

Prof. dr hab. inż. Adam Krzyżak
Department of Computer Science
and Software Engineering
Concordia University
Montreal
Quebec H3G 1M8
Canada

Montreal, 28 listopada, 2024 r.

SEKRETARIAT
Rady Dyscypliny AEEITK

Wpłynęło dnia 3.12.2024
Zarejestrowano pod nr 510-3.6/
Podpis [signature]

Recenzja
rozprawy doktorskiej mgr inż. Mateusza Pabiana
pt. "Event-based Machine Learning with Bayesian Methods and Spiking Neural
Networks".

1. Obszar problemowy rozprawy

Przedstawiona mi do oceny, na podstawie uchwały Rady Dyscypliny Automatyki, Elektroniki, Elektrotechniki i Technologii Kosmicznych Akademii Górniczo-Hutniczej z dnia 6 czerwca 2024 r. praca doktorska mgr inż. Mateusza Pabiana dotyczy zastosowania uczenia maszynowego do analizy danych zdarzeniowych.

Problematyka rozprawy jest ważna zarówno z teoretycznego jak i praktycznego punktu widzenia. W pracy Autor porównuje dwa podejścia do analizy danych zdarzeniowych: pierwsze oparte na teorii procesów punktowych a drugie bazujące na impulsowych sieciach neuronowych. Teoria procesów punktowych jest często wykorzystywana w neurobiologii obliczeniowej do analizy impulsów, jednakże jest rzadko stosowana do nadzorowanej klasyfikacji szeregów czasowych. Z kolei impulsowe sieci neuronowe cieszą się dużym zainteresowaniem badaczy, mimo iż ich proces uczenia zwykle wymaga symulowania stanu całej sieci w każdej chwili czasowej, co nie jest efektywnym wykorzystaniem zasobów obliczeniowych. Ponadto nie jest jasne w jaki sposób konwersja sygnału do postaci zdarzeniowej wpływa na działanie wyuczonego modelu. Wyżej wspomniane problemy zostały rozwiązane w rozprawie przy pomocy metod analizy statystycznej oraz symulacji numerycznych, a uzyskane wyniki będą szczegółowo omówione i ocenione w dalszej części recenzji.

Zgodnie z zakresem i tezami pracy przedstawionymi w rozdziale pierwszym rozprawy zasadniczym jej celem jest opracowanie metod klasyfikacyjnych dla danych zdarzeniowych. W szczególności sformułowano w rozprawie następujące zadania:

- Przeanalizowanie dwóch różnych podejść do zagadnienia uczenia maszynowego dla danych zdarzeniowych przy wykorzystaniu metod analizy statystycznej oraz symulacji numerycznych.
- Opracowanie algorytmów klasyfikacji procesów punktowych przy pomocy metod bayesowskich i statystyczna analiza zbieżności algorytmów.

- Opracowanie algorytmów klasyfikacji danych zdarzeniowych w oparciu o sieci neuronowe.
- Opracowanie algorytmów klasyfikacji danych zdarzeniowych dla wielowymiarowych szeregów czasowych.
- Zastosowanie opracowanych algorytmów do zagadnień praktycznych.

Wybór tematyki badań jak i sformułowane cele oraz tezę rozprawy, a także przyjęte sposoby ich realizacji przy użyciu metod statystycznych i symulacyjnych uważam za aktualne i trafne zarówno z teoretycznego jak i praktycznego punktu widzenia. Rozprawa mieści się w całości w obszarze dyscypliny naukowej **automatyka, elektronika, elektrotechnika i technologie kosmiczne**.

2. Kompozycja treści i redakcja rozprawy

Rozprawa liczy łącznie 185 stron. Składa się z 6 rozdziałów, załącznika zawierającego wykaz skrótów i oznaczeń oraz bibliografii zawierającej 256 pozycje. Wykaz cytowanych prac zawiera 4 współautorskie prace Autora, w tym 1 opublikowaną w czasopiśmie Elsevier, 2 opublikowane w materiałach konferencyjnych międzynarodowych IEEE oraz 1 w formie preprintu arXiv.

Wstęp (rozdział 1) zawiera podstawowe definicje sekwencji czasowych dyskretnych zdarzeń oraz zdarzeniowych (impulsowych) sieci neuronowych (ang. *spiking neural networks* - *SNN*). W podrozdziale 1.2 zaprezentowano motywację podjętych badań. Szczególną uwagę poświęcono dwóm podejściom do uczenia maszynowego w oparciu o dane zdarzeniowe: pierwsze podejście wykorzystujące teorie procesów punktowych oraz podejście oparte na SNN. Oba podejścia zostały szczegółowo przeanalizowane w rozprawie. W podrozdziale 1.3 szczegółowo podsumowano osiągnięcia rozprawy.

Rozdział 2 rozważa klasyczne podejście do klasyfikacji sekwencji zdarzeń oparte na teorii procesów punktowych. Wyprowadzono optymalną regułę klasyfikacji w kategoriach funkcji intensywności oraz zbadano i zaproponowano nieparametryczne klasyfikatory typu plug-in dla danych impulsowych, a wśród nich klasyfikator Parzena z jądrem. Przeanalizowano zbieżność klasyfikatorów do optymalnego klasyfikatora Bayesa, gdy rośnie długość ciągu uczącego. Dodatkowo oceniono wpływ efektów brzegowych na wydajność klasyfikatora, gdy długość interwału obserwacji zdarzeń jest wystarczająco krótka. Pokazano zgodność teorii z praktyką w badaniach symulacyjnych na skończonej próbie oraz przetestowano zaproponowane algorytmy na rzeczywistych danych w zadaniu wykrywania bota w danych Twittera. W tym konkretnym zadaniu okno obserwacji jest dość długie, a zdarzenia występujące w skalach czasowych różniących się o wiele rzędów wielkości.

Rozdział 3 jest zasadniczym rozdziałem w rozprawie i koncentruje się na zastosowaniu impulsowych sieci neuronowych do problemów uczenia maszynowego dla danych zdarzeniowych. Autor omawia istniejący model *time-coding single-spike time-to-first-spike SNN* i identyfikuje ograniczenia tego modelu wynikające z jego założeń. Proponuje kilka

modyfikacji, które łagodzą te niedociągnięcia poprzez skrócenie czasu przetwarzania, stabilizację dynamiki szkolenia, umożliwiając dokładniejszą kontrolę nad impulsami aktywności i proponując ramy przetwarzania sygnałów zmieniających się w czasie. Ten ostatni punkt jest opisany w kategoriach iteracji w przestrzeni zdarzeń, co stoi w kontraście do innych modeli SNN, które iterują w czasie dyskretnym. Na koniec, wydajność proponowanego SNN jest oceniana na podstawie wspomnianego zadania klasyfikacji bota Twittera. Ponowne użycie tego samego zestawu danych pozwala na porównanie podejścia opartego na procesach punktowych i SNN oraz na ocenę ich przydatności do innych zadań.

W Rozdziale 4 Autor proponuje algorytm trenowania syjamskiej sieci SNN kompatybilnej z siecią *time-coding single-spike time-to-first-spike SNN* omówioną w Rozdziale 3 czego efektem jest syjamska sieć SNN. Prowadzi to do pierwszej w historii sieci syjamskiej trenowanej od początku do końca w domenie impulsowej. Proponowana metodologia została oceniona na dwóch zestawach danych obrazowych. Najpierw użyto prostego zestawu danych cyfrowych MNIST. Oceniono wpływ liczby neuronów wyjściowych na wydajność klasyfikatora, aktywność sieciową i opóźnienie predykcji. Zaproponowaną sieć syjamską zastosowano do wykrywania artefaktów w kontekście obrazów promieniowania kosmicznego uzyskanych przez nowoczesne smartfony. Ten osobliwy zestaw danych jest reprezentatywnym przykładem stosowalności syjamskiego SNN, ponieważ same obrazy zawierają bardzo mały informacyjny obszar zainteresowania w porównaniu do całkowitego obszaru obrazu, co sprawia, że dane obrazu są rzadkie (patrz prace [23,24]).

W Rozdziale 5 zastosowano model SNN do analizy wielowymiarowych szeregów czasowych. Walidację modelu przeprowadzono na praktycznym zagadnieniu identyfikacji typu pojazdu na podstawie profili magnetycznych (VMP). Zbadano różne schematy próbkowania wyzwalane zdarzeniami oraz omówiono różne sposoby doboru parametrów próbkowania.

Rozdział 6 zawiera podsumowanie badanych metod i ich ocenę zbiorczą oraz wnioski i uwagi końcowe.

Całość rozprawy kończy wykaz literatury (256 pozycji).

Kompozycja i struktura formalna rozprawy nie budzą zastrzeżeń. Praca jest zredagowana starannie, z czytelnie i szczegółowo przedstawionymi wynikami badań dotyczącymi modeli zdarzeniowych oraz poprawnie i treściwie zinterpretowanymi wynikami badań.

3. Podstawowe oryginalne osiągnięcia

Uwagi ogólne:

Przedstawioną pracę doktorską oceniam wysoko. Wnikliwie zbadano w niej problem modelowania probabilistycznego procesów zdarzeniowych przy wykorzystaniu metod uczenia maszynowego. W pracy tej zbadano dwa różne podejścia do uczenia maszynowego na danych zdarzeń: klasyczne podejście oparte na teorii procesów punktowych oraz rozwiązanie wykorzystujące sztuczną inteligencję i zdarzeniowe sieci neuronowe. Szczególną uwagę poświęcono budowie klasyfikatorów w oparciu o podejście bayesowskie, zdarzeniowym

sieciom neuronowym, zdarzeniowym sieciom syjamskim oraz klasyfikacji sekwencji zdarzeniowych dla wielowymiarowych szeregów czasowych.

Tak postawione zadanie jest oryginalnie sformułowanym problemem badawczym, który nie był dotychczas rozważany i którego rozwiązanie ma duże znaczenie dla teoretycznych i praktycznych badań prowadzonych w ostatnich latach nad zastosowaniem metod uczenia maszynowego do analizy procesów zdarzeniowych.

Godną uwagi jest szeroki zakres problemów badanych oraz ich wnikliwa analiza w badaniach symulacyjnych i eksperymentach na bazach danych rzeczywistych takich jak RT_{BUST} Twitter dataset, MNIST oraz CREDO. Zaprojektowane klasyfikatory charakteryzują się niskim błędem klasyfikacji co wskazuje na to, że otrzymane wyniki są wiarygodne i stanowią cenny wkład w rozwiązanie rozpatrywanych problemów. Świadczą także o wysokiej wiedzy teoretycznej Autora i umiejętnościach wykorzystania tej wiedzy do rozwiązywania skomplikowanych problemów procesów zdarzeniowych.

Pozwolę sobie teraz przedstawić długą listę oryginalnych i ważnych osiągnięcia Autora rozprawy.

1. Biorąc pod uwagę, że stan wiedzy w tematyce klasyfikacji sekwencji procesów punktowych, w odniesieniu do długości okresu obserwacji i rozmiaru zestawu danych treningowych jest bardzo ograniczony Kandydat opracował nową metodologię w oparciu o teorię klasyfikacji Bayesa dla problemu dwuklasowego dla klasy danych zdarzeniowych charakteryzującymi się nielosowymi funkcjami intensywności procesu punktowego. Uzyskał optymalne reguły Bayesa, a następnie zaproponował empiryczne klasyfikatory typu „plug-in”, zbieżne do ryzyka Bayesa w miarę wzrostu przedziału obserwacji zdarzeń (dowód zbieżności we współautorskim raporcie [49]). Ponadto zaproponował klasyfikator Parzena z jądrem i uzyskał jego asymptotyczną optymalność w sensie Bayesa (dowód w pracy [49]). Rozległe badania symulacyjne potwierdziły wyniki teoretyczne jak również pokazały, że w przypadku proponowanego klasyfikatora z jądrem negatywny efekty brzegowe są istotne tylko wtedy, gdy długość okna obserwacji jest porównywalna z przepustowością jądra. Algorytm z jądrem został też wykorzystany do detekcji botów w rzeczywistej bazie danych RT_{BUST} Twitter dataset.
2. Szereg istotnych wyników zostało uzyskanych w rozprawie dla impulsowych sieci neuronowych (SNN) typu *time-to-first-spike*. Model ten uwzględnia stan sieci tylko w momentach czasowych związanych z wystąpieniem zdarzenia, co odpowiada na jedno z pytań badawczych związanych z trenowaniem modeli SNN. W rozprawie zidentyfikowano i rozwiązano kilka kluczowych ograniczeń tego modelu. W szczególności:
 - (i) pokazano, jak zwektoryzować obliczenia bieżącej warstwy SNN, aby uzyskać wyniki warstwy w jednym przejściu przez dane wejściowe modelu skracając czas potrzebny do obliczenia wyniku o trzy rzędy wielkości w porównaniu z oryginalnym algorytmem, co pozwala na jego wykorzystanie do uczenia nowoczesnych głębokich sieci
 - (ii) wprowadzono modyfikację modelu, która sprawia, że model jest w stanie przetwarzać wiele impulsów na wejściu i wywoływać wiele impulsów na wyjściu przetwarzając sygnały wektorowo. To podejście kontrastuje z istniejącymi

- podejściami, które symulują stan całej sieci w skończonym oknie czasowym z ustalonym krokiem czasowym
- (iii) (iii) w trakcie uczenia sieci SNN Autor zauważył, że sieć wykazuje niestabilność numeryczną, gdy jest trenowana z czasami zdarzeń o dużej wielkości. Problem ten został rozwiązany poprzez przesunięcie zdarzeń z powrotem do momentu zerowego przed każdym obliczeniem warstwy, albo poprzez transformację zdarzeń
 - (iv) (IV) innym zaobserwowanym zjawiskiem była powolna zbieżność funkcji straty spowodowana utrzymywaniem się parametru regularyzacji synaptycznej na stałym poziomie w trakcie trenowania. Problem ten rozwiązano skalując wartość tego parametru w trakcie uczenia. Na uwagę zasługuje też „*ablation study*”, w których przebadano wpływ wybranych komponentów całego systemu na jakość modelu. Zaproponowane algorytmy zostały też zastosowane do detekcji botów w bazie rzeczywistych danych twitterowskich *RT_{BUST} Twitter dataset*.
3. Autor uzyskał ciekawe nowatorskie rezultaty dla syjamskiej sieci impulsowej (*Siamese SNN*). Sieć ta jest trenowana bezpośrednio w przestrzeni zdarzeń czym się różni od klasycznych sieci syjamskich, które są trenowane nie-impulsowo, a następnie są transformowane do domeny impulsowej. W funkcji strat wykorzystano *odległość Earth Mover*, która jest szczególnym przypadkiem metryki Wassersteina. Wytrenowane sieci syjamskie zostały wykorzystane do rozpoznawania znaków pisanych w bazie MNIST oraz odrzucania artefaktów obrazu podczas detekcji cząstek promieniowania kosmicznego w bazie CREDO.
4. Praktyczną stosowalność opracowanych algorytmów zweryfikowano w trzech aplikacjach: identyfikacji botów w mediach społecznościowych (baza danych *RT_{BUST} Twitter*), wykrywaniu artefaktów podczas detekcji cząstek promieniowania kosmicznego (baza CREDO) oraz do kategoryzacji pojazdów drogowych (baza VMP). Proponowane metody osiągnęły dobrą wydajność we wszystkich omówionych aplikacjach.

Najważniejsze wyniki rozprawy zostały opublikowane w materiałach prestiżowych konferencji międzynarodowych: *2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, *2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* oraz w czasopiśmie Elseviera *Measurement*.

4. Uwagi ogólne i szczegółowe

Rozprawa jest opracowana bardzo starannie i cechuje ją dbałość o precyzyjne wyrażanie sformułowanych w niej treści. Nie stwierdzam w rozprawie żadnych mankamentów zarówno natury ogólnej jak i redakcyjnej. Drobne literówki w języku angielskim zdarzają się bardzo rzadko.

5. KONKLUZJA

W konkluzji stwierdzam, że rozprawa doktorska „Event-based Machine Learning with Bayesian Methods and Spiking Neural Networks”, której autorem jest mgr. inż. Mateusz Pabian, spełnia wymagania stosownej ustawy o stopniach naukowych i tytule naukowym. Wnoszę o jej przyjęcie i dopuszczenie do publicznej obrony.

Adam Krzyżel