

Prof. dr hab. inż. Jacek Kluska
Katedra Informatyki i Automatyki
Wydział Elektrotechniki i Informatyki
Politechnika Rzeszowska im. Ignacego Łukasiewicza
al. Powstańców Warszawy 12
35-959 Rzeszów
e-mail: jacklu@prz.edu.pl

Wpłynęło dnia 16.07.2024
Zarejestrowano pod nr 510.3.7/24
Podpis 

Rzeszów, 3 lipca 2024 r.

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

Niniejsza recenzja została przygotowana w odpowiedzi na pismo nr RDAEEiTK.510.3-3/24 z dnia 6 czerwca 2024 r. Pana dr hab. inż. Ryszarda Sroki, prof. AGH – Przewodniczącego Rady Dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne (AEEiTK) Akademii Górniczo – Hutniczej (AGH) im. Stanisława Staszica w Krakowie, w związku z powołaniem mnie na recenzenta rozprawy doktorskiej mgr inż. Mateusza Pabiana przez Radę Dyscypliny AEEiTK AGH.

W recenzji postaram się zawrzeć szczegółową ocenę dotyczącą spełnienia wymagań stawianym rozprawom doktorskim, określonym w art. 187 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz.U.2023.742 t.j.), postępując zgodnie z wytycznymi zawartymi w umowie.

1 Informacja o rozprawie doktorskiej

a) Tytuł rozprawy doktorskiej stanowiącej podstawę ubiegania się w aktualnym postępowaniu o nadanie stopnia doktora

Podstawę ubiegania się o nadanie stopnia doktora przez mgr. inż. Mateusza Pabiana stanowi rozprawa doktorska napisana w języku angielskim pt. *Event-Based Machine Learning with Bayesian Methods and Spiking Neural Networks*, wydana w 2024 roku i zrealizowana pod promotorską opieką prof. dr. hab. inż. Mirosława Pawlaka oraz promotora pomocniczego – dr. inż. Dominika Rzepki na Wydziale Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej AGH.

Tytuł rozprawy w jęz. polskim brzmi: *Uczenie maszynowe dla danych zdarzeniowych przy pomocy metod bayesowskich oraz impulsowych sieci neuronowych*. Jest on zgodny z zawartością przedłożonej rozprawy.

Rozprawa dotyczy uczenia maszynowego (ML), które oczywiście wkroczyło do robotyki, automatyki i technologii kosmicznych, więc mieści się w dyscyplinie **automatyka, elektronika, elektrotechnika i technologie kosmiczne**. Oczywiście ML mieści się też w dyscyplinie informatyka techniczna i telekomunikacja, jakkolwiek sztywne przypisanie problematyki doktoratu do tej dyscypliny nie uważam za konieczne lub potrzebne.

Dane zdarzeniowe, które mogą być kodowane jako sekwencje impulsów są powszechnie spotykane. Zastosowanie zaawansowanych metod uczenia maszynowego, jak metody bayesowskie czy impulsowe sieci neuronowe (Spiking Neural Networks, SNNs) jest jak najbardziej właściwe i potrzebne dla tego rodzaju danych, jakkolwiek nie należy do zadań prostych i bardzo rozpowszechnionych. Metody bayesowskie można zaliczyć do zaawansowanej statystyki i opracowanie analiz w tym zakresie wymaga dużego wysiłku teoretycznego. Z kolei sieci SNN symulują naturalne procesy przetwarzania informacji w ludzkim mózgu za pomocą impulsów (spikes). Uważa się, że modele SSN naśladują działanie mózgu lepiej od wielu typów dobrze zbadanych i powszechnie stosowanych sztucznych sieci neuronowych, jak perceptron wielowarstwowy, probabilistyczna sieć neuronowa, sieć z radialnymi funkcjami aktywacji i wiele innych. Badanie modeli SNN prowadzi do zwiększenia możliwości ich praktycznego zastosowania i lepszego zrozumienia procesów neurologicznych. W sieciach tych informacje są kodowane za pomocą ciągów impulsów. Implementacja sieci SNN (programowa, czy na wyspecjalizowanym sprzęcie neuromorficznym) ma wiele zalet, takich jak niskie zużycie energii i duża szybkość działania, stąd ich zastosowania obejmują przetwarzanie informacji sterowanych zdarzeniami, takich jak inteligentne przetwarzanie danych z czujników wizyjnych, śledzenie czy rozpoznawanie gestów. Sieci te stanowią więc alternatywę dla typowych sztucznych sieci neuronowych w robotyce czy innym sprzęcie z zasilaniem bateryjnym. Należy jednak zauważyć, że neuronowe sieci impulsowe są obecnie mniej rozwinięte i trudniejsze do uczenia niż sieci tradycyjne. Ich algorytmy uczenia stanowią więc naukowe wyzwanie, co powoduje, że temat rozprawy jest jak najbardziej na czasie.

b) Ocena układu rozprawy doktorskiej, w tym informacje o jej poszczególnych częściach składowych

W rozprawie zawarto listę stosowanych akronimów, streszczenie w języku polskim zawierające cel pracy, spis treści, wprowadzenie wraz z motywacją, główne wyniki badań opisane w czterech rozdziałach zakończonych podsumowaniami, wnioski wraz z sugestią przyszłych kierunków badań oraz bibliografię. Zwraca uwagę obszerność tekstu – rozprawa doktorska liczy 185 stron.

Rozdział 2 stoi na wysokim poziomie teoretycznym i jest mocno zbieżny z publikacją M. Pawlaka, M. Pabiana i D. Rzepki: *Bayes Risk Consistency of Nonparametric Classification Rules for Spike Trains Data* (2023, arXiv). W rozdziale tym omówione zostało klasyczne podejście do klasyfikacji sekwencji zdarzeń w oparciu o teorię procesów punktowych. Opisano w nim teorię klasyfikacji dwuklasowej dla danych w postaci ciągu impulsów w oparciu o teorię Bayesa; w szczególności sformułowano optymalną regułę Bayesa i podano jej asymptotyczne właściwości. Wykazano m.in., że reguła klasyfikacji za pomocą funkcji jądra, która jest stosowana do danych impulsowych, jest spójna z ryzykiem Bayesa, co oznacza, że ryzyko popełnienia błędu klasyfikacji dąży do zera (przy pewnych założeniach) wraz z rosnącą liczbą danych. Wyniki teoretyczne zostały potwierdzone symulacyjnie. Pokazano, że oszacowanie Monte Carlo ryzyka Bayesa zbiega się do zera wraz ze wzrostem długości przedziału obserwacji, analizując problem szybkości zbieżności ryzyka błędnej klasyfikacji. Pokazano, że nie zawsze można zagwarantować zbieżność ryzyka Bayesa do zera.

Do istotnych osiągnięć teoretycznych tego rozdziału należy rozpatrzenie ogólnej klasy empirycznych reguł klasyfikacyjnych typu *plug-in* i sformułowanie wystarczających wa-

runków ich zbieżności do ryzyka Bayesa. Podobnie do analizy przeprowadzonej dla optymalnej reguły klasyfikacji pokazano, że empiryczne ryzyko zaproponowanego klasyfikatora jądrowego zbiega się do ryzyka Bayesa wraz ze wzrostem rozmiaru zbioru uczącego.

Oceniono również wpływ korekcji obwiedni na etapie estymacji funkcji kształtu zaproponowanego algorytmu na wydajność klasyfikatora. Zbadano wpływ różnych podejść na poprawę dokładności klasyfikacji i zmniejszenia ryzyka błędnej klasyfikacji. Badano wydajność modelu w zależności od długości okresów obserwacji strumienia zdarzeń.

Przedstawiono również przykładowy scenariusz przypadku użycia modelu dla realnych danych dotyczących aktywności użytkowników Twittera w celu odkrycia, czy analizowany użytkownik jest sterowany przez człowieka, czy przez bota. Interesującą właściwością tych danych jest to, że czasy zdarzeń w każdej sekwencji mogą się między sobą bardzo mocno różnić. Okazało się, że zaproponowane w pracy podejście jest porównywalne z istniejącymi, jednak model opisany w rozprawie potrzebuje znacznie mniej przykładów uczących, niż metody dotychczasowe.

W eksperymentach symulacyjnych autor badał wpływ różnych parametrów na wydajność algorytmu. Stwierdził, że znaczący wpływ mają: długość badanej sekwencji, rozmiar zestawu uczącego i algorytm wyboru przepustowości. Wydaje się, że interesujące może być rozważenie w przyszłości adaptacyjnie zmieniającej się przepustowości funkcji jądra.

W rozdziale 3 autor omówił impulsowe sieci neuronowe w kontekście uczenia głębokiego i przetwarzania danych o zdarzeniach. Skoncentrował się na specyficznym rodzaju impulsowych sieci neuronowych, w których informacje są kodowane na podstawie czasu wystąpienia pierwszego impulsu. W tych sieciach każdy neuron może wygenerować tylko jeden impuls w odpowiedzi na bodziec, a najważniejszą rolę odgrywa czas wystąpienia tego impulsu. Odpowiednie kodowanie informacji pozwala na energetycznie efektywne i szybkie przetwarzanie danych w porównaniu z tradycyjnymi sieciami neuronowymi. Autor przeprowadził badanie polegające na odtworzeniu artykułu, który wprowadził sieci SNN, dzięki czemu mógł ocenić poprawność własnej realizacji takiej sieci. W wyniku badań wykrył słabe i mocne strony rozpatrywanej sieci. Okazało się, że badany algorytm jest kosztowny obliczeniowo co sprawia, że uczenie "głębszych" sieci neuronowych jest niewykonalne. Ponadto zaobserwował, że przesunięcie skoków wejściowych w czasie powoduje, że model reaguje dokładnie w ten sam sposób, tylko w innym czasie, co ma negatywny wpływ na dynamikę procesu uczenia. Sprawdził też, że nauczony model może wywołać skok wyjściowy, gdy tylko sygnał zostanie rozpropagowany przez sieć, nawet jeśli niektóre neurony w ukrytych warstwach jeszcze się nie aktywowały, co powoduje, że przyszłe impulsy tych neuronów z warstwy ukrytej są zbędne.

Autor wprowadził kilka istotnych modyfikacji procesu uczenia SNN. Zaproponował wektoryzację obliczeń, przez co znacznie skrócił czas generowania wyjść sieci. Wektoryzacja ta wymaga znalezienia wszystkich możliwych kombinacji danych wejściowych i wyznaczenie tych, które najwcześniej generują impuls. Interesujące jest to, że zaproponowany algorytm jest o trzy rzędy wielkości szybszy od algorytmu podstawowego, co daje szansę rozwoju głębokiego uczenia SNN. Ponadto, autor zaproponował wariant modelu, który zapewnia, że wszystkie warstwy sieci obserwują zdarzenia rozpoczynające się w czasie $t = 0$. Zaproponował przesuwanie w czasie zdarzeń wejściowych i zmodyfikował człon regularyzacyjny, który dynamicznie skaluje funkcję kary, tzn. stosuje ją wtedy, gdy zadanie uczenia sieci nie zostanie poprawnie rozwiązane.

Kolejną, interesującą modyfikacją podstawowego modelu impulsowej sieci neuronowej było złagodzenie wymogu nieskończenie długiego okresu refrakcji neuronów (czyli okresu

braku reakcji neuronów na bodźce). Autor zaproponował sieć SNN o wielu wejściach i wielu wyjściach (MIMO), która działa w inny sposób, niż w pracach symulujących stan całej sieci w skończonym oknie czasowym z ustalonym krokiem czasowym. Wykazał, że takie podejście nadaje się również do dużych ilości danych. Model został zastosowany do oznaczonego podzbioru danych o aktywności użytkowników Twittera, który został wcześniej wprowadzony w celu oceny klasyfikatora opartego na jądrze. Najlepszy model doktoranta osiągnął dokładność ok. 73%, czyli wynik o 14 % gorszy od dotychczas uzyskanego badania RTbust polegającego na wykorzystaniu wzorców czasowych do wykrywania botnetów na Twitterze. Interesujące jest to, że model autora wykorzystuje tylko 1.2% oznaczonych przykładów w porównaniu z nieoznaczonymi przypadkami w badaniu RTbust. Autor pokazał, że proponowany model SNN MIMO działa bezpośrednio w domenie zdarzeń, czyli nie ma potrzeby kodowania szeregów czasowych. Doktorant zaprezentował nowatorskie etapy wstępnego przetwarzania sygnału i kilka innych elementów, np. wprowadził pewną heurystykę modyfikowania współczynnika skali regularyzacji podczas procesu uczenia.

W porównaniu z klasyfikatorem opartym na jądrze analizowanym w poprzednim rozdziale, okazało się, że sieć impulsowa SNN osiągnęła lepszą dokładność i wskaźnik F1 w zadaniu wykrywania botów na Twitterze (dane zawierały ok. 10 mln retweetów od 1,4 mln użytkowników). Jednak sądzę, że ten wynik autora powinien być wielokrotnie potwierdzony, aby mógł być uznany za statystycznie wiarygodny. Stwierdzono, że sieć SNN jest trudniejsza do dostrojenia, jednak lepiej skaluje się wraz z liczebnością zbioru danych uczących. Ponadto, klasyfikator SNN może być używany do rozwiązywania problemów wieloklasowych i nie jest ograniczony do jednego kanału.

W rozdziale 4 doktorant przedstawił nowy sposób nadzorowanego uczenia syjamskich wielowarstwowych sieci neuronowych. Sądzę, że stanowi to istotne osiągnięcie autora rozprawy, jako współtwórcy opisanych w tym rozdziale algorytmów. Sieci syjamskie optymalizują odległość Earth Mover's Distance (EMD) między wyjściowymi szeregami impulsów. W omawianym rozdziale została opisana konstrukcja sieci z neuronami sumującymi sygnały do osiągnięcia progu, generujące impuls po jego przekroczeniu z resetem pobudzenia (Integrate-and-Fire). Podejście do rozwiązania problemu jest nowatorskie, gdyż opisywana syjamska sieć neuronowa jest optymalizowana bezpośrednio, bez użycia konwersji istniejącej sieci neuronowej do domeny impulsowej. Model został oceniony na danych obrazowych, które zostały odpowiednio przekształcone przed wykorzystaniem ich do uczenia. Dla danych zawierających obrazy ręcznie pisanych cyfr (popularny zbiór danych MNIST zawierający 60 000 obrazów do uczenia i 10 000 do testowania o rozmiarach 28×28 pikseli), zaproponowana metodologia okazała się odporna na zmiany wymiarów warstwy wyjściowej. Procedura uczenia sieci prowadzi do modeli, które są szybkie i przetwarzają sygnały za pomocą niewielkiej liczby neuronów. Zbadano wpływ liczby neuronów wyjściowych na wydajność klasyfikatora, aktywność impulsów sieci i opóźnienie predykcji oraz wydajność sieci dla typowych wskaźników dla obrazów czarno-białych (binarnych) i obrazów w odcieniach szarości.

Doktorant opisał również metodykę uczenia syjamskich impulsowych sieci neuronowych na wymagającym zestawie danych obrazów z eksperymentu, w którym chodziło o detekcję promieniowania kosmicznego na zdjęciach wykonanych przez smartfony (projekt CREDO, którego skrót pochodzi od "Skrajnie Rozproszonego Obserwatorium Promieniowania Kosmicznego"). Rozpatrywane obrazy zawierały bardzo mały obszar informacyjny, więc problem rozpoznawania nie należy do łatwych i trochę przypomina problem segmentacji obrazów medycznych czy wykrywanie anomalii.

Zasugerowana w tym rozdziale adaptacja neuronu impulsowego do konstrukcji warstwy spłotowej jest warta dalszych badań. Wyniki prac rozdziału 4 zostały opublikowane na konferencji *IEEE Int. Conf. Acoustics, Speech and Signal Processing* (2022) oraz w czasopiśmie *Measurement* (2023), gdzie pierwszym autorem był mgr inż. Mateusz Pabian.

W rozdziale 5 autor omówił różne metody próbkowania sygnału wywołane zdarzeniami. Zwrócił uwagę na możliwość konwersji sygnałów wielowymiarowych na ciągi zdarzeń i pokazał sposób określania parametrów próbkowania pod kątem uzyskania dobrej efektywności klasyfikacji. Rozwiązywał problem identyfikacji typu pojazdu za pomocą sieci SNN. Sygnały uczące dla tej sieci pochodziły z czujników pola magnetycznego, które są wykorzystywane w inteligentnych systemach zarządzania ruchem drogowym (Vehicle Magnetic Profile, VMP). Autor rozpatrzył zbiór danych zawierający ponad 3 tys. rekordów, podzielonych na pięć klas: motocykl (24,32%), rower (20,42%), samochód (15,02%), samochód dostawczy (14,11%) i ciężarówka (6,61%). Dane nie były więc zrównoważone. Autor włożył spory wysiłek, aby znaleźć zestaw parametrów dla funkcji kodowania, przeprowadzając optymalizację bayesowską. Wykorzystał zaawansowaną bibliotekę "Hyperopt" służącą do wyboru modelu i optymalizacji hiperparametrów. Autor wykazał, że udaje się skutecznie nauczyć model sieci MIMO SNN rozwiązywania zadania identyfikacji typu pojazdu, jako problem klasyfikacji wieloklasowej.

Rozdział 6 podsumowuje badania i proponuje kierunki dalszych prac.

Autor zauważył – z czym się całkowicie zgadzam, że każdy kolejny rozdział opiera się na wynikach przedstawionych wcześniej. Generalnie, układ rozprawy doktorskiej jest kompletny i dobrze przemyślany.

c) Ocena zastosowanego piśmiennictwa w ramach rozprawy doktorskiej

Bibliografia w rozprawie doktorskiej mgr inż. Mateusza Pabiana liczy 256 pozycji, co dobrze świadczy o doktoracie, jakkolwiek mam wątpliwości czy autor rzeczywiście dokładnie przestudiował wszystkie cytowane prace. W rozprawie autor zamieścił powołania na znakomite książki, dobre publikacje w artykułach naukowych i konferencjach, jak również pozycje umieszczone w internetowym repozytorium tekstów naukowych arXiv, gdzie twórcy modeli sztucznej inteligencji coraz częściej prezentują swoje najnowsze dokonania. Wśród cytowanych w rozprawie publikacji są 4 powołania na prace, w których doktorant był współautorem. Wiele spośród cytowanych prac dotyczy impulsowych sieci neuronowych, są więc istotne dla tematu rozprawy, sporo ukazało się w ostatnich trzech latach a 9 prac pochodzi z roku 2023. Autor starał się więc wykorzystać najnowsze osiągnięcia z zakresu uczenia maszynowego dla danych zdarzeniowych, metod bayesowskich, impulsowych sieci neuronowych, optymalizacji i tematów pokrewnych. Nie zauważyłem braku powołań na literaturę w tekście rozprawy, jakkolwiek niektóre pozycje były wykorzystane w minimalnym zakresie, co często się zdarza nawet w publikacjach czasopism renomowanych.

d) Wskazanie oraz ocena celu pracy Kandydata do stopnia doktora

Ogólnym celem rozprawy było omówienie i zastosowanie podejścia do klasyfikacji danych, które polega na wykorzystaniu zarówno metod bayesowskich, jak również użyciu niedawno opracowanych rozwiązań wykorzystujących impulsowe sieci neuronowe. Klasyfikowane dane mają postać pewnych sekwencji czasowych. Sekwencje te mogą kodować roz-

maite informacje: obrazy przedstawiające ręcznie pisane cyfry, dane przestrzenno-czasowe czy dane akustyczne. Cel naukowy jest więc bardzo ambitny. Autor stara się rozwiązać nowe problemy, identyfikując istniejące luki w literaturze i starając się utrzymać odpowiedni rygor matematyczny. Jest to ważne, ponieważ podejście rygorystyczne dostarcza solidnych podstaw umożliwiających zrozumienie, optymalizację i dowodzenie poprawności algorytmów, lecz niestety, zdarza się rzadko w doktoratach omawiających algorytmy uczenia maszynowego. Uważam, że zamierzony cel pracy został w pełni osiągnięty a rozprawa wniosła znaczący wkład teoretyczny (przez podanie twierdzeń w rozdziale 2) i praktyczny (przez wykonanie wielu symulacji).

e) Wskazanie oraz ocena zastosowanych metod badawczych

W rozprawie rozpatrzono dwa różne podejścia do klasyfikacji danych. Pierwsze wykorzystuje zaawansowaną analizę statystyczną, dekompozycję martyngałową i metody bayesowskie, drugie zaś impulsowe sieci neuronowe. Obydwa podejścia są właściwe, a ich porównanie jest interesujące i istotne zarówno z punktu widzenia teorii, jak i zastosowań. Autor badał ograniczenia wydajności klasyfikatora w odniesieniu do długości okresu obserwacji i rozmiaru zbioru danych uczących. Oprócz rozważań teoretycznych stosował symulacje numeryczne. Zaawansowany aparat matematyczny świadczy o bardzo dobrym przygotowaniu teoretycznym autora. Wykazała to przeprowadzona analiza procesów punktowych, analiza zbieżności algorytmu do ryzyka bayesowskiego w funkcji liczby przykładów uczących czy zbadanie wpływu efektów brzegowych na działanie klasyfikatora opartego o jądrowy estymator gęstości. Przez zastosowanie odpowiedniego podejścia autor znacząco skrócił czas generowania wyjścia neuronu w sieci SNN i czas uczenia sieci. Ponadto zdefiniował funkcję kosztu, która umożliwia uczenie sieci syjamskiej bezpośrednio w dziedzinie zdarzeń. Zbadał również wpływ reprezentacji sygnału w postaci zdarzeniowej oraz hiperparametrów na działanie modelu klasyfikacyjnego. Sposób prezentacji rozważań i pokazane wyniki świadczą o poprawności stosowanych metod badawczych w rozprawie.

f) Ocena części rozprawy doktorskiej dotyczącej omówienia wyników badań

Wyniki w rozprawie mają postać wzorów, trzech twierdzeń matematycznych, pseudokodów, schematów blokowych, czytelnych rysunków i tabel. Od strony graficznej rozprawa została przygotowana wzorowo. Autor dokonał podsumowania każdego rozdziału rozprawy, przez co wprowadził porządek i ułatwił całościową ocenę uzyskanych rezultatów. Najwięcej wyników teoretycznych zawiera rozdział 2, gdzie są wnioski z zastosowania teorii Bayesa dla problemu klasyfikacji binarnej. Skomentowanie wyników teoretycznych tego rozdziału nie jest proste i wymaga dojrzałości. Dobrze, że autor poparł wyniki teoretyczne symulacjami. Interesujące jest zastosowanie zaproponowanego podejścia do danych rzeczywistych nt. aktywności użytkowników Twittera oraz wykrywania artefaktów podczas detekcji cząstek promieniowania kosmicznego. Omówienie wyników klasyfikacji jest przekonujące w rozdziałach opisujących te problemy. Z kolei metoda identyfikacji pojazdów w rozdziale 5 na podstawie pomiarów profilu magnetycznego została również opisana zrozumiale.

g) Informacje dotyczące praktycznego zastosowania uzyskanych wyników badań

Doktorant wykazał możliwość praktycznego zastosowania zaproponowanych metod przez rozwiązywanie następujących problemów:

- identyfikacja botów w mediach społecznościowych,
- wykrywanie artefaktów podczas detekcji cząstek promieniowania kosmicznego,
- identyfikacja typu pojazdu drogowego za pomocą złożonej impulsowej sieci neuronowej.

Zgadzam się z autorem, że wybór tak zróżnicowanych zastosowań dowodzi dużej uniwersalności opracowanych metod.

h) Informacja o ewentualnych nieprawidłowościach, które pojawiły się w ocenianej rozprawie doktorskiej

W recenzowanej rozprawie doktorskiej nie zauważyłem nieprawidłowości.

i) Ocena czy rozprawa doktorska stanowi oryginalne rozwiązanie problemu naukowego

Uważam, że rozprawa doktorska mgr. inż. Mateusza Pabiana stanowi oryginalne rozwiązanie problemu naukowego. Na szczególną uwagę zasługują:

1. Opracowanie nowej metodologii klasyfikacji opartej na teorii Bayesa. Praca wprowadza innowacyjną metodologię klasyfikacji danych sekwencyjnych, skupiając się na analizie danych z nielosowymi funkcjami intensywności. Pokazanie, że ryzyko Bayesa dąży do zera w miarę wydłużania okresu obserwacji, stanowi istotny wkład naukowy autora w zakresie klasyfikacji obserwacji długotrwałych.
2. Udoskonalenie metod uczenia impulsowej sieci neuronowej. Autor wprowadził znaczące innowacje w zakresie uczenia SNN, w tym wektoryzację obliczeń warstwy sieci, co zredukowało czas obliczeń o trzy rzędy wielkości. Przedstawił też modyfikacje pozwalające na przetwarzanie wielokrotnych impulsów, co zwiększa możliwość zastosowania modeli SNN w sytuacjach realnych.

Dodatkowo, rozprawa rozszerza możliwości modeli SNN przez wprowadzenie sieci syjamskich, uczonych w przestrzeni zdarzeń, co jest nowością w stosunku do metod tradycyjnych. Ostatecznie, zastosowanie opracowanych metod do realnych danych i ich dobre wyniki w różnorodnych zastosowaniach, jak detekcja botów na Twitterze czy klasyfikacja typów pojazdów drogowych, podkreślają oryginalność i praktyczną użyteczność podejścia.

j) Ocena czy rozprawa doktorska prezentuje ogólną wiedzę teoretyczną Kandydata do stopnia doktora w dyscyplinie albo dyscyplinach oraz umiejętność samodzielnego prowadzenia pracy naukowej

Analiza rozprawy doktorskiej mgr. inż. Mateusza Pabiana oraz artykułów naukowych, w których był on współautorem dowodzi, że wykazał on ogólną wiedzę teoretyczną w dyscyplinie automatyka, elektronika, elektrotechnika i technologie kosmiczne. Dodatkowo, opanował zaawansowane techniki przetwarzania danych i uczenia maszynowego, mieszczące się w dyscyplinie informatyka techniczna i telekomunikacja. Praca wykorzystuje zaawansowane metody przetwarzania danych zdarzeniowych, co wymaga znajomości teorii procesów punktowych, sieci neuronowych, neurobiologii obliczeniowej i teorii pomiarów.

Poprzez następujące dokonania:

- współautorstwo artykułów naukowych, w których występował jako autor korespondencyjny,
- identyfikacja luk w istniejącej wiedzy dotyczącej klasyfikacji sekwencji zdarzeń i neuronowych sieci impulsowych,
- rozwój innowacyjnych metod, takich jak zastosowanie teorii Bayesa w klasyfikacji oraz optymalizacja algorytmów uczenia sieci SNN,
- przeprowadzenie symulacji numerycznych i analiz statystycznych w celu weryfikacji proponowanych rozwiązań,
- zastosowanie opracowanych metod w praktycznych scenariuszach uczenia maszynowego, takich jak wykrywanie botów w mediach społecznościowych czy klasyfikacja pojazdów,

autor rozprawy wykazał zdolność do samodzielnej pracy badawczej, co jest kluczowe w pracy doktorskiej i dalszej karierze naukowej. Praca doktorska jest więc w znacznym stopniu interdyscyplinarna.

2 Zauważone błędy, braki oraz niesłuszne lub niedokładne sformułowania

Większość uwag ogólnych i niektórych pytań, które wymieniam poniżej, nadaje się raczej do dyskusji i nie wpływa na ostateczną wysoką ocenę rozprawy.

2.1. Uwagi ogólne

Poniższe uwagi mają wyłącznie charakter dyskusyjny.

1. Czy autor udostępnia oprogramowanie w celu zagwarantowania odtwarzalności wyników badań?

2. Ponieważ rozpatruje się problem klasyfikacji danych, jak można umiejscowić (pod względem wydajności lub wymagań obliczeniowych) wyniki otrzymywane w tej rozprawie (dzięki sieci SNN) z wynikami sieci LSTM, RNN czy CNN (np. dla danych MNIST)?
3. Jaka przesłanka przemawiała za tym, aby w symulacji na str. 14–15 brać pod uwagę iloraz ϕ_2/ϕ_1 a nie np. różnicę? To samo dotyczy r_2/r_1 w następnym przykładzie.
4. Czy zawsze przy spełnieniu założeń A1 i A2 ryzyko R_T^* w (2.12) zanika monotonicznie (czy może się zdarzyć, że $dR_T^*/dt > 0$ pomimo $\lim_{T \rightarrow \infty} R_T^* = 0$)?
5. Str. 44. W jaki sposób było dokonane etykietowanie ok. 600 przykładów spośród ponad 63 tys. przypadków nieoznakowanych?
6. Nie wspomniano, że oprócz podejścia do klasyfikacji wieloklasowej opisanego na str. 44 wzorem (2.36) można zastosować inne algorytmy, jak OVA, czy AVA.
7. W podrozdziale 4.2.1 w (4.10) i dalej użyto funkcji $\delta(t)$ – delta Diraca, która jest dystrybucją (granica ciągu funkcyjnego), więc nie jest bezwzględnie całkowna w sensie Lebesgue-a (czyli formalnie, całka (4.11)) – metryka Wassersteina nie istnieje). Czy nie można użyć delty Kroneckera, tym bardziej, że istotne są tylko czasy występowania zdarzeń plus ewent. intensywność (singleton)?

2.2 Dostrzeżone błędy i drobne usterki

1. Przy pierwszym użyciu skrótu “i.i.d.” warto napisać “independent and identically distributed”.
2. Czym jest \mathbf{x} w (2.5) w zapisie $f(\mathbf{x})$?
3. W (2.10) jest raz $p_i(t) = \lambda_i(t) / \tau_i$ a innym razem $p_i(t) = \lambda_i(u) / \tau_i$.
4. Zamiast szerokiego cytowania pracy *Bayes Risk Consistency of Nonparametric Classification Rules for Spike Trains Data* (2023, arXiv), wolałbym wyjaśnienia udziału doktoranta w opracowaniu trzech twierdzeń w rozdziale 2.
5. Trochę brakuje mi odniesienia się do innych, prostszych klasyfikatorów (np. MLP, PNN, LVQ, DT, ...), zdolnych do rozwiązania identycznych zadań klasyfikacji (np. dla danych MNIST), aby mieć wyobrażenie dotyczące wskaźników jakości, niezbędnych zasobów obliczeniowych, szybkości uczenia, itp.
6. Jakkolwiek autor omówił kilka interesujących impulsowych sieci neuronowych, np. model sieci typu “time-to-first-spike” (czas do pierwszego impulsu), to zabrakło mi krótkiej dyskusji nt. możliwości realizacji sprzętowej tych nowatorskich sieci, które są szybkie i energooszczędne.

3 Konkluzja

Zauważone drobne usterki w rozprawie nie mają znaczenia dla całościowej oceny. Cel pracy został osiągnięty. Z moich dotychczasowych uwag jednoznacznie wynika, że:

- 1 - przedmiotem rozprawy doktorskiej mgr. inż. Mateusza Pabiana jest oryginalne rozwiązanie problemu naukowego,
- 2 - rozprawa doktorska prezentuje ogólną wiedzę teoretyczną doktoranta w dyscyplinie **automatyka, elektronika, elektrotechnika i technologie kosmiczne** (a nawet informatyka techniczna i telekomunikacja),
- 3 - rozprawa i współautorskie publikacje naukowe doktoranta wskazują na umiejętność samodzielnego prowadzenia pracy naukowej.

W związku z tym stwierdzam, że rozprawa doktorska mgr. inż. Mateusza Pabiana spełnia wszystkie wymagania określone w art. 187 ustawy z dnia 20 lipca 2018r. Prawo o szkolnictwie wyższym i nauce (t.j. Dz.U. z 2021r. poz.478 z późn.zm.). Jednocześnie zwracam się do Wysokiej Rady Dyscypliny Naukowej Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne Akademii Górniczo – Hutniczej im. Stanisława Staszica w Krakowie o dopuszczenie Pana mgr. inż. Mateusza Pabiana do dalszego postępowania w sprawie nadania mu stopnia doktora w dyscyplinie **automatyka, elektronika, elektrotechnika i technologie kosmiczne**.

Ponadto, ze względu na dokonania doktoranta wymienione w punkcie 1i niniejszej recenzji (oryginalność rozwiązania problemu naukowego), ogrom włożonej pracy w przygotowanie rozprawy i współautorstwo kilku znaczących publikacji naukowych, wnioskuję do Wysokiej Rady o **wyróżnienie rozprawy**.

