

Dr inż. Andrzej Rusiecki

Katedra Informatyki Technicznej  
Wydział Elektroniki, Politechnika Wrocławska

## AUTOREFERAT

przedstawiający opis dorobku i osiągnięć naukowych,  
w szczególności osiągnięcia, o którym mowa w art. 16 ust. 2 ustawy o stopniach naukowych  
i tytule naukowym oraz o stopniach i tytule w zakresie sztuki

Wrocław, kwiecień 2019

## Spis treści

1. Imię i nazwisko .....	2
2. Posiadane dyplomy, stopnie naukowe.....	2
3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych.....	2
4. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. 2017 r. poz. 1789): .	2
4.1 Tytuł osiągnięcia naukowego .....	2
4.2 Publikacje wchodzące w skład osiągnięcia naukowego .....	3
4.3 Omówienie celu naukowego ww. prac i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania.....	5
Syntetyczny spis zawartości poszczególnych prac .....	5
Wprowadzenie .....	6
Motywacja podjęcia badań .....	7
Uczenie sieci neuronowych w obecności zakłóceń .....	7
Iteracyjny algorytm najmniejszej mediany kwadratów .....	8
Algorytm najmniejszych przycinanych wartości bezwzględnych .....	9
Odporna na błędy sieć neuronowa jako metoda detekcji anomalii w strumieniach danych .....	11
Algorytmy hybrydowe poprawiające efektywność uczenia sieci poprzez redukcję szumów w danych .....	12
Przycinana entropia krzyżowa.....	14
Syntetyczne podsumowanie najważniejszych osiągnięć.....	15
Możliwości wykorzystania wyników badań.....	16
5. Omówienie pozostałych osiągnięć naukowo - badawczych.....	16
5.1 Badania nie związane z cyklem publikacji .....	16
Symulacja ruchu w aglomeracji miejskiej.....	16
Teoretyczne aspekty uczenia sieci neuronowych .....	18
Zastosowania sieci neuronowych.....	19
Odporne algorytmy uczenia sieci .....	19
Przetwarzanie obrazów .....	20
5.2 Dane bibliometryczne.....	21
5.3 Wykonane recenzje .....	21
5.4 Dorobek dydaktyczny .....	21
5.6 Opieka nad doktorantami.....	22
5.5 Działalność organizacyjna.....	22
5.6 Uczestnictwo w projektach .....	22
Bibliografia.....	23

## 1. Imię i nazwisko

Andrzej Rusiecki

## 2. Posiadane dyplomy, stopnie naukowe

- Doktor nauk technicznych, dyscyplina Informatyka, Wydział Elektroniki, Politechnika Wrocławska, 2007 r.

Tytuł rozprawy doktorskiej: *Algorytmy uczenia sieci neuronowych odporne na błędy w danych* (rozprawa obroniona z wyróżnieniem, dodatkowo nagroda Rektora Politechniki Wrocławskiej za wyróżnioną rozprawę doktorską)

Promotor: Prof. dr hab. inż. Ewa Skubalska-Rafajłowicz

Recenzenci: Prof. dr hab. inż. Marek Kurzyński

Prof. dr hab. inż. Leszek Rutkowski

- Magister inżynier, kierunek: Elektronika i Telekomunikacja, Wydział Elektroniki, Politechnika Wrocławska, 2003 r., promotor: Prof. dr hab. inż. Ewaryst Rafajłowicz

## 3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych

- 2014 – obecnie: adiunkt naukowo – dydaktyczny, Katedra Informatyki Technicznej, Politechnika Wrocławska
- 2011 – 2014 r.: adiunkt naukowo – dydaktyczny, Instytut Informatyki, Automatyki i Robotyki, Politechnika Wrocławska
- 2007 – 2011r. – asystent naukowo-dydaktyczny, Instytut Informatyki, Automatyki i Robotyki, Politechnika Wrocławska

4. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. 2017 r. poz. 1789):

### 4.1 Tytuł osiągnięcia naukowego

**Metody redukcji wpływu zakłóceń na efektywność uczenia sztucznych sieci neuronowych**

## 4.2 Publikacje wchodzące w skład osiągnięcia naukowego

Przedłożone przez habilitanta osiągnięcia obejmuje cykl powiązanych tematycznie publikacji pod zbiorczym tytułem: **Metody redukcji wpływu zakłóceń na efektywność uczenia sztucznych sieci neuronowych.**

Przedstawiony do oceny cykl publikacji składa się z ośmiu prac, w tym czterech artykułów z listy JCR, oraz czterech prac z konferencji indeksowanych w Web of Science.

*Wyjaśnienie: krótka przerwa w ciągłości chronologicznej publikacji wynika z problemów zdrowotnych habilitanta w roku 2017.*

**A1. Andrzej Rusiecki (100%):** Robust learning algorithm based on iterative least median of squares, Neural Processing Letters. 2012, vol. 36, nr 2, s. 145-160, ISSN: 1370-4621, <http://dx.doi.org/10.1007/s11063-012-9227-z>, Punktacja MNiSW: 20; IF: 01.240

Mój wkład w powstanie tej pracy polegał na pomyśle, wykonaniu całości prac i napisaniu artykułu. Mój udział procentowy szacuję na 100%.

**A2. Andrzej Rusiecki (100%):** Robust neural network for novelty detection on data streams, W: Artificial intelligence and soft computing : 11th International Conference, ICAISC 2012, Zakopane, Poland, April 29 - May 3, 2012 : proceedings. Pt. 1 / Leszek Rutkowski [i in.] (eds.). Berlin ; New York : Springer, 2012. s. 178-186, ISBN: 978-3-642-29346-7, (Lecture Notes in Computer Science. Lecture Notes in Artificial Intelligence, ISSN 0302-9743; vol. 7267), [http://dx.doi.org/10.1007/978-3-642-29347-4\\_21](http://dx.doi.org/10.1007/978-3-642-29347-4_21), Web of Science: 13

Mój wkład w powstanie tej pracy polegał na pomyśle, wykonaniu całości prac i napisaniu artykułu. Mój udział procentowy szacuję na 100%.

**A3. Andrzej Rusiecki (100%):** Robust learning algorithm based on LTA estimator, Neurocomputing. 2013, vol. 120, s. 624-632, ISSN: 0925-2312, <http://dx.doi.org/10.1016/j.neucom.2013.04.008>, Punktacja MNiSW: 30, IF: 02.005

Mój wkład w powstanie tej pracy polegał na pomyśle, wykonaniu całości prac i napisaniu artykułu. Mój udział procentowy szacuję na 100%.

**A4. Mirosław Kordos, Andrzej Rusiecki (50%):** Improving MLP neural network performance by noise reduction, W: Theory and practice of natural computing : second international conference, TPNC 2013, Cáceres, Spain, December 3-5, 2013 : proceedings / Adrian-Horia Dediu [i in.] (eds.). Berlin ; Heidelberg : Springer, cop. 2013. s. 133-144, ISBN: 978-3-642-45007-5, Lecture Notes in Computer Science, ISSN 0302-9743; vol. 8273, [http://link.springer.com/chapter/10.1007/978-3-642-45008-2\\_11](http://link.springer.com/chapter/10.1007/978-3-642-45008-2_11), Web of Science: 15

Mój wkład polegał na wspólnym ze współautorem zaproponowaniu tematu, stworzeniu koncepcji i programu pracy, oraz na wspólnej implementacji struktury programu w języku C#, przy czym mój udział programistyczny koncentrował się na

implementacji algorytmów LMLS, MAE, MIF i MedSum, oraz na napisaniu następujących rozdziałów publikacji: 2.1, 2.2, 4.3, oraz przeprowadzeniu eksperymentów przedstawionych w tabeli 1 i wspólnym napisaniu rozdziałów 1 i 5, a także na współudziale w ostatecznej weryfikacji tekstu. Mój udział procentowy szacuję na 50%.

**A5. Andrzej Rusiecki (55%),** Mirosław Kordos, Tomasz Kamiński, Krzysztof Greń: Training neural networks on noisy data, W: Artificial intelligence and soft computing : 13th International Conference, ICAISC 2014, Zakopane, Poland, June 1-5, 2014 : proceedings. Pt. 1 / Leszek Rutkowski [i in.] (eds.). Cham [i in.] : Springer, cop. 2014. s. 131-142, ISBN: 978-3-319-07172-5, Lecture Notes in Computer Science. Lecture Notes in Artificial Intelligence, ISSN 0302-9743; vol. 8467, [http://dx.doi.org/10.1007/978-3-319-07173-2\\_13](http://dx.doi.org/10.1007/978-3-319-07173-2_13), Web of Science: 15

Mój wkład w powstanie tej pracy polegał na wspólnym z M. Kordosem zaproponowaniu tematu pracy, stworzeniu koncepcji i programu pracy, przygotowaniu zbiorów danych, implementacji miar błędu nieczułych na szum w języku C#, napisaniu rozdziałów 2 i 3, 5.1, współudziale w napisaniu rozdziałów 1 i 6, oraz na opracowaniu wyników eksperymentalnych i współudziale w weryfikacji tekstu publikacji. Mój udział procentowy szacuję na 40%.

**A6.** Mirosław Kordos, **Andrzej Rusiecki (25%),** Marcin Blachnik: Noise reduction in regression tasks with distance, instance, attribute and density weighting, W: 2015 IEEE 2nd International Conference on Cybernetics, CYBCONF 2015 [Dokument elektroniczny] : Gdynia, Poland, 24-26 June 2015 / eds. Piotr Jędrzejowicz [i in.]. Piscataway, NJ : IEEE, cop. 2015. s. 73-78, ISBN: 978-1-4799-8322-3, <http://dx.doi.org/10.1109/CYBCConf.2015.7175909>, Web of Science: 15

Mój wkład w powstanie pracy polegał na konstruktywnym udziale w dyskusjach na temat celowości proponowanych rozwiązań, napisaniu rozdziału 1, wspólnym ze współautorami napisaniu rozdziału 7, oraz przeprowadzeniu eksperymentów przedstawionych w tabelach nr 4 i 5. Mój udział procentowy szacuję na 25%.

**A7.** Mirosław Kordos, **Andrzej Rusiecki (50%):** Reducing noise impact on MLP training, Soft Computing. 2016, vol. 20, nr 1, s. 49-65, ISSN: 1432-7643, <http://dx.doi.org/10.1007/s00500-015-1690-9>, Punktacja MNiSW: 25, IF: 02.472

Mój wkład w powstanie pracy polegał na wspólnym ze współautorem zaproponowaniu tematu, stworzeniu koncepcji i programu pracy, oraz na wspólnej implementacji struktury programu w języku C#, przy czym mój udział programistyczny koncentrował się na implementacji algorytmów LTA i ILMeds, oraz na napisaniu następujących rozdziałów publikacji: 2.1, 3.1, 3.2, 3.3, oraz przeprowadzeniu eksperymentów przedstawionych w tabelach 6, 7, 8, 9, 10 i wspólnym napisaniu rozdziałów 1, 2, 6.4 i 7 a także na współudziale w ostatecznej weryfikacji tekstu. Mój udział procentowy szacuję na 50%.

**A8. Andrzej Rusiecki (100%):** Trimmed categorical cross-entropy for deep learning with label noise, *Electronics Letters*. 2019, vol. 55, nr 6, s. 319-320, ISSN: 0013-5194, <http://dx.doi.org/10.1049/el.2018.7980>, Punktacja MNiSW 2016: 25; IF: 01.232 (2017)

Mój wkład w powstanie tej pracy polegał na pomyśle, wykonaniu całości prac i napisaniu artykułu. Mój udział procentowy szacuję na 100%.

Tabela 1: Podsumowanie cyklu publikacji wchodzących w skład osiągnięcia

Publikacja	Udział habilitanta	Web of Science	Impact Factor	Liczba cytowań wg WoS	Punkty MNiSW
A1	100%		1.240	11	20
A2	100%	Tak		2	13
A3	100%		2.005	9	30
A4	50%	Tak		-	15
A5	55%	Tak		8	15
A6	25%	Tak		2	15
A7	50%		2.472	4	25
A8	100%		1.232	-	25

Przy pracach podano punktację MNiSW i Impact Factor z roku publikacji. W przypadku najnowszej pracy podano dane z roku 2017. Zebrane dane dotyczące całego cyklu przedstawiono w Tabeli nr 1.

Oświadczenia współautorów dotyczące ich wkładu w przygotowaniu poszczególnych publikacji załączono do wniosku.

### 4.3 Omówienie celu naukowego ww. prac i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania

#### Syntetyczny spis zawartości poszczególnych prac

**A1:** Algorytm najmniejszej mediany kwadratów (*Iterative Least Median of Squares, ILMedS*) i związane z nim eksperymenty numeryczne na sztucznie zakłóconych danych.

**A2:** Opis metody detekcji anomalii i danych odstających bazującej na odpornej sieci neuronowej.

**A3:** Algorytm najmniejszej przycinanej sumy błędów bezwzględnych (*Least Trimmed Absolute Value, LTA*) i związane z nim eksperymenty numeryczne na sztucznie zakłóconych danych.

**A4:** Połączenie mediany jako funkcji aktywacji neuronów z metodami wykrywania anomalii (*Median Neuron Input Function, MIF; Median and Sum Input Function, MedSum*), oraz opis eksperymentów numerycznych na niezakłóconych danych.

**A5, A7:** Opis eksperymentów numerycznych dotyczących efektywności działania zarówno zaproponowanych wcześniej metod, jak i podejść hybrydowych na sztucznie zakłóconych danych. Za wyjątkiem TFE, obie prace – powstałe w podobnym czasie – analizują te same algorytmy, przy czym bardziej rozbudowane eksperymenty omówiono w **A7**. Mimo to, zdecydowano się włączyć do cyklu również **A5** ze względu na ścisły związek tematyczny, oraz wykorzystanie w testach funkcji analogicznych do **A1** i **A3**.

**A8:** Kryterium przycinanej entropii krzyżowej (*Trimmed Categorical Cross-Entropy*) umożliwiające uczenie na danych z zaszumionymi etykietami.

## Wprowadzenie

Sztuczne sieci neuronowe od kilkadziesiąt już lat pozostają jedną z najpopularniejszych grup metod uczenia maszynowego. Po chwilowym spadku zainteresowania tą tematyką w latach 90. ubiegłego wieku, pojawienie się paradygmatu uczenia głębokiego (*deep learning*) [1, 4] spowodowało gwałtowny wzrost zarówno publikacji opisujących ich teoretyczne własności, jak i – w większym stopniu – możliwości aplikacyjne.

Jako metody oparte na danych (*data-driven*) również sztuczne sieci neuronowe są potencjalnie mocno wrażliwe na ich jakość [2, 3, 8]. W sytuacji, gdy dane takie zawierają szum, błędy grube, czy błędne etykiety, ma to oczywisty wpływ na działanie opartego na nich modelu neuronowego. Biorąc pod uwagę rosnącą popularność stosowanych w codziennym życiu rozwiązań bazujących na sztucznych sieciach neuronowych, uzasadniona wydaje się być konieczność znalezienia metod pozwalających na przezwycięzenie tego problemu.

Głównym celem prac badawczych prowadzonych przez habilitanta było zatem opracowanie i przebadanie metod służących redukcji wpływu szumu w danych uczących na efektywność uczenia sztucznych sieci neuronowych. Wiodący nurt badań dotyczył zaprojektowania algorytmów, które mogą poprawić przebieg procesu uczenia na zbiorach danych nieznannej jakości. Podejścia takie powinny umożliwiać poprawne uczenie sieci neuronowych nawet w przypadku błędów pojawiających się w danych uczących. Problem zaszumionych lub błędnych obrazów uczących dotyczyć może zarówno zadań regresji, jak i klasyfikacji, przy czym w tym pierwszym przypadku możemy mieć zwykle do czynienia z zakłóconymi wartościami modelowanej funkcji, natomiast w przypadku drugim z błędnymi etykietami klas (oczywiście rozważać można ponadto luki w danych, brak części składowych zmiennej zależnej lub niezależnej, czy wreszcie zaszumienie wartości wejściowych).

W efekcie związanych z tymi zagadnieniami prac habilitanta opracowano podejścia takie jak: algorytm iteracyjnej mediany kwadratów (*Iterative Least Median of Squares, ILMedS*) [A1], połączenie mediany jako funkcji aktywacji neuronów z metodami wykrywania anomalii (*Median Neuron Input Function, MIF; Median and Sum Input Function, MedSum*) [A4], algorytm najmniejszej przycinanej sumy błędów bezwzględnych (*Least Trimmed Absolute Value, LTA*)

[A3], oraz przedstawiono i przebadano szereg metod hybrydowych (z algorytmami redukcji danych odstających poprzez wykrywanie anomalii, oraz selekcji przypadków) [A5, A6, A7]. Zaproponowano również kryterium przycinanej entropii krzyżowej (*Trimmed Categorical Cross-Entropy*) [A8] umożliwiające efektywne uczenie sieci głębokich w zadaniach klasyfikacji przy zaszumionych etykietach. Ponadto opracowano metodę detekcji anomalii i danych odstających bazującą na odpornej sieci neuronowej [A2].

## Motywacja podjęcia badań

Badania dotyczące uczenia sztucznych sieci neuronowych przy istnieniu szumu lub zakłóceń w obrazach uczących umiejscawiane są zazwyczaj w literaturze w jednym z dwóch głównych nurtów. Pierwszy z nich to uczenie w obecności danych odstających [2, 3, 7, 8], będących rezultatem ogonów rozkładów statystycznych, błędów pomiarowych, lub też – najczęściej – błędów człowieka, których w naukach opisowych (np. medycyna) może pojawiać się nawet do 10% [5]. Zakłada się tu zwykle, że problem danych odstających dotyczy zadania regresji, gdzie zmienna zależna, a zatem i wyjścia sieci neuronowej, przyjmują ciągłe wartości. Oczywiście, jeśli zakłócone jest również wejście, zagadnienie rozszerzyć można na zadania klasyfikacji. W ich przypadku jednak, częściej rozważany jest problem uczenia na danych o zaszumionych etykietach. Może być on rozumiany, jako przyjmowanie przez część obrazów uczących niewłaściwych etykiet, z puli wszystkich dostępnych.

Należy zauważyć, że obserwowana dzisiaj popularność rozwiązań opartych na głębokich sieciach neuronowych, powiązana jest ściśle z publiczną dostępnością dużych anotowanych kolekcji danych, które umożliwiają uczenie takich struktur. Ich powstanie nie byłoby często możliwe bez – trudnej do weryfikacji jeśli chodzi o poprawność – pracy wielu osób odpowiedzialnych za ustalanie właściwych etykiet [9, 10]. Również ewentualne stosowanie algorytmów eksploracji danych (szczególnie w dziedzinie *web mining*) nie gwarantuje poprawności uzyskanych rezultatów. Widać więc, że opisywany problem ma poważne implikacje dla rzeczywistych zastosowań sieci.

## Uczenie sieci neuronowych w obecności zakłóceń

W najprostszym przypadku wielowarstwowa sieć neuronowa trenowana jest poprzez minimalizację błędu (najczęściej średniokwadratowego), opisującego odległość wyjść sieci od zadanych wartości dla danego wejścia. Naturalną konsekwencją takiego podejścia jest to, że celem procesu uczenia staje się możliwie bliskie odwzorowanie owych zadanych wartości, co powoduje, że wszelkie niedoskonałości zbioru uczącego są odzwierciedlane w budowanym w ten sposób modelu. Oczywiście, stosowanie regularyzacji w postaci standardowych rozwiązań takich, jak podział danych na część uczącą i walidującą, zmniejsza niebezpieczeństwo późniejszego błędnego uogólniania, lecz szczególnie w tym przypadku nie eliminuje go całkowicie. Dlatego właśnie w literaturze znaleźć można rozwiązania starające się rozwiązać ten problem [2, 3, 7, 8]. Większość z nich opiera się, przynajmniej w części, na zmodyfikowaniu funkcji błędu tak, aby ograniczyć wpływ zakłóconych obrazów uczących na proces kształtowania modelu neuronowego.



Inne podejścia wykorzystują często metody selekcji danych (*instance selection*) [12] oparte na kompresji danych lub filtrowaniu szumu. Kompresja rozumiana jest tu jako odrzucanie obserwacji zbyt podobnych do siebie, ale w kontekście uczenia przy błędnych danych dużo większe znaczenie ma filtrowanie szumów, czyli odrzucanie obrazów uczących zbyt odległych od innych, a tym samym podlegających pod definicję danych odstających.

Uczenie na danych z błędnymi etykietami to zagadnienie, w którym znaleźć można liczne podobieństwa do opisanych powyżej metod uczenia w obecności szumu, należy jednak zauważyć, że problemy te nie są tożsame. Podobnie jak w przypadku poprzednim mamy tu do czynienia z dwiema grupami podejść. Oprócz prób skonstruowania metod umożliwiających uczenie bezpośrednio na podstawie zakłóconych etykiet [6], wykorzystuje się algorytmy czyszczenia danych poprzez usuwanie lub poprawianie niepewnych obrazów uczących [13].

W dalszej części autoreferatu przedstawiono w syntetycznej formie rezultaty prac habilitanta związanych z omówionym pokrótce zagadnieniem uczenia sieci neuronowych na danych zawierających szum.

## Iteracyjny algorytm najmniejszej mediany kwadratów

Jak już wspomniano, uczenie polegające na minimalizacji błędu średniokwadratowego jest rozwiązaniem bezpiecznym jedynie w sytuacji, gdy dane uczące zakłócone są co najwyżej białym szumem. Niestety, w sytuacjach, kiedy rozkład błędów przyjmuje bardziej złożoną postać (np. pojawiają się błędy grube) takie podejście nie zdaje egzaminu. Jednym z rozwiązań opracowanych przez habilitanta jest iteracyjny algorytm najmniejszej mediany kwadratów (*Iterative Least Median of Squares, ILMedS*) [A1]. Stanowi on rozwinięcie metody ze zmodyfikowaną funkcją kryterialną poprzez faktyczne połączenie jej z metodą selekcji przypadków polegającą na filtrowaniu danych w kolejnych iteracjach algorytmu.

Jako inspiracja do opracowania funkcji błędu posłużył znany ze statystyki estymator najmniejszej mediany kwadratów [11]. Zastosowanie funkcji kryterialnej opartej na nim jest rozwiązaniem mającym uzasadnienie statystyczne, gdyż teoretyczny punkt załamania (*breakdown point*), czyli część danych obarczona zakłóceniami tolerowana przez estymator LMedS wynosi  $\varepsilon = 0.5$ . Punkt załamania estymatora to inaczej najmniejszy procentowy udział zakłóconych obserwacji wśród wszystkich danych, który powoduje, że estymator zaczyna przyjmować niewłaściwe wartości. Dla metody najmniejszych kwadratów punkt załamania to  $\varepsilon = 0$ , podobnie jak dla innych M-estymatorów, czy najmniejszych wartości bezwzględnych (normy L1). Najmniejsza mediana kwadratów z teoretycznym punktem załamania na poziomie 0.5 jest zatem interesującą alternatywą, choć oczywistą wadą wydaje się być słaba efektywność tego estymatora (zbieżność  $n^{-1/3}$ ).

Bezpośrednie przełożenie omawianej metody na grunt uczenia sieci neuronowych nie jest oczywiście możliwe, można natomiast zdefiniować funkcję kryterialną bazującą na najmniejszej medianie kwadratów [A1]:

$$E_{MedS} = \text{med}(r_i)^2, \quad (1)$$

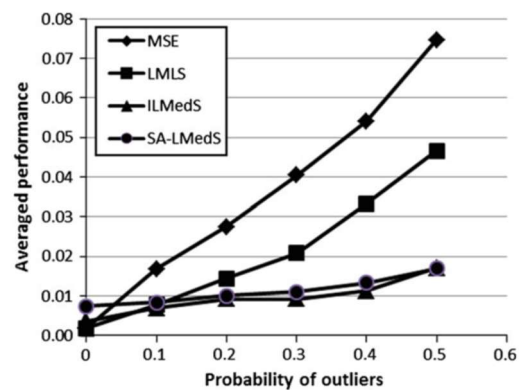
gdzie  $r_i$  to residua na wyjściu sieci, dane jako:

$$r_i = \sum_{k=1}^m |y_{ik} - t_{ik}|, \quad (2)$$

przy założeniu, że  $y_{ik}$  i  $t_{ik}$  to odpowiednio wartość  $k$ -tej składowej wyjścia dla  $i$ -tego obrazu uczącego, oraz zadana wartość (*target*)  $k$ -tej składowej wyjścia, dla  $m$ -wymiarowego wyjścia sieci.

Biorąc pod uwagę fakt, że w standardowym podejściu algorytmy uczenia sieci neuronowych bazują na optymalizacji gradientowej, a mediana wprowadza do modelu nieróżniczkowalność, oczywistym problemem wydaje się być minimalizacja tak zdefiniowanej funkcji błędu. Można w tej sytuacji próbować zastosować np. heurystyczne algorytmy optymalizacji globalnej (algorytmy genetyczne, symulowane wyżarzanie [8]), co może się jednak przekładać na znaczące zwiększenie nakładu obliczeniowego bez gwarancji osiągnięcia pożądanego rezultatu (optymalizujemy globalnie, a nie lokalnie na danych uczących, podczas gdy celem jest dopasowanie globalne do nieznanymi danych testowych). Eksperymenty numeryczne wykazują, że oprócz konieczności ustalenia hiperparametrów właściwych dla wybranej metody optymalizacji, problemy generuje również słaba efektywność estymatora przekładająca się na duży rozrzut rezultatów również dla opartej na nim funkcji błędów, co pociąga za sobą konieczność douczania sieci algorytmem standardowym.

Opracowane w ramach prac badawczych habilitanta podejście rozwiązuje te problemy umożliwiając uczenie algorytmem gradientowym bez konieczności douczania sieci algorytmem optymalizującym klasyczną funkcję błędu średniokwadratowego. Zaproponowany algorytm wykorzystuje metodę RBP (*Resilient Backpropagation*) do minimalizacji funkcji błędu medianowego, przyjmując jednak jako wartość zastępczą gradient dla funkcji kwadratowej. Należy więc zauważyć, że minimalizacja funkcji błędu odbywa się w kierunku, który jedynie aproksymuje jej gradient. Ten sposób optymalizacji stanowi podstawę właściwego algorytmu, w którym iteracyjnie optymalizowana jest funkcja błędu, następnie na jej podstawie odrzucane są obserwacje uznane za błędne i ponownie przeprowadzany jest proces minimalizacji błędu medianowego na zredukowanym zbiorze danych. Dzięki temu unika się pułapki związanej ze słabą zbieżnością zmodyfikowanej funkcji błędu, jak i niedokładności związanych z aproksymowaniem gradientu. Jak pokazały eksperymenty symulacyjne, metoda ta umożliwia skuteczne uczenie sieci neuronowych na zaszumionych danych (Rysunek nr 1), przy czym pozostaje stosunkowo efektywna również jeśli chodzi o czas obliczeń.



Rysunek 1: Przykładowy uśredniony błąd dla różnych metod uczenia sieci w zależności od poziomu szumu [A1]. Widać znaczne różnice, zwłaszcza w porównaniu z metodą klasyczną (MSE).

## Algorytm najmniejszych przycinanych wartości bezwzględnych

Ten, opracowany przez habilitanta, algorytm również po części czerpie inspiracje z metod statystycznych, wykorzystując pomysł estymatora najmniejszych przycinanych wartości bezwzględnych LTA (*Least Trimmed Absolute Values*) [A3]. Dla LTA punkt załamania

nie jest stałą wartością, gdyż zależy od przyjętego odpowiedniego sparametryzowania sposobu wyliczania wartości estymatora. Niemniej jednak, jego graniczna, możliwa teoretycznie do uzyskania wielkość to również, podobnie jak dla LMedS,  $\epsilon = 0.5$ . Sam estymator definiuje się jako:

$$\hat{\theta} = \arg \min_{\theta \in \mathbb{R}^p} \sum_{i=1}^h (|r|)_{i:n}, \quad (3)$$

gdzie  $(|r|)_{1:n} \leq \dots \leq (|r|)_{n:n}$  oznacza posortowane niemalejąco wartości bezwzględne residuów. Widać więc, że stała przycinania  $h$  jest parametrem decydującym o potencjalnym punkcie załamania: gdy bliska jest 50%, również  $\epsilon$  zbliża się do 0.5, natomiast gdy dąży do 100%, punkt załamania maleje do 0. Opierając się na estymatorze LTA, sformułować można więc definicję funkcji błędu przystosowaną do uczenia sieci neuronowych.

Dla algorytmu najmniejszych przycinanych wartości bezwzględnych zdefiniowano funkcję błędu daną jako:

$$E_{LTA} = \sum_{i=1}^h (|r|)_{i:n}, \quad (4)$$

przy czym posortowane niemalejąco residua  $(|r|)_{1:n} \leq \dots \leq (|r|)_{n:n}$  dotyczą teraz błędów na wyjściu sieci i mogą być wyrażone wzorem (2). Jak można zauważyć, w porównaniu z klasycznym kryterium zmiana uległa nie tylko operacja wykonywana na pojedynczych błędach (moduł zamiast kwadratu), ale przede wszystkim sumę zastąpiła suma przycinana. W rezultacie, funkcja kryterialna po każdej aktualizacji wag zależy może bezpośrednio od innych obrazów uczących, gdyż pewna część z nich, zależna od parametru  $h$ , odrzucana jest w trakcie sumowania.


Dla tak dobranej funkcji kryterialnej znów problemem może być jej nieróżniczkowalność. W pracy [A3] wskazano zatem możliwość optymalizacji jej metodami gradientowymi. Warto zauważyć, że odpowiedni dobór stałej przycinania odpowiada nie tylko za liczbę odrzucanych w każdym kroku, potencjalnie błędnych, danych, ale również za rozrzut wyników będący konsekwencją zbieżności estymatora, który posłużył za inspirację do zdefiniowania funkcji celu. W związku z tym zaproponowano automatyczny sposób ustalania stałej  $h$ , polegający na uzależnieniu jej od aktualnej wartości mediany bezwzględnych odchyłek od mediany MAD (*median of all absolute deviations from the median*). Parametr przycinania aktualizowany jest więc w procesie uczenia i dopasowywany do aktualnego rozrzutu błędów.

W pracy [A3] zaprezentowano wyniki badań eksperymentalnych na kilku zbiorach danych przy różnym stopniu sztucznego zaszumienia porównując działanie zaproponowanej metody z innymi algorytmami. Przeprowadzono również odpowiednie testy statystyczne, które potwierdziły jej lepszą efektywność.

Algorytm LTA może być również wykorzystany jako część składowa podejść hybrydowych, wykorzystujących metody selekcji danych [A5, A6, A7]. Okazuje się być metodą, która poprawia efektywność uczenia przy istniejących zakłóceniach nie tylko w zadaniach regresji, ale i klasyfikacji.

## Odporna na błędy sieć neuronowa jako metoda detekcji anomalii w strumieniach danych

Na marginesie badań mających na celu poprawę efektywności uczenia sieci neuronowych przy zaszumieniu danych uczących, została przez habilitanta opracowana prosta metoda detekcji anomalii w danych mających postać strumieniową [A2]. W algorytmie tym wykorzystywane są dwie sieci autoasocjacyjne, zwane inaczej autoenkoderami. Zadaniem autoenkodera jest odtworzenie na wyjściu wartości wejściowej, przy czym, ze względu na strukturę takiej sieci, przekształcenie ma nieliniowy charakter i nie powinno uwzględniać otrzymania na wyjściu niezmiennego sygnału wejściowego (przy lekko zaszumionym wejściu, wyjście nie powinno się zmieniać).



*Rysunek 2: Przykładowa detekcja anomalii w szeregu czasowym metodą odpornej sieci neuronowej [A2]. Górny przebieg przedstawia analizowany szereg, przebieg dolny ilustruje punkty wykrycia anomalii.*

W przypadku analizy danych strumieniowych, istotnym jest uwzględnienie zjawiska tzw. *concept drift*, czyli stopniowej zmiany właściwości statystycznych modelowanych zmiennych w czasie, zatem zastosowanie pojedynczej sieci autoasocjacyjnej i wykrywanie anomalii na podstawie jej zdolności rekonstrukcji nie wydaje się być dobrym rozwiązaniem.

Pomysł polega więc na użyciu dwóch autoenkoderów, z których jeden uczony jest w sposób klasyczny, natomiast wagi drugiego dobierane są tak, aby ograniczyć wpływ błędnych danych, bazując na metodzie LMLS (*Least Mean Log Squares*) [7]. Dzięki temu sposób rekonstrukcji obrazów mocno różniących się od większości, będzie dla tych dwóch sieci różny, co może pozwolić na detekcję nietypowych elementów.

Jako, że dane napływają w sposób ciągły, rozmiar zbioru uczącego zależy od długości okna przesuwanego po strumieniu danych, przy czym po zaakumulowaniu odpowiedniej liczby obrazów uczących, następuje douczenie sieci, a następnie obliczenia ich odpowiedzi dla kolejno napływających próbek. Okna czasowe nie nachodzą na siebie, choć ewentualnie może dzielić je pewien ustalony interwał. Na podstawie progowanej, w oparciu o aktualną

wariancję, różnicy sygnałów wyjściowych obu autoenkoderów, następuje detekcja nowości w strumieniu danych. Przykład takiej detekcji przedstawiono na Rysunku nr 2. Algorytm ten może być również pomocny w wykrywaniu danych odstających w przypadku klasycznego zbioru uczącego.

## Algorytmy hybrydowe poprawiające efektywność uczenia sieci poprzez redukcję szumów w danych

Omówione powyżej metody stanowiły podstawę do przeprowadzenia eksperymentów dotyczących możliwości hybrydyzacji algorytmów zmniejszających wpływ szumu na efektywność uczenia sieci. Oczywistym rozwiązaniem wydaje się być połączenie podejść polegających na wykrywaniu anomalii i selekcji przypadków (a więc *de facto* redukcji danych uczących) z podejściami, w których modyfikowane są parametry sieci neuronowej lub jej algorytm uczenia. Należy zwrócić uwagę, że LTA lub ILMedS zostały zaprojektowane do uczenia w zadaniach, gdzie zmienna wyjściowa jest typu ciągłego (regresja), więc – choć mogą być użyte w zadaniach klasyfikacji – niekoniecznie należy się spodziewać polepszenia zdolności uogólniania sieci przy zastosowaniu tych rozwiązań. W pracach [A5, A6, A7] przedstawiono możliwość połączenia metod takich jak ENN (*Edited Nearest Neighbor*), k-NN GAS (*Global Anomaly Score*) z algorytmami LTA i ILMedS, oraz przebadano wpływ modyfikacji funkcji wejściowej neuronu (mediana i ważona suma sumy i mediany) [A4] na zdolność uogólniania na wielu zestawach danych z zakresu zarówno regresji, jak i klasyfikacji, do której metody selekcji danych są zwykle przeznaczane.

Neurony o medianie jako funkcji wejściowej neuronu, zostały zaproponowane w ramach wcześniejszych prac habilitanta. Motywacją była tu potencjalnie większa odporność takich struktur na uszkodzenia. Wyjście neuronu typu MIF (*Median Neuron Input Function*) jest dane jako:

$$y_{MIF} = f(\text{med}\{w_i x_i\}_{i=1}^N), \quad (5)$$

gdzie  $f()$  oznacza funkcję aktywacji, natomiast  $w_i$  i  $x_i$  kolejno wagi i składowej wejścia neuronu. Jak można zauważyć, tak zdefiniowana funkcja wejścia, potencjalnie zwiększa zdolność uogólniania sieci neuronowej, gdyż jej działanie można w pewnym stopniu porównać do regularyzacji typu *dropout*, polegającej na wyłączaniu części wag sieci w trakcie uczenia. W pracy [A4] zaproponowano dodatkowo funkcję wejściową będącą złożeniem sumy i mediany, daną jako:


$$y_{MedSum} = f(\delta \text{med}\{w_i x_i\}_{i=1}^N + (1 - \delta) \sum_{i=1}^N w_i x_i), \quad (6)$$

gdzie parametr  $\delta$  decyduje o wpływie mediany na wejście sieci.

Sieci o neuronach typu  $y_{MedSum}$ , oraz  $y_{MIF}$  zostały wraz z innymi rozwiązaniami przebadane na kilku rzeczywistych zbiorach niezakończonych danych, zarówno w zadaniach regresji, jak i klasyfikacji. Oprócz tych rozwiązań wykorzystano dwie zmodyfikowane funkcje kryterialne, oraz metody selekcji przypadków. W związku z tym, że eksperymenty przeprowadzono na zbiorach rzeczywistych, trudno powiedzieć, czy zawierały one szum – jedyną sensowną miarą

oceny było więc przeprowadzenie wielokrotnej krosvalidacji. Jak się okazało, najbardziej zaskakującym rezultatem symulacji był fakt, że uczenie polegające na minimalizacji błędu średniokwadratowego nie okazało się nigdy najlepszą metodą, natomiast w zadaniach regresji zdecydowanie najefektywniejsza okazała się hybryda MIF i k-NN GAS.

Dalsze badania algorytmów hybrydowych przedstawione w pracach [A5, A6, A7] dotyczyły już możliwości ich działania na danych sztucznie zakłóconych. Pod uwagę zostały wzięte zarówno algorytmy ILMedS i LTA, a z grupy metod selekcyjnych ENN i GAS, jak również możliwe ich kombinacje (ENN-LTA, GAS-LTA, etc.). Dodatkowo przebadano połączenie ich z metodami ważenia (atrybutów, odległości i przypadków). Studium eksperymentalne dotyczące analizy efektywności zaproponowanych podejść opierało się na testowaniu ich na wielu benchmarkach odpowiadających zarówno zadaniom klasyfikacji, jak i regresji. Szum w danych modelowany był m. in. poprzez zakłócanie wartości wejściowych lub wyjściowych obrazów uczących losowymi zakłóceniami o różnym charakterze.



*Rysunek 3: Przykładowa uśredniona dokładność klasyfikacji w zależności od poziomu i rodzaju szumu [A7]. Szczegóły i omówienie dostępne w pracy [A7].*

Nie opisując szczegółowo uzyskanych rezultatów (przykłady na Rysunku nr 3), należy podkreślić kilka najbardziej ogólnych wniosków. Po pierwsze, jak się okazuje, nawet jeśli dane uczące nie zawierają błędów, zastosowanie udoskonalonych algorytmów uczenia, posiadających różne mechanizmy niwelujące wpływ szumu, zwiększa zdolność uogólniania sieci mierzoną – w zależności od zadania – błędem lub dokładnością klasyfikacji na danych testowych. Ponadto, gdy w danych pojawiają się zakłócenia, większość z tych metod działa zdecydowanie efektywniej od klasycznego podejścia. Trudno jest oczywiście zaproponować podejście uniwersalne, które pozwala na uzyskanie najlepszych rezultatów w każdych warunkach, można natomiast wskazać, że algorytm LTA i jego hybrydowe wersje w połączeniu z ENN, lub GAS wydają się zapewniać pożądane stabilne wyniki, również w zadaniach klasyfikacji, podczas gdy metoda ILMedS nie jest do końca wiarygodna w przypadku tych ostatnich (również z powodu większego rozrzutu), natomiast można ją polecić do zadań, gdzie wyjście przyjmuje ciągłe wartości.

## Przycinana entropia krzyżowa

O ile w klasycznym podejściu, podczas uczenia nadzorowanego sieci neuronowych, wykorzystuje się miary takie jak błąd średniokwadratowy, to – szczególnie w kontekście uczenia mającego na celu zbudowanie modelu klasyfikującego – potrzebne są inne rozwiązania. Wraz z rozwojem sieci głębokich (*deep learning*), bardzo popularną miarą stała się, znana oczywiście dużo wcześniej, entropia krzyżowa CCE (*categorical cross-entropy*). Przy założeniu  $N$ -elementowego zbioru uczącego, w którym na podstawie  $\gamma$ -wymiarowego wejścia chcemy dokonać przyporządkowania obrazu do jednej z  $C$  klas, błąd kategorycznej entropii krzyżowej zdefiniować można następująco:

$$E_{CCE} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C (p_{ic} \log(y_{ic})), \quad (7)$$

gdzie  $p_{ic}$  przyjmuje binarne wartości wskazujące, czy  $i$ -ty obraz uczący należy do klasy  $c$ . W takim ujęciu  $p_{ic}$  może być rozważane jako prawdziwy, natomiast wyjście  $y_{ic}$  jako przewidywany przez sieć rozkład prawdopodobieństwa przynależności  $i$ -tej obserwacji do klasy  $c$ .

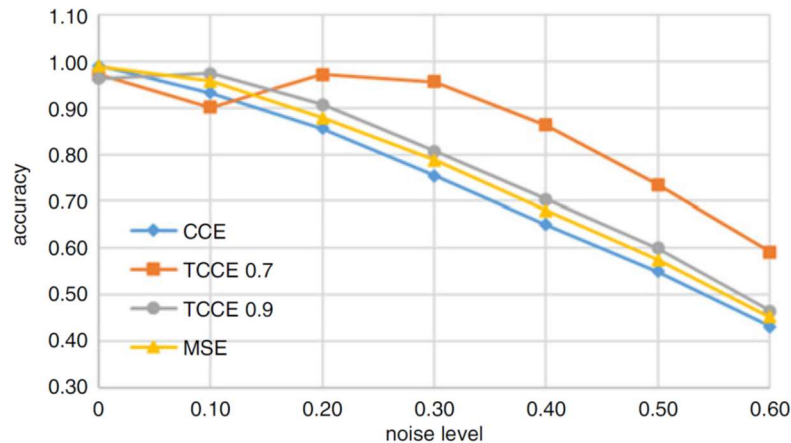
Niestety, nie jest to miara zapewniająca prawidłowe działanie algorytmu uczącego, gdy etykiety danych obarczone są szumem, rozumianym jako nieprawidłowe ich wartości. Badania habilitanta przyniosły propozycję nowej miary, opartej na CCE, nazwanej *Trimmed Categorical Cross-Entropy* (TCCE) [A8], której zadaniem jest utrzymanie efektywności uczenia nawet w przypadku danych z zamienionymi etykietami. Definiowana jest ona jako:

$$E_{TCCE} = -\frac{1}{h} \sum_{i=1}^h q_{i:N}, \quad (8)$$

gdzie  $q_{1:N} \leq \dots \leq q_{N:N}$  oznaczają posortowane niemalejąco błędy dla poszczególnych obserwacji obliczane jako:

$$q_i = \sum_{c=1}^C (p_{ic} \log(y_{ic})). \quad (9)$$

Podobnie jak w przypadku przedstawionego wcześniej algorytmu LTA, pojawia się tu parametr  $h$ , stała przycinania, odpowiadający za odrzucanie przy poszczególnych ewaluacjach funkcji błędu, składowych pochodzących od niektórych obrazów uczących. Dzięki temu możliwe jest poprawne budowanie modelu neuronowego nawet jeśli część danych uczących opisana jest błędnymi etykietami.



Rysunek 4: Przykładowe uśredniona dokładność klasyfikacji w zależności od części zaszumionych etykiet dla różnych parametrów algorytmu TCCE [A8]

Przedstawione w pracy [A8] wyniki wstępnych eksperymentów symulacyjnych (Rysunek nr 4) pokazały, że właściwie sparametryzowana metoda TCCE rzeczywiście pozwala na utrzymanie skuteczności klasyfikacji na poziomie nieosiągalnym dla sieci uczonych z CCE na danych z błędnymi etykietami. Co ciekawe, okazało się również, że w przypadku niestosowania regularyzacji typu *dropout*, bardziej skuteczny od niej okazuje się nawet zwykły błąd średniokwadratowy.

## Syntetyczne podsumowanie najważniejszych osiągnięć

Przedstawione w powyższym opisie najważniejsze osiągnięcia habilitanta można krótko podsumować jako:

- Opracowanie algorytmu iteracyjnej mediany kwadratów (*Iterative Least Median of Squares, ILMedS*),
- Opracowanie algorytmu najmniejszej przycinanej sumy błędów bezwzględnych (*Least Trimmed Absolute Value, LTA*),
- Zaproponowanie połączenie mediany jako funkcji aktywacji neuronów z metodami wykrywania anomalii (*Median Neuron Input Function, MIF; Median and Sum Input Function, MedSum*),
- Opracowanie metody detekcji anomalii i danych odstających bazującej na odpornej sieci neuronowej,
- Zaproponowanie kryterium przycinanej entropii krzyżowej (*Trimmed Categorical Cross-Entropy*)
- Przedstawienie i przebadanie szeregu metod hybrydowych łączących zaproponowane podejścia z algorytmami redukcji danych odstających poprzez wykrywanie anomalii, oraz selekcję przypadków.



## Możliwości wykorzystania wyników badań

Praca badawcze prowadzone przez habilitanta przyczyniły się do opracowania szeregu metod mogących mieć bezpośrednie zastosowanie do poprawy jakości uczenia sztucznych sieci neuronowych, w tym struktur głębokich, gdy dane uczące są nieznannej lub wątpliwej jakości. Jak już wspomniano, sytuacja taka jest typowa dla dużych korpusów ręcznie anotowanych danych [9], wykorzystywanych zwykle do uczenia współczesnych architektur sieci neuronowych. Również, gdy do generowania danych uczących wykorzystuje się różnego rodzaju algorytmy typu *web search*, nie ma pewności odnośnie właściwie przyporządkowanych etykiet. Biorąc pod uwagę mnogość zastosowań, szczególnie w kontekście sieci głębokich, możliwości wykorzystania wyników badań jest potencjalnie dużo i wynikają one bezpośrednio z możliwości zastosowań samych sieci. Wymieniając jedynie niewielką część z nich, warto wspomnieć przede wszystkim o rozpoznawaniu i klasyfikacji obrazów (np. w systemach bezpieczeństwa, pojazdach autonomicznych, systemach identyfikacji użytkowników i obiektów), rozpoznawaniu mowy, czy szeroko pojętym przetwarzaniu języka naturalnego.

Jak pokazują wyniki eksperymentów, nawet dla danych rzeczywistych, dla których nie istnieją przesłanki wskazujące na występowanie w nich zakłóceń, sieci uczone algorytmami umożliwiającymi redukcję wpływu zakłóceń na efektywność uczenia, osiągają lepsze rezultaty mierzone zdolnością uogólniania, a więc mniejszym błędem lub większą dokładnością klasyfikacji dla danych testowych.

## 5. Omówienie pozostałych osiągnięć naukowo - badawczych

### 5.1 Badania nie związane z cyklem publikacji

Pozostałe wątki badawcze pojawiające się w publikacjach habilitanta podzielić można na kilka nachodzących na siebie zakresów. Pierwszy z nich to zagadnienia realizowane w ramach szerszego zespołu, a związane z symulacją ruchu w aglomeracji miejskiej. Drugi z obszarów zainteresowań to teoretyczne aspekty uczenia głębokich i klasycznych sieci neuronowych. Kolejny z obszarów badawczych dotyczy możliwości zastosowań sieci, natomiast najstarsze prace, związane z tematyką rozprawy doktorskiej, poruszają zagadnienia odpornych algorytmów uczenia. Habilitant jest również współredaktorem i współautorem książki dotyczącej cyfrowego przetwarzania obrazów z wykorzystaniem otwarto-źródłowej biblioteki OpenCV. Poniżej przedstawiono syntetyczny opis najważniejszych nurtów badań wraz z przykładowymi publikacjami autorstwa habilitanta powiązanymi z poszczególnymi obszarami zainteresowań.

#### Symulacja ruchu w aglomeracji miejskiej

Badania związane z symulacją ruchu miejskiego prowadzone były w ramach kilkusobowego zespołu we współpracy z Urzędem Miasta Wrocławia. Dzięki pozyskaniu

danych z wrocławskiego inteligentnego systemu transportowego ITS (*intelligent transportation system*), powstały m.in. prace dotyczące przewidywania czasu przejazdu w aglomeracji, optymalizacji tzw. „zielonej fali”, czy metod audytowania systemów typu ITS. Ponadto zaproponowano metodę detekcji pojazdów poruszających się pod prąd, oraz wielowątkową implementacją algorytmu Dijkstry użytego do optymalizacji czasu przejazdu w aglomeracji, szacowanego na podstawie pomiarów prowadzonych przez ITS.

Większość prac związanych z tą tematyką miała charakter nie tylko teoretycznych rozważań mających na celu przedstawienie ogólnych metod, ale – dzięki dostępności rzeczywistych danych – badań dotyczących konkretnego studium przypadku i możliwości zastosowań dla istniejącego systemu ITS. W artykułach dotyczących audytowania systemów ITS pokazano jak może wyglądać schemat takiej procedury przy wykorzystaniu mikrosymulacji ruchu na poszczególnych skrzyżowaniach, oceniając przykładowe nastawy sygnalizacji na wrocławskich ulicach. Wskazano ponadto sposoby oceny umiejscowienia poszczególnych elementów ITS takich jak kamery ARTR (rozpoznające pojazdy i ich numery rejestracyjne), czy kamery mierzące jedynie prędkość i wymiary pojazdów.

Bazując na danych rejestrowanych przez tego typ urządzenia, zaproponowano optymalizację ustawień zielonej fali, takich jak przesunięcia czasowe między kolejnymi skrzyżowaniami, czasy otwarcia dla poszczególnych pasów, czy ograniczenia prędkości, w celu zmniejszenia średniego czasu przejazdu i długości kolejek na skrzyżowaniach. Ponadto zbadano i przeanalizowano możliwości zrównoleżenia obliczeń dla popularnego algorytmu Dijkstry nie tylko dla przykładów sztucznie generowanych grafów, ale i dla rzeczywistej sieci drogowej, co przyniosło dość zaskakujące rezultaty ze względu na różną naturę obu zadań.

- Marek Bazan, Piotr Ciskowski, Krzysztof Halawa, Tomasz Janiczek, Łukasz Madej, **Andrzej Rusiecki**: Green wave optimisation, Archives of Transport System Telematics. 2016, vol. 9, nr 3, s. 3-8, ISSN: 1899-8208  
Punktacja MNiSW: 11
- Marek Bazan, Piotr Ciskowski, Roland Dudek, Krzysztof Halawa, Tomasz Janiczek, Piotr Kozaczewski, **Andrzej Rusiecki**: Multithreaded enhancements of the Dijkstra algorithm for route optimization in urban networks, Archives of Transport System Telematics. 2016, vol. 9, nr 2, s. 3-7, ISSN: 1899-8208  
Punktacja MNiSW: 11
- Marek Bazan, Piotr Ciskowski, Krzysztof Halawa, Tomasz Janiczek, Piotr Kozaczewski, Łukasz Madej, **Andrzej Rusiecki**: Intelligent Transport System auditing using road traffic micro-simulation, Archives of Transport System Telematics. 2015, vol. 8, nr 4, s. 3-8, ISSN: 1899-8208,  
[http://yadda.icm.edu.pl/baztech/element/bwmeta1.element.baztech-64fc0acd-2d61-44a5-bb67-e8ca612f4969?q=d4cb540a-9a83-4a0f-8e1a-f2343a3f92c1&qt=IN\\_PAGE](http://yadda.icm.edu.pl/baztech/element/bwmeta1.element.baztech-64fc0acd-2d61-44a5-bb67-e8ca612f4969?q=d4cb540a-9a83-4a0f-8e1a-f2343a3f92c1&qt=IN_PAGE)  
Punktacja: 11

## Teoretyczne aspekty uczenia sieci neuronowych

Jest to niewątpliwie najszersza grupa zagadnień leżących w obszarze zainteresowań badawczych habilitanta. Nie wliczając badań związanych z omówionym wcześniej cyklem publikacji, oraz wspomnianych dalej badań związanych z realizacją rozprawy doktorskiej, prace dotyczyły m.in. wstępnego nienadzorowanego uczenia głębokich sieci neuronowych, bezgradientowego algorytmu uczenia sieci, oraz nowej architektury sieci MLP z medianą na wejściu neuronu.

Mediana jako funkcja wejściowa neuronu, to pomysł, którego inspiracją było zapewnienie sztucznej sieci neuronowej typu MLP większej odporności na ewentualne uszkodzenia, rozumiane jako usunięcie części wag lub neuronów. Jak się okazało, sieć złożona z takich neuronów rzeczywiście wykazuje się zwiększoną tolerancją na usuwanie poszczególnych jej parametrów. Dodatkową własnością tak zmodyfikowanej struktury jest fakt lepszej niż w przypadku klasycznej sieci, zdolności uogólniania. Z perspektywy czasu można zauważyć, że pomysł habilitanta wyprzedził o kilka lat pojawienie się regularyzacji typu *dropout*, gdyż działanie sieci z medianą na wejściu, ze względu na fakt nieuczestniczenia w kolejnych krokach algorytmu optymalizacji niektórych parametrów (ich zmiana nie wpływa na medianę), można porównać właśnie do wyłączenia pewnej części losowo wybranych wag podczas uczenia sieci.

Inne wątki badań w tym zakresie dotyczyły bezgradientowego heurystycznego podejścia do optymalizacji wag, jak również wpływu nienadzorowanego uczenia wstępnego (*pretraining*) na efektywność działania głębokich sieci neuronowych. Wykorzystując algorytm *Contrastive Divergence* wykonano próby wstępnego uczenia struktur o różnej głębokości, przy założeniu różnych udziałów danych nie zawierających etykiet. Najbardziej ogólnym wnioskiem z przeprowadzonych eksperymentów było stwierdzenie, że *pretraining* pomaga jedynie w przypadku sieci o wielu warstwach ukrytych, natomiast jeśli chodzi o sieci płytkie może nawet pogarszać otrzymane rezultaty.

- **Andrzej Rusiecki**: Fault tolerant feedforward neural network with median neuron input function, *Electronics Letters*. 2005, vol. 41, nr 10, s. 603-605, ISSN: 0013-5194, Punktacja MNiSW: 27; IF: 01.016
- **Andrzej Rusiecki**: Testing the generalization of feedforward neural networks with median neuron input function, W: *Artificial intelligence and soft computing : 12th international conference, ICAISC 2013, Zakopane, Poland, June 9-13, 2013 : proceedings. Pt. 1 / Leszek Rutkowski [i in.] (eds.)*. Berlin ; Heidelberg : Springer, cop. 2013. s. 174-182, ISBN: 978-3-642-38657-2, (Lecture Notes in Computer Science. Lecture Notes in Artificial Intelligence, ISSN 0302-9743; vol. 7894), <http://dx.doi.org/10.1007/978-3-642-38658-9>, Web of Science: 15
- Mirosław Kordos, **Andrzej Rusiecki**, Tomasz Kamiński, Krzysztof Greń: Weight update sequence in MLP networks, W: *Intelligent data engineering and automated learning - IDEAL 2014 : 15th International Conference, Salamanca, Spain, September 10-12, 2014 / Emilio Corchado [i in.] (eds.)*. Cham [i in.] : Springer, cop. 2014. s. 266-274, ISBN: 978-3-319-10839-1, (Lecture Notes in Computer Science, ISSN 0302-9743; vol. 8669), [http://dx.doi.org/10.1007/978-3-319-10840-7\\_33](http://dx.doi.org/10.1007/978-3-319-10840-7_33), Web of Science: 15

- **Andrzej Rusiecki**, Mirosław Kordos: Effectiveness of unsupervised training in deep learning neural networks, *Schedae Informaticae*. 2015, vol. 24, s. 1-10, ISSN: 0860-0295, <http://dx.doi.org/10.4467/20838476SI.15.004.3026>, Punktacja: 11

### Zastosowania sieci neuronowych

W tym obszarze badania dotyczyły możliwości wykorzystania głębokich sieci neuronowych do segmentacji obrazów medycznych, oraz przewidywania czasu przejazdu przez aglomerację miejską z wykorzystaniem sieci neuronowych.

Głęboka sieć neuronowa wykorzystana została do segmentacji obrazów przedstawiających preparaty zawierające przekroje przez żyły. Zaproponowano zmodyfikowaną architekturę sieci bazującą na strukturze *U-net*, do której dodano m.in. dodatkowe warstwy normalizujące. W zadaniu klasyfikacji trzech, istotnych z medycznego punktu widzenia, warstw, rozwiązano ponadto problem wstępnego przetworzenia i braku zbalansowania zbioru uczącego, uzyskując po kilkudziesięciu godzinach nauki na GPU wysoką skuteczność segmentacji.

Kolejnym z rozważanych zastosowań była próba modelowania i przewidywania natężenia ruchu drogowego oparta na klasycznych sieciach MLP. Zadanie dotyczyło przewidywania natężenia ruchu w wybranym punkcie miejskiej sieci drogowej w oparciu o dane odnoszące się do tego samego, bądź innych skrzyżowań. Zaproponowane podejście (komitet sieci MLP) uzyskiwało niski błąd predykcji nawet w sytuacji, gdy całość wnioskowania odbywała się wyłącznie na podstawie danych o wcześniejszym natężeniu ruchu pochodzących z innych punktów miasta.

- Bartosz Miselis, Michał Kulus, Tomasz Jurek, **Andrzej Rusiecki**, Łukasz Jeleń: Deep neural network for whole slide vein segmentation /W: *Computer Information Systems and Industrial Management : 17th International Conference, CISIM 2018 Olomouc, Czech Republic, September 27-29, 2018 : proceedings* / Khalid Saeed, Władysław Homenda (eds.). [Cham] : Springer, cop. 2018. s. 57–67, ISBN: 978-3-319-99953-1, (Lecture Notes in Computer Science, ISSN 0302-9743; vol. 11127), [http://dx.doi.org/10.1007/978-3-319-99954-8\\_6](http://dx.doi.org/10.1007/978-3-319-99954-8_6)
- Krzysztof Halawa, Marek Bazan, Piotr Ciskowski, Tomasz Janiczek, Piotr Kozaczewski, **Andrzej Rusiecki**: Road traffic predictions across major city intersections using multilayer perceptrons and data from multiple intersections located in various places, *IET Intelligent Transport Systems*. 2016, vol. 10, nr 7, s. 469-475, ISSN: 1751-956X, <http://dx.doi.org/10.1049/iet-its.2015.0088>, Punktacja MNiSW: 25; IF: 01.194

### Odporne algorytmy uczenia sieci

Ten wątek badawczy związany był z rozprawą doktorską, w której zaproponowano kilka odpornych algorytmów uczenia sieci neuronowych. Prace z nim związane publikowane były również po uzyskaniu stopnia doktora i po części stanowiły inspirację do dalszych badań.

W ramach prac związanych z algorytmami uczenia odpornymi na błędy grube i dane odstające, opracowano metody oparte o zmienną funkcję aktywacji neuronu, adaptacyjnie dobierany współczynnik uczenia, czy ważenie obserwacji na podstawie oszacowania MCD (*minimum covariance determinant*). Ponadto zaproponowano algorytm optymalizacyjny będący odpowiednikiem algorytmu Levenberga-Marquardt'a dla, wspomnianej już wcześniej, zmodyfikowanej funkcji błędu LMLS (*Least Mean Log Squares*).

- **Andrzej Rusiecki:** Robust LTS backpropagation learning algorithm, Lecture Notes in Computer Science. 2007, vol. 4507, s. 102-109, ISSN: 0302-9743, 9th International Work-Conference on Artificial Neural Networks, IWANN 2007. San Sebastian, Spain, June 20-22, 2007, [http://dx.doi.org/10.1007/978-3-540-73007-1\\_13](http://dx.doi.org/10.1007/978-3-540-73007-1_13), Punktacja MNiSW z: 2010: 13
- **Andrzej Rusiecki:** Robust MCD-based backpropagation learning algorithm, Lecture Notes in Computer Science. Lecture Notes in Artificial Intelligence. 2008, vol. 5097, s. 154-163, ISSN: 0302-9743, 9th International Conference on Artificial Intelligence and Soft Computing - ICAISC 2008. Zakopane, Poland, June 22-26, 2008, [http://dx.doi.org/10.1007/978-3-540-69731-2\\_16](http://dx.doi.org/10.1007/978-3-540-69731-2_16), Punktacja MNiSW: 13
- **Andrzej Rusiecki:** Fast robust learning algorithm dedicated to LMLS criterion, Lecture Notes in Computer Science. Lecture Notes in Artificial Intelligence. 2010, vol. 6114, s. 96-103, ISSN: 0302-9743, Artificial intelligence and soft computing : 10th International Conference, ICAISC 2010, Zakopane, Poland, June 13-17, 2010. Pt. 2., [http://dx.doi.org/10.1007/978-3-642-13232-2\\_13](http://dx.doi.org/10.1007/978-3-642-13232-2_13), Punktacja MNiSW: 13; Lista Filadelfijska

## Przetwarzanie obrazów

W dziedzinie cyfrowego przetwarzania obrazów, badania związane z realizacją grantu rozwojowego skupiły się na możliwościach biblioteki OpenCV i zaimplementowanych w niej algorytmach. Wątek ten pojawiał się ponadto w publikacjach związanych z segmentacją obrazów medycznych (opisane powyżej), czy detekcją pojazdów poruszających się w niewłaściwym kierunku. Dodatkowo, badania o tej tematyce habilitant podejmował w kontekście uczestnictwa w projekcie rozwojowym z obszaru obronności i bezpieczeństwa państwa.

Publikacje obejmują tu współredaktorstwo pierwszej książki w języku polskim dotyczącej biblioteki OpenCV i autorstwo kilku rozdziałów w niej zamieszczonych, dotyczących podstawowych transformacji, czy operacji morfologicznych. W pracy dotyczącej wykrywania pojazdów poruszających się „pod prąd” wykorzystano model mieszany Gaussa (*Gaussian mixture model*), oraz analizę pola wektorowego przepływów optycznych (*optical flow*) w celu detekcji anomalii, polegających na ruchu w niewłaściwym kierunku.

- Ewaryst Rafajłowicz [Red.] , Wojciech Rafajłowicz [Red.] , **Andrzej Rusiecki [Red.]**: Algorytmy przetwarzania obrazów i wstęp do pracy z biblioteką Open CV

/ pod red. Ewarysta Rafajłowicza, Wojciecha Rafajłowicza, Andrzeja Rusieckiego. Wrocław: Oficyna Wydawnicza Politechniki Wrocławskiej, 2009. 168, [1] s. ISBN: 978-83-7493-475-6

- Andrzej Rusiecki: Podstawowe transformacje, W: Algorytmy przetwarzania obrazów i wstęp do pracy z biblioteką OpenCV / pod red. Ewarysta Rafajłowicza, Wojciecha Rafajłowicza, Andrzeja Rusieckiego. Wrocław : Oficyna Wydawnicza Politechniki Wrocławskiej, 2009. s. 53-79, ISBN: 978-83-7493-475-6
- Marek Bazan, Piotr Ciskowski, Krzysztof Halawa, Tomasz Janiczek, **Andrzej Rusiecki**, Mateusz Śmigowski: Detection of vehicles moving in wrong direction, Archives of Transport System Telematics. 2016, vol. 9, nr 1, s. 3-9, ISSN: 1899-8208

Punktacja MNiSW: 11

## 5.2 Dane bibliometryczne

W Tabeli nr 2 umieszczono h-indeks, oraz sumaryczną liczbę cytowań prac habilitanta według 3 najpopularniejszych baz bibliograficznych. Wszystkie prace habilitanta były cytowane **90 razy w 56 artykułach** (przeciętnie 5,63 cytowania/pracę), 63 razy nie licząc autocytowań, natomiast prace wchodzące w skład osiągnięcia naukowego habilitanta były cytowane 36 razy wg Web of Science.

Tabela 2: Indeks Hirscha i liczba cytowań prac habilitanta

Baza	Web of Science	Scopus	Google Scholar
<b>Indeks Hirscha</b>	6	7	9
<b>Liczba cytowań</b>	90 (63 bez autocytowań)	116	178

## 5.3 Wykonane recenzje

Habilitant wykonał łącznie **34 recenzje do 7 czasopism z listy JCR** (IEEE Trans. On Neural Networks and Learning Systems, Neurocomputing, Neural Processing Letters, Electronics Letters, IET Image Processing, IET Signal Processing, Pattern Analysis & Applications), **13 recenzji referatów** konferencyjnych (m.in. ICAISC), oraz recenzje 2 rozdziałów książek.

## 5.4 Dorobek dydaktyczny

Działalność dydaktyczna habilitanta zaowocowała promotorstwem **41 prac magisterskich**, oraz **75 prac i projektów inżynierskich** prowadzonych na Wydziale Elektroniki Politechniki Wrocławskiej. Trzy prowadzone przez habilitanta prace magisterskie zostały **wyróżnione w konkursach krajowych**, a część z nich prowadzona była we współpracy z przemysłem.

W ramach pracy dydaktycznej na Politechnice Wrocławskiej habilitant prowadził **wykłady (5 przedmiotów)**, oraz projekty, laboratoria, seminaria i ćwiczenia (łącznie **ponad 25 różnych kursów**), natomiast w latach 2008-2018 dodatkowo 2 przedmioty na Wydziale Lekarskim

Uniwersytetu Medycznego (Akademii Medycznej) we Wrocławiu. Jest autorem lub współautorem programów 5 kursów prowadzonych na Wydziale Elektroniki.

## 5.6 Opieka nad doktorantami

Od 2015 roku habilitant pełni funkcję promotora pomocniczego w przewodzie doktorskim zatytułowanym: *Recognition and matching of microscopic images in 2D space*.

## 5.5 Działalność organizacyjna

Od roku 2010 do dziś habilitant pełni funkcję **Sekretarza Komisji Egzaminów Dyplomowych** dla specjalności ART na Wydziale Elektroniki PWr., oraz funkcję **Doradcy Toku Studiów**. Brał również udział w Komisjach Programowych dwóch specjalności. W roku 2012 w ramach projektu „Wzrost liczby absolwentów Politechniki Wrocławskiej na kierunkach o kluczowym znaczeniu dla gospodarki opartej na wiedzy”, UDA-PKL.04.01.02.-00-065/09-01, uczestniczył w przygotowaniu i przeprowadzeniu **seminarium wyjazdowego** dla studentów kierunku Automatyka i Robotyka.

## 5.6 Uczestnictwo w projektach

Habilitant brał udział jako wykonawca lub podwykonawca w kilku projektach m.in. **badawczym MNiSW** (Metody i algorytmy przetwarzania sekwencji danych wielowymiarowych, okres realizacji: 2009-2010), **rozwojowym MNiSW** (Modułowy system wizyjny monitorowania jakości ciągłych procesów produkcyjnych, okres realizacji: 2007-2009), **projekcie rozwojowym z obszaru obronności i bezpieczeństwa państwa** (Zintegrowane systemy wieloczujnikowych sensorów bezprzewodowych i ich sieci do aktywnej ochrony obiektów i wojsk własnych, w ramach VI konkursu na realizację projektów rozwojowych z obszaru obronności i bezpieczeństwa państwa, okres realizacji: 2008-2010), czy **projekcie NCBiR w ramach programu BIOSTRATEG III** (BeeSensor, Opracowanie innowacyjnych, inteligentnych narzędzi monitorujących wstępowanie zgnilca złośliwego (amerykańskiego) oraz podwyższonego poziomu porażenia *Varroa destructor* w rodzinach pszczoły miodnej, 2018-2019).

W trakcie podpisywania (oferta złożona z inicjatywy habilitanta wybrana została w postępowaniu ofertowym) jest umowa na wykonanie prac badawczo-rozwojowych finansowanych ramach Programu Operacyjnego Inteligentny Rozwój od kwietnia 2019. Ponadto uczestniczył on jako wykonawca w kilku projektach/grantach o różnorodnej tematyce, finansowanych z dotacji na utrzymanie potencjału badawczego.

Podczas pobytu na stypendium **Marie Curie Host Fellowship** na Politechnice w Bukareszcie w okresie 2006-2007 uczestniczył również w projekcie (CHAMELEON RF: Comprehensive High-Accuracy Modelling of Electromagnetic Effects in Complete Nanoscale RF Blocks) w **6. Programie Ramowym UE (FP6-IST)**.

## Bibliografia

1. Bengio, Y., Lamblin, P., Popovici, D., et al.: Greedy layer-wise training of deep networks, NIPS 2006, Vancouver, BC, Canada, pp. 153–160, December 2006
2. Chen, D., and Jain, R.: A robust backpropagation learning algorithm for function approximation, IEEE Trans. Neural Netw., 5, (3), pp. 467–479, 1994
3. Chuang, C.C., Su, S.F., and Hsiao, C.C.: The annealing robust backpropagation (ARBP) learning algorithm, IEEE Trans. Neural Netw., 11, (5), pp. 1067–1077, 2000
4. Goodfellow, I., Bengio, Y., and Courville, A.: Deep Learning, MIT Press, 2016
5. Hampel, FR., Ronchetti, EM., Rousseeuw, PJ., Stahel, WA., Robust statistics: the approach based on influence functions (Wiley Series in Probability and Statistics), revised edn. Wiley, New York, 2005
6. Joulin, A., van der Maaten, L., Jabri, A., et al. Learning visual features from large weakly supervised data. European Conf. on Computer Vision, (ECCV), Amsterdam, Netherlands, October 2016
7. Liano, K., Robust error measure for supervised neural network learning with outliers, IEEE Trans. Neural Netw., pp. 246–250, January 1996
8. El-Melegy, M., Essai, M., and Ali, A.: Robust training of artificial feedforward neural networks, in Abraham, A.E., Vasilakos, A., Pedrycz, A., Hassanien, W. (Eds.): Foundations of Computational Intelligence Volume 1, Studies in Computational Intelligence, vol. 201, Springer, Berlin, Heidelberg, pp. 217–242, 2009
9. Misra, I., Lawrence, Z.C., Mitchell, M., et al.: Seeing through the human reporting bias: visual classifiers from noisy human-centric labels. Computer Vision and Pattern Recognition (CVPR), Las Vegas, CA, USA, 26 June–1 July 2016
10. Natarajan, N., Inderjit, S.D., Ravikumar, P.K., et al.: Learning with noisy labels. Advances in Neural Information Processing Systems (NIPS), Lake Tahoe, CA, USA, December 2013
11. Rousseeuw, PJ., Least median of squares regression. J Am Stat Assoc 79(388):871–880, 1984
12. Salvador, G., Derrac, J., Ramon, C.: Prototype selection for nearest neighbor classification: Taxonomy and empirical study. IEEE Transactions on Pattern Analysis and Machine Intelligence 34, 417–435, 2012
13. Sukhbaatar, S., Bruna, J., Paluri, M., et al.: Training convolutional networks with noisy labels, arXiv preprint arXiv:1406.2080, 2014

*Audrey Rusiecki*