analizę porównawczą algorytmu SEVQ z podejściami alternatywnymi (rozważa 10 metod klasycznych i 15 inkrementalnych), z wykorzystaniem 36 zbiorów danych – benchmarków pochodzących z powszechnie znanego repozytorium KEEL. W rozdziale 7 Doktorant omawia rezultaty implementacji algorytmu SEVQ na platformach FPGA i ARM. Z kolei, w rozdziale 8 przedstawia autorskie oprogramowanie (implementacja w języku Python) do testowania algorytmu SEVQ, będące naukowym warsztatem pracy Doktoranta podczas realizacji rozprawy doktorskiej. W rozdziale 9 Doktorant prezentuje podsumowanie rozprawy, a w szczególności podsumowanie własnych osiągnięć. W dwóch dodatkach Doktorant przedstawia instrukcję przeprowadzenia eksperymentów numerycznych z wykorzystaniem narzędzia z rozdziału 8 (Dodatek A) oraz architekturę tego narzędzia i kilka szczegółów implementacyjnych (Dodatek B).

Do szczególnie wartościowych i o oryginalnym charakterze elementów rozprawy należy zaliczyć:

1. Opracowanie inkrementalnego algorytmu kwantyzacji wektorowej SEVQ, jako rozszerzenia znanego algorytmu LVQ. Proponowany algorytm SEVQ łączy efektywność z prostotą.
2. Demonstracja funkcjonowania algorytmu SEVQ z wykorzystaniem czterech syntetycznych, dwuwymiarowych zbiorów danych.
3. Przeprowadzenie obszernej analizy porównawczej proponowanego podejścia z alternatywnymi metodami (rozważono 10 metod klasycznych i 15 inkrementalnych), z wykorzystaniem 36 zbiorów danych – benchmarków pochodzących z repozytorium KEEL. Wykazanie, że algorytm SEVQ uzyskuje lepsze (w sensie formalnych miar oceny jakości klasyfikatorów) wyniki niż: a) wszystkie, rozważane w pracy, alternatywne algorytmy inkrementalne oraz b) zdecydowana większość, rozważanych w pracy, algorytmów klasycznych.
4. Opracowanie implementacji sprzętowej algorytmu SEVQ z wykorzystaniem układów FPGA i ARM; implementacja tego typu umożliwia efektywne wykorzystanie proponowanego algorytmu również w przypadku dużych zbiorów danych.
5. Opracowanie profesjonalnego środowiska programistycznego do testowania algorytmu SEVQ z wykorzystaniem własnej biblioteki o nazwie „*sevq*” dla języka Python. Warto podkreślić, że biblioteka „*sevq*” została publicznie udostępniona wraz ze szczegółową dokumentacją w sieci Internet oraz opisana w artykule naukowym [66] (Doktorant jest zarówno pierwszym jak i korespondencyjnym jego autorem), opublikowanym w renomowanym czasopiśmie SoftwareX (200 pkt. na liście czasopism punktowanych MNiSW).
6. Demonstracja praktycznego wykorzystania środowiska z pkt. 5.

Obok wymienionych wyżej zalet rozprawy, jej lektura może nasuwać następujące uwagi ogólne:

1. Rozwiązania do pewnego stopnia zbliżone do proponowanego algorytmu SEVQ można znaleźć w literaturze (np. mechanizm dodawania prototypów w algorytmie SILVQ<sup>1</sup> lub analogiczny mechanizm w algorytmie SLDP<sup>2</sup>). Wskazane byłoby odniesienie się Doktoranta do tych algorytmów.
2. Wydaje się, że Doktorant nie przedstawił w pełni dużego potencjału kryjącego się w proponowanym przez Niego algorytmie, w szczególności zdolności do pracy tego

<sup>1</sup> Manome N., et al.: *Self-incremental learning vector quantization with human cognitive biases*. Scientific Reports, vol. 11:3910, 2021, pp.1-12 - patrz krok 4 pseudokodu na str. 5.

<sup>2</sup> Orhan Umut, Mahmut Hekim: *A Novel Supervised Learning Based on Density*. Journal of New Theory, vol. 1, 2015, pp. 17-23 - patrz krok 4 pseudokodu na str. 19.



algorytmu w trybie *online*. Kluczowy Listing 1 (str. 30) opisuje fazę uczenia w trybie *offline* (proces trwa skończoną liczbę  $N_e$  epok, a dane uczące nie zmieniają się). Co więcej, Doktorant przedstawia kolejny Listing 2 opisujący fazę odtwarzania wiedzy. Faza ta jest charakterystyczna dla trybu *offline* (w trybie *online* nie rozróżnia się faz uczenia i odtwarzania wiedzy, gdyż obie odbywają się równocześnie). Z kolei, w części eksperymentalnej rozprawy Doktorant stosował raczej tryb *offline*. Na podstawie stwierdzenia „Poprawę wyników działania algorytmu może zapewnić zastosowanie wielu epok uczenia.” (cytat, str. 35) można sądzić, że procesy uczenia trwają określoną z góry liczbę epok. Doktorant stosuje procedurę walidacji krzyżowej charakterystyczną dla trybu *offline* (oddzielne fazy uczenia i testowania klasyfikatora).

3. Wskazane byłoby uzupełnienie rozdziału 5 o ilustracje – z wykorzystaniem dwuwymiarowych zbiorów danych – zmian liczby prototypów, liczby zidentyfikowanych klas podczas uczenia, czy mechanizmu identyfikacji nowych klas.
4. Nasuwają się również pewne pytania, np. jak będzie zachowywać się algorytm, gdy kształt skupisk danych będzie ewoluować w czasie (co może się zdarzyć podczas uczenia *online*)? Czy liczba prototypów nie będzie rosła w niekontrolowany sposób? Algorytm nie posiada mechanizmów usuwających zbędne prototypy.
5. Niektóre z algorytmów wykorzystywanych w analizie porównawczej nie zostały szczegółowo scharakteryzowane (tzn.: *Additive Expert Ensemble* (AEE), *Adaptive Random Forest* (ARF), *Dynamic Weighted Majority* (DWM), *Extremely Fast Decision Tree* (EFDT), *Hoeffding Adaptive Tree* (HAT), *Hoeffding Tree* (HT), inkrementalna wersja klasyfikatora  $k$ -NN ( $k$ -NNI) oraz algorytm *Oza Bagging* (OB)).
6. W podrozdziale 4.1 Doktorant nieco komplikuje opis miar jakości klasyfikatorów wieloklasowych, używając mało intuicyjnych działań na zbiorach. Miary te można wyrazić za pomocą przyjaznych (interpretowalnych) pojęć stosowanych w odniesieniu do klasyfikatorów binarnych (liczby odpowiedzi prawdziwie/fałszywie pozytywnych/negatywnych).
7. Usytuowanie podrozdziału 4.2 w rozdziale 4 jest nieco dyskusyjne, gdyż walidacja krzyżowa nie jest techniką porównywania klasyfikatorów (taki tytuł nosi rozdział 4); jest to metoda weryfikacji skuteczności algorytmu uczenia klasyfikatora (przy założeniu poprawności danych treningowych) lub poprawności danych treningowych (przy założeniu wysokiej skuteczności algorytmu uczenia). Usytuowanie podrozdziałów 4.3, 4.4 i 4.5 jest również nieco dyskusyjne – mają one niewielki związek z technikami porównywania klasyfikatorów. Ponadto, test Wilcoxona został opisany bardzo pobieżnie.
8. W rozdziale 6 Doktorant nie przedstawia szczegółowych wyników dla każdego rzeczywistego zbioru danych z osobna, lecz jedynie wyniki uśrednione. W ten sposób

Doktorant pozbawia się możliwości zademonstrowania jednego z potencjalnych atutów swojej pracy bazujących na porównaniu wyników proponowanej metody z wynikami metod alternatywnych, bezpośrednio zaczerpniętymi z literatury (w tym celu wykorzystuje się w testach znane zbiory benchmarkowe). Ponadto, warto rozważyć przedstawienie wyników klasyfikacji niezależnie dla danych uczących i dla danych testowych, gdyż pozwala to ocenić zdolności klasyfikatorów do generalizacji wiedzy.

Nieznaczące zastrzeżenia można mieć do edycyjnego przygotowania rozprawy, np.:

- a) na str. 17 (ósmą wiersz od dołu) powinno być „*winner takes all*” a nie „*winner takes it all*”,
- b) na rys. 6.1–6.10 błędnie są opisane osie pionowe; ponadto, skala osi pionowej powinna rozpoczynać się od zera (istnieje przesunięcie wykresów słupkowych względem osi o 1),
- c) str. 26, wzór (4.12): brak opisu  $AUC_{j,k}$ .

Powyższe uwagi, poza redakcyjnymi, mają głównie charakter dyskusyjny i nie kwestionują wyników zaprezentowanych w rozprawie. Należy podkreślić, że wszystkie określone w rozprawie cele zostały w pełni osiągnięte, a otrzymane i zaprezentowane w rozprawie wyniki stanowią potwierdzenie słuszności sformułowanych przez Doktoranta hipotez badawczych.

Rozprawa napisana jest w sposób przejrzysty i, generalnie, stanowi logiczną całość. Zawiera przy tym wszystkie wymagane elementy rozprawy naukowej, tzn. obszerny i krytyczny przegląd literatury, wskazanie – na tym tle – zagadnień wymagających rozwiązania, sformułowanie celu i hipotez badawczych rozprawy, propozycję nowych rozwiązań oraz ich eksperymentalną weryfikację. Rozprawa stanowi oryginalne rozwiązanie problemu naukowego potwierdzające zarówno ogólną wiedzę teoretyczną Doktoranta, jak i umiejętność samodzielnego prowadzenia pracy naukowej.

Podsumowując przedstawioną wyżej ocenę rozprawy doktorskiej mgr. inż. Sylwestra Czmila, stwierdzam, że spełnia ona wymagania stawiane kandydatom do stopnia doktora przez obowiązującą ustawę, wobec czego wnioskuję o dopuszczenie Doktoranta do kolejnych etapów postępowania w sprawie nadania Mu stopnia doktora.

