



**AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE**

**DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH**

DYSCYPLINA AUTOMATYKA, ELEKTRONIKA, ELEKTROTECHNIKA  
I TECHNOLOGIE KOSMICZNE

## **AUTOREFERAT ROZPRAWY DOKTORSKIEJ**

Uczenie maszynowe dla danych zdarzeniowych przy  
pomocy metod bayesowskich oraz impulsowych sieci  
neuronowych

Autor: mgr inż. Mateusz Pabian

Promotor rozprawy: prof. dr hab. Mirosław Pawlak

Promotor pomocniczy: dr inż. Dominik Rzepka

Praca wykonana: Akademia Górniczo-Hutnicza im. Stanisława Staszica  
w Krakowie, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii  
Biomedycznej

Kraków, 2025

# Streszczenie

W związku z narastającą ilością danych przetwarzanych przez współczesne systemy informatyczne i pomiarowe pojawia się konieczność opracowania skalowalnych metod uczenia maszynowego analizujących dane zdarzeniowe. Możliwe jest przetworzenie tego rodzaju danych przez metody klasyczne, jednak ich użycie wymaga konwersji danych do postaci zawierającej redundancję. Kluczowe jest zatem rozwijanie algorytmów dedykowanych do danych zdarzeniowych.

Celem prac przedstawionych w rozprawie było przeanalizowanie dwóch podejść do zagadnienia uczenia maszynowego dla danych zdarzeniowych. Pierwsze z nich opierało się o zastosowanie teorii procesów punktowych, która jest często wykorzystywana w neurobiologii obliczeniowej do analizy impulsów, a rzadziej – w kontekście nadzorowanej klasyfikacji szeregów czasowych. Rozwiązaniem alternatywnym są impulsowe sieci neuronowe cieszące się dużym zainteresowaniem badaczy, mimo iż ich proces uczenia zwykle wymaga symulowania stanu całej sieci w każdej chwili czasowej, co powoduje zaangażowanie znaczących zasobów obliczeniowych. Ponadto, nie zostało w pełni zbadane w jaki sposób konwersja sygnału do postaci zdarzeniowej wpływa na działanie wyuczonego modelu.

Do rozwiązania tych problemów wykorzystano metody analizy statystycznej oraz symulacje numeryczne. Zaproponowano reguły klasyfikacji procesów punktowych przy pomocy metod bayesowskich, a następnie przeanalizowano zbieżność algorytmu do ryzyka bayesowskiego w funkcji liczby przykładów uczących. Sprawdzone również wpływ efektów brzegowych na działanie klasyfikatora opartego o jądrowy estymator gęstości. W kontekście impulsowych sieci zrównoleglono algorytm obliczania wyjścia neuronu reagującego na czas wystąpienia impulsu wejściowego, co znacząco skróciło czas uczenia sieci. Ponadto zaproponowano modyfikacje modelu obliczeniowego neuronu w tej sieci impulsowej umożliwiające generowanie ciągu zdarzeń w odpowiedzi na zadaną sekwencję wejściową. Zdefiniowano również funkcję kosztu, która umożliwia uczenie sieci syjamskiej bezpośrednio w dziedzinie zdarzeń.

Praktyczną stosowalność tych metod zweryfikowano w kontekście trzech problemów badawczych: identyfikacji botów w mediach społecznościowych, wykrywania artefaktów podczas detekcji cząstek promieniowania kosmicznego oraz kategoryzacji pojazdów drogowych. W każ-

dym z tych scenariuszy sprawdzono wpływ reprezentacji sygnału w postaci zdarzeniowej oraz hiperparametrów procesu uczenia na działanie gotowego modelu. Wybór tak zróżnicowanych zastosowań pokazuje szeroką stosowalność opracowanych metod.

# Spis treści

<b>1</b>	<b>Wstęp</b>	<b>1</b>
1.1	Wprowadzenie . . . . .	1
1.2	Cel pracy i problemy badawcze . . . . .	2
<b>2</b>	<b>Najważniejsze wyniki pracy</b>	<b>4</b>
2.1	Klasyfikacja sekwencji zdarzeń przy pomocy teorii procesów punktowych . . . .	4
2.2	Uczenie sieci SNN wrażliwej na czas wygenerowania pierwszego impulsu wyjściowego . . . . .	6
2.3	Wpływ wyboru mechanizmu kodowania sygnałów na postać zdarzeniową . . . .	8
2.4	Ewaluacja modeli na przykładzie rzeczywistych problemów badawczych . . . .	10
<b>3</b>	<b>Podsumowanie i kierunki dalszych prac</b>	<b>13</b>
	<b>Lista najważniejszych publikacji</b>	<b>15</b>
	<b>Bibliografia</b>	<b>16</b>

# Wstęp

## 1.1 Wprowadzenie

Dane zdarzeniowe są przykładem szeregu czasowego, w którym każdy punkt (zdarzenie) jest opisany przez trzy własności: chwilę czasową, w której nastąpiło dane zdarzenie; kategorię zdarzenia; oraz jego wartość (tj. deskryptor) [1]. O ile moment wystąpienia zdarzenia musi być zawsze zdefiniowany, o tyle pozostałe dwie własności mogą być domniemane (np. system rejestruje tylko jeden rodzaj zdarzenia; zdarzenie nie posiada deskryptora, gdyż jedyną istotną cechą jest fakt jego zajścia). Dane zdarzeniowe naturalnie występują w takich dziedzinach jak modelowanie aktywności klientów w bankowości [2] czy mediach społecznościowych [3], wykrywanie zagrożeń w cyberbezpieczeństwie [4], detekcja anomalii i usterek na podstawie rejestru aktywności [5], czy analiza danych pochodzących z elektronicznej dokumentacji medycznej [6].

Ciąg zdarzeń można otrzymać również poprzez próbkowanie sygnału analogowego na podstawie zadanych kryteriów opartych o zdarzeniowość. Koncepcja ta oparta jest na założeniu, że moment wystąpienia zdarzenia ma dużą wartość informacyjną. Dla przykładu: w biologicznych sieciach neurony komunikują się przy pomocy potencjału czynnościowego będącego przejściową zmianą potencjału błonowego komórki. Generowaniem potencjałów czynnościowych rządzi zasada “wszystko albo nic” – jeśli bodziec działający na komórkę jest odpowiednio silny, to wygenerowany sygnał zawsze osiągnie tę samą amplitudę. Z uwagi na istotę tego procesu w analizie aktywności biologicznych komórek w badaniach neurobiologicznych stosuje się abstrakcję sekwencji zdarzeń (impulsów) jako chwili czasowych wystąpienia potencjałów czynnościowych, ignorując inne zarejestrowane zjawiska [7].

Wnioski z badań nad rolą zdarzeń w przekazywaniu informacji przez neurony doprowadziły do stworzenia czujników zdarzeniowych [8]. W odróżnieniu od typowych czujników nie rejestrują one sygnałów w regularnych odstępach czasu. Zamiast tego próbują sygnał po wystąpieniu pewnego (istotnego z punktu widzenia systemu) zdarzenia. Dzięki temu charakteryzują się one szerokim zakresem dynamicznym (tj. możliwością rejestracji zarówno bardzo niskich jak i bardzo wysokich składowych częstotliwościowych sygnału), znaczną redukcją liczby pró-

bek, a także niskim opóźnieniem w asynchronicznej transmisji zakodowanego sygnału. Rozwój badań nad kodowaniem w ludzkim procesie odbierania bodźców umożliwił stworzenie neuro-morficznych czujników rejestrujących obraz [9], dźwięk [10], zapach [11] czy nacisk [12] przy pomocy zdarzeń.

Co istotne, użycie czujników zdarzeniowych nie jest jedynym sposobem otrzymywania sekwencji zdarzeń kodującej dane zjawisko. Możliwe jest transformowanie istniejących zbiorów danych do postaci zdarzeniowej przy pomocy obliczeń komputerowych [13] lub specjalizowanych rozwiązań sprzętowych [14]. Takie podejście pozwala opracowywać algorytmy przetwarzające dane zdarzeniowe nawet gdy nie istnieją jeszcze mechanizmy umożliwiające optymalne pozyskanie sekwencji zdarzeń na podstawie obserwacji danego zjawiska. Z tego powodu symulacje komputerowe z wykorzystaniem takich syntetycznych danych zdarzeniowych mogą być przydatne w procesie prototypowania nowych czujników do akwizycji sygnałów. Ponadto umożliwiają one porównanie z klasycznym (niezdarzeniowym) sposobem przetwarzania sygnałów.

## 1.2 Cel pracy i problemy badawcze

Celem badań prowadzonych w ramach doktoratu było zastosowanie metod uczenia maszynowego do danych zdarzeniowych. Podstawowym problemem stojącym na drodze takich badań jest fakt, że dane użyte do uczenia modeli muszą charakteryzować się pewnym zestawem cech, na podstawie których model uczy się rozwiązywać postawiony przed nim problem. Pojęcie “cech” dla danych zdarzeniowych jest jednak trudne do zdefiniowania, ponieważ muszą one kodować wszystkie własności zdarzeń: czas (który może być dowolny), kategorię (gdzie zdarzenia różnego typu mogą mieć różną częstość występowania) oraz wartość (gdzie każdy typ zdarzenia może mieć inny poziom szczegółowości deskryptora). To powoduje, że dane zdarzeniowe cechują się niezdefiniowaną wymiarowością oraz rzadkością reprezentacji, co stanowi problem dla klasycznych algorytmów uczenia maszynowego. W wybranych przypadkach możliwe jest transformowanie sekwencji zdarzeń na inną postać, która może być przetworzona przez klasyczne algorytmy, np. poprzez wprowadzanie dodatkowej informacji o braku zdarzenia lub przepróbkowanie sygnału. Uzyskany w ten sposób sygnał charakteryzuje się pewną redundancją informacji. Konieczne jest zatem opracowanie nowych, specjalizowanych algorytmów bezpośrednio operujących na postaci zdarzeniowej wynikającej z danych.

Na podstawie przeprowadzonego przeglądu literatury zaproponowano następujące problemy badawcze:

- 1) Klasyczne podejście oparte o teorię procesów punktowych jest szeroko wykorzystywane w neurobiologii obliczeniowej do wysokopoziomowego opisu procesów zachodzących w

biologicznych sieciach neuronowych. Ta metoda mogłaby znaleźć zastosowanie do nadzorowanej klasyfikacji sekwencji zdarzeń, pod warunkiem zdefiniowania reguły uczenia modelu oraz zbadania zależności skuteczności klasyfikacji od ilości danych uczących.

- 2) Impulsowe sieci neuronowe (ang. *Spiking Neural Networks*, SNN) łączą współczesne techniki głębokiego uczenia z modelami obliczeniowymi neuronu uwzględniającymi biologiczne zjawiska takie jak komunikacja przy pomocy zdarzeń, plastyczność synaptyczna (zmiany połączeń wywoływane aktywnością sieci) czy okres refrakcji (względnej niewrażliwości neuronu na bodźce). W literaturze istnieje wiele różnych metod uczenia tych modeli. Dominującym nurtem badań jest uczenie oparte o symulowanie zmiennego w czasie stanu sieci (tj. zmian potencjału membrany każdego sztucznego neuronu) poprzez jego dyskretyzację w czasie. Alternatywnym sposobem przetwarzania informacji w modelu byłoby próbkowanie stanu sieci tylko w chwili wygenerowania impulsu przez jeden z neuronów. Pozwoliłoby to zredukować złożoność obliczeniową procesu uczenia, co może być istotne w przypadku realizowania go na urządzeniu o ograniczonej zdolności do równoleglenia obliczeń.
- 3) Przetwarzanie danych z postaci ciągłej do postaci zdarzeniowej jest zazwyczaj procesem stratnym. W kontekście uczenia maszynowego na danych zdarzeniowych istotne jest zatem sprawdzenie różnych sposobów przeprowadzania tego rodzaju konwersji oraz doboru ich parametrów. Nasuwa to pytanie czy wybór mechanizmu konwersji danych wpływa na własności gotowego rozwiązania (a jeśli tak, to na które z nich) i w jaki sposób należy dobrać parametry użytej metody konwersji.
- 4) Użycie opracowanych metod do rozwiązania praktycznych problemów badawczych pozwala zweryfikować ich zakres stosowalności oraz przedstawić niezbędne modyfikacje, które są specyficzne dla danego zastosowania. Stanowi to również okazję do porównania skuteczności proponowanego rozwiązania z innymi podejściami, jak również do przeanalizowania jak poszczególne elementy składowe modelu wpływają na jego końcowe działanie.

W przeprowadzonych badaniach ograniczono się do problemów klasyfikacyjnych (opartych o funkcję decyzyjną lub wzajemne podobieństwo sygnałów) dla sekwencji zdarzeń pozbawionych deskryptora (tj. gdy czas wystąpienia i typ zdarzenia są jedynymi dostępnymi informacjami).

# Najważniejsze wyniki pracy

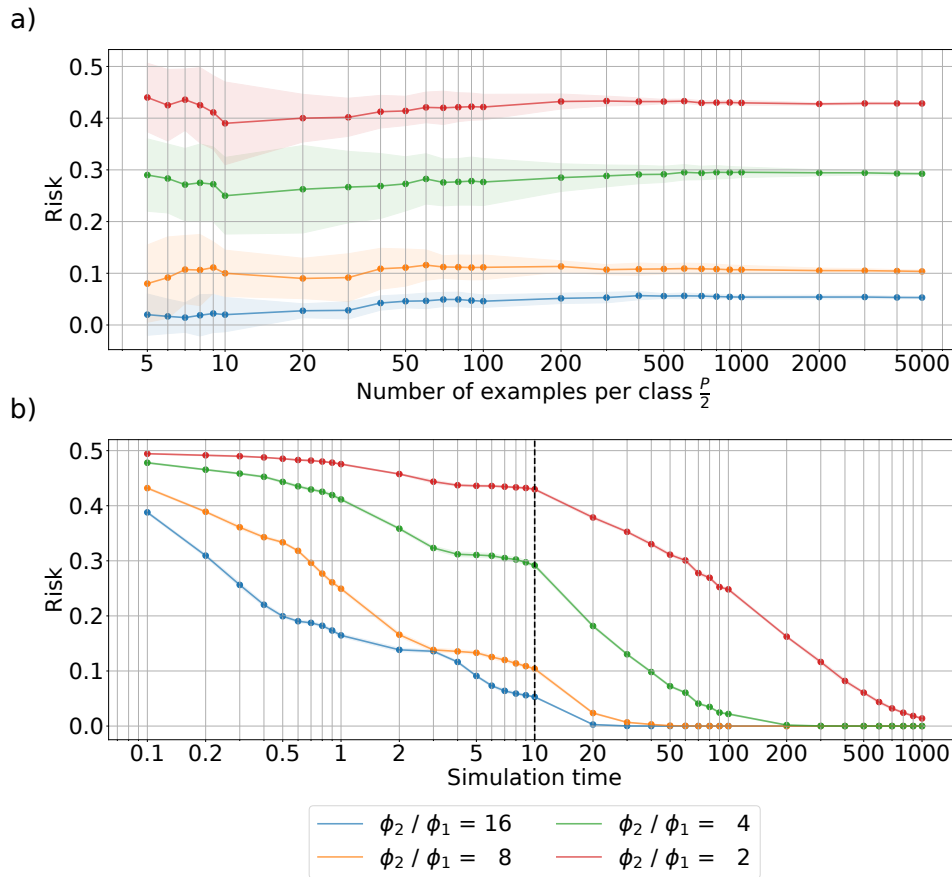
Główną część rozprawy stanowią cztery rozdziały, z czego pierwszy z nich dotyczy podejścia opartego o teorię procesów punktowych, zaś pozostałe trzy traktują o impulsowych sieciach neuronowych. Każdy z rozdziałów wprowadza czytelnika w tematykę omawianego zagadnienia, przedstawia nowo opracowaną metodologię (z podkreśleniem jej obszarów stosowalności, ograniczeń oraz charakterystycznych właściwości), a następnie prezentuje jej zastosowanie dla praktycznego problemu badawczego na danych rzeczywistych.

W kolejnych sekcjach niniejszego dokumentu zestawiono najważniejsze wyniki przedstawione w rozprawie, pogrupowane pod kątem zrealizowanych celów badawczych.

## 2.1 Klasyfikacja sekwencji zdarzeń przy pomocy teorii procesów punktowych

- 1) Dla binarnego problemu klasyfikacji sekwencji zdarzeń zaproponowano klasyfikator Bayesa zdefiniowany w oparciu o funkcję gęstości prawdopodobieństwa wystąpienia zdarzenia w zadanym procesie punktowym. Celem zweryfikowania poprawności algorytmu wykonano badania symulacyjne Monte Carlo dla par procesów punktowych będących przykładami niehomogenicznego procesu Poissona. W ramach symulacji zaobserwowano zbieżność ryzyka empirycznego do ryzyka bayesowskiego (Rysunek 2.1a). Jednocześnie empirycznie wykazano zbieżność ryzyka bayesowskiego do zera, gdzie tempo zbieżności uzależnione jest od stopnia trudności problemu klasyfikacyjnego – im bardziej podobne są badane klasy, tym dłuższy horyzont czasowy należy przeanalizować celem ich poprawnej klasyfikacji (Rysunek 2.1b). Przedstawiono również warunki stosowalności opracowanej metodologii wraz z zasymulowaniem kontrprzykładu, dla którego nie jest możliwe wykonanie klasyfikacji przy pomocy proponowanego rozwiązania.
- 2) Przedstawiono odpowiednik ww. klasyfikatora Bayesa stosowalny w praktycznych problemach badawczych, tj. gdy nie jest znana funkcja gęstości prawdopodobieństwa wystąpienia zdarzenia. Opracowana metodologia (reguła empiryczna) opiera się na estymowaniu funkcji gęstości prawdopodobieństwa na podstawie różnych realizacji (powtórzeń) każ-






**Rysunek 2.1:** Wynik symulacji Monte Carlo dla binarnego problemu klasyfikacji sekwencji zdarzeń. Różnymi kolorami oznaczono stopień podobieństwa pomiędzy klasami (niebieski – najmniej podobne; czerwony – najbardziej podobne). a) Zbieżność ryzyka empirycznego reguły klasyfikacyjnej do pewnej wartości (będącej wartością ryzyka bayesowskiego) w funkcji liczby zasymulowanych par  $P$  przy zadanym oknie obserwacji zdarzeń  $T$ . b) Zbieżność ryzyka bayesowskiego do zera (co odpowiada idealnej klasyfikacji) w funkcji długości okna obserwacji zdarzeń  $T$ . Pionowa linia przerywana w punkcie  $T = 10$  reprezentuje wycinek symulacji przedstawiony na górnym wykresie.

dego z procesów punktowych stanowiących parę w analizowanym binarnym problemie klasyfikacyjnym. Zbiór tych realizacji stanowi zbiór uczący modelu. Wykonano symulacje Monte Carlo potwierdzające zbieżność reguły empirycznej opartej o estymację funkcji gęstości przy pomocy jądrowego estymatora gęstości (ang. *kernel density estimation*, KDE) do ryzyka bayesowskiego w funkcji liczby przykładów wchodzących w skład zbioru uczącego. Zaobserwowano, że optymalna wartość parametru wygładzania jądra (ang. *bandwidth*) estymatora KDE rośnie wraz z długością analizowanej sekwencji, ale maleje wraz z rozmiarem zbioru uczącego.

- 3) Estymator KDE jest podatny na efekty brzegowe objawiające się niedokładnościami estymacji w otoczeniu dolnej i górnej granicy nośnika estymowanej funkcji. Symulacyjnie zweryfikowano wpływ trzech różnych, klasycznych podejść rozwiązujących problem



**Rysunek 2.2:** Wpływ wektoryzacji obliczeń w sieci SNN na czas uczenia w zależności od wymiarowości problemu (tj. liczby neuronów wejściowych, liczby neuronów wyjściowych oraz liczby sekwencji podanych na wejście modelu). Obie osie w skali logarytmicznej. Wartości na osi y oznaczają względne skrócenie czasu niezbędnego do wykonania obliczeń algorytmu zwektoryzowanego w odniesieniu do oryginalnej implementacji. Dla odpowiednio dużej wymiarowości problemu proponowany algorytm jest o ok. trzy rzędy wielkości szybszy.

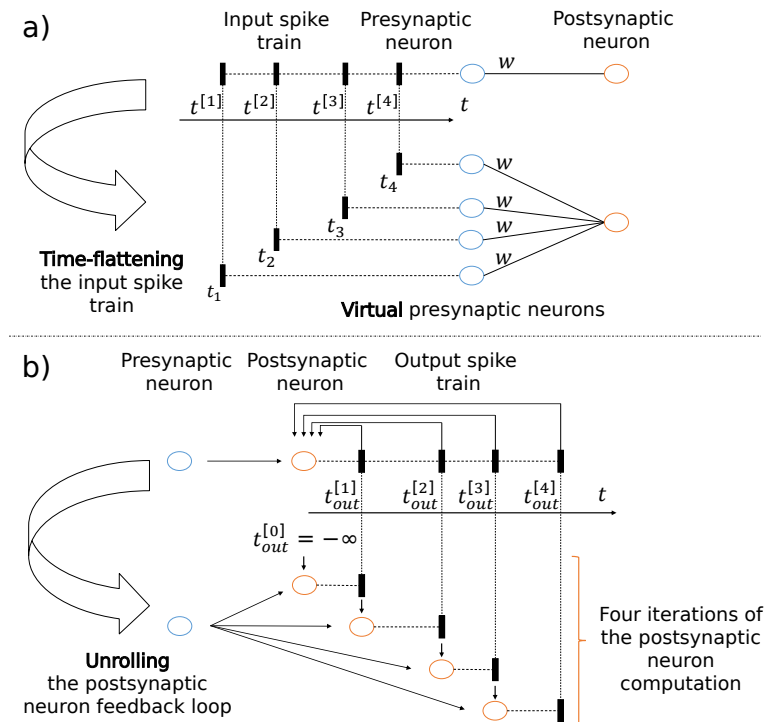
efektów brzegowych w omawianym zagadnieniu binarnej klasyfikacji procesów punktowych. Uzyskane wyniki sugerują, że zastosowanie algorytmu ograniczającego efekty brzegowe ma pozytywny wpływ na skuteczność klasyfikacji, pod warunkiem że sekwencja jest odpowiednio krótka (tj. sumaryczna szerokość regionów przy granicach nośnika estymowanej funkcji jest relatywnie duża w stosunku do długości całej sekwencji). Wykazano, że dla dostatecznie długich sekwencji zdarzeń wpływ efektów brzegowych na problem klasyfikacyjny jest pomijalny.

## 2.2 Uczenie sieci SNN wrażliwej na czas wygenerowania pierwszego impulsu wyjściowego

- 1) W wyniku przeprowadzonego przeglądu literatury zidentyfikowano model sieci SNN, dla której zdefiniowane zostały reguły propagacji sygnału oparte o czas wygenerowania pierwszego impulsu wyjściowego. Model ten uczony jest w całości w dziedzinie zdarzeń, co odróżnia go od rozwiązań opartych o konwersję nieimpulsowej sztucznej sieci neuronowej na model SNN. Ponadto, proces uczenia nie wymaga symulowania stanu całej sieci w czasie. Przeprowadzono studium replikowalności potwierdzające wyniki z oryginalnej publikacji. Na tej podstawie zidentyfikowano główne ograniczenia metody i zaproponowano modyfikacje rozszerzające jej zakres stosowalności.
- 2) Podstawowym problemem ww. algorytmu jest jego duża złożoność obliczeniowa – wy-

znaczenie czasu wygenerowania pierwszego zdarzenia przez pojedynczy neuron wymaga sprawdzenia każdej kombinacji zdarzeń na wejściu neuronu. Te obliczenia należy powtórzyć dla każdego neuronu sieci i dla każdego przykładu podanego na wejście modelu, co sumarycznie skutkuje długim czasem obliczeń. W rozprawie zaproponowano modyfikacje algorytmu mające na celu wykonanie wszystkich obliczeń w jednym kroku (tzw. wektoryzacja). W efekcie uzyskano algorytm będący o trzy rzędy wielkości szybszy niż wersja zaproponowana w publikacji źródłowej (Rysunek 2.2).

- 3) Zaobserwowano wrażliwość omawianego modelu SNN na bezwzględny czas wystąpienia zdarzenia, co objawia się niestabilnością procesu uczenia dla dużych wartości czasu zdarzenia. Zaproponowano mechanizm przesuwania impulsów w czasie w trakcie uczenia tak, aby pierwszy z nich występował we względnej chwili czasowej  $t = 0$ . Dzięki temu proces uczenia zawsze skutkuje uzyskaniem tego samego zestawu wartości wag połączeń pomiędzy neuronami, niezależnie od bezwzględnego czasu wystąpienia pierwszego zdarzenia. Ponadto, celem uniknięcia problemów numerycznych występujących gdy czas wystąpienia zdarzenia jest bardzo duży, zaproponowano transformowanie sekwencji zdarzeń przy pomocy funkcji wzajemnie jednoznacznej ze zredukowanym zakresem wartości (np. stosując funkcję logarymiczną).
- 4) Zaproponowano modyfikację składnika funkcji kosztu odpowiedzialnego za penalizowanie braku aktywności sieci. Zauważono, że zadanie postawione przed modelem w procesie uczenia może być rozwiązane bez wymagania, aby każdy neuron sieci SNN wygenerował impuls (co jest wymogiem modelu bazowego). Ucząc model na danych pochodzących ze zbioru zdjęć MNIST zweryfikowano, że model trenowany ze zmodyfikowaną funkcją kosztu wykazuje średnio niższą aktywność sieci bez istotnej redukcji w skuteczności klasyfikacji. Otwiera to możliwość stosowania tego modelu w problemach badawczych, w których wymaga się możliwie rzadkiej aktywności sieci.
- 5) Fundamentalnym ograniczeniem analizowanego bazowego modelu SNN jest fakt, że każdy neuron może wygenerować co najwyżej jedno zdarzenie w odpowiedzi na zadany sygnał wejściowy. W związku z tym zaproponowano dwa mechanizmy mające na celu umożliwienie propagacji sekwencji zdarzeń przez model bez dokonywania fundamentalnych zmian w funkcji przejścia każdego neuronu: spłaszczanie sekwencji wejściowej wraz z powielaniem neuronów wejściowych (Rysunek 2.3a) oraz iterowanie po kolejnych zdarzeniach wyjściowych (Rysunek 2.3b). Należy podkreślić, że proponowane rozwiązanie iteruje po przestrzeni zdarzeń (która jest ograniczona – neuron nie może wygenerować więcej impulsów niż obserwuje), a nie po kolejnych chwilach czasowych.



**Rysunek 2.3:** Proponowana modyfikacja sieci SNN umożliwiająca obserwowanie i generowanie sekwencji zdarzeń przez każdy neuron. a) Spłaszczanie sekwencji wejściowej wraz z powielaniem neuronów wejściowych – sekwencja zdarzeń obserwowana przez pojedynczy neuron jest równoznaczna z wieloma neuronami obserwującymi jedno zdarzenie. b) Iterowanie po kolejnych zdarzeniach wyjściowych – podczas obliczania czasu wygenerowania impulsu należy uwzględnić moment wygenerowania poprzedniego impulsu (gdzie neuron obserwuje taki sam zbiór sekwencji niezależnie od numeru iteracji).

## 2.3 Wpływ wyboru mechanizmu kodowania sygnałów na postać zdarzeniową

- 1) W rozprawie zaproponowano metodologię klasyfikacji obrazów przy pomocy opisujących metod poprzez ich transformację do postaci zdarzeniowej. Konwersję przeprowadzono przypisując do każdego z pikseli co najwyżej jedno zdarzenie, gdzie czas zdarzenia odpowiada jasności pikseli. Dla obrazów w skali szarości pochodzących ze zbioru MNIST zaproponowano trzy metody kodowania: binarne (oddzielne zdarzenia dla pikseli białych i czarnych), indykatorowe (tylko dla pikseli białych) oraz w skali ciągłej (zdarzenie występuje tym wcześniej, im jaśniejszy jest dany piksel). Ucząc sieć SNN na takich danych opracowano kryterium optymalizacyjne oparte na wzajemnym podobieństwie analizowanych sekwencji, dzięki czemu gotowy model stanowi przykład syjamskiej sieci SNN. W wyniku przeprowadzonej analizy zaobserwowano, że wyższą dokładność klasyfikacji uzyskuje się kosztem znacznego zwiększenia aktywności sieci (tj. większy odsetek neu-

**Tabela 2.1:** Parametry kodowania sygnałów pochodzących z drogowych czujników pojazdów na postać zdarzeniową wraz z metrykami skuteczności klasyfikacji typu pojazdu metodą k-najbliższych sąsiadów.

Encoding type	Chosen parameters	Number of events per VMP sensor	stratified 10-fold cross-validated k-NN performance	
			Accuracy	F <sub>1</sub> -score
level-crossing	$L = 12$	$29.484 \pm 8.996$	$0.912 \pm 0.011$	$0.907 \pm 0.016$
send-on-delta	$\Delta = 0.06$	$36.536 \pm 9.040$	$0.910 \pm 0.014$	$0.909 \pm 0.019$
LIF	$\tau_{\text{int}} = 0.1$ $\tau_{\text{leak}} = 0.5$ $V_{\text{thr}} = 0.2$	$8.317 \pm 5.673$	$0.905 \pm 0.011$	$0.900 \pm 0.015$

ronów generuje impulsy). Dla wszystkich trzech rodzajów kodowania zaobserwowano wzrost dokładności klasyfikacji obserwując wynikową sekwencję przez dłuższy czas, przy czym modele uczone z kodowaniem binarnym osiągały swoje maksimum dokładności ok. 45% później niż modele uczone z kodowaniem indykatorowym i w skali ciągłej. Uzyskane wyniki sugerują zatem istnienie konieczności ustalenia kompromisu między dokładnością modelu a jego złożonością obliczeniową i szybkością odpowiedzi.

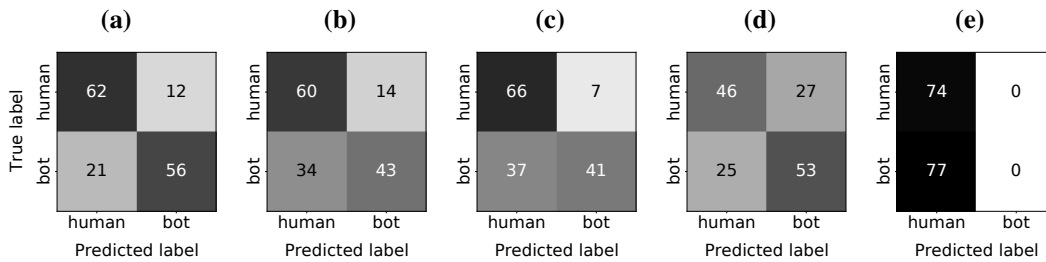
- 2) Opracowano metodologię wyboru parametrów próbkowania zdarzeniowego w sposób niezależny od rodzaju modelu użytego do dalszego zadania klasyfikacyjnego tak, aby proces próbkowania nie skutkował utratą informacji istotnych z punktu widzenia zadania klasyfikacji. Opracowana technika polega na ewaluowaniu skuteczności pomocniczego klasyfikatora k-najbliższych sąsiadów podejmującego decyzję na podstawie wzajemnego podobieństwa sekwencji zdarzeń. Parametry kodowania wybierane są w procesie optymalizacji bayesowskiej, co pozwala utworzyć ranking wpływu parametrów kodowania na dokładność klasyfikacji metodą k-najbliższych sąsiadów. Na podstawie tego rankingu możliwy jest wybór konkretnego zestawu parametrów jako docelowych parametrów do użycia w dalszym przetwarzaniu. Metodologię sprawdzono dla danych pochodzących z drogowych czujników pomiarowych w kontekście klasyfikacji pojazdów dla trzech różnych rodzajów kodowania. Otrzymane w procesie optymalizacji bayesowskiej wartości dokładności klasyfikacji mieściły się w zakresie od ok. 77.5% do 95.9%, co świadczy o dużym wpływie doboru parametrów kodowania na działanie modelu. Tabela 2.1 przedstawia ostatecznie wybrane zestawy parametrów, tj. takie, dla których klasyfikator dobrze radził sobie niezależnie od wyboru danych ewaluacyjnych. Uzyskano podobne skuteczności klasyfikacji dla wszystkich trzech mechanizmów kodowania, mimo iż różnią się one liczbą zdarzeń wchodzących w skład pojedynczej sekwencji.

**Tabela 2.2:** Zestawienie wyników różnych podejść do problemu klasyfikacji botów w mediach społecznościowych.

Source	Learning type	Technique	Accuracy [%]	F <sub>1</sub> -score [%]
[3]	supervised	Botometer	58.30	42.86
		HoloScope	49.08	0.96
		Social fingerprinting	71.14	75.82
[3]	unsupervised	RT <sub>BUST</sub> (handcrafted features)	53.64	62.70
		RT <sub>BUST</sub> (PCA)	51.54	66.49
		RT <sub>BUST</sub> (TICA)	53.64	67.47
		RT <sub>BUST</sub> (VAE)	87.55	86.87
our	supervised	KDE	67.81 ± 3.31	60.33 ± 4.08
		SNN	73.25 ± 3.71	72.46 ± 5.08

## 2.4 Ewaluacja modeli na przykładzie rzeczywistych problemów badawczych

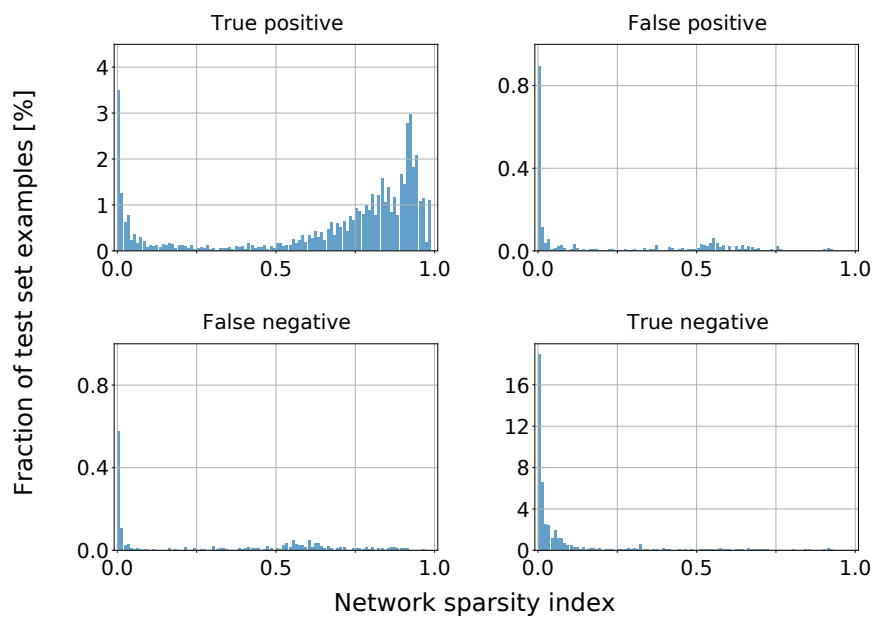
- 1) Opracowane podejścia do klasyfikacji sekwencji zdarzeń (wykorzystujące teorię procesów punktowych, sieć SNN) zastosowano do praktycznego problemu identyfikacji botów na podstawie analizy aktywności użytkowników mediów społecznościowych. Uzyskane wyniki otrzymanych modeli zestawiono w Tabeli 2.2 wraz z innymi podejściami użytymi do analizy tego problemu. Dla tego problemu badawczego sieci SNN okazały się być lepszym podejściem niż model wykorzystujący teorię procesów punktowych. Co więcej, impulsowa sieć neuronowa uzyskała lepsze wyniki niż wszystkie inne modele przytoczone bądź opracowane w publikacji referencyjnej poza jednym z nich (RT<sub>BUST</sub>), będącym na chwilę obecną najlepszym możliwym rozwiązaniem tego problemu. Model RT<sub>BUST</sub> uzyskano w wyniku nienadzorowanego uczenia na szerszym zbiorze danych, podczas gdy podejścia opracowane w rozprawie operowały na niewielkim podzbiore zawierającym pełny opis danych. Stanowi to przesłankę do konieczności opracowania metod uczenia nienadzorowanego dla zaproponowanych algorytmów.
- 2) Dla przytoczonego problemu klasyfikacji botów sprawdzono wpływ różnych czynników na działanie finalnego modelu. Klasyfikator procesów punktowych przeanalizowano pod kątem długości obserwowanej sekwencji zdarzeń; rodzaju i gęstości siatki punktów, w których estymowano funkcję gęstości prawdopodobieństwa przy pomocy estymatora KDE; a także wyboru metody korekcji efektów brzegowych. Najsilniejszy wpływ na skuteczność klasyfikacji miała długość obserwowanej sekwencji zdarzeń oraz gęstość siatki punktów estymacji KDE (im więcej, tym lepiej). Pozostałe analizowane zmienne miały marginalny wpływ na działanie modelu. W przypadku modelu SNN przeprowadzono studium ablacyjne, tj. analizę polegającą na ewaluacji modelu po usunięciu



**Rysunek 2.4:** Macierze pomyłek dla przykładowej iteracji uczenia sieci SNN w studium ablacyjnym: (a) model bazowy, (b) brak augmentacji danych (tj. losowych przesunięć w czasie i usuwania zdarzeń), (c) ustawienie nieskończenie długiego okresu refrakcji (neuron może generować co najwyżej jeden impuls), (d) brak podziału sekwencji zdarzeń na krótsze wycinki podawane na wiele neuronów, (e) brak transformacji dziedziny czasu.

wybranych komponentów, każdego z nich oddzielnie. Rysunek 2.4 przedstawia macierze pomyłek dla przykładowej serii uczeń z identycznym zestawem wag początkowych. Zweryfikowano słuszność stosowania wybranych technik do uczenia sieci SNN, gdyż mają one pozytywny wpływ na skuteczność klasyfikacji. Co więcej, zidentyfikowano transformację dziedziny czasu jako kluczowy element składowy procesu uczenia, bez którego nie jest możliwe uzyskanie użytecznego modelu.

- 3) Opracowaną syjamską sieć SNN zastosowano do problemu rozróżniania artefaktów od użytecznego sygnału promieniowania kosmicznego dla danych pochodzących z eksperymentu badawczego CREDO. Dane CREDO składają się z obrazów, w których średnio 90% pikseli ma wartość zero, w związku z czym zastosowano konwersję na postać zdarzeniową nieprzypisującą tym pikselom zdarzeń. Wyuczona sieć syjamaska SNN osiągnęła dokładność rzędu  $96.35 \pm 0.74\%$ , podczas gdy najlepsze rozwiązanie problemu przy pomocy modelu niezdarzeniowego uzyskało dokładność  $98.93 \pm 0.39\%$ . Należy zaznaczyć, że ów model stanowi przykład konwolucyjnej sieci, podczas gdy analizowana w rozprawie metodologia ograniczona jest do warstw niekonwolucyjnych. Analizowanie zdjęć przy pomocy takich warstw może zatem być trudniejszym zadaniem dla modelu.
- 4) Sieć SNN uczoną na danych CREDO sprawdzono także pod kątem własności otrzymanego rozwiązania. Zweryfikowano możliwość porównywania podobieństwa zdjęć przy pomocy sieci syjamskiej. Zastobserwowano, że podobieństwo zdjęć skategoryzowanych jako podobne w dziedzinie zdarzeń nie pokrywa się z intuicyjnym pojęciem “podobieństwa” obrazów. Ponadto wykazano zdolność modelu do dostosowywania aktywności sieci do obserwowanego przykładu (Rysunek 2.5). Sieć generuje zdecydowanie mniej zdarzeń obserwując sekwencje zdarzeń odpowiadające zakodowanym zdjęciom użytecznego sygnału w porównaniu do sekwencji zdarzeń dla artefaktów.



**Rysunek 2.5:** Rozkłady empiryczne wskaźnika rzadkości sieci SNN w zależności od werdyktu klasyfikacji zdjęć CREDO jako anomalne. Wartość 0 na osi poziomej oznacza, że wszystkie neurony generują co najmniej jeden impuls w odpowiedzi na wejściową sekwencję zdarzeń; wartość 1 – brak wygenerowanych impulsów przez którykolwiek neuron modelu. Na osi pionowej przedstawiono procent liczby wszystkich przykładów ze zbioru testowego, dla których zaobserwowano dany wskaźnik rzadkości sieci (oś pionową na wykresach znormalizowano w taki sposób, aby suma wartości wszystkich czterech rozkładów wynosiła 100%).



## Podsumowanie i kierunki dalszych prac

W rozprawie przeanalizowano dwa sposoby na zastosowanie uczenia maszynowego do danych zdarzeniowych: metodologię opartą o teorię procesów punktowych oraz metodę wykorzystującą impulsowe sieci neuronowe.

Opracowano metodologię wykorzystującą klasyfikator Bayesa sformułowany na podstawie funkcji intensywności procesów punktowych. Przedstawiono klasyfikator Bayesa oraz jego empiryczny odpowiednik, do zastosowania gdy nie jest znana prawdziwa funkcja intensywności. Dla danych symulacyjnych zweryfikowano zbieżność ryzyka bayesowskiego do zera wraz ze zwiększeniem liczby obserwowanych w czasie zdarzeń. Zweryfikowano również zbieżność empirycznej reguły klasyfikacji opartej o estymator KDE do klasyfikatora Bayesa wraz ze wzrostem liczby przykładów wchodzących w skład zbioru treningowego. Ponadto wykazano, że negatywny wpływ efektów brzegowych na estymację KDE w danym kontekście ma znaczenie tylko wtedy, gdy szerokość okna obserwacji zdarzenia jest zbliżona do wartości parametru wygładzania jądra.

W kontekście impulsowych sieci neuronowych skupiono się na analizie istniejącego modelu sieci wrażliwej na czas wygenerowania pierwszego impulsu wyjściowego. Zidentyfikowano zbiór ograniczeń tego modelu: dużą złożoność obliczeniową; wrażliwość na wartość bezwzględną czasu zdarzeń w sekwencji, generowanie redundantnych impulsów oraz nieskończenie długi okres refrakcji neuronów. Zaproponowano usprawnienia modelu mające na celu rozwiązanie ww. problemów, dzięki czemu poszerzono zakres stosowalności tego rozwiązania. Oprócz tego przedstawiono modyfikację funkcji kosztu umożliwiającą uczenie impulsowej syjamskiej sieci neuronowej w dziedzinie zdarzeń.

Praktyczną stosowalność opracowanych metod zweryfikowano w kontekście trzech problemów badawczych: identyfikacji botów w mediach społecznościowych, wykrywania artefaktów podczas detekcji cząstek promieniowania kosmicznego oraz kategoryzacji pojazdów drogowych. W tym pierwszym przypadku dane mają naturalnie zdarzeniowy charakter, natomiast w pozostałych dwóch zagadnieniach konieczna była dodatkowa konwersja sygnałów do postaci zdarzeniowej. Zaprezentowano wpływ kodowania na skuteczność klasyfikacji oraz własności modelu takie jak szybkość osiągnięcia stanu ustalonego odpowiedzi oraz rzadkość reprezentacji

wewnątrz sieci SNN.

Zidentyfikowano kilka potencjalnych kierunków dalszych prac:

- podejście oparte o teorię procesów punktowych:
  - uogólnienie reguł klasyfikacji na wielowymiarowe procesy punktowe,
  - zaproponowanie reguł klasyfikacji dla problemów wieloklasowych,
  - zastosowanie różnych wartości parametru wygładzania dla różnych skal czasowych,
- sieci SNN:
  - zmiana modelu obliczeniowego neuronu na taki, który umożliwia powrót do stanu początkowego bez generowania impulsu (w przypadku braku obserwowania zdarzeń przez pewien okres),
  - zaadaptowanie zwektoryzowanego algorytmu obliczania impulsów w danej warstwie do warstw konwolucyjnych,
- aktualizowanie predykcji modelu w trybie ciągłym, po zaobserwowaniu każdego nowego zdarzenia.

## Lista najważniejszych publikacji

- **M. Pabian**, D. Rzepka, Ł. Bibrzycki i M. Pawlak, “Differentiating signal from artefacts in cosmic ray detection: Applying Siamese spiking neural networks to CREDO experimental data,” *Measurement*, t. 220, s. 113–273, 2023.
- M. Pawlak, **M. Pabian** i D. Rzepka, “Asymptotically Optimal Nonparametric Classification Rules for Spike Train Data,” w *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2023, s. 1–5.
- **M. Pabian**, D. Rzepka i M. Pawlak, “Supervised Training of Siamese Spiking Neural Networks with Earth Mover’s Distance,” w *ICASSP 2022 - 2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2022, s. 4233–4237.

## Bibliografia

- [1] W. Gerstner, W. M. Kistler, R. Naud i L. Paninski, *Neuronal Dynamics: From Single Neurons to Networks and Models of Cognition*. Cambridge: Cambridge University Press, 2014.
- [2] Z. Chen, L. D. Van Khoa, E. N. Teoh i in., “Machine learning techniques for anti-money laundering (AML) solutions in suspicious transaction detection: a review,” *Knowledge and Information Systems*, t. 57, nr. 2, s. 245–285, 2018.
- [3] M. Mazza, S. Cresci, M. Avvenuti i in., “RTbust: Exploiting Temporal Patterns for Botnet Detection on Twitter,” w *Proceedings of the 10th ACM Conference on Web Science*, Boston, Massachusetts, USA: Association for Computing Machinery, 2019, s. 183–192.
- [4] Y. Shen, E. Mariconti, P. A. Vervier i G. Stringhini, “Tiresias: Predicting Security Events Through Deep Learning,” w *Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security*, Toronto, Canada: Association for Computing Machinery, 2018, s. 592–605.
- [5] M. Du, F. Li, G. Zheng i V. Srikumar, “DeepLog: Anomaly Detection and Diagnosis from System Logs through Deep Learning,” w *Proceedings of the 2017 ACM SIGSAC Conference on Computer and Communications Security*, Dallas, Texas, USA: Association for Computing Machinery, 2017, s. 1285–1298.
- [6] B. Shickel, P. J. Tighe, A. Bihorac i P. Rashidi, “Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis,” *IEEE Journal of Biomedical and Health Informatics*, t. 22, nr. 5, s. 1589–1604, 2018.
- [7] P. Dayan i L. F. Abbott, *Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems*. The MIT Press, 2001.
- [8] S.-C. Liu, B. Rueckauer, E. Ceolini i in., “Event-Driven Sensing for Efficient Perception: Vision and Audition Algorithms,” *IEEE Signal Processing Magazine*, t. 36, nr. 6, s. 29–37, 2019.

- [9] C. Posch, T. Serrano-Gotarredona, B. Linares-Barranco i T. Delbruck, “Retinomorphic Event-Based Vision Sensors: Bioinspired Cameras With Spiking Output,” *Proceedings of the IEEE*, t. 102, nr. 10, s. 1470–1484, 2014.
- [10] S.-C. Liu, A. van Schaik, B. A. Minch i T. Delbruck, “Asynchronous Binaural Spatial Audition Sensor With  $2 \times 64 \times 4$  Channel Output,” *IEEE Transactions on Biomedical Circuits and Systems*, t. 8, nr. 4, s. 453–464, 2014.
- [11] A. Vanarse, A. Osseiran i A. Rassau, “An Investigation into Spike-Based Neuromorphic Approaches for Artificial Olfactory Systems,” *Sensors*, t. 17, nr. 11, 2017.
- [12] B. Ward-Cherrier, N. Pestell i N. F. Lepora, “NeuroTac: A Neuromorphic Optical Tactile Sensor applied to Texture Recognition,” w *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 2020, s. 2654–2660.
- [13] E. Doutsis, L. Fillatre, M. Antonini i P. Tsakalides, “Dynamic Image Quantization Using Leaky Integrate-and-Fire Neurons,” *IEEE Transactions on Image Processing*, t. 30, s. 4305–4315, 2021.
- [14] G. Orchard, A. Jayawant, G. K. Cohen i N. Thakor, “Converting Static Image Datasets to Spiking Neuromorphic Datasets Using Saccades,” *Frontiers in Neuroscience*, t. 9, 2015.