



**POLITECHNIKA POZNAŃSKA**  
Wydział Informatyki  
Instytut Automatyki i Robotyki



dr inż. Aleksandra Świetlicka

---

**Opis dorobku i osiągnięć naukowych oraz dydaktycznych**  
dziedzina: Nauki Techniczne  
dyscyplina: Automatyka i Robotyka

---

Autoreferat

Poznań, 2019

---

## Spis treści

<b>Wstęp</b>	<b>1</b>
<b>1 Uzyskane tytuły oraz stopnie naukowe</b>	<b>1</b>
<b>2 Informacje o zatrudnieniu</b>	<b>2</b>
<b>3 Ogólny przegląd osiągnięć naukowych</b>	<b>2</b>
<b>4 Wskazane osiągnięcie naukowo-badawcze</b>	<b>8</b>
4.1 Publikacje dotyczące wskazanego osiągnięcia . . . . .	8
4.2 Opis publikacji wchodzących w skład osiągnięcia . . . . .	9
4.2.1 Wprowadzenie . . . . .	9
4.2.2 Opis modeli wykorzystywanych w badaniach . . . . .	12
4.2.3 Trenowanie stochastycznych kinetycznych modeli biologicznego neuronu . . . . .	15
4.2.4 Badanie zdolności uogólniania wiedzy wybranych modeli biologicznego neuronu . .	16
4.2.5 Zastosowania modeli biologicznego neuronu oraz sztucznych sieci neuronowych . .	18
4.2.6 Podsumowanie . . . . .	23
4.2.7 Opis wkładu w poszczególne artykuły wchodzące w skład osiągnięcia . . . . .	24
<b>5 Pozostałe osiągnięcia naukowo-badawcze i dydaktyczne</b>	<b>27</b>
5.1 Wykaz pozostałych publikacji . . . . .	27
5.1.1 Publikacje w czasopismach naukowych z listy A czasopism punktowanych . . . . .	27
5.1.2 Publikacje w czasopismach naukowych nieujętych na liście A czasopism punktowanych	27
5.1.3 Monografie oraz rozdziały w monografiach naukowych . . . . .	28
5.1.4 Wygłoszenie referatu lub prezentacja plakatu na konferencjach międzynarodowych	29
5.2 Udział w projektach naukowych . . . . .	31
5.3 Recenzowanie artykułów do czasopism naukowych . . . . .	32
5.4 Międzynarodowe i krajowe nagrody za działalność naukową . . . . .	32
5.5 Członkostwo w organizacjach oraz towarzystwach naukowych . . . . .	33
5.6 Udział w warsztatach, konferencjach i kursach . . . . .	33
5.7 Działalność dydaktyczna . . . . .	34
5.7.1 Udział w projektach dydaktycznych . . . . .	34
5.7.2 Prowadzone zajęcia . . . . .	34
5.7.3 Uzyskane nagrody za działalność dydaktyczną . . . . .	35
5.7.4 Inne osiągnięcia dydaktyczne . . . . .	35

---

## Wstęp

W niniejszym autoreferacie prezentuję wszystkie informacje dotyczące mojej działalności naukowo-badawczej oraz dydaktycznej z okresu obejmującego czas przygotowania do uzyskania stopnia naukowego doktora (tj. do końca roku 2013) oraz następne lata, do dnia dzisiejszego.

W opracowaniu można znaleźć informacje dotyczące zarówno dorobku naukowego, a zatem zestawienie wszystkich artykułów (z list ministerialnych A i B), monografii, rozdziałów w monografiach, jak również dorobku dydaktycznego, jak współautorstwo podręcznika czy informacja o prowadzonych zajęciach i uzyskanych między innymi z tego tytułu nagrodach.

W rozdziale czwartym prezentuję dokładny opis osiągnięcia, będącego główną częścią niniejszego autoreferatu.

Matematyka zawsze była i wciąż pozostaje w obszarze moich najważniejszych zainteresowań. Z tego powodu zdecydowałam się na studia w tym kierunku, które okazały się być solidną podstawą narzędziową w trakcie poznawania zagadnień z zakresu automatyki i robotyki. Dyscyplina ta jest mocno ugruntowana w matematyce, ze szczególnym uwzględnieniem rachunku różniczkowego, metod numerycznych czy rachunku operatorowego.

Przeglądając prezentowane zestawienie dorobku, warto zwrócić uwagę, że jest on bardzo spójny. Moje zainteresowania związane zarówno z biologicznymi jak i sztucznymi sieciami neuronowymi sięgają studiów. Ponieważ modele te często opisane są układami równań różniczkowych, stąd wiele moich prac publikowanych jest w czasopismach matematycznych.

W prezentowanym osiągnięciu, będącym meritum niniejszego autoreferatu, wymieniam osiem prac, stanowiących jednorodną całość, jednakże niektóre z pozostałych prac również mogłyby być uwzględnione, jak na przykład rozdział w monografii *Computer Vision in Sports* czy artykuł opublikowany w czasopiśmie *Electrical Power and Energy Systems*. Uważam jednak, że wyszczególnione osiem prac stanowi pewną całość i nie ma potrzeby dokładania dodatkowych elementów.

Moja praca dydaktyczna również jest ściśle powiązana z dziedziną automatyki i robotyki. Wśród podstawowych przedmiotów, które prowadzę, znajduje się rachunek operatorowy – obejmujący transformaty całkowite i dyskretne takie jak transformata Laplace’a,  $Z$  czy Fouriera, będące podstawą opisu liniowych układów dynamicznych – oraz matematykę dyskretną z elementami teorii automatów. Ponadto prowadzę kurs z zakresu sztucznych sieci neuronowych, podczas którego studenci realizują projekty, w których wykorzystują narzędzia metod uczenia maszynowego w konkretnych zadaniach automatyki i robotyki.

## 1 Uzyskane tytuły oraz stopnie naukowe

- styczeń 2014 – doktor inżynier
  - dziedzina: nauki techniczne, dyscyplina: automatyka i robotyka, specjalność: cybernetyka techniczna
  - Politechnika Poznańska, Wydział Informatyki
  - tytuł rozprawy: „Stochastyczny model biologicznej sieci neuronowej oparty na kinetycznych schematach Markowa”
  - promotor: prof. dr hab. inż. Andrzej Rybarczyk
  - recenzenci: prof. dr hab. inż. Mirosław Galicki (Uniwersytet Zielonogórski, Wydział Mechaniczny, Instytut Budowy i Eksploatacji Maszyn), prof. dr hab. inż. Marek Kurzyński (Politechnika Wrocławska, Wydział Elektroniki, Katedra Systemów i Sieci Komputerowych)
- czerwiec 2009 – magister inżynier
  - Politechnika Poznańska, Wydział Informatyki i Zarządzania (obecnie Wydział Informatyki), Katedra Inżynierii Komputerowej
  - kierunek: Automatyka i Zarządzanie, specjalność: Reprogramowalne Systemy Sterowania

- 
- tytuł pracy: „Opracowanie i implementacja modelu biologicznej sieci neuronowej z wykorzystaniem stochastycznych równań różniczkowych”
  - promotor: prof. dr hab. inż. Andrzej Rybarczyk
  - sierpień 2008 – magister
    - Politechnika Poznańska, Wydział Budowy Maszyn i Zarządzania
    - kierunek: Matematyka, specjalność: Matematyczne Metody Informatyki
    - tytuł pracy: „Chaos dyskretny”
    - promotor: dr hab. Małgorzata Migda
  - luty 2008 – inżynier
    - Politechnika Poznańska, Wydział Informatyki i Zarządzania (obecnie Wydział Informatyki), Katedra Inżynierii Komputerowej
    - kierunek: Automatyka i Zarządzanie
    - tytuł pracy: „Implementacja metod numerycznych (z wykorzystaniem pakietu MATLAB) w wybranych zagadnieniach symulacji biologicznych sieci neuronowych”
    - promotor: prof. dr hab. inż. Andrzej Rybarczyk

## 2 Informacje o zatrudnieniu

- kwiecień 2019 – obecnie  
Informatyk – doświadczony naukowiec (praca w ramach projektu NCBiR), Wrocławski Instytut Zastosowań Informatyki Przestrzennej i Sztucznej Inteligencji sp. z o.o.
- październik 2017 – obecnie  
Adiunkt, Politechnika Poznańska, Wydział Informatyki, Instytut Automatyki i Robotyki
- marzec 2014 – wrzesień 2017  
Adiunkt, Politechnika Poznańska, Wydział Informatyki, Katedra Inżynierii Komputerowej
- październik 2009 – luty 2014  
Asystent, Politechnika Poznańska, Wydział Informatyki i Zarządzania, Katedra Inżynierii Komputerowej

## 3 Ogólny przegląd osiągnięć naukowych

W tym rozdziale zaprezentowane zostały ogólne informacje dotyczące mojego dorobku naukowo-badawczego oraz dydaktycznego. Oprócz tabel pokazujących współczynnik Impact Factor (o ile nadany) i punktację według wykazu czasopism punktowanych MNiSW pokazuję również aktualną analizę cytowań z baz Web of Science i Scopus oraz dodatkowo z profilu utworzonego na Google Scholar. W tabelach 1 i 2 znajduje się podsumowanie wszystkich prac z podziałem na okres przed i po uzyskaniu stopnia naukowego doktora. W tabelach 3 i 4 podsumowane są publikacje odpowiednio znajdujące i nie znajdujące się w wykazie A listy czasopism punktowanych MNiSW, podczas gdy w tabeli 5 podsumowane są pozostałe prace, tj. monografie i rozdziały w monografiach.

Tablica 1: Ogólny wykaz osiągnięć naukowo-badawczych

L.p.	Wykaz osiągnięć	Liczba publikacji		
		Przed doktoratem	Po doktoracie	Łącznie
1	Publikacje w czasopismach wyróżnionych przez Journal Citation Reports (Lista Filadelfijska)	1	9	10
2	Publikacja w innym recenzowanym czasopiśmie krajowym lub zagranicznym	7	0	7
3	Autorstwo podręcznika, monografii lub rozdziału w monografii	4	2	6
4	Publikacje w materiałach międzynarodowych konferencji naukowych	18	10	28
5	Udział w projektach badawczych i dydaktycznych	3	5	8

Tablica 2: Ogólne podsumowanie punktacji MNiSW

L.p.	Publikacje	Liczba punktów		
		Przed doktoratem	Po doktoracie	Łącznie
1	Publikacje w czasopismach wyróżnionych przez Journal Citation Reports (Lista Filadelfijska)	25	275	300
2	Publikacja w innym recenzowanym czasopiśmie krajowym lub zagranicznym	46	0	46
3	Autorstwo podręcznika, monografii lub rozdziału w monografii	41	30	71
4	Publikacje w materiałach międzynarodowych konferencji naukowych	10	15	25
	Suma	122	320	444

Tablica 3: Zestawienie Impact Factor oraz liczby punktów dla wszystkich publikacji z listy A czasopism punktowanych (pokazane wartości IF oraz liczby punktów obowiązywały w podanym roku publikacji)

L.p.	Czasopismo	Rok publikacji	Impact Factor	Punkty	Liczba publikacji	Łącznie IF	Łącznie punkty
------	------------	----------------	---------------	--------	-------------------	------------	----------------

**opublikowane po uzyskaniu stopnia doktora**

1	Advances in Computational Mathematics	2019	1,439	35	1	1,439	35
2	Applied Mathematics and Computation	2018	2,3	35	2	4,6	70
3	Electrical Power & Energy Systems	2018	3,61	35	1	3,61	35
4	Biocybernetics and Biomedical Engineering	2017	1,374	15	1	1,374	15
5	Applied Mathematics and Computation	2015	1,345	40	2	2,69	80
6	Neural Network World	2015	0,562	15	1	0,562	15
7	Signal Processing – Image Communication	2015	1,602	25	1	1,602	25
				Suma	9	15,877	275

**opublikowane przed uzyskaniem stopnia doktora**

8	Computing	2013	1,055	25	1	1,055	25
				Suma	10	16,932	300

Tablica 4: Zestawienie liczby punktów dla artykułów nie znajdujących się w wykazie A listy czasopism punktowanych MNiSW – wszystkie pozycje ukazały się przed uzyskaniem stopnia naukowego doktora.

L.p.	Czasopismo	Rok publikacji	Punkty	Liczba publikacji	Łącznie punkty
1	Solid State Phenomena	2013	10	2	20
2	International Journal of Electronics and Telecommunications	2012	8	1	8
3	Elektronika	2012	6	1	6
4	Elektronika	2011	6	1	6
5	Prace Naukowe Politechniki Śląskiej – Elektryka	2011	4	1	4
6	Neuroskop	2008	2	1	2
			Suma	7	46

Tablica 5: Punktacja monografii, rozdziałów w monografiach i podręczników.

L.p.	Monografia/Rozdział w monografii/Podręcznik	Rok publikacji	Punkty
------	---	----------------	--------

**opublikowane po uzyskaniu stopnia doktora**

1	Monografia doktorska	2015	25
2	Computer Vision in Sports (Springer)	2014	5
		Suma	71

**opublikowane przed uzyskaniem stopnia doktora**

3	Praktyczne aspekty wykorzystania systemów ERP ERP w wybranych przedsiębiorstwach Wielkopolski	2012	4
4	Rachunek Operatorowy Metody rozwiązywania zadań	2012	25
5	Information Technology and its Applications	2011	5
6	Advances in Systems Science	2010	7
		Suma	71

## Bazy naukowe



Poniżej prezentuję analizy cytowań z najbardziej popularnych obecnie baz naukowych. Według bazy Web of Science indeks Hirsha dla moich prac wynosi 4, według bazy Scopus: 5, natomiast według Google Scholar: 6.

### 1) Web of Science

Aktualnie w bazie Web of Science znajduje się 14 pozycji mojego autorstwa. Artykuł:

**Aleksandra Świetlicka**, *Regularization Theory in the Study of Generalization Ability of a Biological Neural Network Model*, *Advances in Computational Mathematics*, DOI: 10.1007/s10444-018-09658-6. **Punktacja MNiSW: 35, IF: 1,439**


jeszcze nie znajduje się w bazie, jest aktualnie w druku (*article in press*).



### 2) Scopus

Ze względu na to, że baza naukowa Scopus zawiera również moje wczesne prace naukowe, utworzyłam profil, który zbiera wszystkie moje artykuły (nazwisko panińskie: Figas, obecne nazwisko: Świetlicka – drobne problemy z kodowaniem litery Ś):


<https://www.scopus.com/authid/detail.uri?authorId=55540538900>






### 3) Google Scholar

Google Scholar jest aktualnie szeroko stosowaną bazą zbierającą publikacje naukowców, dlatego też prezentują również statystyki z tej bazy.


**Aleksandra Świetlicka** 


 OBSERWUJ

[Politechnika Poznańska](#)  
Zweryfikowany adres z put.poznan.pl  
[sieci neuronowe](#)

Cytowane przez

	Wszystkie	Od 2014
Cytowania	100	97
h-indeks	6	6
i10-indeks	2	2

	CYTOWANE PRZEZ	ROK
		
<b>n in sports</b> omas, A Hilton	27	2014
<b>t classification in field sport videos</b> icka, A Rybarczyk, K Kolanowski Image Communication 35, 35-45	14	2015



---

## 4 Wskazane osiągnięcie naukowo-badawcze

Dynamiczne modele biologicznego neuronu oraz przykłady ich zastosowań w automatyce i robotyce

### 4.1 Publikacje dotyczące wskazanego osiągnięcia

Na osiągnięcie składają się następujące artykuły, podane w kolejności chronologicznej począwszy od najnowszego:

1. [ACOM\_2019] Aleksandra Świetlicka, *Regularization Theory in the Study of Generalization Ability of a Biological Neural Network Model*, Advances in Computational Mathematics, 2019, DOI: 10.1007/s10444-018-09658-6.  
**Punktacja MNiSW: 35, IF: 1,439**
2. [RoMoCo\_2017] Rafał Kapela, Aleksandra Świetlicka, Krzysztof Kolanowski, Janusz Pochmara, Andrzej Rybarczyk, *A set of dynamic artificial neural networks for robot sensor failure detection*, RoMoCo (International Workshop on Robot Motion and Control), Wąsowo, Polska, 2017, pp. 199-204, DOI: 10.1109/RoMoCo.2017.8003913.  
**Punktacja MNiSW: 15, udział procentowy: 45%**
3. [AMC\_2017\_a] Krzysztof Kolanowski, Aleksandra Świetlicka, Rafał Kapela, Janusz Pochmara, Andrzej Rybarczyk, *Multisensor data fusion using Elman neural networks*, Applied Mathematics and Computation, 2018, vol. 319, pp. 236-244, DOI: 10.1016/j.amc.2017.02.031.  
**Punktacja MNiSW: 35, IF: 2,3, udział procentowy: 50%**
4. [AMC\_2017\_b] Aleksandra Świetlicka, Krzysztof Kolanowski, Rafał Kapela, Mirosław Galiński, Andrzej Rybarczyk, *Investigation of generalization ability of a trained stochastic kinetic model of neuron*, Applied Mathematics and Computation, 2018, vol. 319, pp. 115-124, DOI: 10.1016/j.amc.2017.01.058.  
**Punktacja MNiSW: 35, IF: 2,3, udział procentowy: 75%**
5. [BBE\_2017] Aleksandra Świetlicka, Karol Gugala, Witold Pedrycz, Andrzej Rybarczyk, *Development of the deterministic and stochastic Markovian model of a dendritic neuron*, Biocybernetics and Biomedical Engineering, 2017, vol 37, nr 1, pp. 201-216, DOI: 10.1016/j.bbe.2016.10.002.  
**Punktacja MNiSW: 15, IF: 1,374, udział procentowy: 60%**
6. [SPIC\_2015] Rafał Kapela, Aleksandra Świetlicka, Andrzej Rybarczyk, Krzysztof Kolanowski, Noel E. O'Connor, *Real-time event classification in field sport videos*, Signal Processing – Image Communication, 2015, vol. 35, pp. 35-45, DOI: 10.1016/j.image.2015.04.005.  
**Punktacja MNiSW: 25, IF: 1,602, udział procentowy: 40%**
7. [AMC\_2015] Aleksandra Świetlicka, *Trained stochastic model of biological neural network used in image processing task*, Applied Mathematics and Computation, 2015, vol. 267, pp. 716-726, DOI: 10.1016/j.amc.2014.12.082.  
**Punktacja MNiSW: 40, IF: 1,345**
8. [NNW\_2015] Aleksandra Świetlicka, Karol Gugala, Agata Jurkowlaniec, Paweł Śniatała, Andrzej Rybarczyk, *The Stochastic, Markovian, Hodgkin-Huxley Type of Mathematical Model of the Neuron*, Neural Network World, 2015, vol. 25, nr 3, pp. 219-239, DOI: 10.14311/NNW.2015.25.012.  
**Punktacja MNiSW: 15, IF: 0,562, udział procentowy: 45%**

---

## 4.2 Opis publikacji wchodzących w skład osiągnięcia

### 4.2.1 Wprowadzenie

#### Sztuczna inteligencja w automatyce i robotyce

W dzisiejszych czasach sztuczna inteligencja jest coraz częściej wykorzystywana w skomplikowanych zadaniach automatyki i robotyki. Zarówno naukowcy jak i przedsiębiorcy sięgają po metody uczenia maszynowego, wykorzystując je do nauczania robotów. Posłużyć ma to z jednej strony zrozumieniu niejasności, które powstają wokół sztucznej inteligencji, jednak z drugiej strony przede wszystkim mają one ułatwić współpracę ludzi i maszyn.

Należy rozumieć różnicę między inteligencją człowieka, a inteligencją sztuczną. Robot wykonujący nawet najbardziej skomplikowane zadania nie jest w stanie przyswoić sobie przyczyny i celowości wykonywanych czynności, ponieważ nie rozumie otaczającego go świata. Maszyny w związku z tym nie są w stanie zastąpić człowieka, ponieważ to właśnie oryginalne pomysły istoty ludzkiej napędzają rozwój automatyki i robotyki. Współpraca człowieka z robotem ma mieć charakter wzajemnie uzupełniający się, gdzie maszyna ma wykonywać za zadanie wykonywać uciążliwe czy też wręcz niemożliwe dla człowieka prace fizyczne.

Wśród ciekawych urządzeń, które wykorzystują sztuczną inteligencję, znajdują się z całą pewnością autonomiczne samochody, które już w roku 2020 mają wyjechać na ulice Tokio. Pojawia się tutaj wiele skomplikowanych zagadnień niezwiązanych z techniką, między innymi aspekty z zakresu etyki i moralności, które rozwiązywane są z wykorzystaniem algorytmów uczenia głębokiego. W związku z tym naukowcy z MIT (*Massachusetts Institute of Technology*) utworzyli projekt *Moral Machine* [4], w ramach którego prowadzone były szeroko zakrojone badania analityczne. W ich ramach badane osoby miały podejmować decyzje w imieniu inteligentnego samochodu z uszkodzonym układem hamulcowym. Wiedząc, że samochód nie uniknie wypadku, badani musieli wskazywać kogo sztuczna inteligencja powinna uratować, a kogo poświęcić.

Innym ciekawym projektem jest zastosowanie sztucznej inteligencji w robotach chwytających. Pomyśły na wykorzystanie takich robotów w codziennym życiu wydają się nieograniczone, wśród oczywistych można wymienić logistyczną pracę magazynową czy niezwykle precyzyjne zabiegi chirurgiczne. Wśród zapewne licznych projektów, które zajmują się zagadnieniem robotów chwytających można znaleźć Dexterity Network [3], w którym roboty trenowane są z wykorzystaniem metod uczenia maszynowego. Zastosowane tu zostały głębokie sztuczne sieci neuronowe, którym jako wzorce prezentowano miliony trójwymiarowych obiektów o różnych rozmiarach i kształtach oraz obrazów prezentujących sposoby chwytania.

Świetnym przykładem z zakresu automatyki są inteligentne budynki (ang. *Building Management System*), które wyposażone są w szeroko rozbudowane systemy czujników i detektorów oraz system nimi zarządzający, pozwalający na zintegrowaną pracę wszystkich instalacji [13, 26]. Dzięki wbudowanym elementom infrastruktury technicznej budynek taki ma „reagować” na pojawiające się zmiany środowiskowe i dzięki temu minimalizować koszty eksploatacji oraz zapewniać komfort, bezpieczeństwo a przede wszystkim funkcjonalność.

Określenie „dom inteligentny” zakłada zastosowanie w nim systemów wykazujących cechy sztucznej inteligencji, a więc kojarzenia, podejmowania decyzji, uczenia się czy przewidywania. Współczesne budynki mają coraz więcej zautomatyzowanych systemów, które zaczynają działać niezależnie. Wykonują różne programy, często skoordynowane, co może dawać wrażenie, że dom podejmuje własne niezależne decyzje. (źródło: <https://bit.ly/2UQsphd>, strona ostatnio odwiedzana: 23.04.2019 r.).

#### Uczenie maszynowe i sztuczne sieci neuronowe

Samouczenie się maszyn, uczenie maszynowe (ang. *machine learning*) czy też uczenie głębokie (ang. *deep learning*) jest nieodłączną składową sztucznej inteligencji. Głównym celem, dla którego powstała dziedzina sztucznej inteligencji, jest chęć zastosowania metod uczenia maszynowego do stworzenia systemu automatycznego, który na podstawie gromadzonego doświadczenia potrafiłby się doskonalić. Wśród rodzajów uczenia maszynowego można wyróżnić: uczenie nadzorowane (ang. *supervised learning*), gdzie

---

maszyna po wytrenowaniu potrafi jedynie rozpoznawać wzorce (problem klasyfikacji); uczenie nienadzorowane (ang. *unsupervised learning*) polegające na dostarczaniu maszynie ogromnej ilości danych bez pokazywania konkretnego celu; uczenie ze wzmocnieniem (ang. *reinforcement learning*), w którym maszynie stawia się konkretny cel, który ma osiągnąć. Ostatni z wymienionych sposobów uczenia uważany jest za podstawę postępu w zagadnieniu samochodów autonomicznych [2].

Do roku 2006 sztuczne sieci neuronowe miały architektury płytkie, tzn. posiadały najczęściej jedną warstwę ukrytą. Właśnie w roku 2006, po ukazaniu się pracy [17] nastąpił przełom, kiedy Geoffrey E. Hinton wraz z współautorami zaproponował algorytm trenowania sieci głębokich, o wielu warstwach (ang. *greedy layer-wise pretraining*). Od tego czasu rozwój sieci neuronowych bardzo przyspieszył, głównie ze względu na to, że wiele olbrzymich korporacji ery cyfrowej, z Google, Amazon i Microsoft na czele, zaczęło tworzyć własne biblioteki do szerokiej implementacji metod uczenia maszynowego. Przykładem jest potężna, ogólnodostępna biblioteka *TensorFlow*, stworzona przez programistów Google, której pierwsza wersja wydana została w 2015 roku [5].

Sztuczne sieci neuronowe są strukturami matematycznymi, których powstanie zainspirowane zostało chęcią opisu rzeczywistych neuronów, łączących je synaps oraz ostatecznie układu nerwowego, a co za tym idzie – mózgu. Konstruowanie, trenowanie oraz badanie możliwości tego typu struktur składa się na swoistą interdyscyplinarną dziedzinę, która jest nieustannie rozwijana. Podczas gdy sztuczne sieci neuronowe opisują neurony w sposób bardzo ścisły, mówi się również o modelach biologicznych neuronów i sieci neuronowych, które z kolei w sposób wierniejszy odwzorowują impulsową naturę komórek nerwowych (ang. *spiking neural networks*). Coraz częściej jednak modele biologicznych neuronów i sieci neuronowych stosowane są nie tylko do opisu procesów związanych ze zmianą potencjału na błonie komórkowej, ale również wykorzystuje się je w praktycznych aplikacjach.

### „Inżynieria wsteczna”

Można zatem podejść do modeli biologicznego neuronu na kilka sposobów. Jednym z nich jest matematyczny opis procesów fizycznych zachodzących w neuronach i ich sieciach. Dokładniejszy opis zapewni lepsze zrozumienie pracy mózgu. Z drugiej strony można mówić o rozwijaniu badań nad budową ludzkiego mózgu w myśl tzw. „inżynierii wstecznej”. Innym jeszcze podejściem jest wpisanie tych modeli do metod uczenia maszynowego czy też uczenia głębokiego, poprzez ich trenowanie.

Technika „inżynierii wstecznej” czy też programowania zwrotnego (ang. *reverse engineering*) jest procesem badania istniejącego obiektu (maszyny, urządzenia, programu) w celu jego późniejszego odtworzenia. Największe projekty w tym obszarze związane są właśnie z badaniem pracy mózgu.

Najgłośniejszym projektem z zakresu symulacji pracy mózgu jest *Blue Brain Project* [1], którego istotą jest zbudowanie sztucznego mózgu. Jego założeniem jest aby w najbliższych latach przeprowadzić symulację pracy całego mózgu. Projekt ten założony w roku 2005 przez Henrego Markrama na Politechnice Federalnej w Lozannie w Szwajcarii, obejmuje w tej chwili kilka ośrodków ze Stanów Zjednoczonych, Wielkiej Brytanii czy Hiszpanii. Badacze biorący udział w tym projekcie zajmują się opisem matematycznym, implementacją oraz symulacją pojedynczych komórek, ale również konkretnych obszarów mózgu.

Innym znanym zagadnieniem z obszaru „inżynierii wstecznej” jest wykorzystanie memrystorów do symulacji działania synapsy. Memrystor, czyli opornik z pamięcią, jest jednym z podstawowych biernych elementów elektronicznych. Został opisany w roku 1971 [10], a pierwszy raz fizycznie zaimplementowany w roku 2008 [23] i stanowi od wielu lat obiekt badań i zainteresowań wielu naukowców, szczególnie tych, którzy zajmują się sieciami neuronowymi. W roku 2017 autorzy pracy [7] z wykorzystaniem memrystorów stworzyli sztuczną synapsę zdolną do samodzielnego uczenia się i rozpoznawania wzorców.

Sieci neuronowe zbudowane z modeli biologicznych neuronów mogą mieć ogromny potencjał ze względu na zwiększoną zdolność uczenia się i douczania podczas pracy, co wciąż stanowi problem w przypadku sztucznych sieci neuronowych. W metodyce badań zaprezentowanych w pracach składających się na osiągnięcie wykorzystane jest rozumowanie oparte na „inżynierii wstecznej”. Rozwijanie badań nad budową ludzkiego mózgu i próba zrozumienia istoty myślenia czy procesu zapamiętywania jest jednym z aspektów. Z drugiej strony sieci zbudowane z modeli biologicznego neuronu można wykorzystać w problemach automatyki i robotyki, takich jak sterowanie, które podlega losowym zależnościom, o niepewnych wartościach

---

czy zaszumieniu.

Niezwykle ciekawym zagadnieniem, które opisywane było już w wielu pracach, między innymi w [9, 20, 22], jest wykorzystanie żywych neuronów szczura do sterowania ramieniem robota. Tak zwany interfejs mózg-maszyna lub mózg-komputer (ang. *BMI – Brain Machine Interfaces* lub *Brain Computer Interfaces*) to urządzenie, które umożliwia „przetłumaczenie” aktywności neuronowej na komendy, które pozwalają na sterowanie zewnętrznym lub wbudowanym systemem, takim jak komputer lub ramię robota. Aktualnie badane systemy dotyczą najczęściej urządzeń, które mają pomóc usprawnić lub naprawić ludzkie czynności ruchowe.

## Podsumowanie

Rozwój maszynowych metod uczenia wraz z bardziej wiernymi modelami biologicznego neuronu, umożliwi w niedługim czasie dynamiczny rozwój zastosowań sztucznej inteligencji, również w dziedzinie automatyki i robotyki. Powyżej pokazane przykłady z obszaru „inżynierii wstecznej” pokazują jak bardzo interdyscyplinarna jest dzisiejsza nauka. W badaniach nad ludzkim mózgiem biorą udział nie tylko biolodzy czy medycy, ale coraz częściej matematycy, fizycy czy też informatycy i automatycy. Możliwość analizowania ogromnych zbiorów danych i zastosowania głębokiego uczenia w systemach komputerowych adaptujących się do doświadczenia, doprowadzi na pewnym etapie do przełomu. Jedną z idei takiego rozumowania jest również konstruowanie robotów, które będą posiadać świadomość otaczającego ich świata.

Biorąc pod uwagę powyższe można spodziewać się, że konstruowanie dużych, wielowarstwowych sieci neuronowych bazujących na modelach biologicznego neuronu w połączeniu z metodami trenowania zaczerpniętymi z technik uczenia głębokiego, umożliwi w niedługim czasie dynamiczny rozwój zastosowań sztucznej inteligencji w automatyce i robotyce.

W swoich badaniach podejmuję tematykę związaną zarówno ze sztucznymi sieciami neuronowymi jak i z opisem matematycznym i doskonaleniem metod trenowania nowych modeli biologicznego neuronu. Warto tu zwrócić uwagę na cechę niezwykle istotną, szczególnie w odniesieniu do „inżynierii wstecznej”, mianowicie na zdolność uogólniania wiedzy. Potocznie zdolność uogólniania wiedzy można zdefiniować jako zauważanie cech wspólnych dla obiektów czy zjawisk. Z punktu widzenia sieci neuronowej jest to zdolność generowania właściwej odpowiedzi dla danych, które nie znalazły się w zbiorze trenującym. Sieć neuronowa, która takiej zdolności nie posiada jest albo niedouczona, albo przeuczona (wyuczona „na pamięć”), zatem potrafi poprawnie klasyfikować jedynie dane, które zna.

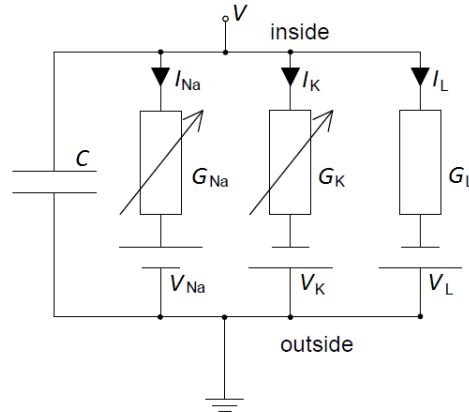
Aby pokazać potencjalne możliwości modeli biologicznego neuronu czy sieci neuronowych, wykorzystuję je w badaniach związanych z przetwarzaniem obrazów jak również z wyznaczaniem pozycji obiektu w przestrzeni. W badaniach najczęściej wykorzystuję stochastyczne wersje proponowanych modeli, głównie ze względu na zdecydowanie szybszą ich implementację, ale również ze względu na to, że dynamika biologicznego neuronu może być wysoce losowa. Opis stochastyczny pozwala zatem na bliższe odzwierciedlenie faktycznego stanu panującego na błonie komórkowej.

Można zatem zauważyć, że stosowane przeze mnie rozwiązania wykorzystujące modele biologicznego neuronu (również w połączeniu ze sztucznymi sieciami neuronowymi) stanowią swoiste instrumentarium. Ze względu na to, że są to metody wcześniej nie stosowane w zagadnieniach automatyki i robotyki, niezbędnym było zbadanie ich cech, które charakterystyczne są dla metod uczenia głębokiego. Tak też przebiegała moja praca nad przygotowaniem modeli biologicznego neuronu, mianowicie na wyprowadzeniu równań modelu, sposobie jego trenowania, następnie na zbadaniu jego właściwości, aby ostatecznie móc je wykorzystać w konkretnych obliczeniach, w tym przypadku w zagadnieniach określania pozycji obiektu w przestrzeni oraz usuwania szumów z obrazów szarych.

W kolejnych sekcjach zwięźle prezentuję efekty swoich badań. W sekcji 4.2.2 opisuję modele, które rozważam w swoich pracach, podczas gdy w sekcji 4.2.3 pokazuję sposoby ich trenowania. Opis analizy zdolności uogólniania wiedzy przez te modele pokazane zostały w sekcji 4.2.4. Zastosowania badanych przeze mnie modeli biologicznego neuronu i sieci neuronowych oraz sztucznych sieci neuronowych w dziedzinie automatyki i robotyki zostały zaprezentowane w sekcji 4.2.5.

## 4.2.2 Opis modeli wykorzystywanych w badaniach

W swoich pracach opisują nowe modele biologicznego neuronu, które wywodzą się z modelu zaproponowanego już w 1952 roku przez Alana Lloyd Hodgkina i Andrew Fielding Huxley'a w pracy [18]. W modelu tym zakłada się, że elektryczne właściwości błony komórkowej mogą być zamodelowane poprzez równoważny obwód elektryczny, pokazany na rysunku 1.



Rysunek 1: Obwód elektryczny modelujący elektryczne właściwości błony komórkowej [6, 15, 18].

Model Hodgkina-Huxleya opisany jest układem czterech równań różniczkowych. Pierwsze z tych równań opisuje zmianę potencjału  $V$  na błonie komórkowej:

$$C \frac{dV}{dt} = I - g_{Na} m^3 h (V - V_{Na}) + g_K n^4 (V - V_K) + g_L (V - V_L) \quad (1)$$

gdzie  $I$  jest prądem wymuszającym,  $C$  jest konduktancją, elementy  $g_{Na} m^3 h$ ,  $g_K n^4$  oraz  $g_L$  wyrażają przepuszczalność jonową błony komórkowej oraz  $V_{Na}$ ,  $V_K$ ,  $V_L$  są potencjałami zwrotnymi, odpowiednio dla sodu, potasu i chloru. Parametry  $m$ ,  $n$  i  $h$  są zmiennymi bezwymiarowymi, które przyjmują wartości z zakresu  $\langle 0, 1 \rangle$ .

Kanały jonowe, zbudowane z mniejszych elementów – bramek, kontrolują przepływ jonów przez błonę komórkową. W modelu Hodgkina-Huxley'a zakłada się, że pojedyncza bramka może być w stanie przepuszczania lub nieprzepuszczania (ang. *permissive* i *non-permissive*). Pozostałe trzy równania tego modelu opisują prawdopodobieństwo, że pojedyncza bramka znajduje się w stanie przepuszczania:

$$\begin{aligned} \frac{dn}{dt} &= \alpha_n(V) \cdot (1 - n) - \beta_n(V) \cdot n \\ \frac{dm}{dt} &= \alpha_m(V) \cdot (1 - m) - \beta_m(V) \cdot m \\ \frac{dh}{dt} &= \alpha_h(V) \cdot (1 - h) - \beta_h(V) \cdot h \end{aligned} \quad (2)$$

Funkcje sigmoidalne  $\alpha_i(V)$  oraz  $\beta_i(V)$ , których postaci przedstawione są w tabeli 6, reprezentują współczynnik przejścia jonów pomiędzy wnętrzem i otoczeniem neuronu. Parametry modelu Hodgkina-Huxleya zostały pokazane w tabeli 7.

Rozpatrywane przeze mnie modele dotyczą neuronu o budowie punktowej (w każdym punkcie błony komórkowej potencjał jest identyczny) oraz o budowie drzewiastej (matematyczny opis potencjału rozchodzącego się wzdłuż dendrytów neuronu – bardzo prosta sieć neuronowa). Poniżej zostaną pokrótce omówione modele neuronu badane w pracach wchodzących w skład osiągnięcia.

### 1) Deterministyczny model kinetyczny neuronu o budowie punktowej

W modelu tym wprowadzone jest założenie, że bramki jonowe sodu mogą znajdować się w jednym z ośmiu stanów, natomiast bramki jonowe potasu – w jednym z pięciu stanów. Do opisu zależności



Tablica 6: Funkcje sigmoidalne  $\alpha_i(V)$  i  $\beta_i(V)$  [18]. Tablica 7: Parametry modeli biologicznego neuronu.

$i$	$\alpha_i(V)$	$\beta_i(V)$
$n$	$\frac{0.01 \cdot (10 - V)}{\exp\left(\frac{10-V}{10}\right) - 1}$	$0.125 \cdot \exp\left(-\frac{V}{80}\right)$
$m$	$\frac{0.1 \cdot (25 - V)}{\exp\left(\frac{25-V}{10}\right) - 1}$	$4 \cdot \exp\left(-\frac{V}{18}\right)$
$h$	$0.07 \cdot \exp\left(-\frac{V}{20}\right)$	$\frac{1}{\exp\left(\frac{30-V}{10}\right) + 1}$

$i$	$V_i$ [mV]	$g_i$ [mS/cm <sup>2</sup> ]
Na	115	120
K	-12	36
L	10.6	0.3

między poszczególnymi stanami wykorzystuje się tzw. schematy kinetyczne Markowa. W każdym ze schematów tylko jeden stan odpowiada bramce, która jest w pełni przepuszczająca. W przypadku jonów sodu jest to stan  $[m_3h_0]$  schematu (3), natomiast dla jonów potasu – stan  $[n_4]$  schematu (4).



Równanie opisujące zmianę potencjału  $V$  na błonie komórkowej przyjmuje wówczas postać:

$$C \frac{dV}{dt} = I - g_{Na} [m_3h_0] (V - V_{Na}) + g_K [n_4] (V - V_K) + g_L (V - V_L), \quad (5)$$

natomiast równania (2) zastąpione zostają trzynastoma równaniami, których postaci wynikają bezpośrednio z układu odpowiedniego schematu kinetycznego. Przykładowo równanie różniczkowe stanu  $[m_1h_0]$  przyjmuje postać:

$$\begin{aligned}
 \frac{d[m_1h_0]}{dt} = & 3\alpha_m(V) [m_0h_0] + \alpha_h(V) [m_1h_1] + 2\beta_m(V) [m_2h_0] + \\
 & - (\beta_m(V) + \beta_h(V) + 2\alpha_m(V)) [m_1h_0]
 \end{aligned} \quad (6)$$

## 2) Stochastyczny model kinetyczny neuronu o budowie punktowej

W stochastycznej wersji modelu kinetycznego, równania różniczkowe wynikające z postaci schematów kinetycznych są zastępowane formułami, w których wykorzystuje się fakt, że liczba bramek zmieniających stan w danej chwili czasu jest losowana z rozkładu normalnego [11]. Przykładowo równanie dla stanu  $[m_3h_0]$  przyjmuje postać [AMC\_2017\_b]:

$$\Delta [m_3h_0] = N(\mu_1, \sigma_1) + N(\mu_2, \sigma_2) - N(\mu_3, \sigma_3) - N(\mu_4, \sigma_4) \quad (7)$$



gdzie:

$$\begin{aligned}
 \mu_1 &= [m_2h_0] \cdot \alpha_m(V) \Delta t, & \sigma_1 &= [m_2h_0] \cdot \alpha_m(V) \Delta t (1 - \alpha_m(V) \Delta t), \\
 \mu_2 &= [m_3h_0] \cdot 3\beta_m(V) \Delta t, & \sigma_2 &= [m_3h_0] \cdot 3\beta_m(V) \Delta t (1 - 3\beta_m(V) \Delta t), \\
 \mu_3 &= [m_3h_1] \cdot \alpha_h(V) \Delta t, & \sigma_3 &= [m_3h_1] \cdot \alpha_h(V) \Delta t (1 - \alpha_h(V) \Delta t), \\
 \mu_4 &= [m_3h_0] \cdot \beta_h(V) \Delta t, & \sigma_4 &= [m_3h_0] \cdot \beta_h(V) \Delta t (1 - \beta_h(V) \Delta t).
 \end{aligned} \quad (8)$$

### 3) Rozszerzony model kinetyczny neuronu

W pracy [NNW\_2015] zaproponowana została rozszerzona wersja kinetycznego modelu neuronu. W modelu tym zostało wprowadzone założenie, że schematy kinetyczne Markowa dla bramek odpowiadających jonom sodu oraz potasu mogą być zbudowane z dowolnej liczby stanów, gdzie, podobnie jak w wyjściowym modelu kinetycznym, tylko jeden stan jest w pełni przepuszczający.

Schematy kinetyczne mają zatem postacie (9) dla bramek sodowych oraz (10) dla bramek potasowych. W zaprezentowanych w [NNW\_2015] rozpatrywane były różne rozmiary schematów, tzn.  $k \in \{1, 2, \dots, 31\}$  oraz  $l \in \{1, 2, \dots, 15\}$ . Wówczas największy możliwy schemat kinetyczny czy to dla potasu, czy dla sodu, miał 32 stany.



Główne równanie tego modelu przyjmuje postać:


$$C \frac{dV}{dt} = I - g_{Na} [m_j h_0] (V - V_{Na}) + g_K [n_i] (V - V_K) + g_L (V - V_L), \quad (11)$$

gdzie  $i \in \{0, \dots, k\}$  oraz  $j \in \{0, \dots, l\}$ . Pozostałe równania różniczkowe, podobnie jak w wyjściowym modelu kinetycznym, wynikają bezpośrednio z postaci schematów kinetycznych.

Rozszerzony model kinetyczny neuronu rozpatrywany był w wersji deterministycznej (z wykorzystaniem równań różniczkowych wynikających ze schematów kinetycznych (9) i (10)) oraz w wersji stochastycznej, gdzie liczba bramek zmieniających w danej chwili czasu stan losowana jest z rozkładu normalnego.

### 4) Model kinetyczny neuronu o budowie drzewiastej

Kinetyczny model neuronu o budowie drzewiastej (prostej sieci neuronowej) jest rozszerzeniem modelu zaproponowanego również w oryginalnej pracy Hodgina i Huxleya [18]. Przykładowa struktura takiej sieci neuronowej przedstawiona została na rysunku 2. W modelu obliczane są wartości potencjału w wyróżnionych punktach, gdzie w pierwszym punkcie uwzględniony zostaje prąd wymuszający.



Rysunek 2: Przykładowa struktura sieci neuronowej i sposób wyznaczania punktów, w których jest wyliczany potencjał [AMC\_2015].

Równanie opisujące wartość potencjału rozchodzącego się wzdłuż sieci neuronowej opisane jest następującym równaniem różniczkowym:

$$\frac{a}{2R} \frac{\partial^2 V}{\partial x^2} = C \frac{\partial V}{\partial t} + g_{Na} m^3 h (V - V_{Na}) + g_K n^4 (V - V_K) + g_L (V - V_L), \quad (12)$$



podczas gdy pozostałe równania są takiej samej postaci jak w wyjściowym modelu Hodgkina-Huxleya, to znaczy (2).

W modelu kinetycznym, natomiast, główne równanie przyjmuje postać:

$$\frac{a}{2R} \frac{\partial^2 V}{\partial x^2} = C \frac{\partial V}{\partial t} + g_{\text{Na}} [m_3 h_0] (V - V_{\text{Na}}) + g_{\text{K}} [n_4] (V - V_{\text{K}}) + g_{\text{L}} (V - V_{\text{L}}), \quad (13)$$

podczas gdy pozostałe równania mają postacie wynikające z budowy schematów kinetycznych Markowa (3) i (4). Również ten model rozpatrywany był w dwóch wersjach: deterministycznej oraz stochastycznej, a opis dyskretyzacji opisujących ten model równań w czasie i przestrzeni oraz ich implementacji przedstawiony został w pracy [BBE\_2017].

### 4.2.3 Trenowanie stochastycznych kinetycznych modeli biologicznego neuronu

#### 1) Modele neuronu o budowie punktowej

W przypadku dowolnego modelu biologicznego neuronu o budowie punktowej stosuje się metody zaczerpnięte z [12], gdzie trenowano oryginalny model Hodgkina-Huxleya z wykorzystaniem metody gradientu prostego. W swoich pracach adaptuję tę metodę tak, aby móc wykorzystać ją do modeli kinetycznych, a w szczególności ich stochastycznych wersji.

Podobnie jak w przypadku sztucznych sieci neuronowych dla modelu biologicznego neuronu formuluje się funkcję błędu postaci:

$$E = \frac{1}{T} \int_0^T \frac{1}{2} (V(t) - V^*(t))^2 dt. \quad (14)$$

Jest to standardowa funkcja błędu chwilowego, gdzie  $V$  oznacza wartość potencjału wyznaczoną na podstawie równań badanego modelu, podczas gdy  $V^*$  jest celem trenowania (potencjałem do którego model ma dążyć). Parametr  $T$  jest wielkością przedziału, w którym rozpatrywana jest praca modelu.

W metodzie gradientu prostego wagi modelu wyznaczane są według reguły:  $w_i \leftarrow w_i - \eta \nabla E$ , gdzie  $\eta$  jest współczynnikiem uczenia. Gradient funkcji błędu wyznaczany jest względem wag modelu. W przypadku stochastycznej wersji modelu kinetycznego jedynie trzy wagi są brane pod uwagę [AMC\_2017\_b], mianowicie  $g_{\text{Na}}$ ,  $g_{\text{K}}$  oraz  $g_{\text{L}}$ :

$$\begin{aligned} w_1 &= g_{\text{Na}} = \check{g}_{\text{Na}} e^{\tilde{g}_{\text{Na}}} \\ w_2 &= g_{\text{K}} = \check{g}_{\text{K}} e^{\tilde{g}_{\text{K}}} \\ w_3 &= g_{\text{L}} = \check{g}_{\text{L}} e^{\tilde{g}_{\text{L}}} \end{aligned} \quad (15)$$

gdzie  $\check{g}$  oznacza wartość domyślną konduktancji (pokazaną w tabeli 7), podczas gdy  $\tilde{g}$  to faktycznie obliczana podczas trenowania wartość wagi. Stąd ogólną postać gradientu funkcji błędu można zapisać następująco:

$$\frac{\partial E}{\partial w_i} = \frac{1}{T} \int_0^T \frac{1}{2} (V(t) - V^*(t)) \frac{\partial V(t)}{\partial w_i} dt. \quad (16)$$

#### 2) Modele neuronu o budowie drzewiastej

Trenowanie stochastycznej wersji kinetycznego modelu biologicznej sieci neuronowej odbywa się z wykorzystaniem metody mnożników Lagrange'a [AMC\_2015], [ACOM\_2019]. W metodzie tej

szuka się minimum (lub maksimum) pewnej funkcji, przy konkretnych ograniczeniach. W przypadku struktury pokazanej na rysunku 2 funkcja błędu przyjmuje postać:

$$E = \frac{1}{T} \sum_{i=1}^5 (V_i - V_i^*)^2, \quad (17)$$

natomiast jako ograniczenia przyjmowany jest układ równań:

$$\begin{aligned} F_1 &= C \frac{V_1 - V_{1prev}}{\Delta t} + g_{Na} [m_3 h_0]_1 (V_1 - V_{Na}) + g_K [n_4]_1 (V_1 - V_K) \\ &\quad + g_L (V_1 - V_L) - \frac{a_1 I_0 t^2 e^{-10t}}{2\pi \Delta x} - a_1 \frac{V_2 - V_1}{2R\Delta x^2} \\ F_2 &= C \frac{V_2 - V_{2prev}}{\Delta t} + g_{Na} [m_3 h_0]_2 (V_2 - V_{Na}) + g_K [n_4]_2 (V_2 - V_K) \\ &\quad + g_L (V_2 - V_L) - a_1 \frac{V_3 - 2V_2 + V_1}{2R\Delta x^2} \\ F_3 &= a_1^2 (V_3 - V_2) - a_2^2 (V_4 - V_3) - a_3^2 (V_5 - V_3) \\ F_4 &= C \frac{V_4 - V_{4prev}}{\Delta t} + g_{Na} [m_3 h_0]_4 (V_4 - V_{Na}) + g_K [n_4]_4 (V_4 - V_K) \\ &\quad + g_L (V_4 - V_L) - a_2 \frac{V_4 - V_3}{2R\Delta x^2} \\ F_5 &= C \frac{V_5 - V_{5prev}}{\Delta t} + g_{Na} [m_3 h_0]_5 (V_5 - V_{Na}) + g_K [n_4]_5 (V_5 - V_K) \\ &\quad + g_L (V_5 - V_L) - a_3 \frac{V_5 - V_3}{2R\Delta x^2} \end{aligned} \quad (18)$$

który w pełni opisuje każdy punkt rozpatrywanej struktury (z uwzględnieniem warunków brzegowych). Aby znaleźć minimum funkcji  $E$  jest formułowana pomocnicza funkcja:

$$L = E + \sum_{i=1}^5 \lambda_i F_i = \frac{1}{T} \sum_{i=1}^5 (V_i - V_i^*)^2 + \sum_{i=1}^5 \lambda_i F_i \quad (19)$$

gdzie  $\lambda_i$  to tak zwane mnożniki Lagrange'a. Z tak utworzonej funkcji  $L$  oblicza się pochodne względem wszystkich parametrów modelu biologicznej sieci neuronowej, do tych parametrów są zaliczone:

- wartości potencjału we wszystkich rozpatrywanych punktach sieci, czyli  $V_1, V_2, V_3, V_4, V_5$ ,
- wagi modelu:  $\tilde{g}_{Na}, \tilde{g}_K, \tilde{g}_L$ ,
- mnożniki Lagrange'a:  $\lambda_1, \lambda_2, \lambda_3, \lambda_4$  oraz  $\lambda_5$ .

W następnym kroku pochodne te przyrównuje się do zera i tworzy układ równań, którego rozwiązanie stanowi minimum wyjściowej funkcji  $E$ .

#### 4.2.4 Badanie zdolności uogólniania wiedzy wybranych modeli biologicznego neuronu

Istnieje wiele metod badania zdolności uogólniania wiedzy przez sieć neuronową. Jedną z najbardziej znanych metod jest badanie miary Vapnika-Chervonenkisa [25], która wymaga stosunkowo dużego zbioru trenującego [14]. Inną metodą stosowaną w nowszych badaniach jest, zaczerpnięta z teorii regularyzacji, metoda polegająca na badaniu wpływu tzw. czynnika regularyzującego dodawanego do funkcji błędu sieci neuronowej [16].

##### 1) Funkcja błędu

Do analizy zdolności generalizacji modelu biologicznego neuronu wykorzystuje się tak zwany czynnik regularyzujący. Poprzez analogię do dynamicznych sieci neuronowych czynnik taki dodaje się do funkcji błędu sieci neuronowej [14]. W przypadku dowolnych modeli biologicznego neuronu o budowie punktowej stosowana jest następująca funkcja błędu [AMC\_2017\_b]:

$$E = \frac{1}{T} \int_0^T \frac{1}{2} (V(t) - V^*(t))^2 dt + \lambda E_\lambda, \quad (20)$$

podczas gdy dla modeli sieci neuronowej należy wziąć pod uwagę wszystkie punkty rozpatrywanej struktury i stąd przykładowo dla struktury pokazanej na rysunku 2 funkcja ta przyjmuje postać [ACOM\_2019]:

$$E = \frac{1}{T} \sum_{i=1}^5 (V_i - V_i^*)^2 + \lambda E_\lambda. \quad (21)$$

Występujący w powyższych funkcjach składnik  $\lambda E_\lambda$  nazywany jest czynnikiem regularyzującym (ang. *regularizer*), gdzie  $E_\lambda$  jest funkcjonałem regularyzującym (ang. *regularization functional*), podczas gdy  $\lambda$  jest parametrem regularyzującym (ang. *regularization parameter*). Analizowane postacie funkcjonału  $E_\lambda$  zaprezentowano w następnej sekcji. Parametr  $\lambda$  jest wartością stałą, która zapewnia kompromis pomiędzy zadaniem realizowanym przez model biologicznego neuronu, a precyzją odwzorowania wejściowo-wyjściowego modelu (ang. *input-output mapping*) [16].

## 2) Rodzaje funkcjonału regularyzującego

W swoich badaniach nad zdolnością uogólniania wiedzy wykorzystywałam trzy różne postaci funkcjonału regularyzującego:

- funkcja kary (ang. *penalty function*):

$$E_\lambda = \frac{1}{T} \int_0^T \left( \sum_{i,j} w_{ij}^2 \right) dt = \frac{1}{T} \int_0^T (g_{Na}^2 + g_K^2 + g_L^2) dt. \quad (22)$$

- funkcjonal Tikhonova:

$$E_\lambda = \frac{1}{2T} \int_0^T \|DV\|^2 dt = \frac{1}{2T} \int_0^T \left\| \frac{\partial V}{\partial I} \right\|^2 dt, \quad (23)$$

- norma kwadratowa krzywizny sieci:

$$E_\lambda = \frac{1}{2T} \int_0^T \left\| \frac{\partial^2 V}{\partial I^2} \right\|^2 dt. \quad (24)$$

Wszystkie trzy czynniki były brane pod uwagę przy analizie modelu biologicznej sieci neuronowej [ACOM\_2019], podczas gdy pierwsze dwa – przy analizie modelu biologicznego neuronu [AMC\_2017\_b].


Każdy z czynników regularyzacji ma inny wpływ na sieć neuronową. Funkcja kary pozwala na kontrolę nad strukturą sieci, co jest bardzo istotne, ponieważ jej przewymiarowanie może wpływać na przetrenowanie. Funkcjonał Tikhonova wprowadza dodatkowe założenie, że funkcja odwzorowująca wyjście ma być gładka, co oznacza, że podobne wartości wejścia prądowego  $I$  mają odpowiadać podobnym wartościom wyjścia  $V$  [16]. Z kolei minimalizacja normy kwadratowej krzywizny sieci sprawia, że pochodna jest lokalnie niezmienna względem niewielkich odchyień wejścia  $I$  [14]. Wykorzystanie tej postaci czynnika regularyzacji pozwala na uzyskanie lepszego odwzorowania zbioru uczącego przez sieć.

---


#### 4.2.5 Zastosowania modeli biologicznego neuronu oraz sztucznych sieci neuronowych

##### 1) Usuwanie szumu z obrazu szarego

W pracach [AMC\_2017\_b] i [ACOM\_2019] badany był wpływ czynnika regularyzującego odpowiednio na trenowanie modelu biologicznego neuronu i modelu biologicznej sieci neuronowej w zagadnieniu usuwania szumu z obrazu szarego. W pierwszym artykule zaszumienie do obrazów było wprowadzane sztucznie poprzez dodanie do niego białego szumu Gaussa (rys. 3). Na rysunku 4 zostało pokazane zdjęcie obwodu drukowanego wraz z przykładem wprowadzonego zaszumienia, które powstało poprzez przesłonięcie obiektywu folią plastikową – przykład zaszumienia wykorzystywanego w drugim opisywanym w tej sekcji artykule.



Rysunek 3: Zdjęcie Leny: A. oryginalne, B. zaszumione przez wprowadzenie białego szumu Gaussa.



Rysunek 4: Zdjęcie obwodu drukowanego (A) i jego zaszumienie wprowadzone przez przesłonięcie obiektywu plastikową folią (B) [ACOM\_2019].

Zadaniem modelu biologicznej sieci neuronowej było stopniowe usuwanie szumu na obrazie, który zadany był jako prąd  $I$  na wejściu sieci neuronowej. W ten sposób potencjał uzyskany w dowolnym końcowym punkcie rozpatrywanej struktury sieci (dowolnym ponieważ wybrana struktura jest symetryczna), miał reprezentować obraz odszumiony, najbardziej zbliżony do obrazu oryginalnego.


W pracach [AMC\_2017\_b] oraz [ACOM\_2019] pokazano, że dodanie czynnika regularyzacji do funkcji błędu odpowiednio modelu biologicznego neuronu i modelu biologicznej sieci neuronowej podczas trenowania wpływa korzystnie na wykorzystane do porównań miary, takie jak błąd średnio-kwadratowy oraz miarę odległości od szukanego rozwiązania (ang. *first-order optimality measure* – miara związana z warunkami Karusha-Kuhna-Tuckera metody mnożników Lagrange'a [21]). W przypadku modelu biologicznego neuronu korzystniej wypada funkcjonal Tikhonova, podczas gdy w przypadku modelu biologicznej sieci neuronowej najkorzystniej wypada norma kwadratowa krzywizny sieci. Dzięki wykorzystaniu normy kwadratowej krzywizny sieci, błąd średnio-kwadratowy poprawia się nawet o rząd wielkości, podczas gdy miara odległości poprawia się z wartości rzędu  $10^{-2}$  na wartości rzędu  $10^{-8}$ .

2) Rekurencyjne sieci neuronowe do wyznaczania pozycji obiektu w przestrzeni


Położenie robota można wyznaczyć na różne sposoby, jednym z najbardziej znanych jest wyznaczenie przemieszczenia pomiędzy dwoma układami współrzędnych (układami odniesienia), gdzie pierwszy powiązany jest z Ziemią, albo punktem początkowym po kalibracji czujników, podczas gdy drugi powiązany jest z pozycją sterowanego obiektu, np. drona (rys. 5A). Obrót wektora w przestrzeni Euklidesowej odbywa się poprzez jego mnożenie przez tak zwaną macierz rotacji  $R$ :

$$R = \begin{pmatrix} \cos \theta \cos \psi & \sin \phi \sin \theta \cos \psi - \cos \phi \sin \psi & \cos \phi \sin \theta \cos \psi + \sin \phi \sin \psi \\ \cos \theta \sin \psi & \sin \phi \sin \theta \sin \psi + \cos \phi \cos \psi & \cos \phi \sin \theta \sin \psi - \sin \phi \cos \psi \\ -\sin \theta & \sin \phi \cos \theta & \cos \phi \cos \theta \end{pmatrix} \quad (25)$$

gdzie  $\phi$  – Roll,  $\theta$  – Pitch,  $\psi$  – Yaw, są odpowiednio osiami obrotu wzdłużnego, poprzecznego oraz pionowego.



A



B

Rysunek 5: Zdjęcie drona (A) oraz mocowanego do niego urządzenia rejestrującego sygnały z czujników (B).

Inną metodą wyznaczania położenia obiektu w przestrzeni jest wykorzystanie matematyki kwaternionów, to znaczy czterowymiarowych liczb zespolonych, które reprezentują orientację bryły sztywnej lub układ współrzędnych w przestrzeni trójwymiarowej. Wówczas, wiedząc, że kwaternion zdefiniowany jest jako:

$$q = q_0 + iq_1 + jq_2 + kq_3 = (q_0, q_1, q_2, q_3) \quad (26)$$

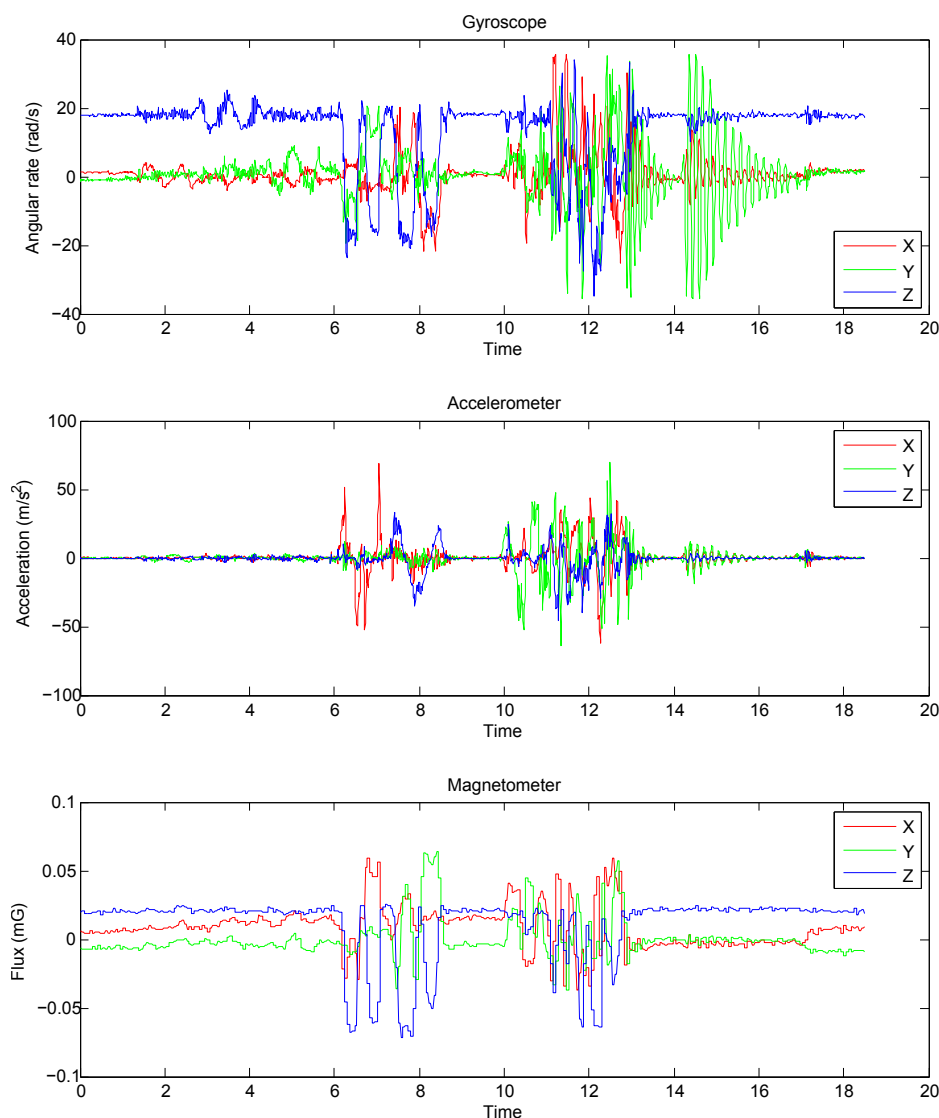
gdzie  $i$ ,  $j$  oraz  $k$  są jednostkami zespolonymi kwaternionu, podczas gdy  $q_0$ ,  $q_1$ ,  $q_2$  i  $q_3$  są wartościami rzeczywistymi, można przeprowadzić transformację kwaternionów w układ kątów Eulera:

$$\phi = \tan^{-1} \left( \frac{2(q_1q_2 + q_0q_3)}{q_3^2 - q_2^2 - q_1^2 + q_0^2} \right) \quad (27)$$

$$\theta = \sin^{-1} (-2(q_0q_2 + q_1q_3)) \quad (28)$$

$$\psi = \tan^{-1} \left( \frac{2(q_0q_1 + q_3q_2)}{q_3^2 - q_2^2 - q_1^2 + q_0^2} \right) \quad (29)$$

System pomiaru wysokości i naprowadzania (ang. *Attitude and Heading Reference System* – AHRS) umożliwia obliczanie położenia obiektu w przestrzeni na podstawie liniowego i kąтового przyspieszenia, kierunku oraz wielkości pola magnetycznego Ziemi [19]. System ten typowo składa się z akcelerometru, żyroskopu oraz magnetometru [8], czyli sensorów utworzonych w technologii MEMS



Rysunek 6: Przykładowe odczyty z czujników drona, żyroskopu, akcelerometru oraz magnetometru [RoMoCo\_2017, AMC\_2017\_b].

(ang. *Micro Electro-Mechanical Systems* — Mikroukłady elektromechaniczne). Przykładowy odczyt sygnałów z takiego zestawu czujników pokazany został na rysunku 6.

W pracy [AMC\_2017\_a] przedstawione zostały wyniki wyznaczania kątów Eulera z zastosowaniem rekurencyjnych sieci neuronowych. Na wejście sieci neuronowej Elmana podawane były wartości odczytanych z czujników sygnałów wzdłuż trzech osi współrzędnych. W celu zebrania danych z czujników zostało zbudowane urządzenie sterujące pokazane na rysunku 5B, a następnie przypięte do drona pokazanego na rysunku 5A [AMC\_2017\_a]. W urządzeniu tym wykorzystano inercyjny moduł pomiarowy (ang. *IMU – Inertial Measurement Unit*), który, jak już wspomniano wcześniej, wyposażony jest w akcelerometr, żyroskop oraz magnetometr. Wyjście sieci neuronowej generować ma wartości trzech kątów Eulera (*Roll*, *Pitch* oraz *Yaw*).

Sztuczne sieci neuronowe Elmana należą do grupy sieci rekurencyjnych i potrafią nauczyć się dowolnej dynamicznej, nieliniowej zależności między wyjściem a wejściem. W pracy [AMC\_2017\_a] oprócz opisu budowy platformy sprzętowej, można znaleźć również realizowany przeze mnie opis doboru odpowiedniej architektury tej sieci oraz efekty jej trenowania.

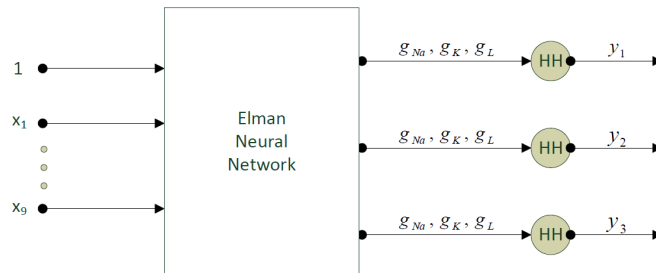
### 3) Model biologicznego neuronu w wyznaczaniu pozycji obiektu w przestrzeni

W pracy

**Aleksandra Świetlicka**, Krzysztof Kolanowski, Rafał Kapela,

*Training the Stochastic Kinetic Model of Neuron for Calculation of an Object's Position in Space,*

która aktualnie znajduje się w recenzji w czasopiśmie *Intelligent & Robotic Systems*, a wstępne wyniki tych badań zaprezentowane zostały w [24], zaprezentowano algorytm trenowania modelu biologicznego neuronu z wykorzystaniem gradientu prostego, w celu jego dalszego wykorzystania w procesie wyznaczania trzech kątów Eulera (ang. *Roll, Pitch, Yaw*). Ze względu na złożoność obliczeniową algorytmu AHRS [19] zdecydowano się na wykorzystanie rekurencyjnych sieci neuronowych Elmana (szczegółowy opis sieci neuronowych Elmana do wyznaczania kątów Eulera znajduje się w pracy [AMC\_2017\_a]) w połączeniu z modelem biologicznego neuronu (rys. 7). Zadaniem modeli biologicznego neuronu było „wygładzenie” czy też doprecyzowanie wartości kątów otrzymanych za pomocą sieci sztucznej.



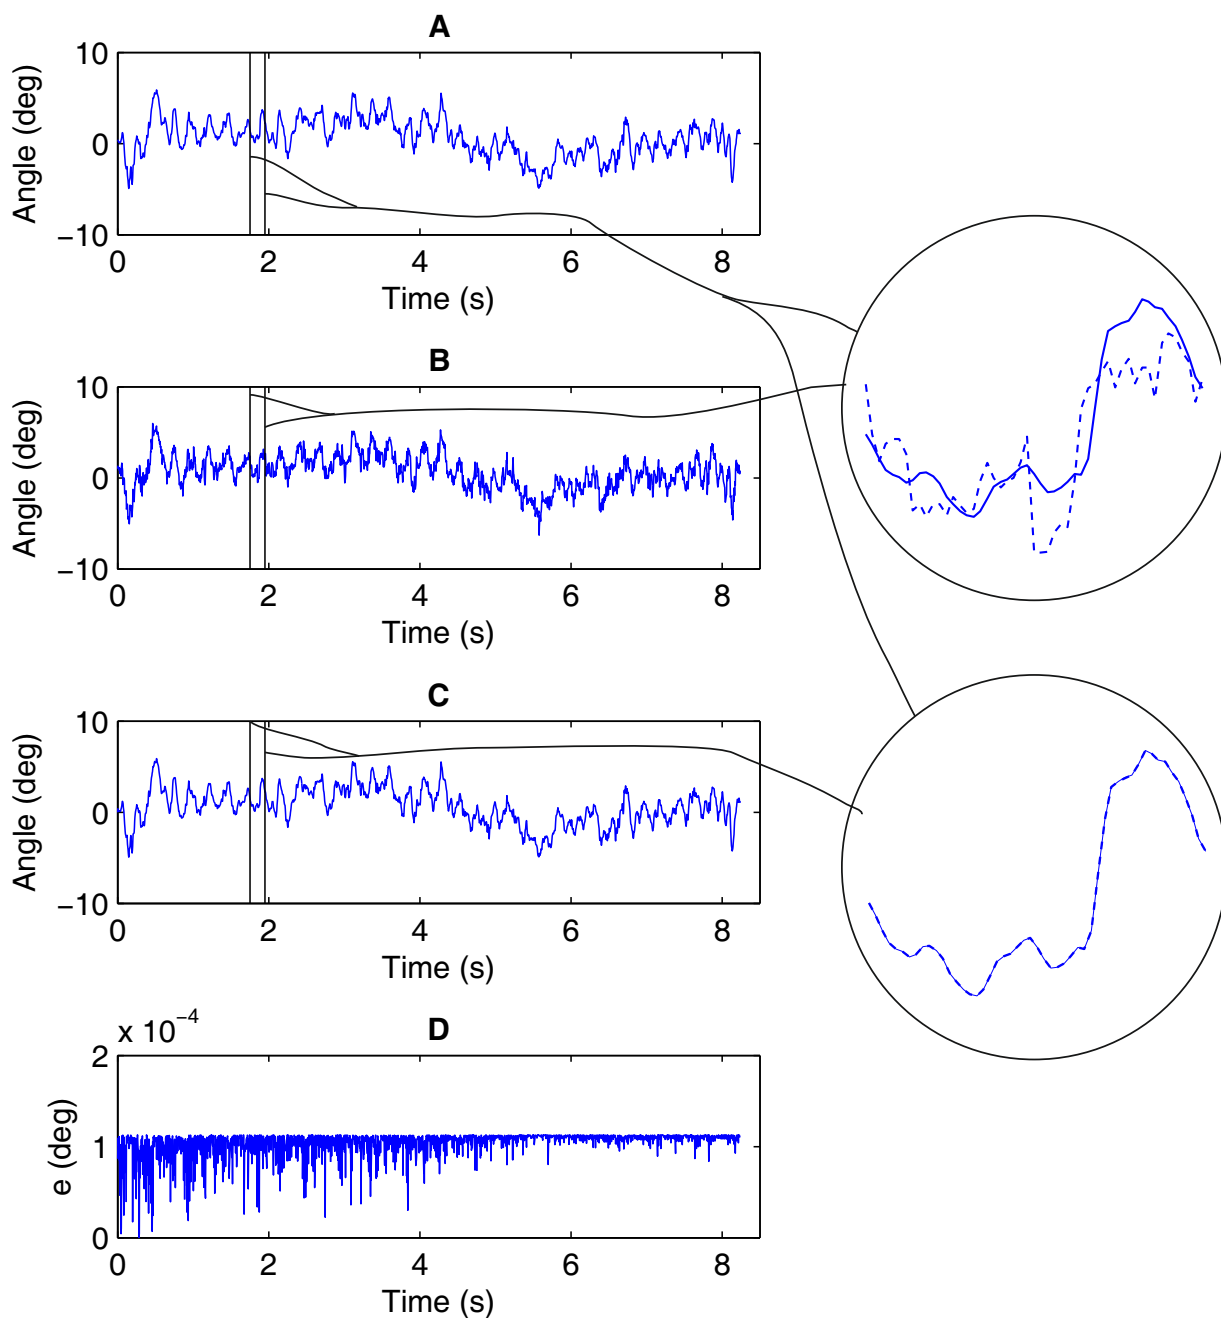
Rysunek 7: Struktura sieci neuronowej wykorzystanej do wyznaczania kątów Eulera.

Na rysunku 8 przedstawiona została przykładowa wartość kąta Eulera (kąt *Roll*) wraz z przybliżeniem wybranego przedziału czasu, tak aby wskazać precyzję modelu biologicznego neuronu w porównaniu z rekurencyjną sztuczną siecią neuronową Elmana. Rysunek 8A przedstawia oczekiwaną wartość kąta, podczas gdy 8B oraz 8C przedstawiają wyniki otrzymane odpowiednio z wykorzystaniem sieci neuronowej Elmana oraz tej samej sieci rozbudowanej o modele biologicznego modelu. Na rysunku 8D przedstawiona została różnica między wartościami pokazanymi na rysunkach 8B i 8C.

#### 4) Rekurencyjne sieci neuronowe do badania uszkodzeń w czujnikach obiektu w przestrzeni

W pracy [RoMoCo\_2017], będącej kontynuacją badań zaprezentowanych w pracy [AMC\_2017\_a], zaprezentowany został system wykrywania uszkodzeń na czujnikach dowolnego obiektu (w tym przypadku drona). Ideą proponowanego systemu była znajomość wartości referencyjnych badanego sygnału, aby móc wykryć nieadekwatności lub uszkodzenie w aktualnym stanie sterowanego urządzenia. Zaprojektowana wyjściowa sieć neuronowa miała za zadanie aproksymować kąty Eulera do wyznaczenia pozycji obiektu w przestrzeni, nie musiała jednak być idealnie precyzyjna, ponieważ nie była ona wytrenowana do rzeczywistego sterowania obiektem, a docelowo miała posłużyć jako element systemu detekcji uszkodzeń. Oczywiście im mniejszy błąd uogólniania wiedzy sieci neuronowej tym lepsza jej precyzja, jednak przede wszystkim należy sprawdzić czy otrzymane z sieci neuronowej wyjście znajduje się w znanym, poprawnym jej zakresie.

Można było zatem utworzyć system detekcji uszkodzeń z wykorzystaniem  $k$ -krotnej walidacji krzyżowej. Przykładowa struktura tego systemu pokazana jest na rysunku 9. W tym celu utworzony został system, na wejściu którego podawane jest  $N$  wartości sygnałów pobieranych z czujników robota, a następnie rozdzielane na taką samą liczbę aproksymatorów o  $N - 1$  liczbie wejść. Aproksymatory, czyli sztuczne sieci neuronowe, celowo zostały pomniejszone o jedno wejście. Wartość wyznaczana przez aproksymator jest następnie podawana na dodatkowy blok badający czy znajduje się ona w zakresie referencyjnym. Jeżeli dany aproksymator nie zgłasza błędu, podczas gdy




Rysunek 8: Wartości kąta Eulera wzdłuż osi  $x$  ( $Roll$ ) wyznaczone za pomocą: A. algorytmów AHRS, B. rekurencyjnej sieci neuronowej Elmana, C. stochastycznego kinetycznego modelu biologicznego neuronu oraz różnica pomiędzy wykresami A i C.

pozostałe „sygnalizują” błąd, daje to informację, że sygnał z czujnika, który został wykluczony na wejściu, jest uszkodzony.

##### 5) Detekcja zdarzeń w czasie rzeczywistym


W pracy [SPIC\_2015] zostały wykorzystane m.in. sztuczne sieci neuronowe do klasyfikacji interesujących zdarzeń występujących w transmisji sportowej. W tym celu zaimplementowany został algorytm umożliwiający ekstrakcję wektorów cech obrazowych na podstawie globalnych deskryptorów binarnych. Do detekcji zdarzeń zostały wykorzystane nie tylko sztuczne sieci neuronowe (jednokierunkowe oraz rekurencyjne), ale również drzewa decyzyjne. Każdy z klasyfikatorów został





Rysunek 9: Struktura systemu rejestrującego uszkodzenia na czujnikach [RoMoCo\_2017].

zbadany z punktu widzenia ich użyteczności, w przypadku sieci neuronowych niezbędny był dobór odpowiedniej architektury, tj. liczby neuronów w warstwie ukrytej czy funkcji aktywacji w każdej warstwie. Struktura systemu detekcji zdarzeń pokazana jest na rysunku 10.



Rysunek 10: Struktura systemu detekcji zdarzeń [SPIC\_2015]

#### 4.2.6 Podsumowanie

Podsumowując, na osiągnięcie opisane cyklem publikacji o tytule *Dynamiczne modele biologicznego neuronu oraz przykłady ich zastosowań w automatyce i robotyce*, składają się następujące pozycje:

- analiza zagadnienia usuwania szumu z obrazu w odcieniach szarości z wykorzystaniem modeli biologicznego neuronu oraz biologicznej sieci neuronowej, wraz z opisem niezbędnych operacji matematycznych umożliwiających implementację trenowania wykorzystywanych modeli;
- badanie zdolności uogólniania wiedzy modeli biologicznego neuronu i biologicznej sieci neuronowej;
- określanie pozycji obiektu w przestrzeni na podstawie wyznaczanych – zarówno przez sztuczne jak i biologiczne modele sieci neuronowych – kątów Eulera;
- wykorzystanie sztucznych sieci neuronowych, których pierwotnym zadaniem było obliczanie kątów Eulera w celu określania obiektu w przestrzeni, do utworzenia systemu wykrywania uszkodzeń na czujnikach tego obiektu;
- detekcja momentów interesujących, występujących w transmisjach sportowych z wykorzystaniem metod uczenia maszynowego, wśród których znalazły się zarówno sztuczne sieci neuronowe jak i drzewa decyzyjne.

Zarówno modele biologicznego neuronu i sieci neuronowych jak i sztuczne sieci neuronowe czy też inne metody uczenia maszynowego doskonale sprawdzają się w modelowaniu dynamicznych procesów nieliniowych. Niewątpliwą zaletą tego typu metod jest to, że osoba projektująca dany układ, nie musi znać dokładnej zależności pomiędzy szukanym rozwiązaniem (wyjściem sieci neuronowej), a parametrami opisującymi dane zagadnienie (wejścia sieci neuronowej). Systemy dokładnie opisujące dane zdarzenie

---

muszą być tak zaprojektowane, aby uwzględniać całą wiedzę na temat zagadnień, których będą dotyczyć, podczas gdy dzięki zdolnościom adaptacyjnym oraz tolerancji na nieciągłości, nieoczekiwane zaburzenia czy braki w zbiorze uczącym sieci neuronowe mają zastosowanie wszędzie tam, gdzie klasycznych metod nie da się zastosować.

Z całą pewnością prezentowane w niniejszym autoreferacie modele biologicznego neuronu i sieci neuronowych można w dalszym ciągu rozwijać, analizować i badać pod kątem zastosowań w zagadnieniach automatyki i robotyki. Konstrukcja zdecydowanie większych architektur złożonych z połączonych modeli biologicznego neuronu albo bardziej rozbudowanych struktur biologicznych sieci neuronowych umożliwi ich stosowanie w coraz bardziej skomplikowanych zagadnieniach sterowania.

Innym kierunkiem badań jest dalsza analiza modelu biologicznego neuronu o rozszerzonych schematach kinetycznych. Nie została jeszcze przeprowadzona dokładna analiza powiązania tego modelu z rzeczywistym modelem neuronu ani też analiza jego zdolności uogólniania wiedzy. Z drugiej zaś strony warto zauważyć, że na rzecz zastosowań praktycznych modeli biologicznego neuronu odchodzi się nieco od jego biologicznego wymiaru.

Jeszcze innym aspektem, którego w swoich badaniach nie rozpatrywałam, jest dokładna analiza porównawcza stosowanych przeze mnie modeli biologicznego neuronu i sieci neuronowych z wybranymi innymi metodami stosowanymi w prezentowanych zagadnieniach. Przykładem może być porównanie modeli biologicznego neuronu z filtrami w zagadnieniu usuwania szumu z obrazów.

Warto jeszcze raz nadmienić, że sztuczna inteligencja wraz ze wszystkimi metodami uczenia maszynowego jest nauką coraz bardziej interdyscyplinarną. Można powiedzieć, że kierunków dalszego rozwoju jest nieograniczenie dużo, naturalnie nie tylko w dziedzinie automatyki i robotyki.

#### 4.2.7 Opis wkładu w poszczególne artykuły wchodzące w skład osiągnięcia

Poniżej zaprezentowane zostały podsumowania mojego wkładu w poszczególne prace wchodzące w skład osiągnięcia. Opisy dotyczące prac, gdzie jestem jednym ze współautorów, zaczerpnięte zostały z oświadczeń, które przygotowaliśmy wspólnie z pozostałymi współautorami danej publikacji.

1. W artykule [ACOM\_2019] zostały przedstawione następujące sekcje:

- opis kinetycznego modelu biologicznej sieci neuronowej z wykorzystaniem schematów kinetycznych Markowa; przedstawienie zdyskretyzowanych równań opisujących rozpatrywaną strukturę sieci neuronowej (sekcja 2);
- opis wykorzystanych w badaniach czynników regularyzujących (sekcja 3);
- opis trenowania modelu biologicznej sieci neuronowej z wykorzystaniem metody mnożników Lagrange’a (sekcja 4);
- opis wyników działania modelu biologicznej sieci neuronowej w zagadnieniu odsumowania obrazów z uwzględnieniem wpływu czynników regularyzujących (sekcja 5);
- podsumowanie wyników pracy oraz sformułowanie potencjalnych dalszych kierunków pracy (sekcja 6).

2. Mój wkład w powstanie pracy [RoMoCo\_2017] polegał na:

- opracowaniu i implementacji oprogramowania którego zadaniem była detekcja uszkodzeń na podstawie odczytów z sensorów lokalizacyjnych robota mobilnego;
- porównaniu efektywności detektorów uszkodzeń;
- nadzorze merytorycznym swojej części projektu.

3. Mój wkład w powstanie pracy [AMC\_2017\_a] polegał na:

- opracowaniu wzorów matematycznych na podstawie biblioteki programowej;

- 
- doborze typu, struktury i metody nauki dla sztucznej sieci neuronowej;
  - nadzorze merytorycznym swojej części projektu.
4. Mój wkład w powstanie pracy [AMC\_2017\_b] polegał na:
- opisie stochastycznego kinetycznego modelu biologicznego neuronu (sekcja 2);
  - sformułowaniu problemu (sekcja 3);
  - przeprowadzeniu trenowania modelu biologicznego neuronu z uwzględnieniem w funkcji błędu czynnika regularyzującego (sekcja 4);
  - opisie wyników i podsumowaniu pracy (sekcja 5 i 6).
5. Mój wkład w powstanie pracy [BBE\_2017] polegał na:
- opisie formalizmu schematów kinetycznych Markowa (sekcja 2);
  - przygotowaniu, opisie, zapisie matematycznym modelu biologicznego neuronu o budowie drzewiastej (sieci neuronowej) opartego o schematy kinetyczne Markowa (sekcja 2 i 3, 4.3, 4.4, dodatki A i B);
  - opisie dyskretyzacji równań modelu w czasie i przestrzeni (sekcja 3);
  - opisie złożoności obliczeniowej modelu (sekcja 4.1);
  - przeprowadzeniu symulacji modelu (sekcja 4.5).
6. Mój wkład w powstanie pracy [SPIC\_2015] polegał na:
- opracowaniu i implementacji oprogramowania którego zadaniem była klasyfikacja wektorów cech obrazowych;
  - porównaniu efektywności klasyfikatorów (drzewa decyzyjne, płytkie sieci neuronowe (w tym sieci Elmana));
  - nadzorze merytorycznym swojej części projektu.
7. W artykule [AMC\_2015] zostały przedstawione następujące sekcje:
- opis modelu biologicznego neuronu wg Hodgina-Huxleya oraz jego kinetycznego rozszerzenia (sekcja 2);
  - opis modelu biologicznego neuronu o budowie drzewiastej (prostej sieci neuronowej); sposób dyskretyzacji równań opisujących model (sekcja 3);
  - opis metody gradientu prostego (sekcja 4) i metody mnożników Lagrange’a (sekcja 5);
  - opis sposobu trenowania modelu biologicznej sieci neuronowej z wykorzystaniem metody gradientu prostego oraz metody mnożników Lagrange’a (sekcje 6 i 7);
  - opis wyników działania modelu biologicznej sieci neuronowej w problemie odtwarzania obrazów z obrazów zaszumionych (sekcja 8);
  - sformułowanie wniosków końcowych oraz przedstawienie propozycji kierunków dalszej pracy (sekcja 9).
8. Mój wkład w powstanie pracy [NNW\_2015] polegał na:
- opisie wykorzystywanych w pracy modeli (sekcja 2);
  - opracowaniu różnic między wersją deterministyczną a stochastyczną zaproponowanych modeli; prezentacja średnich wartości liczby kanałów zmieniających stan w danym kroku czasu (sekcja 2.4);
  - opisie dyskretyzacji modelu z wykorzystaniem niejawnej metody Eulera (sekcja 3);
  - opracowaniu i opisie rozszerzonego modelu kinetycznego biologicznego neuronu (sekcja 4).
-

---

## Literatura

- [1] Blue brain project. <https://bluebrain.epfl.ch/>. Strona ostatnio odwiedzana: 14.04.2019 r.
- [2] Control engineering polska. <https://www.controlengineering.pl/>.
- [3] Dexterity network (dex-net). <https://berkeleyautomation.github.io/dex-net/>. Strona ostatnio odwiedzana: 14.04.2019 r.
- [4] Moral machine. <http://moralmachine.mit.edu/>. Strona ostatnio odwiedzana: 14.04.2019 r.
- [5] Tensorflow. <https://www.tensorflow.org/>. Strona ostatnio odwiedzana: 15.03.2019 r.
- [6] J. M. Bower and D. Beeman. *The Book of GENESIS, Exploring Realistic Neural Models with the General NEural SIMulation System*. Internet Edition, 2003.
- [7] S. Boyn, J. Grollier, G. Lecerf, B. Xu, N. Locatelli, S. Fusil, S. Girod, C. Carretero, K. Garcia, S. Xavier, J. Tomas, L. Bellaiche, M. Bibes, A. Barthelemy, S. Saighi, and V. Garcia. Learning through ferroelectric domain dynamics in solid-state synapses. *Nature Communications*, 8, 2017.
- [8] G. Cai, B. Chen, and T. Lee. *Unmanned Rotorcraft Systems*. Springer London Dordrecht Heidelberg, New York, 2011.
- [9] J.K. Chapin, K.A. Moxon, R.S. Markowitz, and M.A.L. Nicolelis. Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex. *Nature Neuroscience*, 2(7):664–670, 1999.
- [10] L. Chua. Memristor-the missing circuit element. *IEEE Transactions on Circuit Theory*, 18(5):507–519, 1971.
- [11] A. Destexhe, Z.F. Mainen, and T.J. Sejnowski. Synthesis of models for excitable membranes, synaptic transmission and neuromodulation using a common kinetic formalism. *Journal of Computational Neuroscience*, 3(1):195–230, 1994.
- [12] K. Doya, A.I. Selverston, and P.F. Rowat. A Hodgkin-Huxley type neuron model that learns slow non-spike oscillations. In *NIPS'93*, pages 566—573, 1993.
- [13] M. Furmankiewicz, M. Wiśniewska, and P. Ziuziański. *Rola informatyki w naukach ekonomicznych i społecznych*, chapter Możliwości zastosowania metod sztucznej inteligencji w inteligentnych budynkach, pages 50–60. Wydawnictwo Wyższej Szkoły Handlowej, 2014.
- [14] M. Galicki, L. Leistriz, E.B. Zwick, and H. Witte. Improving generalization capabilities of dynamic neural networks. *Neural Computation*, 16:1253–1282, 2004.
- [15] W. Gerstner and W. Kistler. *Spiking Neuron Models. Single Neurons, Populations, Plasticity*. Cambridge, 2000.
- [16] S.O. Haykin. *Neural Networks: A Comprehensive Foundation*. Pearson Education, second edition, 1998.
- [17] G.E. Hinton, S. Osindero, and Y.-W. Teh. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006.
- [18] A.L. Hodgkin and A.F. Huxley. A quantitative description of membrane current and its application to conduction and excitation in nerve. *Journal of Physiology*, 117:500–544, 1952.
- [19] S.O.H. Madgwick. An efficient orientation filter for inertial and inertial / magnetic sensor arrays. 2010.
- [20] C.T. Moritz, S.I. Perlmutter, and E.E. Fetz. Direct control of paralysed muscles by cortical neurons. *Nature*, 456, 2008.
- [21] J. Nocedal and S.J. Wright. *Numerical Optimization*. Springer, second edition, 2000.
- [22] W. Song, I. Cajigas, Brown. E.N., and S.F. Giszter. Adaptation to elastic loads and bmi robot controls during rat locomotion examined with point-process glms. *Frontiers in Systems Neuroscience*, 9(62):1–11, 2015.
- [23] D.B. Strukov, G.S. Snider, D.R. Stewart, and R.S. Williams. The missing memristor found. *Nature*, 453:80–83, 2008.
- [24] A. Świetlicka, K. Gugała, I. Karoń, K. Kolanowski, M. Majchrzycki, and A. Rybarczyk. Gradient method of learning for stochastic kinetic model of neuron. In *ISTET 2013: International Symposium on Theoretical Electrical Engineering, Pilsen, Czech Republic*, pages III–17–III–18, 24th – 26th June 2013.
- [25] V.N. Vapnik and A.Y. Chervonenkis. On the uniform convergence of relative frequencies of events to their probabilities. *Theory of Probability Applicat.*, 16:264–280, 1971.
- [26] G. Writer. 3 ways ai is making buildings smarter. <https://www.iotforall.com/ai-for-smart-buildings/>.

---

## 5 Pozostałe osiągnięcia naukowo-badawcze i dydaktyczne

### 5.1 Wykaz pozostałych publikacji

#### 5.1.1 Publikacje w czasopismach naukowych z listy A czasopism punktowanych

1. Michał Lewandowski, Łukasz Majka, **Aleksandra Świetlicka**, *Effective estimation of angular speed of synchronous generator based on stator voltage measurement*, Electrical Power and Energy Systems, 2018, vol. 100, pp. 391-399, DOI: 10.1016/j.ijepes.2018.03.002.  
**Punktacja MNiSW: 35, IF: 3,61, udział procentowy: 25%**  
Mój wkład w powstanie tej pracy polegał na:
  - dokonaniu przeglądu literatury w zakresie metod estymacji częstotliwości z wykorzystaniem sztucznych sieci neuronowych (rozdział 3),
  - dobór architektury sztucznej sieci neuronowej w zagadnieniu estymacji częstotliwości (rozdział 5),
  - implementacji oraz ewaluacji wybranych architektur sztucznych sieci neuronowych.
2. Rafał Kapela, Karol Gugąła, Paweł Śniatała, **Aleksandra Świetlicka**, Krzysztof Kolanowski, *Embedded platform for local image descriptor based object detection*, Applied Mathematics and Computation, 2015, vol. 267, pp. 419-426, DOI: 10.1016/j.amc.2015.02.029.  
**Punktacja MNiSW: 40, IF: 1,345, udział procentowy: 5%**  
Mój wkład w powstanie tej pracy polegał na pomocy przy formatowaniu danych do obliczeń w koprocessorze.
3. Karol Gugąła, **Aleksandra Świetlicka**, Michał Burdajewicz, Andrzej Rybarczyk, *Random number generation system improving simulations of stochastic models of neural cells*, Computing (Springer), 2013, vol. 95, nr 1, pp. 259-275, DOI: 10.1007/s00607-012-0267-z.  
**Punktacja MNiSW: 25, IF: 1,055, udział procentowy: 30%**  
Mój wkład w powstanie tej pracy polegał na:
  - opisie modelu Hodgkina-Huxleya (sekcja 2);
  - wyprowadzeniu równań opisujących generator liczb losowych (sekcja 4.1).

#### 5.1.2 Publikacje w czasopismach naukowych nieujętych na liście A czasopism punktowanych

Poniższe prace opublikowane zostały przed uzyskaniem stopnia doktora w czasopismach, które nie znajdują się w wykazie A czasopism punktowanych:

1. Marta Kolasa, Rafał Długosz, Wojciech Józwicki, Jolanta Pauk, **Aleksandra Świetlicka**, Pierre-André Farine, *Analysis of Significant Prognostic Factors of Patients with Bladder Cancer Using Self-Organizing Maps*, Solid State Phenomena, maj 2013, vol. 199, pp. 217-222, DOI: 10.4028/www.scientific.net/SSP.199.223.  
**Punktacja MNiSW: 10.**  
Mój wkład w powstanie tej pracy polegał na pomocy przy weryfikacji otrzymanych wyników, a mój udział procentowy szacuję na 10%.
2. **Aleksandra Świetlicka**, Karol Gugąła, Marta Kolasa, Jolanta Pauk, Andrzej Rybarczyk, Rafał Długosz, *A new model of the neuron for biological spiking neural network suitable for parallel data processing realized in hardware*, Solid State Phenomena, maj 2013, vol. 199, pp. 223-228, DOI: 10.4028/www.scientific.net/SSP.199.217.  
**Punktacja MNiSW: 10**  
Mój wkład w powstanie tej pracy polegał na przygotowaniu matematycznego opisu kinetycznego modelu biologicznego neuronu o budowie drzewiastej z wykorzystaniem rozszerzonych schematów kinetycznych Markowa oraz rezystorów wbudowanych w architekturę rozpatrywanej sieci neuronowej. Mój udział procentowy szacuję na 35%.
3. Agata Jurkowlanec, Michał Szulc, Tomasz Dybizbański, Sawomir Michalak, **Aleksandra Świetlicka**, Karol Gugąła, Andrzej Rybarczyk, *Supporting Tool for Clinical Observation of the Eyeballs Movements*, International Journal of Electronics and Telecommunications, vol. 58, nr (issue) 3/2012, pp. 219-224, 2012, DOI: 10.2478/v10177-012-0030-6.  
**Punktacja MNiSW: 8**  
Mój wkład w powstanie tej pracy polegał na pomocy przy weryfikacji otrzymanych wyników, a mój udział procentowy szacuję na 10%.
4. Janusz Pochmara, **Aleksandra Świetlicka**, Mateusz Majchrzycki, Krzysztof Kolanowski, Alicja Szulta, Paweł Szablata, Jakub Pałasiewicz, *System kreowania idealnego ruchu drogowego (Ideal traffic system creator)*, Elektronika, vol. 53, nr 4/2012, pp. 51-53.  
**Punktacja MNiSW: 6**  
Mój wkład w powstanie tej pracy polegał na pomocy przy weryfikacji otrzymanych wyników, a mój udział procentowy szacuję na 10%.

- 
5. Karol Gugala, **Aleksandra Figas**, Agata Jurkowlaniec, Andrzej Rybarczyk, *Parallel Simulation of Stochastic Dendritic Neurons using NVidia GPUs with CUDA C*, Elektronika, nr 12/2011, pp. 59-61, grudzień 2011.

**Punktacja MNiSW: 6**

Mój wkład w powstanie tej pracy polegał na opisie kinetycznego modelu biologicznego neuronu o budowie drzewiastej i przygotowaniu modelu do dalszych sprzętowych implementacji. Mój udział procentowy szacuję na 30%.

6. Marta Kolasa, Rafał Długosz, **Aleksandra Figas**, *Wpływ funkcji sąsiedztwa na efektywność uczenia sieci neuronowych Kohonena implementowanych sprzętowo*, Prace Naukowe Politechniki Śląskiej – Elektryka, Zeszyt 1/2011 (217), pp. 63-73.

**Punktacja MNiSW: 4**

Mój wkład w powstanie tej pracy polegał na pomocy przy weryfikacji otrzymanych wyników, a mój udział procentowy szacuję na 10%.

7. Michał Szulc, Sławomir Michalak, **Aleksandra Figas**, Piotr Nowak, Andrzej Rybarczyk, *Fale jonów wapniowych, jako modulator oddziaływania pomiędzy neuronami a glejmem (Calcium waves as a modulator of neuronal – glial interaction)*, Neuroskop 2008, nr 10, 110-114.

**Punktacja MNiSW: 2**

Mój wkład w powstanie tej pracy polegał na pomocy przy weryfikacji otrzymanych wyników, a mój udział procentowy szacuję na 10%.

### 5.1.3 Monografie oraz rozdziały w monografiach naukowych

1. **Aleksandra Świetlicka**, *Stochastyczny model biologicznej sieci neuronowej oparty na kinetycznych schematach Markowa*, monografia doktorska, Wydawnictwo Politechniki Poznańskiej, 2015, ISBN 978-83-7775-386-6.

**Punktacja MNiSW: 25**

„W rozprawie zaprezentowano nowe modele biologicznej komórki nerwowej i sieci neuronowej, możliwie wiernie odwzorujące procesy zachodzące w układzie nerwowym. Poza szczegółowym opisem matematycznym modeli przedstawiono wyniki licznych symulacji potwierdzające ich rzetelność. Istotnym elementem pracy było pokazanie możliwości wykorzystania modeli, które w wyniku procesu nauki mają rozwiązywać wybrane zagadnienia, zwłaszcza z dziedziny automatyki i robotyki.”

2. Rafał Kapela, Kevin McGuinness, **Aleksandra Świetlicka**, Noel E. O'Connor, *Real-time Event Detection in Field Sport Videos*, Computer Vision in Sports, Series: Advances in Computer Vision and Pattern Recognition, edytorzy: Thomas B. Moeslund, Graham Thomas, Adrian Hilton, Springer 2014, pp. 293-316, ISBN 978-3-319-09395-6, DOI: 10.1007/978-3-319-09396-3.

**Punktacja MNiSW: 5**

Mój wkład w powstanie tej pracy polegał na:

- opracowaniu i implementacji oprogramowania którego zadaniem była klasyfikacja wektorów cech obrazowych,
- porównanie efektywności klasyfikatorów (drzewa decyzyjne, płytkie sieci neuronowe (w tym sieci Elmana),
- nadzorce merytorycznym swojej części projektu.

Mój udział procentowy szacuję na 45%.

3. Krzysztof Kolanowski, Mateusz Majchrzycki, **Aleksandra Świetlicka**, *Planowanie zasobów przedsiębiorstwa na poziomie głównego planu produkcji*, rozdział w monografii: *Praktyczne aspekty wykorzystania systemów ERP w wybranych przedsiębiorstwach Wielkopolski*, WSL Poznań, 2012, pp. 75-122, ISBN 978-83-62285-16-7.

**Punktacja MNiSW: 4**

W monografii opisany został wpływ wykorzystania systemów ERP na działalność wybranych przedsiębiorstw z województwa wielkopolskiego. Mój udział szacuję na 30%.

4. Mateusz Majchrzycki, Krzysztof Kolanowski, **Aleksandra Świetlicka**, Karol Gugala, *Information processing in a distributed system of data acquisition*, rozdział w monografii: *Information Technology and its Applications*, NAKOM, Poznań 2011, pp. 167-179, ISBN 978-83-89529-82-4.

**Punktacja MNiSW: 5**

Mój wkład w powstanie tej pracy polegał na wykorzystaniu sztucznych sieci neuronowych w analizie zbieranych z czujników danych. Mój udział procentowy szacuję na 25%.

5. **Aleksandra Figas**, Karol Gugala, Michał Szulc, Agata Jurkowlaniec, Andrzej Rybarczyk, *The FPGA-based CCM Class System Supporting Simulation of Stochastic Biologically Realistic Models of Neural Cell*, w *Advances in Systems Science*, edytorzy: Adam Grzech, Paweł Świątek, Jarosław Drapała, Academic Publishing House Exit, Warszawa 2010, pp. 131-138, ISBN 978-83-60434-77-2.

**Punktacja MNiSW: 7**

Mój wkład w powstanie tej pracy polegał na opisie implementowanego sprzętowo kinetycznego modelu biologicznego neuronu oraz opisie matematycznym zaproponowanego generatora liczb losowych. Mój udział procentowy szacuję na 45%.

---

#### 5.1.4 Wygłoszenie referatu lub prezentacja plakatu na konferencjach międzynarodowych

1. Rafał Kapela, Szymon Sobczak, Dariusz Pazderski, Krzysztof Kozłowski, **Aleksandra Świetlicka**, Kevin McGuinness, Noel O'Connor, *Restricted Boltzmann Machine for Binary Patterns Aggregation for Image Object Recognition*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2018, pp. 89.
2. Krzysztof Kolanowski, **Aleksandra Świetlicka**, *Sensor Failure Detection in Selftesting Navigation System*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2018, pp. 95.
3. **Aleksandra Świetlicka**, Krzysztof Kolanowski, *Gradient Methods of Training and Generalization Ability of a Biological Neural Network Model*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2018, pp. 164.
4. Rafał Kapela, Janusz Pochmara, **Aleksandra Świetlicka**, Krzysztof Kolanowski, Andrzej Rybarczyk, *The Concept of an Industry 4.0 Visual System, (Koncepcja systemu wizyjnego w technologii Industry 4.0)*, SPETO (International Conference on Fundamentals of Electrotechnics and Circuit Theory – Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów), Ustroń, Polska, 2017, pp. 95-96.
5. Rafał Kapela, **Aleksandra Świetlicka**, Kevin McGuinness, Noel E. O'Connor, *Aggregation Techniques of Binary Local Image Descriptors*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2016, pp. 128.
6. Krzysztof Kolanowski, Rafał Kapela, **Aleksandra Świetlicka**, Janusz Pochmara, Andrzej Rybarczyk, *Deep Learning in Data Fusion for Multi-sensor Navigation System*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2016, pp. 135.
7. Michał Lewandowski, Łukasz Majka, **Aleksandra Świetlicka**, *Computationally Efficient Rotational Speed Estimation Method of Synchronous Generator Based on Stator Voltage Measurement*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2016, pp. 152.
8. **Aleksandra Świetlicka**, Krzysztof Kolanowski, Rafał Kapela, Andrzej Rybarczyk, *Investigation of Generalization Capabilities of a Trained Stochastic Kinetic Model of Neuron*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2016, pp. 245.
9. Karol Gugała, **Aleksandra Świetlicka**, Andrzej Rybarczyk, *Hardware accelerated neural computing in embedded systems*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2014, pp. 95.
10. **Aleksandra Świetlicka**, Karol Gugała, Andrzej Rybarczyk, *Training algorithm for stochastic model of biological neural network*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2014, pp. 208.
11. Karol Gugała, **Aleksandra Świetlicka**, Marcin Kubicki, Andrzej Rybarczyk, *Intelligent Home Controller Based on Embedded System (Kontroler inteligentnego budynku oparty o system wbudowany)*, SPETO (International Conference on Fundamentals of Electrotechnics and Circuit Theory – Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów), Ustroń, Polska, 2013, pp. 115-116.
12. Karol Gugała, **Aleksandra Świetlicka**, Krzysztof Kolanowski, Igor Karoń, Mateusz Majchrzycki, Andrzej Rybarczyk, *Neural controller implementation in embedded system with use of FPGA coprocessor*, ISTET (International Symposium on Theoretical Electrical Engineering), Pilzno, Czechy, 2013, pp. IV-53 – IV-54.

- 
13. Paweł Gurzyński, Rafał Kapela, Tomasz Talaśka, **Aleksandra Świetlicka**, *An Optimized Algorithm for Recognition of Complex Patterns Based on Artificial Neural Network*, MIXDES (Mixed Design of Integrated Circuits and Systems), Gdańsk, Polska, 2013, pp. 580-585.  
**Punktacja MNiSW: 10**
  14. Igor Karoń, Krzysztof Kolanowski, Mateusz Majchrzycki, **Aleksandra Świetlicka**, Karol Gugala, Andrzej Rybarczyk, *Multi-agent system based on Artificial Neural Network for terrain exploration*, ISTET (International Symposium on Theoretical Electrical Engineering), Pilzno, Czechy, 2013, pp. III-21 – III-22.
  15. Krzysztof Kolanowski, **Aleksandra Świetlicka**, Mateusz Majchrzycki, Karol Gugala, Igor Karoń, Andrzej Rybarczyk, *Nine-Axis IMU sensor fusion using the AHRs algorithm and neural networks*, ISTET (International Symposium on Theoretical Electrical Engineering), Pilzno, Czechy, 2013, pp. III-23 – III-24.
  16. Mateusz Majchrzycki, **Aleksandra Świetlicka**, Karol Gugala, Igor Karoń, Krzysztof Kolanowski, Rybarczyk Andrzej, *Time synchronization in distributed sensor network*, ISTET (International Symposium on Theoretical Electrical Engineering), Pilzno, Czechy, 2013, pp. IV-75 – IV-76.
  17. **Aleksandra Świetlicka**, Karol Gugala, Igor Karoń, Krzysztof Kolanowski, Mateusz Majchrzycki, Andrzej Rybarczyk, *Gradient method of learning for stochastic kinetic model of neuron*, ISTET (International Symposium on Theoretical Electrical Engineering), Pilzno, Czechy, 2013, pp. III-17 – III-18.
  18. Karol Gugala, **Aleksandra Świetlicka**, Michał Burdajewicz, Andrzej Rybarczyk, *Fast Parallel Random Generator with High Entropy for a Biological Processes Simulations*, ESCO (European Seminar on Computing) Pilzno, Czechy, 2012, pp. 59.
  19. Marta Kolasa, Rafał Długosz, Wojciech Józwicki, Jolanta Pauk, **Aleksandra Świetlicka**, Pierre-André Farine, *Analysis of Significant Prognostic Factors of Patients with Bladder Cancer Using Self-Organizing Maps*, MSM (International Conference Mechatronic Systems and Materials 2012) Białystok, Polska, 2012, pp. 179.
  20. **Aleksandra Świetlicka**, Karol Gugala, Marta Kolasa, Jolanta Pauk, Andrzej Rybarczyk, Rafał Długosz, *A new model of the neuron for biological spiking neural network suitable for parallel data processing realized in hardware*, MSM (International Conference Mechatronic Systems and Materials 2012) Białystok, Polska, 2012, pp. 185.
  21. **Aleksandra Świetlicka**, Karol Gugala, Andrzej Rybarczyk, *Application of Self-Organising Maps in Tasks of Selection of Sizes of Markov Kinetic Schemes for Biologically Realistic Neural Networks (Zastosowanie samoorganizujących się sieci neuronowych w zagadnieniu doboru rozmiaru schematów kinetycznych Markowa dla Biologicznych Sieci Neuronowych)*, SPETO (International Conference on Fundamentals of Electrotechnics and Circuit Theory – Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów), Ustroń, Polska, 2012, pp. 143-144.
  22. **Aleksandra Figas**, Karol Gugala, Andrzej Rybarczyk, *Hardware Implementation of Stochastic Model of Neural Cell (Implementacja Sprzętowa Stochastycznego Modelu Kinetycznego Komórki Nerwowej)*, SPETO (International Conference on Fundamentals of Electrotechnics and Circuit Theory – Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów), Ustroń, Polska, 2011, pp. 137-138.
  23. **Aleksandra Figas**, Karol Gugala, Andrzej Rybarczyk, Rafał Długosz, Marta Kolasa, *Hardware Implementation of the Kinetic Model of the Nerve Cell by Use of the Multivalued Łukasiewicz Logic (Implementacja Sprzętowa Kinetycznego Modelu Komórki Nerwowej z Wykorzystaniem Logiki*
-



---

*Wielowartościowej Łukasiewicza*), SPETO (International Conference on Fundamentals of Electrotechnics and Circuit Theory – Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów), Ustroń, Polska, 2011, pp. 135-136.

24. Karol Gugala, **Aleksandra Figas**, Agata Jurkowlaniec, Andrzej Rybarczyk, *Parallel Simulation of Stochastic Dendritic Neurons using NVidia GPUs with CUDA C*, MIXDES (Mixed Design of Integrated Circuits and Systems), Gliwice, Polska, 2011, pp. 156.
25. Agata Jurkowlaniec, Tomasz Dybizbański, Michał Szulc, Sławomir Michalak, **Aleksandra Figas**, Karol Gugala, Andrzej Rybarczyk, *The System Supporting the Clinical Observation of Eyeball Movements*, MIXDES (Mixed Design of Integrated Circuits and Systems), Gliwice, Polska, 2011, pp. 170.
26. Marta Kolasa, Rafał Długosz, **Aleksandra Figas**, *An Influence of the Neighborhood Function on the Learning Process of the Kohonen Neural Networks – Wpływ Funkcji Sąsiedztwa na Efektywność Ucznienia Sieci Neuronowych Kohonena*, SPETO (International Conference on Fundamentals of Electrotechnics and Circuit Theory – Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów), Ustroń, Polska, 2011, pp. 145-146.
27. **Aleksandra Figas**, Karol Gugala, Michał Szulc, Agata Jurkowlaniec, Andrzej Rybarczyk, *The FPGA-based CCM Class System Supporting Simulation of Stochastic Biologically Realistic Models of Neural Cell*, ICSS (International Conference on Systems Science), Wrocław, Polska, 2010.
28. **Aleksandra Figas**, *Mathematical Models of Nervous Cell*, PODE (Progress on Difference Equations), Będlewo, Polska, 2009, pp. 49.

## 5.2 Udział w projektach naukowych

1. System całodobowego monitorowania i analizy zaburzeń ruchowych i pozaruchowych u chorych z zespołami pozapiramidowymi, 2008 – 2011, źródło finansowania: Ministerstwo Nauki i Szkolnictwa Wyższego, charakter udziału: wykonawca.

Celem projektu było zaprojektowanie i wykonanie systemu monitorowania parametrów pacjenta z zaburzeniami pozapiramidowymi (np. choroba Parkinsona i inne z występowaniem drżenia kończyn). Monitorowane były przemieszczenia kończyn za pomocą czujników inercyjnych, które montowane były na kostkach oraz nadgarstkach pacjenta. Parametry poza-ruchowe jakie były monitorowane to: temperatura ciała oraz wilgotność skóry pacjenta, dodatkowym parametrem którego pomiar był wykonywany rzadziej był pomiar ciśnienia tętniczego oraz tętna. Zbudowany zestaw do akwizycji danych dostarczał zapisane na kartę SD próbki z okresu kilkunastu godzin (analogiczne działanie do holtera, z tym że rejestrowane były inne parametry).

2. Zwiększenie dokładności systemów nawigacyjnych z wykorzystaniem sieci neuronowych, maj 2016 — listopad 2016, źródło finansowania: Ministerstwo Nauki i Szkolnictwa Wyższego, charakter udziału: kierownik projektu.

Finansowanie przyznane w ramach konkursu badawczego wspierającego młodych naukowców, regulamin dostępny jest na stronie Wydziału Informatyki Politechniki Poznańskiej: <http://fc.put.poznan.pl/fc2/drupal/node/774> (strona ostatnio odwiedzana: 23.04.2019 r.), zajęłam pierwsze miejsce na ogłoszonej liście rankingowej.

Celem naukowym projektu było efektywne wyznaczenie położenia obiektu w przestrzeni 3D na podstawie odczytów z wybranych czujników przy wykorzystaniu sztucznych sieci neuronowych.

3. Badanie zdolności uogólniania wiedzy modelu biologicznej sieci neuronowej opartej na schematach kinetycznych Markowa, maj 2017 — listopad 2018, źródło finansowania: Ministerstwo Nauki i Szkolnictwa Wyższego, charakter udziału: kierownik projektu.

---

Finansowanie przyznane w ramach konkursu badawczego wspierającego młodych naukowców, regulamin dostępny jest na stronie Wydziału Informatyki Politechniki Poznańskiej: <http://fc.put.poznan.pl/fc2/drupal/node/915> (strona ostatnio odwiedzana: 23.04.2019 r.), zajęłam czwarte miejsce na ogłoszonej liście rankingowej.

4. Zastosowanie uczenia maszynowego do analiz proteogenomicznych nowotworów, czerwiec 2018 – styczeń 2019, projekt realizowany w ramach Międzynarodowego Instytutu Onkologii Molekularnej, charakter udziału: wykonawca, kierownik laboratorium sztucznej inteligencji.

Moja praca w tym projekcie polegała na dobraniu architektury wybranych sztucznych sieci neuronowych (sieci jednokierunkowe, rekurencyjne oraz konwolucyjne) w zagadnieniu obliczania współczynnika macierzystości na podstawie kilkunastu tysięcy genomów opisujących komórki rakowe.

5. Samotestowanie sensorów dla układów nawigacyjnych z wykorzystaniem sztucznych sieci neuronowych, maj 2018 – obecnie, źródło finansowania: Ministerstwo Nauki i Szkolnictwa Wyższego, charakter udziału: wykonawca.

Finansowanie przyznane w ramach konkursu badawczego wspierającego młodych naukowców, regulamin dostępny jest na stronie Wydziału Informatyki Politechniki Poznańskiej: <http://fc.put.poznan.pl/fc2/drupal/node/1011> (strona ostatnio odwiedzana: 23.04.2019 r.).

Celem projektu jest opracowanie technik z wykorzystaniem sztucznych sieci neuronowych dla wykrywania uszkodzeń w układach sensorycznych.

6. Budowa bazy wiedzy o nieruchomościach, kwiecień 2019 – obecnie, źródło finansowania: Narodowe Centrum Badań i Rozwoju, projekt realizowany we współpracy z Wrocławskim Instytutem Zastosowań Informatyki Przestrzennej i Sztucznej Inteligencji, charakter udziału: wykonawca, informatyk — doświadczony naukowiec.

### 5.3 Recenzowanie artykułów do czasopism naukowych

- Applied Mathematics and Applications, 2014 – 2017, liczba recenzji: 5
- Neural Computing and Applications, 2017, liczba recenzji: 1
- Neural Network World, 2015, liczba recenzji: 1
- Facta Universitatis: Electronics and Energetics, 2014, liczba recenzji: 1
- Advances in Mechanical Engineering, 2017, liczba recenzji: 1
- IEEE Transactions on Industrial Electronics, 2019, liczba recenzji: 1

### 5.4 Międzynarodowe i krajowe nagrody za działalność naukową

- Mixdes 2011 – Best Paper Award  
Agata Jurkowlaniec, Tomasz Dybizbański, Michał Szulc, Sławomir Michalak, **Aleksandra Figas**, Karol Gugąła, Andrzej Rybarczyk, The System Supporting the Clinical Observation of Eyeball Movements, MIXDES (Mixed Design of Integrated Circuits and Systems), Gliwice, Polska, 2011.
- ISTET 2013 – Outstanding Poster Award  
**Aleksandra Świetlicka**, Karol Gugąła, Igor Karoń, Krzysztof Kolanowski, Mateusz Majchrzycki, Andrzej Rybarczyk, Gradient method of learning for stochastic kinetic model of neuron, ISTET (International Symposium on Theoretical Electrical Engineering), Pilzno, Czechy 2013.

- ESCO 2016 – Best Poster Award (Silver Award)  
**Aleksandra Świetlicka**, Krzysztof Kolanowski, Rafał Kapela, Andrzej Rybarczyk, Investigation of Generalization Capabilities of a Trained Stochastic Kinetic Model of Neuron, ESCO (European Seminar on Computing) Pilzno, Czechy, 2016.
- ESCO 2016 – Best Poster Award (Silver Award)  
Michał Lewandowski, Łukasz Majka, **Aleksandra Świetlicka**, Computationally Efficient Rotational Speed Estimation Method of Synchronous Generator Based on Stator Voltage Measurement, ESCO (European Seminar on Computing) Pilzno, Czechy, 2016.
- Nagroda JM Rektora Politechniki Poznańskiej za wyróżniające się osiągnięcia w pracy naukowej za rok 2015/2016 (publikacje w czasopismach znajdujących się na liście JCR)  
**Aleksandra Świetlicka**, Trained stochastic model of biological neural network used in image processing task, Applied Mathematics and Computation, 2015, vol. 267, pp. 716-726, DOI: 10.1016/j.amc.2014.12.082, IF: 1,345, **punktacja MNiSW: 40.**

## 5.5 Członkostwo w organizacjach oraz towarzystwach naukowych

1. Członkostwo w Radzie Naukowej Międzynarodowego Instytutu Onkologii Molekularnej (IIMO – International Institute for Molecular Oncology), od 2015 roku.
2. Członkostwo IEEE, sekcje IEEE Systems, Man, and Cybernetics Society oraz IEEE Robotics and Automation Society, od 2018 roku.
3. Członkostwo w Polskim Stowarzyszeniu Sztucznej Inteligencji, od 2018 roku.

## 5.6 Udział w warsztatach, konferencjach i kursach

### Konferencje:

- Cell Symposia: TCGA Legacy: Multi-Omic Studies in Cancer, Waszyngton, USA, 27-29 września 2018 r.
- Women in Science. The Tradition of Maria Skłodowska-Curie, Łódź, Polska, 29-30 września 2016 r.

### Kursy:

- Kurs w zakresie zaawansowanego planowania zasobów przedsiębiorstwa z wykorzystaniem systemu informatycznego klasy ERP, rok 2012.
- Kurs „Sieci neuronowe”, zorganizowany przez StatSoft Polska, wykładowcy: prof. dr hab. inż. Ryszard Tadeusiewicz, prof. UEK dr hab. Paweł Lula, Kraków, Polska, styczeń 2010 r.

### Warsztaty – staże naukowe:

- Workshop on usage of artificial neural networks in sport event classification and Restricted Boltzmann Machines for binary local descriptors aggregation, Dublin, Irlandia, 16-21 lutego 2013 r.
- Training: Advanced Image and Video Processing for Hardware Realizations, Dublin, Irlandia, 13-17 maja 2012 r.

### Studia podyplomowe

- Studia podyplomowe w zakresie: Kompetencje edukacyjne w obszarze przedmiotów politechnicznych, Politechnika Poznańska, Wydział Inżynierii Zarządzania, rok 2010.

---

## 5.7 Działalność dydaktyczna

### 5.7.1 Udział w projektach dydaktycznych

1. „Nauka Bliżej Biznesu, Biznes Bliżej Nauki” – projekt współfinansowany przez Unię Europejską, w ramach Europejskiego Funduszu Społecznego (projekt nr POKL.08.02.01-30-018/10), charakter udziału: wykonawca.

„Szkolenia i symulacje na platformie edukacyjno-symulacyjnej dla przedstawicieli firm (pracowników, właścicieli), obejmujące – w szczególności – tematykę planowania zasobów firmy z wykorzystaniem systemów ERP. Wykorzystanie nowoczesnych narzędzi zarządzania przedsiębiorstwem i jego zasobami. Podniesienie wiedzy przedsiębiorców o ofercie wielkopolskich ośrodków akademickich wspierających procesy zarządzania przedsiębiorstwami przy użyciu systemów informatycznych klasy ERP.” (źródło: <http://www.nauka-biznes.com/>, z dnia: 11.03.2019 r.)

2. Era Inżyniera. Rozbudowa potencjału rozwojowego Politechniki Poznańskiej – „Opracowanie programów i materiałów dydaktycznych oraz wdrożenie programów kształcenia z wykorzystaniem metod i technik kształcenia na odległość”, charakter udziału: wykonawca.

Projekt Era Inżyniera realizowano na Politechnice Poznańskiej w latach 2008-2012 z dofinansowaniem ze strony Europejskiego Funduszu Społecznego Unii Europejskiej. Głównym celem przedsięwzięcia było dostosowanie kształcenia na poziomie wyższym do potrzeb gospodarki, a przede wszystkim rynku pracy oraz poprawa jakości edukacyjnej Politechniki Poznańskiej.

Opracowanie materiałów dydaktycznych i implementacji kursów w formie e-learningu:

- Modelowanie elementów przestrzennych w systemach Rapid Prototyping
- Projektowanie kompleksowych rozwiązań w systemach Rapid Prototyping

### 5.7.2 Prowadzone zajęcia

Od roku akademickiego 2008/2009, jako doktorantka zaczęłam prowadzić zajęcia na studiach stacjonarnych pierwszego stopnia na kierunku Automatyka i Robotyka (wcześniej: Automatyka i Zarządzanie), na Wydziale Informatyki i Zarządzania (obecnie Wydział Informatyki). W późniejszych latach, zatrudniona już na stanowisku asystenta, a po uzyskaniu stopnia doktora na stanowisku adiunkta, kontynuowałam prowadzenie zajęć również na studiach drugiego stopnia oraz na studiach niestacjonarnych. Wśród prowadzonych przeze mnie zajęć były następujące przedmioty:

- studia stacjonarne I stopnia:
  - logika, później nazwa przedmiotu zmieniona na: matematyka dyskretna; początkowo ćwiczenia, później również wykład
  - rachunek operatorowy, później nazwa przedmiotu zmieniona na: równania różniczkowe i rachunek operatorowy; ćwiczenia i pojedyncze wykłady
- studia stacjonarne II stopnia, specjalności: Reprogramowalne systemy sterowania i Mikrokomputerowe systemy sterowania:
  - sztuczne sieci neuronowe i sterowanie neurorozmyte; laboratoria/projekt
- studia niestacjonarne I stopnia:
  - logika, później nazwa przedmiotu zmieniona na: matematyka dyskretna; początkowo ćwiczenia, później również wykład
  - rachunek operatorowy, później nazwa przedmiotu zmieniona na: równania różniczkowe i rachunek operatorowy; ćwiczenia i wykłady

- 
- studia niestacjonarne II stopnia, specjalność: Wbudowane systemy sterowania:
    - sztuczne sieci neuronowe i sterowanie neurorozmyte; laboratoria

### 5.7.3 Uzyskane nagrody za działalność dydaktyczną

- Nagroda JM Rektora Politechniki Poznańskiej za szczególne osiągnięcia dydaktyczne – wydanie podręcznika w wydawnictwie PWN:  
**Aleksandra Świetlicka**, Andrzej Rybarczyk, Agata Jurkowlaniec  
*Rachunek Operatorowy, Metody rozwiązywania zadań*, PWN, 2012, ISBN 978-83-01169-76-3.  
**punktacja MNiSW: 25**
- Nagroda JM Rektora Politechniki Poznańskiej za wyróżniające się prowadzenie zajęć na pierwszym roku studiów stacjonarnych na kierunku Automatyka i Robotyka, rok akademicki 2017/2018, 2016/2017, 2013/2014, 2012/2013.

### 5.7.4 Inne osiągnięcia dydaktyczne

- Wydanie podręcznika:  
**Aleksandra Świetlicka**, Andrzej Rybarczyk, Agata Jurkowlaniec,  
*Rachunek Operatorowy, Metody rozwiązywania zadań*, PWN, 2012, ISBN 978-83-01169-76-3.  
**Punktacja MNiSW: 25**
- Członkostwo w komisji rekrutacyjnej dla kierunku Automatyka i Zarządzanie w roku akademickim 2010/2011.
- Członkostwo w Komisji ds. Jakości Kształcenia dla kierunku Automatyka i Robotyka, od 2017 roku.