

AUTOREFERAT
przedstawiający opis dorobku i osiągnięć
naukowych, w szczególności określonych
w art. 16 ust. 2 ustawy

Teresa Pamuła
Politechnika Śląska
Wydział Transportu

Katowice, 2018

SPIS TREŚCI:

1. Imię i nazwisko.....	3
2. Posiadane dyplomy i stopnie naukowe.....	3
3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych	3
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. z 2014r., nr 1852 z późn. zm.).....	4
4.1. Tytuł osiągnięcia naukowego.....	4
4.2. Wykaz prac stanowiących osiągnięcie naukowe	5
4.3. Omówienie celu naukowego pracy i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania	6
4.3.1. Ogólny cel naukowy badań	6
4.3.2. Osiągnięte wyniki badań – na podstawie prac [1 – 12].....	8
4.3.3. Wykorzystanie uzyskanych wyników badań.....	13
4.3.4. Omówienie pozostałych osiągnięć naukowo - badawczych	14
4.3.5. Podsumowanie osiągnięć naukowo-badawczych.....	15
5. Działalność dydaktyczna	17
5.1. Podręczniki akademickie	18
5.2. Inne.....	18
6. Działalność organizacyjna.....	18
7. Uzyskane nagrody, wyróżnienia i odznaczenia.....	19

1. Imię i nazwisko

Teresa Pamuła

2. Posiadane dyplomy i stopnie naukowe

- 21.05.1984 Uzyskanie tytułu **magistra inżyniera** na kierunku Informatyka (specjalność: budowa i oprogramowanie maszyn cyfrowych) na Wydziale Automatyki, Elektroniki i Informatyki Politechniki Śląskiej
- 27.06.2002 Uzyskanie stopnia **doktora nauk technicznych** w dziedzinie inżynieria materiałowa na Wydziale Inżynierii Materiałowej, Metalurgii i Transportu Politechniki Śląskiej. Tytuł rozprawy doktorskiej: „Modelowanie struktur spoin z wykorzystaniem sieci neuronowej”. Promotor: prof. dr hab. inż. Piotr Adamiec.

3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych

- 1988 –1991 Programista układów sterowania w Ośrodku Badawczo-Rozwojowym Elektrotechniki i Automatyki Górniczej EMAG w Katowicach.
- 1993 – 2002 Asystent w Zakładzie Inżynierii Ruchu w Instytucie Transportu na Wydziale Inżynierii Materiałowej, Metalurgii i Transportu Politechniki Śląskiej.
- 2002 – 2017 Adiunkt, mianowany nauczyciel akademicki w Katedrze Systemów Informatycznych Transportu, od 2011 w Katedrze Inżynierii Ruchu (aktualnie Katedra Systemów Transportowych i Inżynierii Ruchu) na Wydziale Transportu Politechniki Śląskiej.
- 2017 - obecnie Starszy wykładowca w Katedrze Systemów Transportowych i Inżynierii Ruchu na Wydziale Transportu Politechniki Śląskiej.

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. z 2014r., nr 1852 z późn. zm.)

4.1. Tytuł osiągnięcia naukowego

Moim osiągnięciem naukowym, uzyskanym po otrzymaniu stopnia doktora nauk technicznych, stanowiącym istotny wkład w rozwój dyscypliny naukowej Transport, określonym w art. 16 ust. 2 wyżej wymienionej ustawy, jest jednotematyczny cykl publikacji pt. „**Zastosowanie sztucznych sieci neuronowych do oceny parametrów ruchu drogowego w systemach transportowych**” [1-12]. Cykl publikacji przedstawia autorską metodykę zastosowania sztucznych sieci neuronowych do opracowania zagadnień oceny parametrów ruchu drogowego. Uwaga skupiona jest na zagadnieniach predykcji zmian parametrów ruchu oraz klasyfikacji warunków ruchu.

Chronologicznie pierwsze w cyklu publikacji przedstawiają metody opracowania modeli zadań predykcji zmian parametrów ruchu z zastosowaniem sztucznej sieci neuronowej typu MLP. Zadania predykcji wykonywane są dla pojedynczych miejsc w sieci ulic oraz par węzłów w sieci. Następnie modele rozszerzone zostają na sieć ulic miejskich. Uwzględniono powiązania przestrzenno-czasowe parametrów ruchu drogowego między węzłami pomiarowymi w systemie transportowym.

Kolejne publikacje przedstawiają metody przygotowania modeli z zastosowaniem sieci typu *deep learning* (DLN – Deep Learning Network) trenowanych z użyciem algorytmów „głębokiego uczenia”. Sieci DLN dedykowane są do analizy znacznej liczby różnorodnych zbiorów danych określanych pojęciem „big data”. W szczególności artykuł w czasopiśmie „IEEE Transactions on Intelligent Transportation Systems” zawiera prezentację oryginalnego modelu, z użyciem sieci DLN, uwzględniającego wpływ utraty danych na wyniki predykcji dla dziesięciu skrzyżowań [2]. Dla oceny warunków ruchu opracowano metodę klasyfikacji treści obrazu sytuacji drogowej z użyciem konwolucyjnej sieci neuronowej [3].

Monografia systematyzuje metodykę zastosowania sieci neuronowych do oceny parametrów ruchu drogowego w systemach transportowych i zawiera dyskusję zastosowania uzyskanych wyników [1]. Weryfikację i testowanie metod wykonano korzystając z danych rzeczywistych uzyskanych z Centrów Sterowania Ruchem.

4.2. Wykaz prac stanowiących osiągnięcie naukowe

Jednotematyczny cykl publikacji stanowią moje prace:

1. **Pamuła T.:** *Zastosowanie sztucznych sieci neuronowych do predykcji parametrów i klasyfikacji warunków ruchu drogowego w systemach transportowych*, **Monografia**, Wydaw. Politechniki Śląskiej, Gliwice 2018, ISBN **978-83-7880-568-7**, stron 137. Punktacja **MNiSW 25 pkt.**
2. **Pamuła T.:** *Impact of data loss for prediction of traffic flow on an urban road using neural networks*, IEEE Transactions on Intelligent Transportation Systems, maj **2018**, vol. pp, issue 99, p. 1-10. (*Early Access*), Impact Factor 4.051⁽²⁰¹⁸⁾. Punktacja **MNiSW 40 pkt.** . DOI: [10.1109/TITS.2018.2836141](https://doi.org/10.1109/TITS.2018.2836141)
3. **Pamuła T.:** *Road traffic conditions classification based on multilevel filtering of image content using convolutional neural networks*, IEEE Intelligent Transportation Systems Magazine, **2018**, vol. 10, issue 3, p. 11-21., Impact Factor 3.019⁽²⁰¹⁸⁾. Punktacja **MNiSW 25 pkt.** DOI: [10.1109/MITS.2018.2842040](https://doi.org/10.1109/MITS.2018.2842040)
4. **Pamuła T.:** *Determination of congestion levels using texture analysis of road traffic images*, Contemporary challenges of transport systems and traffic engineering, Springer **2017 (WoS)**, s. 53-61, vol. 2 2367-3370. Punktacja **MNiSW 15 pkt.** DOI: [10.1007/978-3-319-43985-3_5](https://doi.org/10.1007/978-3-319-43985-3_5)
5. **Pamuła T.:** *Przestrzenno-czasowy model predykcji natężenia ruchu z użyciem sieci neuronowych*, Prace Naukowe PW, Transport **2017** z. 117, s. 259-269. p-ISSN: 1230-9265. Punktacja **MNiSW 7 pkt.**
6. **Pamuła T.** *Classification of road traffic conditions based on texture features of traffic images using neural networks*, Scientific Journal of Silesian University of Technology. Series Transport., Vol. 92, **2016, (WoS)**, s. 101-109. p-ISSN: 0209-3324 Punktacja **MNiSW 9 pkt.** DOI: [10.20858/sjsutst.2016.92.10](https://doi.org/10.20858/sjsutst.2016.92.10)
7. **Pamuła T.:** *Neural networks in transportation research – recent applications*, Transport Problems, vol. 11, Issue 2, **2016, (WoS)**, s. 27-36. Punktacja **MNiSW 14 pkt.** DOI: [10.20858/sjsutst.2016.92.10](https://doi.org/10.20858/sjsutst.2016.92.10)
8. **Pamuła T.:** *Predykcja natężenia ruchu na sąsiednich skrzyżowaniach z użyciem sieci neuronowych*, Prace Naukowe PW, Transport **2016** z.113, s. 369-379. p-ISSN: 1230-9265. Punktacja **MNiSW 7 pkt.**
9. **Pamuła T., Król A.:** *The traffic flow prediction using bayesian and neural network*, Intelligent transportation systems - problems and perspectives, **Springer, 2016 (WoS)**, s. 105-126. Seria: Studies in Systems, Decision and Control, vol. 32 2198-4182. Punktacja **MNiSW 15 pkt.** Udział własny 50%. DOI: [10.1007/978-3-319-19150-8_4](https://doi.org/10.1007/978-3-319-19150-8_4)

10. **Pamula T.:** *Short-term traffic flow forecasting method based on the data from video detectors using a neural network.*, Activities of Transport Telematics, **Springer, 2013 (WoS)**, s. 147-154, Seria: Communications in Computer and Information Science, vol. 395 1865-0929. Punktacja **MNiSW 10 pkt.** DOI: [10.1007/978-3-642-41647-7_19](https://doi.org/10.1007/978-3-642-41647-7_19)
11. **Pamula T.:** *Classification and prediction of traffic flow based on real data using neural networks.* **Archives of Transport 2012** vol. 24 no. 4, s. 519-522. Punktacja **MNiSW 5 pkt.** DOI: [10.2478/v10174-012-0032-2](https://doi.org/10.2478/v10174-012-0032-2)
12. **Pamula T.:** *Traffic flow analysis based on the real data using neural networks*, Telematics in the transport environment, **Springer, 2012, (WoS)**, s. 364-371, Seria: Communications in Computer and Information Science , vol. 329 1865-0929. Punktacja **MNiSW 10 pkt.** DOI: [10.1007/978-3-642-34050-5](https://doi.org/10.1007/978-3-642-34050-5)

Publikacje [1] ÷ [12] zamieszczone zostały w załączniku 6 - jako pliki "**hab-6_1.pdf - hab-6_12.pdf**".

4.3. Omówienie celu naukowego pracy i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania

4.3.1. Ogólny cel naukowy badań

Wzrost natężenia ruchu drogowego oraz wymagań stawianych właściwościom funkcjonowania systemów sterowania i zarządzania ruchem wymusza coraz większy udział złożonych technik przetwarzania danych o stanie działania tych systemów. Następuje integracja rozwiązań stosowanych dla usprawnienia współdziałania elementów infrastruktury. Oczekuje się, że rozwijane systemy określane obecnie mianem Inteligentne Systemy Transportu (ITS) pozwolą na zwiększenie efektywności korzystania z systemów transportu przez uczestników ruchu drogowego.

Określanie stanu działania systemu i zaproponowanie modelu wymaga odwzorowania złożonych, wzajemnie powiązanych zależności między wielkościami wpływającymi na warunki ruchu i uczestnikami tego ruchu. Zależności te mogą ulegać dynamicznym zmianom. Zastosowanie metod sztucznej inteligencji, w szczególności sieci neuronowych, łączących w sobie elementy uczenia się, adaptacji i samoorganizacji pozwala efektywnie podjąć opracowanie takich modeli. Sieci neuronowe zaproponowane zostały w latach 60-tych XX wieku, a w zagadnieniach związanych z transportem zaczęto je stosować w latach 90.

Dokonany przegląd zastosowań [7] wskazuje reprezentatywne przykłady z zakresu: predykcji parametrów ruchu drogowego, sterowania ruchem drogowym, pomiarów parametrów ruchu, zachowania kierowców i prowadzenia autonomicznych pojazdów oraz ekonomii

i polityki transportowej. W literaturze brakuje opracowań z zakresu metodyki konstrukcji modeli z użyciem sieci neuronowych w celu osiągnięcia zadanego poziomu odwzorowania wielkości opisujących stan działania systemu transportowego.

Prognozowanie zmian parametrów ruchu i ocena warunków ruchu odgrywają ważną rolę w wypracowaniu decyzji sterowania i zarządzania ruchem w systemie transportowym. Prognozowanie musi uwzględniać informacje historyczne, jak i wzajemne powiązania między strumieniami pojazdów w sieci komunikacyjnej. Powstaje bardzo liczny zbiór wzajemnie powiązanych danych, które powinny być analizowane w czasie rzeczywistym. Zaproponowano opracowanie metod zastosowania sztucznych sieci neuronowych do analizy tych danych. Doświadczenie badawcze w dziedzinie zastosowania sieci neuronowych do przetwarzania danych dowodzi, że poprawnie wytrenowane sieci dostarczają wyniki szybciej od tradycyjnych rozwiązań opartych na metodach statystycznych.

Celem naukowym jest opracowanie metodyki konstrukcji modeli predykcji parametrów ruchu drogowego i klasyfikacji warunków ruchu z zastosowaniem wielowarstwowych sieci neuronowych, która pozwoli efektywnie przetworzyć złożone zależności przestrzenno-czasowe między zmiennymi modelu.

Ważnym ograniczeniem, które warunkuje opracowanie modeli jest rodzaj oraz jakość danych dostępnych dla przetwarzania. W przypadku predykcji ruchu korzysta się z bieżących danych z detektorów pojazdów oraz z danych zarejestrowanych wcześniej. W ITS stosowanych jest kilkanaście rodzajów detektorów różniących się dokładnością pomiarową, a także niezawodnością działania. Stanowiska pomiarowe mogą przestać funkcjonować lub generować fikcyjne wartości parametrów ruchu losowo, bez związku z obrazem ruchu drogowego. Analiza rzeczywistych danych użytych w badaniach dowodzi, że przekłamania mogą stanowić nawet kilkanaście procent zebranych danych.

Klasyfikacja warunków ruchu wykonywana jest z użyciem materiału z drogowych kamer obserwacyjnych lub dronów. Podobnie jak detektory kamery nie są źródłem bezbłędnych danych, dodatkowo mogą być mocno wrażliwe na warunki pogodowe obserwacji sytuacji drogowej.

Sformułowano następujące problemy badawcze:

1. Wybór modelu predykcji parametrów ruchu, który umożliwi opis zadania wyznaczenia poprawnych danych dla sterowania i zarządzania ruchem w systemach transportowych.
2. Wybór modelu klasyfikacji warunków ruchu, który umożliwi opis zadania wyznaczenia poprawnych danych dla sterowania i zarządzania ruchem w systemach transportowych.

Uzyskane prognozy wartości parametrów ruchu drogowego i oceny warunków ruchu, powinny być użyteczne dla praktycznego zastosowania w rozwiązaniach ITS. To wymaganie narzuca konieczność opracowania efektywnych konstrukcji modeli ze względu na dostępne, zwykle mało rozbudowane, zasoby przetwarzania w podsystemach ITS. Dodatkowo ważna jest zdolność do uzyskania wyników w czasie rzeczywistym.

Rozwiązanie problemów badawczych wymaga opracowania następujących zadań:

1. Zebranie i przygotowanie danych dla zadania predykcji parametrów ruchu.
2. Identyfikacja parametrów modeli predykcji parametrów ruchu drogowego.
3. Walidacja rozwiązań architektur sieci neuronowych dla modelu predykcji.
4. Zebranie i przygotowanie danych dla zadania klasyfikacji warunków ruchu.
5. Identyfikacja parametrów modeli klasyfikacji warunków ruchu.
6. Walidacja rozwiązań architektur sieci neuronowych dla modeli klasyfikacji.

Przyjęte kryteria oceny rozwiązań, takie jak: efektywność predykcji i klasyfikacji parametrów ruchu, zdolność do wypracowania wyników w czasie rzeczywistym stanowią istotne ograniczenia dla dziedziny modeli i rozwiązań architektur sieci neuronowych. Na podstawie przeglądu literatury oceniono i wybrano modele predykcji i klasyfikacji warunków ruchu. W toku badań sprawdzono wrażliwość modeli na zmiany parametrów architektur sieci. Przygotowano zalecenia dla przygotowania rozwiązań sieci spełniające postawione kryteria oceny. Opracowane modele uwzględniają najmniejszą możliwą liczbę parametrów opisu. Architektura sieci zawiera co najwyżej kilka warstw wewnętrznych.

Ważnym problemem jest określenie wrażliwości zaproponowanych modeli na brak lub błędne dane, na podstawie których dokonywana jest predykcja. Sieci w znacznym stopniu tolerują błędne dane wejściowe lub ich brak, stąd wynika ich efektywność i szczególna przydatność dla rzeczywistych systemów sterowania i zarządzania ruchem drogowym.

4.3.2. Osiągnięte wyniki badań – na podstawie prac [1 – 12]

Cykl publikacji dokumentuje uzyskane wyniki badań i opracowane sformułowane problemy badawcze. Analiza zebranych danych dla zadania predykcji wykazała [11], [12] konieczność dokonania klasyfikacji danych ze względu na dzień tygodnia zbierania danych. Dni tygodnia charakteryzują się różnymi przebiegami zmian parametrów ruchu, w szczególności natężenia ruchu drogowego. Sieć neuronowa do odwzorowania tych przebiegów wymaga ograniczonego zakresu zmienności wartości parametrów. Wykazano, że podział przebiegów natężenia ruchu na cztery klasy reprezentatywne dla dobowego natężenia ruchu, takie jak: dni

robocze, soboty, niedziele i dni świąteczne spełnia wymagania dla zastosowania sieci. W badaniach użyto rzeczywistych danych o natężeniu ruchu uzyskanych z Centrum Sterowania Ruchem. Dane dotyczyły pomiarów z okresu jednego roku w godzinnych interwałach.

W pracy [10] zaproponowano model predykcji natężenia ruchu korzystający z serii poprzednich pomiarów jako danych opisujących historię zmian przebiegu ruchu. Zbadano wpływ okna czasowego (liczby poprzednich pomiarów) na dokładność prognozy. Testy przeprowadzono dla trzech klas dobowego natężenia ruchu dla dwóch kolejnych skrzyżowań odcinka drogi. Długość okna powyżej 5 wstecznych pomiarów nie wpłynęła znacząco na poprawę dokładności prognozy ruchu.

W pracy [8] zaproponowano model predykcji natężenia ruchu, dla sytuacji braku danych pomiarowych na kolejnym w ciągu skrzyżowaniu. Sytuacja taka zdarza się, gdy detektor pojazdów ulega uszkodzeniu. Uwzględniono historię zmian natężenia ruchu w punkcie pomiarowym na jednym skrzyżowaniu i uzyskano wartości błędów MAPE średnio dla punktu pomiarowego na pierwszym skrzyżowaniu 15%, a na kolejnym 23%. Zwrócono uwagę na konieczność uwzględnienia zależności nie tylko czasowych ale również przestrzennych między źródłami danych. Na duży błąd predykcji wpłynęło położenie kolejnego skrzyżowania, które w bliskim sąsiedztwie miało centrum handlowe.

W artykule [9] zaproponowano dwa krótkoterminowe modele prognozowania do określania wielkości natężenia ruchu w jednym punkcie pomiarowym. Danymi wejściowymi modeli są wcześniejsze wartości natężenia ruchu. Wykonano porównanie implementacji modeli z zastosowaniem sieci bayesowskiej (BN) i neuronowej (NN). Średni błąd MAPE prognozy dla dnia roboczego dla modelu NN wyniósł 6%, a dla modelu BN 10%. Analiza danych wejściowych i zachowanie modeli sugeruje, że w celu uzyskania większej dokładności predykcji należało uwzględnić dodatkowe zależności między zmiennymi modeli.

W zagadnieniach związanych z transportem do analizy i przetwarzania danych najczęściej stosowane są konfiguracje sieci MLP (Multi Layer Perceptron), takie sieci zastosowano w modelach przedstawionych w pracach [8-12]. W 2014 roku pojawiły się pierwsze publikacje, w których zaproponowano użycie złożonych sieci wielowarstwowych typu *deep learning*, takich jak: sieci konwolucyjne (CNN) i sieci DLN z autoenkoderami. Sieć typu DLN zastosowano w modelu przestrzenno-czasowym predykcji parametrów ruchu drogowego przedstawionym w pracach [2], [5] oraz w modelu klasyfikacji warunków ruchu w pracy [3].

Przedmiotem walidacji rozwiązań architektur sieci neuronowych dla modeli predykcji i klasyfikacji jest optymalizacja struktury polegająca na doborze liczby warstw i rodzaju połączeń między warstwami dla uzyskania oczekiwanych właściwości działania. Ważnym celem

jest określenie zaleceń dla postaci sieci spełniającej wymagania rozwiązań ITS.

W pracy [2] przeprowadzono walidację rozwiązań sieci dla opracowanego przestrzenno-czasowego modelu predykcji natężenia ruchu w sieci ulicznej. Model obejmuje 10 skrzyżowań na terenie Gliwic ważnych dla zarządzania ruchem drogowym w mieście. Model predykcji wykonano w dwóch wariantach. Pierwszy wariant zawiera jedną sieć neuronową typu *deep learning* z autoenkoderami (DLN), w drugim zastosowano sieć neuronową typu *multilayer perceptron* (MLP). Model przestrzenno-czasowy odwzorowuje parametry ruchu na skrzyżowaniu na podstawie zbioru wcześniej zmierzonych wartości oraz zbiorów wartości zmierzonych na sąsiednich skrzyżowaniach.

W celu porównania wyników, opracowano model regresyjny sARIMA oraz modele predykcji niezależnie dla każdego punktu pomiarowego. Modele te wykonano również w dwóch wariantach z użyciem sieci typu *deep learning* (model DLNp) oraz sieci typu MLP (model MLPp).

Dobierano liczbę warstw i liczbę neuronów w warstwie dla uzyskania najmniejszego błędu predykcji. Wartość przyszła natężenia ruchu była wyznaczana na podstawie sześciu pomiarów w poprzednich kolejnych interwałach czasowych. Za interwał czasowy przyjęto okres 15 min. W celu porównania działania modeli wyznaczono średni procentowy błąd bezwzględny (MAPE) predykcji.

Wyniki predykcji dla modelu przestrzenno-czasowego z jedną siecią neuronową DLN lub MLP są bardzo podobne. Dla wszystkich sprawnych detektorów średni procentowy błąd predykcji MAPE dla danych testowych wyniósł 9,3% dla modelu DLN i 9,4% dla modelu MLP.

Model z wieloma sieciami neuronowymi DLNp (MLPp) daje lepsze wyniki predykcji niż model z jedną siecią neuronową. Dla modelu DLNp błąd predykcji MAPE wynosi średnio dla wszystkich punktów pomiarowych 7,7% (8,1% dla MLPp). Model ten nie uwzględnia jednak zależności między danymi z poszczególnych punktów pomiarowych występujących w sieci ulic. Z jednej strony jest to zaleta, ponieważ zakłócenia pomiarowe z innych miejsc w sieci ulic nie wpływają na prognozy w danym punkcie. Z drugiej strony uszkodzenie detektora i brak danych o natężeniu ruchu w danym punkcie pomiarowym powoduje brak informacji o przyszłym natężeniu. W przypadku modeli przestrzenno-czasowych z jedną siecią DLN (MLP) możliwe jest prognozowanie przy braku danych.

Przeprowadzono również badanie wrażliwości błędów predykcji na uszkodzenie detektorów w sieci ulic. Przyjęto różne scenariusze możliwych uszkodzeń, brano pod uwagę uszkodzenie dwóch lub trzech detektorów. Brakujące dane zastąpiono zerowymi wartościami natężenia ruchu. Zamodelowanie w ciągach uczących sytuacji awaryjnych wpłynęło znacząco na

poprawę wyników predykcji w tych przypadkach. Użycie danych z sąsiednich detektorów dla obliczania natężenia ruchu w danym miejscu sieci drogowej uodparnia model na zawodność działania detektorów. Dla niektórych punktów pomiarowych, w przypadku uszkodzenia, błąd predykcji MAPE zmalał nawet trzykrotnie w stosunku do sytuacji, gdy w ciągach uczących nie uwzględniono błędnych danych. W modelu można zauważyć wyraźną przewagę sieci DLN z autoenkoderami nad sieciami typu MLP.

Najlepsze zastosowane w modelach DLN sieci zawierały jedną lub dwie warstwy autoenkoderów po dwadzieścia neuronów. Dla modeli z siecią MLP najlepsze konfiguracje miały od 12 do 18 neuronów w warstwie ukrytej.

Model sARIMA w porównaniu z modelami DLN (MLP) oraz DLNp (MLPp) daje gorsze wyniki predykcji średnio o około 20%.

Jednym z najważniejszych parametrów charakteryzujących warunki ruchu jest gęstość ruchu. Gęstość pośrednio określa poziom kongestii – parametr ważny dla zarządzania ruchem drogowym w systemie transportowym. Wyznaczenie liczby pojazdów na odcinku drogi może stanowić wyzwanie dla tradycyjnych systemów korzystających z jezdniowych detektorów pojazdów. Alternatywę pomiarową może stanowić analiza obrazu drogi, która przy zastosowaniu metod z zakresu komputerowego przetwarzania obrazów jest bardzo wymagająca obliczeniowo.

Podjęta została próba uproszczenia zadania. Ocena warunków ruchu zdefiniowana została jako zadanie klasyfikacji treści obrazu sytuacji drogowej. Zaproponowano użycie materiału wideo z drogowych kamer obserwacyjnych lub z kamer umieszczonych na BSP (dronach). Uznano za wystarczającą zdolność modelu do rozróżniania czterech poziomów gęstości ruchu w przybliżeniu odpowiadających poziomom swobody ruchu. Materiał wideo podzielony został na pojedyncze klatki, z których wycięto fragmenty zawierające reprezentatywne dla wybranych poziomów swobody ruchu obrazy sytuacji drogowej.

Autorski model klasyfikacji warunków ruchu na podstawie obrazu sytuacji drogowej przedstawiono w publikacji [4]. Treść obrazu opisano za pomocą cech teksturowych Haralicka. Z użyciem macierzy GLCM (Gray-Level Co-Occurrence Matrix) obliczono takie cechy jak: energia, entropia, jednorodność, odmienność, kontrast oraz korelacja. Warunki ruchu wyznaczone zostały na podstawie zakresów wartości cech. Inne podejście zaproponowano w pracy [6] w tym przypadku użyto zdjęć wykonanych kamerą zamontowaną na dronie. Cechy tekstury wyznaczane dla obrazu pasa ruchu zastosowano jako dane wejściowe klasyfikatora neuronowego. Do klasyfikacji zastosowano odpowiednio dobraną konfigurację sieci MLP.

Wykrywanie cech obiektów na obrazach jest domeną zastosowań sieci konwolucyjnych. Opracowane zostały w celu analizy zależności przestrzennych wartości pikseli obrazów. W 1980 Kunihiro Fukushima zaproponował architekturę sieci neuronowej, która pozwala opisać takie zależności i w dużym stopniu jest odporna na przeuczenie – pierwszą konwolucyjną sieć neuronową (CNN).

Zadanie rozróżnienia kategorii poziomów swobody ruchu (PSR) zamodelowano z użyciem sieci CNN jako zadanie klasyfikacji tekstur w pracy [3]. Określono cztery klasy tekstur. Zaproponowano analizę tylko wybranego fragmentu obserwowanej drogi dobranego tak, aby dla najlepszych warunków ruchu obserwowana była pusta droga. Przyjęto, że długość fragmentu drogi równa jest minimalnemu odstępowi między pojazdami dla drugiego poziomu swobody ruchu. Tekstura PSR I nie zawiera żadnych pojazdów, a tylko pasy drogowe zakłócone zmianami otoczenia. PSR II wydaje się być najbardziej wyraźną klasą, ponieważ przeciętnie jeden pojazd na pas ruchu oznacza pojedynczą dezorganizację tekstury drogi. Rozróżnienie PSR III i PSR IV stwarza największe wyzwanie dla modelu, ponieważ duża liczba pojazdów jest bardzo zniekształcona w perspektywie. Istotną rolę w tej operacji odgrywa rozdzielczość okna. Okno analizy z niewłaściwą rozdzielczością zawiera połączone pojazdy, zakłócając w ten sposób cechy tekstury istotne dla klasyfikacji. Dodatkowo światło otoczenia odbijające się od powierzchni drogi może tworzyć obiekty (cienie) prowadzące do błędnej klasyfikacji.

Walidację modelu wykonano z użyciem danych wideo ze stanowisk obserwacyjnych z różnym kątem widzenia kamery i w różnych warunkach oświetlenia. Zaproponowana metoda klasyfikacji warunków ruchu z użyciem konwolucyjnej sieci neuronowej poprawnie określa PSR dla niemal 90% z 400 testowanych obrazów. Największy błąd klasyfikacji uzyskano dla klasy PSR III. Dobrana architektura sieci konwolucyjnej zawiera trzy warstwy konwolucyjne, które w wystarczający sposób wyodrębniają trzy poziomy opisy tekstur na obrazie co jednoznacznie pozwala sklasyfikować obraz warunków ruchu.

Monografia [1] przedstawia w sposób systematyczny metodykę zastosowania sieci neuronowych do oceny parametrów ruchu drogowego w systemach transportowych. Zdefiniowano opis matematyczny zadania predykcji z użyciem funkcji zmiennych wyrażających: bieżące parametry ruchu, historię zmian i przestrzenne powiązania. Zaproponowano przestrzenno-czasowy model predykcji. Takie rozwiązanie niespotykane wcześniej w opracowaniach pozwala uwzględnić zależności parametrów ruchu w danym węźle sieci drogowej od warunków ruchu w otoczeniu. Liczba zmiennych zależy od rozmiaru okna czasowego historii zmian i rozmiaru zasięgu sąsiedztwa. Postać funkcji można uzyskać z użyciem tradycyjnych metod,

np. regresji lub w toku trenowania sieci neuronowej reprezentującej zależności między zmiennymi.

Zadanie oceny warunków ruchu zdefiniowano jako zadanie klasyfikacji zawartości obrazu sytuacji drogowej. Podkreślono znaczenie teksturowego podejścia oraz zastosowanie sieci CNN do klasyfikacji.

Monografia zawiera dyskusję autorskiego podejścia do optymalizacji architektury sieci dla realizacji postawionego celu opracowania efektywnych modeli do zastosowania w podsystemach ITS. Uwagę skupiono na wielowarstwowych sieciach typu DLN. Wybrana sieć DLN z autoenkoderami jest mało wrażliwa na tzw. przeuczenie, przyspiesza to proces optymalizacji eliminując konieczność wielokrotnego sprawdzania działania, gdy zachodzi podejrzenie że sieć „pamięta” dane a nie wyznacza zależności. Uzyskane rozwiązania pozwalają dostatecznie dokładnie przewidywać zmiany parametrów ruchu dla systemów sterowania i zarządzania ruchem. Przeprowadzono porównanie z modelami opartymi na szeregach czasowych potwierdzając przewagę działania sieci DLN.

Włączenie zależności przestrzennych do opisu zadania predykcji pozwala swobodnie zmieniać wrażliwość na utratę danych. Uwzględnienie dużego sąsiedztwa czyni model odporniejszym na lokalne błędy pomiarowe.

4.3.3. Wykorzystanie uzyskanych wyników badań

Opracowane metody predykcji i klasyfikacji z zastosowaniem sztucznych sieci neuronowych mogą zostać użyte do przetworzenia danych pomiarowych w urządzeniach stanowiących elementy systemów sterowania i zarządzania w czasie rzeczywistym. Wytrenowane sieci tolerują brak lub błędne dane co zwiększa sprawność działania tych elementów w rzeczywistym środowisku systemu transportowego.

Zastosowanie sieci DLN z autoenkoderami umożliwia uzyskanie dobrych wyników predykcji, a stopień złożoności obliczeniowej rozwiązania nie dyskwalifikuje jego przydatności jako podsystemu ITS.

Klasyfikacja treści obrazów sytuacji drogowej z użyciem konwolucyjnej sieci neuronowej pozwala na sprawne określenie warunków ruchu. W tym przypadku pomimo dużych rozmiarów sieci oceny warunków ruchu dostępne mogą być w czasie rzeczywistym. Uzyskane wyniki klasyfikacji przewyższają wyniki klasyfikacji z użyciem innych metod.

Podjęta problematyka zastosowania sieci neuronowych do wspomaganie działania ITS, w szczególności nowych rozwiązań sieci opartych na „głębokim uczeniu”, stanowi ważną dziedzinę badań. Rozwijane systemy sterowania i zarządzania korzystają z coraz większej

liczby danych, które wymagają przetworzenia z użyciem sprawnych narzędzi. Sieci DLN należą do ważnej grupy metod analizy dużych zbiorów danych określanych pojęciem „big data”.

Uzyskane doświadczenie w zakresie zastosowania i opracowywania architektur sieci DLN pozwala zaproponować przykładowe tematy badań dla opracowania rozwiązań przetwarzania danych z rozległej sieci stanowisk pomiaru parametrów ruchu drogowego:

1. Określenie wpływu zamknięć dróg na rozwój obrazu zatłoczenia sieci drogowej.
2. Predykcja zmian rozmiarów potoków ruchu dla zadanych zmian w organizacji ruchu w sieci drogowej.
3. Integracja danych ze stanowisk pomiaru parametrów ruchu i innych źródeł danych w ITS dla predykcji obciążenia sieci drogowej.

Ważnym przedmiotem przyszłych prac powinno być opracowanie metodyki porównywania algorytmów predykcji i przygotowanie bazy wzorcowych testów.

4.3.4. Omówienie pozostałych osiągnięć naukowo - badawczych

Wykaz 10 publikacji nie należących do podstawowego zbioru prac zgłoszonych jako podstawowe osiągnięcie naukowe, będących uzupełnieniem podstawowego osiągnięcia naukowego, zamieszczono w załączniku 4 w punktach II.A i II.B (plik "**hab-4_dorobek.pdf**"). Prace te zawiera załącznik 7 (pliki "**hab-7_1.pdf - hab -7_10.pdf**").

Przed uzyskaniem stopnia doktora tematyka badań skoncentrowana była głównie na analizie treści obrazów cyfrowych z użyciem metod przetwarzania obrazów oraz z zastosowaniem sieci neuronowych. Prace skupiały się na analizie obrazów mikroskopowych struktur materiałów, danych z kamer drogowych, a także obrazów z zakresu diagnostyki medycznej. Opracowany został neuronowy klasyfikator obiektów, a także koncepcja metody określania parametrów przemieszczania się obiektów na obrazach sytuacji drogowej dla rozwiązania systemu rejestracji obrazu cyfrowego zdarzeń drogowych.

Po uzyskaniu stopnia doktora kontynuowane były prace w dziedzinie algorytmów przetwarzania użytecznych dla systemów detekcji i klasyfikacji pojazdów. Opracowane zostały algorytmy identyfikacji i odczytu tablic rejestracyjnych pojazdów na obrazach ruchu drogowego z użyciem metod sztucznej inteligencji (sieci neuronowych, logiki rozmytej) oraz metod analizy i przetwarzania obrazów [II.B.9]. Rezultaty tych badań były prezentowane na konferencjach z dziedziny transportu.

Doświadczenia związane z przetwarzaniem obrazów pozwoliły również na opracowanie algorytmu odczytu napisów na kontenerach morskich z obrazów cyfrowych [II.B.10].

W 2011r. podjęte zostały prace w zakresie analizy oraz predykcji parametrów ruchu dla systemów zarządzania ruchem miejskim z użyciem sieci neuronowych. Ważny wpływ na dalsze prace miało uzyskanie dostępu do obszernej bazy danych o ruchu drogowym. Wyniki wstępnych analiz i predykcji zamieszczone zostały m.in. w publikacjach [II.B.4, II.B.8].

Predykcja stała się wiodącą tematyką badań. W kolejnych latach podjęte zostało opracowanie zagadnień wrażliwości predykcji na zmiany w konfiguracji i rodzaju sieci neuronowej. Udoskonalone narzędzia środowiska projektowania sieci neuronowych umożliwiły efektywne podjęcie problemu predykcji dla kilku węzłów w sieci ulic, ważnego dla ITS [II.B.3]. Uzyskane wyniki stanowiły wstęp do opracowania przestrzenno-czasowego modelu predykcji.

Wyniki prowadzonych badań porównywane były z innymi metodami predykcji, takimi jak metoda k-najbliższego sąsiada (kNN) [II.A.1, II.B.6] oraz metoda regresji wielokrotnej [II.B.5].

Od roku 2015, równoległe z badaniami związanymi z predykcją parametrów ruchu, podjęty został problem klasyfikacji warunków ruchu drogowego na podstawie materiału wideo rejestrowanego przez kamery drogowe lub kamery umieszczone na dronach. W pracy [II.B.2] z 2016 roku przedstawiono pierwszą wersję autorskiego klasyfikatora warunków ruchu drogowego opartego na analizie cech tekstury. Użyte zostały sieci neuronowe typu MLP.

4.3.5. Podsumowanie osiągnięć naukowo-badawczych

Mój dorobek publikacyjny obejmuje 55 publikacji naukowych (w tym 20 współautorских) i cztery podręczniki akademickie, oraz 15 referatów wygłoszonych na konferencjach. Wykaz wszystkich opublikowanych prac z uwzględnieniem udziału procentowego zawiera Załącznik 4 (w pliku "**hab-4_dorobek.pdf**").

W tabeli 2 przedstawiono zbiorcze zestawienie publikacji z podziałem na autorskie i współautorskie. Tabela 3 zawiera sumaryczną liczbę punktów za wszystkie publikacje.

Tabela 2. Zestawienie osiągnięć naukowo-badawczych

Rodzaj publikacji	Autorskie	Współautorskie	Razem
Publikacje w czasopiśmie wyróżnionym w wykazie MNiSW na liście A	2	1	3
Publikacja w recenzowanym czasopiśmie krajowym lub zagranicznym wymienionym w wykazie MNiSW (lista B)	16	9	25
Artykuły naukowe publikowane w recenzowanych czasopismach krajowych lub zagranicznych	5	1	6
Monografie	1	0	1
Rozdziały w monografiach indeksowanych w bazie Web of Science	0	1	1
Rozdziały w monografiach nie indeksowane w bazie WOS	3	2	5
Materiały konferencyjne indeksowane w bazie WOS	3	0	3
Materiały konferencyjne nie indeksowane w bazie WOS	4	3	7
Podręczniki akademickie	1	3	4
Razem publikacje	35	20	55
Wygłoszone referaty naukowe	13	2	15
RAZEM dorobek naukowo-badawczy	48	22	70

Tabela 3. Liczba punktów za publikacje

Przed uzyskaniem stopnia doktora nauk technicznych (z uwzględnieniem udziału procentowego)	Po uzyskaniu stopnia doktora nauk technicznych (z uwzględnieniem udziału procentowego)
38 (36)	386 (312)
Razem: 424 (348)	

Wskaźniki moich dokonań naukowych związanych z zaprezentowanym dorobkiem, zgodnie z Rozporządzeniem Ministra Nauki i Szkolnictwa Wyższego z dnia 1 września 2011 roku w sprawie kryteriów osiągnięć osoby ubiegającej się o nadanie stopnia doktora habilitowanego § 4 oraz § 5 zamieszczono w tabeli 4 (stan na dzień 24.09.2018).

Tabela 4. Wskaźniki dorobku naukowego

Wskaźnik	Wartość
Impact Factor	7.913
Cytowania WoS	22
Cytowania Google Scholar	132
Cytowania Scopus	34
Index Hirscha	2 (WoS) 6 (Google Scholar) 3 (Scopus)

Moim osiągnięciem naukowo-badawczym jest również udział w 12 projektach naukowo-badawczych, w tym w jednym jako kierownik, a w pozostałych jako wykonawca zadania. Szczegółowe informacje na ten temat zamieszczono w załączniku 4 w rozdziale II.H.

Jestem także recenzentem manuskryptów w czasopismach:

1. IEEE Transactions on Intelligent Transportation System, ISSN 1524-9050, (Lista A, 40 pkt. MNiSW).
2. Transportation Research Part D: Transport and Environment, ISSN 0965-8564, (Lista A, 35 pkt. MNiSW).
3. Archives of Transport System Telematics, ISSN 1899-8208, (Lista B, 11 pkt. MNiSW).

5. Działalność dydaktyczna

Prowadzę zajęcia dydaktyczne na Wydziale Transportu w Katowicach od 1993 roku. W latach 1998-2008 prowadziłam również zajęcia dydaktyczne w Wyższej Szkole Ekonomii i Administracji w Bytomiu.

Prowadzone przedmioty to: Informatyka, Technologie Informacyjne, Metody Sztucznej Inteligencji, Badania Operacyjne, Systemy Teleinformatyczne w Transporcie oraz Organizacja i Zarządzanie w Transporcie. Przygotowałam autorskie programy zajęć wykorzystujące zarówno pracę w laboratoriach, jak na platformie zdalnej edukacji. Zdobyte doświadczenie stało się podstawą opracowania podręczników.

Od roku 2003 jestem członkiem Wydziałowej Komisji Dydaktycznej, która zajmuje się m.in. przygotowaniem i wdrażaniem Krajowych Ram Kwalifikacji (KRK) na Wydziale Transportu Politechniki Śląskiej oraz weryfikacją i zatwierdzaniem programów kształcenia zgodnych z KRK.

5.1. Podręczniki akademickie

Jestem autorką lub współautorką czterech podręczników akademickich. Zestawienie zawiera tabela 6.

Tabela 6. Podręczniki akademickie

Lp.	Autor/Autorzy	Tytuł	Wydawnictwo, rok wydania, liczba stron
1	Pamuła T. Król A.	Badania operacyjne w przykładach z rozwiązaniami w Excelu	Wyd. Politechniki Śląskiej 2013, 180 s.
2	Pamuła T.	Aplikacje w Delphi. Przykłady. (3 wydania)	Gliwice, Helion, 2003, 260 s. Wydanie 2. Helion Gliwice, 2007, 354 s. Wydanie 3, Helion Gliwice 2011, 414 s. <i>E-book</i> w 2013.
3	Pamuła T., Krawiec S:	Programowanie strukturalne i obiektowe w Delphi.	Gliwice: Wyd. Politechniki Śląskiej, 2005, 316 s.
4.	Pamuła T., Krawiec S.	Budowa aplikacji w Delphi.	Wyd. Bytom: WSEiA, 2005, 292 s. ISBN 83-88587-12-9

5.2. Inne

Jestem promotorem 15 prac dyplomowych magisterskich i 30 inżynierskich.

W latach 2012-2013 uczestniczyłam w międzynarodowej wymianie nauczycieli akademickich – Teaching Staff Mobility w ramach programu LLP Erasmus.

Prowadziłam wykłady w takich ośrodkach akademickich, jak:

- 1) Vilnius University of Applied Engineering Sciences 2012 (Litwa),
- 2) University of Szeged 2013 (Węgry).

Tematy wykładów:

- 1) “Prediction of traffic volume using neural networks”
- 2) “Neural Networks. Construction, Operation and Application”

6. Działalność organizacyjna

2003 – 2013 Sekretarz prac dyplomowych w Katedrze Systemów Informatycznych Transportu oraz w Katedrze Inżynierii Ruchu

2003 – obecnie – Koordynator do spraw obciążeń dydaktycznych w Katedrze Systemów In-

formatycznych Transportu oraz w Katedrze Systemów Transportowych i Inżynierii Ruchu
2003 – obecnie – Członek Komisji Dydaktycznej na Wydziale Transportu

2011 – obecnie – Członek Komisji Rekrutacyjnej na Wydziale Transportu

2013 – 2014 – członek komisji maturalnych w szkołach średnich, które podpisały umowę o tzw. maturach łączonych.

Funkcje organizacyjne w konferencjach:

2009 – członek Komitetu Organizacyjnego Konferencji Telematyka, Logistyka i Bezpieczeństwo Transportu TLTS 2009

2011 – członek Komitetu Organizacyjnego Konferencji Telematyka, Logistyka i Bezpieczeństwo Transportu TLTS 2011.

7. Uzyskane nagrody, wyróżnienia i odznaczenia.

Za pracę dydaktyczną oraz organizacyjną otrzymałam następujące nagrody:

1. Rok 2003 - Zespołowa Nagroda Rektora stopnia 3 za osiągnięcia w dziedzinie organizacyjnej
2. Rok 2005 - Zespołowa Nagroda Rektora stopnia 3 za osiągnięcia w dziedzinie dydaktycznej
3. Rok 2007 - Zespołowa Nagroda Rektora stopnia 2 za osiągnięcia w dziedzinie organizacyjnej
4. Rok 2009 - Zespołowa Nagroda Rektora stopnia 2 za osiągnięcia organizacyjne
5. Rok 2011 - Zespołowa Nagroda Rektora stopnia 2 za osiągnięcia organizacyjne
6. Rok 2013 - Zespołowa Nagroda Rektora stopnia 2 za osiągnięcia dydaktyczne
7. Rok 2014 - Zespołowa Nagroda Rektora stopnia 3 za osiągnięcia dydaktyczne
8. Rok 2015 - Zespołowa Nagroda Rektora stopnia 3 za osiągnięcia organizacyjne
9. Rok 2016 – Zespołowa Nagroda Rektora stopnia 3 za osiągnięcia organizacyjne
10. Rok 2007 – Brązowy medal za długoletnią służbę.

J. Pamte