



Imię i nazwisko autora rozprawy: Anna Jakubczyk–Gałczyńska  
Dyscyplina naukowa: Budownictwo

## **ROZPRAWA DOKTORSKA**

Tytuł rozprawy w języku polskim: **Prognozowanie wpływu drgań komunikacyjnych na budynki mieszkalne za pomocą sztucznych sieci neuronowych i maszyn wektorów wspierających**

Tytuł rozprawy w języku angielskim: **Forecasting the impact of traffic-induced vibrations on residential buildings using artificial neural networks and support vector machines**

Promotor
<i>podpis</i>
prof. dr hab. inż. Robert Jankowski
Promotor pomocniczy
<i>podpis</i>
dr inż. Adam Kristowski

*Pragnę serdecznie podziękować  
promotorowi prof. dr hab. inż. Robertowi Jankowskiemu  
oraz promotorowi pomocniczemu dr inż. Adamowi Kristowskiemu  
za pomoc, inspiracje i bardzo cenne uwagi,  
dr inż. Tomaszowi Falborskiemu i mgr inż. Natalii Lasowicz  
oraz mężowi Patrykowi Gałczyńskiemu za pomoc przy pomiarach,  
mieszkańcom, którzy udostępnili swoje domy w celach badawczych  
oraz mojej rodzinie za cierpliwość i wsparcie.*



## OŚWIADCZENIE

Autor rozprawy doktorskiej: mgr inż. Anna Jakubczyk–Gałczyńska

Ja, niżej podpisany(a), wyrażam zgodę/~~nie wyrażam zgody~~\* na bezpłatne korzystanie z mojej rozprawy doktorskiej zatytułowanej:

**Prognozowanie wpływu drgań komunikacyjnych na budynki mieszkalne za pomocą sztucznych sieci neuronowych i maszyn wektorów wspierających**

do celów naukowych lub dydaktycznych.<sup>1</sup>

Gdańsk, dnia .....

.....  
*podpis doktoranta*

Świadomy(a) odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (Dz. U. Z 2006 r., nr 90, poz. 631) i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym (Dz. U. Z 2012 r., poz. 572 z późn. Zm.),<sup>2</sup> a także odpowiedzialności cywilno–prawnej oświadczam, że przedkładana rozprawa doktorska została napisana przeze mnie samodzielnie.

Oświadczam, że treść rozprawy opracowana została na podstawie wyników badań prowadzonych pod kierunkiem i w ścisłej współpracy z promotorem prof. dr hab. inż. Robertem Jankowskim, promotorem pomocniczym dr inż. Adamem Kristowskim.

Niniejsza rozprawa doktorska nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem stopnia doktora.

Wszystkie informacje umieszczone w ww. rozprawie uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami zgodnie z art. 34 ustawy o prawie autorskim i prawach pokrewnych.

Potwierdzam zgodność niniejszej wersji pracy doktorskiej z załączoną wersją elektroniczną.

Gdańsk, dnia .....

.....  
*podpis doktoranta*

Ja, niżej podpisany(a), wyrażam zgodę/~~nie wyrażam zgody~~\* na umieszczenie ww. rozprawy doktorskiej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej, Pomorskiej Bibliotece Cyfrowej oraz poddawania jej procesom weryfikacji i ochrony przed przywłaszczeniem jej autorstwa.

Gdańsk, dnia .....

.....  
*podpis doktoranta*

\*) niepotrzebne skreślić

<sup>1</sup> Zarządzenie Rektora Politechniki Gdańskiej nr 34/2009 z 9 listopada 2009 r., załącznik nr 8 do instrukcji archiwalnej PG.

<sup>2</sup> Ustawa z dnia 27 lipca 2005 r. Prawo o szkolnictwie wyższym: Rozdział 7 Odpowiedzialność dyscyplinarna doktorantów, Art. 226.





## **OPIS ROZPRAWY DOKTORSKIEJ**

**Autor rozprawy doktorskiej:** mgr inż. Anna Jakubczyk–Galczyńska

**Tytuł rozprawy doktorskiej w języku polskim:** Prognozowanie wpływu drgań komunikacyjnych na budynki mieszkalne za pomocą sztucznych sieci neuronowych i maszyn wektorów wspierających

**Tytuł rozprawy w języku angielskim:** Forecasting the impact of traffic–induced vibrations on residential buildings using artificial neural networks and support vector machines

**Język rozprawy doktorskiej:** polski

**Promotor rozprawy doktorskiej:** prof. dr hab. inż. Robert Jankowski

**Promotor pomocniczy rozprawy doktorskiej:** dr inż. Adam Kristowski

**Data obrony:**

**Słowa kluczowe rozprawy doktorskiej w języku polski:** drgania komunikacyjne, uczenie maszynowe, sztuczne sieci neuronowe, maszyny wektorów wspierających

**Słowa kluczowe rozprawy doktorskiej w języku angielskim:** traffic–induced vibrations, machine learning, artificial neural networks, support vector machines







**Streszczenie rozprawy w języku polskim:** Drgania komunikacyjne mogą stanowić duże obciążenie eksploatacyjne budynku, powodując zarysowania i spękania tynków, odpadanie wypraw, zarysowania konstrukcji, pęknięcie elementów konstrukcji lub nawet zawalenie się budynku. Pomiary drgań na rzeczywistych konstrukcjach są pracochłonne i kosztowne, a co ważne nie w każdym przypadku są one uzasadnione. Celem pracy jest analiza autorstwa algorytmu, dzięki któremu z dużym prawdopodobieństwem można przewidzieć zagrożenie negatywnego oddziaływania dynamicznego na dany budynek mieszkalny. Do prognozy oddziaływań dynamicznych wywołanych ruchem kołowym utworzono modele oparte na dwóch metodach: sztucznych sieciach neuronowych oraz maszynach wektorów wspierających. Do utworzenia algorytmów użyto polowych badań własnych wykonanych zgodnie z normą PN-85/B-02170 oraz przykładów zaczerpniętych z literatury. Wyniki przeprowadzonych analiz pokazują, iż obie metody mogą być dobrymi narzędziami w prognozowaniu wpływu drgań komunikacyjnych na budynki mieszkalne odznaczając się dużą wiarygodnością.

**Streszczenie rozprawy w języku angielskim:** Traffic-induced vibrations may constitute a considerable load to a building, may cause cracking of plaster, cracks in load-bearing elements or even collapse of the whole structure. Measurements of vibrations of real structures are costly and laborious and, what is important, they are not justified in all the cases. The aim of the work is the analysis of original algorithm, which allows us to predict with high probability the negative dynamic impact on the examined residential building. The models for forecasting the impact of vibrations on buildings have been based on two methods: artificial neural networks and support vector machines. Own field studies carried out according to the Polish standard PN-85/B-02170 and examples taken from the literature have been used to create the algorithms. The results of the conducted analysis show that both methods can be considered as good tools for predicting the impact of traffic-induced vibrations on residential buildings, being characterized by high reliability.



## SPIS TREŚCI

NAJWAŻNIEJSZE SKRÓTY STOSOWANE W PRACY .....	7
1. WSTĘP .....	8
1.1. Wprowadzenie .....	8
1.2. Analiza stanu wiedzy .....	10
1.3. Cel, zakres i teza naukowa .....	15
2. DRGANIA KOMUNIKACYJNE .....	17
2.1. Definicja i geneza drgań .....	17
2.2. Wpływ drgań komunikacyjnych na budynki mieszkalne i przebywających w nich ludzi .....	19
2.3. Metodyka pomiarowa wpływu drgań komunikacyjnych na budynki mieszkalne .....	22
2.4. Wpływ drgań komunikacyjnych na przebywających w budynkach ludzi .....	25
2.5. Drgania komunikacyjne a hałas .....	28
2.6. Metody redukcji wpływu drgań .....	28
3. BADANIA EKSPERYMENTALNE DRGAŃ KOMUNIKACYJNYCH .....	30
4. RYZYKO I ALGORYTMY WSPOMAGAJĄCE PODEJMOWANIE DECYZJI .....	58
4.1. Ryzyko i metody jego szacowania .....	58
4.2. Ryzyko uszkodzeń budynków spowodowanych drganiami komunikacyjnymi .....	59
4.3. Sztuczne sieci neuronowe .....	60
4.4. Maszyny wektorów wspierających .....	65
5. BUDOWA ALGORYTMU SZTUCZNYCH SIECI NEURONOWYCH .....	73
5.1. Informacje wejściowe i wyjściowe .....	73
5.2. Informacje techniczne tworzenia SSN .....	73
5.3. Utworzone sztuczne sieci neuronowe .....	80
6. BUDOWA ALGORYTMU MASZYN WEKTORÓW WSPIERAJĄCYCH .....	136
6.1. Informacje wejściowe i wyjściowe .....	136
6.2. Informacje techniczne tworzenia MWW .....	136
6.3. Utworzone maszyny wektorów wspierających .....	137
7. PODSUMOWANIE i WNIOSKI KOŃCOWE .....	158
7.1. Wyniki dla sztucznych sieci neuronowych .....	158
7.2. Wyniki dla maszyn wektorów wspierających .....	160
7.3. Porównanie wyników SSN – MWW .....	161
7.4. Uwagi ogólne .....	162
7.5. Kierunki dalszych badań .....	163
7.6. Elementy oryginalne pracy .....	163
8. BIBLIOGRAFIA .....	165
9. SPIS RYSUNKÓW .....	172
10. SPIS TABEL .....	174

## NAJWAŻNIEJSZE SKRÓTY STOSOWANE W PRACY

B <sub>DO</sub>	odległość budynku od krawędzi drogi
BFGS	algorytm uczenia <i>Broyden–Fletcher–Goldfarb–Shanno</i>
B <sub>ST</sub>	stan techniczny budynku
D <sub>N</sub>	rodzaj nawierzchni drogi
D <sub>STN</sub>	stan techniczny nawierzchni drogi
G <sub>A</sub>	absorpcja drgań w gruncie
MWW	maszyna wektorów wspierających
P	typ pojazdu
RBF	radialne funkcje bazowe
SSN	sztuczna sieć neuronowa
SWD I	skala wpływów dynamicznych I
SWD II	skala wpływów dynamicznych II

## 1. WSTĘP

### 1.1. Wprowadzenie

Drgania komunikacyjne wywołane ruchem pojazdów kołowych i szynowych generują negatywne skutki eksploatacyjne, zarówno dla budynków jak i mieszkańców obiektów poddanych tym oddziaływaniom dynamicznym. Drgania wywołane ruchem drogowym mogą mieć ogromny wpływ na ludzi znajdujących się w zasięgu ich występowania, ponadto ruch kołowy powoduje hałas uciążliwy dla mieszkańców. Problem ten jest szczególnie zauważalny, kiedy ludzie narażeni są na długotrwałe obciążenia drganiami i hałasem (zob. np. Kawecki i Stypuła, 2013).

Problem występowania drgań coraz bardziej narasta, ponieważ coraz więcej obszarów podlega urbanizacji. Budowane są nowe drogi, zarówno w miastach, na ich obrzeżach, a także na terenach wiejskich coraz więcej budynków powstaje w pobliżu dróg. Obszary, które są dobrze skomunikowane, są chętnie zabudowywane i zamieszkiwane. W związku z tym, drgania w budynkach spowodowane ruchem pojazdów dotyczą coraz większej liczby domów istniejących jak i projektowanych.

Biorąc pod uwagę skutki drgań spowodowanych ruchem drogowym na budynki, mogą być one niezauważalne lub nawet mogą spowodować awarię budowlaną. Drgania występujące stale, zwłaszcza w dolnych pasmach częstotliwości, powodują szybszą konsolidację gruntu i w związku z tym nierównomierne, przyspieszone osiadanie (Hunaidi, 2000). Długotrwałe obciążenie wibracjami może być poważnym obciążeniem dla budynku. Powoduje ono zarysowania i spękania tynków, odpadanie wypraw, zarysowania konstrukcji, pękanie elementów konstrukcji lub nawet zawalenie się budowli (Ciesielski i Maciąg, 1990; Kawecki, 2015). Na szkodliwość oddziaływania drgań na elementy budynku wpływ ma wiele czynników dotyczących drogi, po której poruszają się pojazdy. Istotne są również parametry dynamiczne samego obiektu budowlanego. Pomiar drgań na rzeczywistych konstrukcjach są pracochłonnymi i kosztownymi przedsięwzięciami, a co ważne, nie w każdym przypadku uzasadnionymi.

Już w fazie projektowania, a później także w fazie eksploatacji, należy zwrócić szczególną uwagę na możliwość występowania drgań komunikacyjnych. Według normy PN-85/B-02170 można na ogół pominąć obciążenie budynku wywołane drganiami przekazywanymi przez podłoże, jeżeli budynek znajduje się:

- w odległości większej niż 25 m od osi linii kolejowej;
- w odległości większej niż 15 m od osi linii tramwajowej albo osi drogi kołowej I kategorii lub ulicy przelotowej.

Zatem jeśli budynek znajduje się w odległości mniejszej niż wskazuje norma, zaleca się sprawdzenie wpływu drgań. Po wykonaniu badań polowych przy użyciu specjalistycznego sprzętu dość często okazuje się jednak, że nie ma bezpośredniego zagrożenia dla konstrukcji. Przeprowadzanie takich badań dla wszystkich budynków zlokalizowanych przy drodze może okazać się więc nieopłacalne z ekonomicznego punktu widzenia. Nowoczesna, wciąż rozwijająca się technologia przynosi szereg możliwości rozwiązania tego typu problemów. Pojawia się zatem potrzeba opracowania efektywnych metod prognozowania wpływu drgań komunikacyjnych na budynki mieszkalne. Znaczenie mają tutaj eksperci, którzy dzięki doświadczeniu i zdobytej wiedzy przekazują informacje, które stanowią podstawę programów i systemów obliczeń. Celem działań jest więc utworzenie systemu eksperckiego, dzięki któremu można przewidzieć z pewnym prawdopodobieństwem zagrożenie negatywnego oddziaływania dynamicznego na badany budynek, nie wykonując pracochłonnych pomiarów polowych. Istnieje wiele metod służących do prognozowania różnego typu zjawisk, zaczynając od drzew decyzyjnych, analizy ryzyka (zob. Jaśkowski i Biruk, 2011) poprzez statystyki i algorytmy losowe (np. Jaśkowski i Sobotka, 2006), aż po sztuczną inteligencję i uczenie maszynowe (zob. Michalski i in., 1983).

Sztuczna inteligencja (z ang. *artificial intelligence*) jest bardzo obszerną interdyscyplinarną dziedziną nauk. Podstawową cechą systemów sztucznej inteligencji jest wzorowanie się na żywej istocie i zjawiskach jakie zachodzą w jej życiu. Przykładem są tutaj Sztuczne Sieci Neuronowe (SSN), algorytmy ewolucyjne, czy też roboty tworzone na wzór człowieka. Autorem terminu *sztuczna inteligencja* był John McCarthy (1956). Od tego czasu nastąpił przełom w nauce, rozpoczął się okres intensywnego rozwoju tego obszaru badań. Celem naukowców było między innymi wykorzystanie zdobytej wiedzy do rozwiązywania bieżących problemów, ale przede wszystkim poszukiwanie optymalnych (w różnym zakresie) algorytmów.

Dzisiejsza nauka bogata jest w wiele systemów wspomagających podjęcie decyzji, narzędzi badawczych i programów komputerowych niezbędnych do ich zastosowania. Problemem jest zatem znalezienie takich rozwiązań, aby były one zarówno przydatne jak i tanie. Dlatego coraz częściej stosuje się metody przybliżone. Najważniejsze, aby metody te umożliwiły rozwiązanie problemu inżynierskiego na tyle dokładnie, aby wynik był zadowalający, nawet jeżeli jest przybliżony.

Nauka o sztucznej inteligencji składa się z wielu kooperujących ze sobą dziedzin, w skład których wchodzi między innymi uczenie maszynowe (z ang. *machine learning*). Jest to metodyka oparta na zastosowaniu inteligentnych algorytmów, metod statystycznych i optymalizacyjnych w rozwiązywaniu problemów takich jak klasyfikacja, regresja (uczenie z nadzorem, z ang. *supervised learning*), ale także klasteryzacja i redukcja wymiarów (uczenie bez nadzoru,

z ang. *unsupervised learning*). Przykładem metodyki uczenia maszynowego jest algorytm oparty na Maszynach Wektorów Wspierających (MWW).

Pomysł zastosowania uczenia maszyn pojawił się już w 1952 roku, kiedy to Arthur Samuel z firmy IBM, rozpoczął budowę programu komputerowego do szkolenia zawodników szachowych (Copeland i Proudfoot, 2000). Pojęcie uczenia maszyn pojawiło się po raz pierwszy w 1983r. w publikacji Michalskiego i in. (1983). Cel i sens działania maszyn uczących się opisał w prostej definicji Tom Michael Mitchell w podstawowej pozycji bibliograficznej dotyczącej algorytmów sztucznej inteligencji (Mitchell, 1997). Definicja ta brzmi: „*W odniesieniu do danego rodzaju zadań, maszyna (program komputerowy) uczy się z doświadczenia, mierząc wydajność, która poprawia się wraz ze zwiększeniem doświadczeń*”.

## 1.2. Analiza stanu wiedzy

Temat rozprawy łączy naukę o dynamice budowli z nauką o sztucznej inteligencji i podejmowaniu decyzji. Podstawowym źródłem wiedzy dotyczącej wpływu drgań na budynki jest polska norma PN-85/B-02170 oraz specjalistyczna literatura z tej dziedziny (zob. np. Ciesielski i Maciąg, 1990; Kuźniar, 2002; Stypuła i Kawecki, 2008; Dulińska i in., 2014; Stypuła, 2015).

W dzisiejszej inżynierii istnieje wiele metod pozwalających na rozwiązywanie problemów związanych z prognozowaniem różnego typu zjawisk. Przykładem są wspomniane wcześniej SSN, które wykorzystuje się w różnych celach, poczynając od diagnostyki układów elektrycznych (Kowalski i Ewert, 2009), poprzez badania psychiatryczne (Duch, 2000), prognozy giełdowe (Domaradzki, 2007) czy analizę produkcji i dystrybucji (Jurczyk, 2011; Koszela i in., 2005).

Sieci neuronowe mają również swoje zastosowanie w inżynierii lądowej. Janas i Miller (2011) wykorzystali SSN do stworzenia rankingu obiektów mostowych. Celem autorów było stworzenie systemu, który na podstawie kilku czynników mógłby określić, czy dany obiekt mostowy wymaga natychmiastowego remontu, czy też istnieją obiekty, które powinny być umieszczone wyżej na liście rankingowej. Uzyskane wyniki pokazują, że algorytm SSN średnio wykazywał pomyłkę o jedną pozycję na liście planowanych remontów, a maksymalnie pomylił się o 7 pozycji, względem niezależnej listy utworzonej przez ekspertów. Ze względu na zadowalające wyniki działania systemu, wykorzystano go w Generalnej Dyrekcji Dróg Krajowych i Autostrad.

Kogut (1999) zastosował algorytmy SSN w problemach drogownictwa. Celem analiz było określenie czasu krytycznego potrzebnego do przejechania przez dwupasmową drogę główną

w Ohio (USA) podczas ruchu pojazdów przy dopuszczalnej prędkości 55 mil/h. Autor wziął pod uwagę różne czynniki środowiskowe, meteorologiczne, ekologiczne oraz społeczne. Sieć poprawnie sklasyfikowała 87,5% prawidłowych reakcji przy błędzie dopuszczalnym 5%. Jednym z kolejnych zagadnień rozpatrywanych przez Koguta (1999) było określenie oczekiwanego poziomu zanieczyszczenia powietrza tlenkiem węgla w obrębie skrzyżowań w centrum Seattle (USA). W tym przypadku sieć prawidłowo opisała 70% danych testujących.

Sieci neuronowe znalazły zastosowanie w inżynierii parasejsmicznej w prognozowaniu wpływu drgań pochodzenia górniczego na budynki (zob. np. Kuźniar, 2002; Kuźniar i Waszczyszyn, 2003; Kuźniar, 2011; Chudyba, 2011; Kuźniar i Chudyba, 2013). Kuźniar (2002) przedstawiła wykorzystanie SSN do wyznaczania odpowiedzi dynamicznej budynków z elementów prefabrykowanych. W pracy porównano również wyniki sieci z badaniami rzeczywistymi, co potwierdziło możliwość zastosowania SSN do tego typu problemów. Kuźniar i Waszczyszyn (2003) zastosowali SSN do określania oddziaływań dynamicznych spowodowanych poprzez wybuchy w kamieniołomach na 5-cio piętrowe budynki. Chudyba (2011) analizował wrażliwość parametrów na wybór rodzaju SSN do prognozowania wpływów parasejsmicznych. Kuźniar i Chudyba (2013) zaproponowali zastosowanie SSN do predykcji przekazywania składowych prędkości oraz przyspieszeń drgań z gruntu na fundament budynku mieszkalnego zlokalizowanego w strefie wpływu drgań pochodzenia górniczego w Legnicko-Głogowskim Okręgu Miedziowym.

Urbański (2004) przedstawił kolejne zastosowanie SSN w budownictwie, jakim jest ocena stopnia zużycia technicznego mieszkalnych budynków zabytkowych. Celem badań było określenie, które z rozpatrywanych czynników mają duży, a które mniej istotny wpływ na stan techniczny badanego obiektu. Autor zbudował bazę danych na podstawie licznej dokumentacji i ankiet, protokołów z okresowych kontroli budynków wzniesionych w technologii tradycyjnej przed rokiem 1918. Analizie poddano 229 obiektów. Utworzono sieć neuronową, w której jako sygnały wejściowe przyjęto czynniki mające wpływ na zużycie techniczne budynku, tj. wiek budynku, rodzaj zabudowy, rodzaj poddasza i pokrycia dachowego, sposób podpiwniczenia, warunki gruntowe, występowanie wód gruntowych, natężenie ruchu ulicznego, zdarzenia losowe oraz sposób zarządzania obiektem. Otrzymane wyniki porównano z innymi metodami uzyskując zadowalający wynik mieszczący się w granicy przyjętego błędu (20%). Analizując wagi sygnałów wejściowych, okazało się, że najistotniejszy wpływ na zużycie budynków ma sposób utrzymania i pokrycie dachu. Obiektywnie rzecz biorąc, sposób pozyskania danych, jakim była jedynie ocena wizualna budynków, może budzić jednak pewne wątpliwości, co do zasadności praktycznego wykorzystania stworzonego przez autora systemu.



W kolejnym artykule, Yeung i Smith (2005) przedstawili zastosowanie sieci neuronowych do wykrywania uszkodzeń mostów. Autorzy poddali badaniom model rzeczywistej konstrukcji ponad 100 letniego mostu wiszącego podczas różnych scenariuszy symulujących obciążenia. Wykorzystując sieci neuronowe wykazali, że algorytmy te z wystarczająco dużym prawdopodobieństwem prognozują odpowiedź konstrukcji na zadawane obciążenia, nawet przy zakłóceniach związanych z zaszumieniem danych.

Sieci neuronowe znalazły również zastosowanie w ocenie odpowiedzi budynków na wpływy sejsmiczne. Praktyczne zastosowanie sieci przedstawiono w artykule Huang'a i in. (2003). Praca dotyczy wyznaczania charakterystyk dynamicznych budynku i diagnozowania przy użyciu SSN, czy budynek został zniszczony przez trzęsienie ziemi. Autorzy wykonywali pomiary przyspieszeń wprowadzając wymuszenia na stole wstrząsowym dla modelu 5-piętrowego budynku dla trzęsienia ziemi w Kobe (17.01.1995).

De Stefano i in. (1999) przedstawili metodę przetwarzania danych gromadzonych przez Krajową Grupę Obrony przed Trzęsieniami Ziemi (*Gruppo Nazionale per la Difesa dai Terremoti*). Celem analizy było stworzenie systemu klasyfikującego obiekty pod względem ich podatności na wpływy sejsmiczne, określającego prawdopodobieństwo wystąpienia uszkodzeń, wykorzystując do tego sieci neuronowe jak również twierdzenie Bayesa o prawdopodobieństwie warunkowym.

Sztuczne sieci wykorzystano także do przewidywania uszkodzeń połączeń konstrukcji stalowych podczas trzęsień ziemi (Yun i in., 2001). Do analiz numerycznych wykorzystano model 10-piętrowej konstrukcji ramowej, a do badań eksperymentalnych model konstrukcji 2-piętrowej. Stworzono algorytm, który w prosty sposób szacuje uszkodzenia połączeń w analizowanym typie konstrukcji.

W dwuczęściowej publikacji, Bani i in. (1999a, 1999b) opisali zastosowanie algorytmów SSN do kontroli konstrukcji budynków narażonych na skutki trzęsień ziemi. Podstawą systemu były badania eksperymentalne na modelu 3-piętrowego budynku, które umożliwiły pozyskanie informacji wejściowych do sieci. Wyniki pokazały, iż SSN są dobrym narzędziem do przewidywania skutków trzęsienia.

Inne zastosowanie SSN opisano w publikacji Ghaboussi'ego i Lin'a (1998). W tym przypadku sieci wykorzystano zarówno do zmniejszenia liczby parametrów wejściowych jak i do wyznaczania spektrum odpowiedzi konstrukcji posługując się danymi zapisanymi łącznie w 30 punktach pomiarowych podczas dziewięciu trzęsień ziemi.





Wykorzystanie maszyn wektorów wspierających nie jest tak powszechne jak zastosowanie SSN, choć znaleźć można praktyczne koncepcje ich zastosowania również w inżynierii. Pionierskie systemy użyto do rozpoznawania obrazu na podstawie klasyfikacji liniowej wzorów z maksymalnym marginesem (Vapnik i Lerner, 1963). Kolejnym przykładem zastosowania MWW jest aplikacja mająca na celu rozpoznawanie mowy, w której wykorzystano metodę wektorów wspierających do identyfikacji mowy (Schmidt i Gish, 1996; Kasprzak, 2009).

Ciekawą implementacją MWW jest publikacja Joachims'a (1998), w której podjęto problem rozpoznawania tekstu. Autor wykazał, że metoda MWW przynosi bardzo dobre rezultaty w odniesieniu do problemu kategoryzacji tekstu w porównaniu, na przykład, do sieci Bayes'a czy też metody K–najbliższych sąsiadów.

Metodę MWW wykorzystano także w inżynierii geotechnicznej do wyznaczania możliwości upłynnienia gruntu na podstawie testów geotechnicznych wykonywanych w naturalnych warunkach (Pal, 2006).

Z kolei, Vanajakshi i Rilett (2004) przedstawili porównanie SSN i MWW użytych do prognozowania prędkości i czasu pokonywania podróży. Autorzy, na podstawie danych z autostrad w San Antonio w Teksasie (USA), opracowali system do przewidywania prędkości pojazdów oraz czasu podróży biorąc pod uwagę rzeczywiste dane czasowe i dane historyczne.

Metoda MWW ma także zastosowanie w medycynie. Przykładem może być algorytm do przewidywania chorób nowotworowych (Kim, 2016). Stworzony system ułatwił diagnozę chorób, a także podejmowanie decyzji lekarzy o dalszej hospitalizacji. Z kolei, Kołodziej i in. (2011) zaproponowali wykorzystanie MWW do analizy sygnałów podczas wykonywania badania elektroencefalografii (EEG). Podczas eksperymentu wykorzystano sygnał EEG zarejestrowany za pomocą 32 elektrod. Osoba badana miała za zadanie wykonywanie trzech czynności: ruch prawą ręką, ruch lewą ręką oraz wypowiedzenie słów zaczynających się na zadanej literze. Otrzymane wyniki posłużyły do utworzenia algorytmu, którego celem była jak najlepsza klasyfikacja tych zdarzeń. Autorzy potwierdzili, że MWW jest dobrym narzędziem do tego typu badań.

Metoda MWW znalazła również zastosowanie w ekonomii, na przykład do klasyfikacji podatników i zmian w ich budżecie na podstawie zebranych danych z przeprowadzanych kontroli podatkowych (Budziski i Misztal, 2009).

Inne praktyczne zastosowanie MWW przedstawiono w publikacji Goszczyńskiego (2006). Celem badań w tym przypadku było utworzenie inteligentnej kosiarki wyposażonej w system rozpoznawania obrazu w jej otoczeniu.

Z kolei, Chen i in. (2005) wykorzystali system SSN oraz MWW do wykrywania włamywaczy. Na podstawie danych o włamaniach utworzono algorytmy mające na celu wykrycie intruza w strefie działania monitoringu. Wyniki analizy pokazały, że w tego typu problemach najlepszym rozwiązaniem jest zastosowanie metody MWW, która wykazała najmniej pomyłek.

Uczenie maszynowe zastosowano również w problemach eksploatacji budynków. Przykładem jest publikacja Wabika (2012), w której przedstawiono system oparty na technikach sztucznej inteligencji i uczenia maszynowego wspomagający wykrycie zagrożenia, na przykład w postaci pożaru, na podstawie analizy obrazu pochodzącego z monitoringu. Z pokrewnych niżej pracy tematów przytoczyć należy także pracę Firka i in. (2016), której celem było utworzenie modelu zużycia technicznego budynków zlokalizowanych na terenach górniczych, poddanych oddziaływaniom parasejsmicznym. W artykule przedstawiono metody uczenia maszynowego, wykorzystane między innymi w predykcji stopnia zużycia eksploatacyjnego analizowanych obiektów budowlanych.

Ciekawe zastosowanie można również znaleźć w pracy Martínez'a-Rego i in. (2011). Autorzy przedstawili ideę wykrywania usterek w młynie wiatrowym. W artykule przenieśli drgania elementów konstrukcji w celu predykcji ich uszkodzeń. Założono różne scenariusze działania wiatraka porównując je z wynikami uzyskanymi z pomiarów polowych. Stwierdzono, że przewidywania za pomocą MWW są dokładniejsze nawet w przypadku zaszumionych danych.

Wykorzystywanie metod przybliżonych, również tych opartych na maszynowym uczeniu, jest ściśle związane z podejmowaniem pewnego ryzyka, ponieważ algorytm nigdy nie będzie w stanie wyznaczyć rozwiązania z wiarygodnością 100%. Dlatego ważne jest, oprócz samego modelowania algorytmu prognozującego, uwzględnienie zasady związanej z analizą ryzyka. Temat ten szeroko, w ujęciu interdyscyplinarnym, przedstawił Kaczmarek (2005). W książce przedstawione są definicje i metody zarządzania zgodnie z zapisami normowymi, a także praktyczne przykłady analiz ryzyka.

Ciekawymi przykładami zastosowania w praktyce analizy ryzyka jest zarządzanie harmonogramem przedsięwzięcia budowlanego z użyciem metody AHP (z ang. *Analytic Hierarchy Process*) i rozmytej metody AHP (Jaśkowski i Biruk, 2011; Jaśkowski i in., 2011). W artykułach podjęto problem specyfiki każdego projektu, indywidualnych warunków i występowanie zakłóceń opóźniających prace budowlane i przedstawiono przykładowe rozwiązania w celu optymalnego wykonywania projektów.

Ważną kwestię analizy ryzyka poruszył Szer (2012). W artykule przedstawiono problem katastrof budowlanych i ich nierzadko tragicznych skutków. Opisano także czynniki, które statystycznie najczęściej są przyczyną awarii budowlanych.

Inne zastosowanie analizy ryzyka przedstawiła Romanowska i in. (2017). W artykule przeanalizowano wypadki drogowe z udziałem pieszych. Przedstawiono ideę zarządzania bezpieczeństwem na drodze poprzez wprowadzenie do systemu zarządzania ruchem drogowym metod opartych na ocenie ryzyka i reakcji na jego występowanie.

Zwrócić należy również uwagę na zastosowanie technik szacowania ryzyka przy obliczaniu kosztów inwestycji i ich różnic wynikających z kalkulacji inwestora i oferentów (Grzyl i Kristowski, 2016). Zaproponowane rozwiązanie polega na zastosowaniu technologii BIM w celu wzbogacenia danych projektowych architektoniczno–budowlanych o analizę czasu realizacji, kalkulację kosztów inwestycji jako całości oraz jej poszczególnych etapów, a także analizę efektywności energetycznej.

Przegląd literatury wskazuje, że uczenie maszynowe może mieć szerokie zastosowanie, a wdrożenie tej metody w różnych dziedzinach może pozytywnie wpłynąć na rozwój technologii oraz na obniżenie kosztów przy jednoczesnej minimalizacji ryzyka wystąpienia skutków niepożądanych. Według wiedzy autorki, do tej pory nie wykorzystywano jednak sztucznej inteligencji do prognozowania wpływu drgań komunikacyjnych na budynki w odniesieniu do normy PN–85/B–02170, dlatego też próbę taką podjęto w niniejszej rozprawie.

### **1.3. Cel, zakres i teza naukowa**

#### **1.3.1. Cel i zakres pracy**

Celem niniejszej rozprawy jest budowa algorytmów do prognozowania wpływu drgań komunikacyjnych na budynki mieszkalne oraz sprawdzenie efektywności tych metod obliczeniowych. Pomiar drgań na rzeczywistych konstrukcjach są czasochłonne i kosztowne, a do ich wykonania potrzebny jest specjalistyczny sprzęt i personel. Jednocześnie brakuje prostych metod, które z dużą dozą prawdopodobieństwa umożliwiłyby prognozowanie zagrożenia powstającego wskutek drgań. Celem badawczym niniejszej pracy doktorskiej jest zatem utworzenie (algorytmizacja) i sprawdzenie efektywności zastosowania sztucznych sieci neuronowych oraz maszyn wektorów wspierających do prognozowania wpływu drgań wywołanych ruchem drogowym na budynki mieszkalne.

W trakcie wykonywania badań sklasyfikowano różne sytuacje pomiarowe według określonych kryteriów, które następnie wykorzystano do budowy autorskiego systemu opartego na

SSN i MWW (zob. Jakubczyk–Gałczyńska i in., 2017, 2018). Wybór obu metod przeanalizowanych w rozprawie jest efektem przeprowadzenia obszernej analizy i wielokrotnego podejmowania prób rozwiązania problemu prognozowania wpływu drgań za pomocą różnych technik.

Rozprawa składa się z 7 rozdziałów. W pierwszym rozdziale umieszczono wstęp, w którym przedstawiono wprowadzenie, cel, zakres i tezę naukową pracy, a także analizę obecnego stanu wiedzy w zakresie badanego problemu. W drugim rozdziale przedstawiono definicję oraz opisano problem występowania drgań. Opis przeprowadzonych badań pomiarowych drgań komunikacyjnych, wraz z metodyką, umieszczono w rozdziale trzecim. W rozdziale czwartym omówiono algorytmy statystyczne i matematyczne mające na celu wspomaganie podjęcia decyzji, a także przedstawiono część teoretyczną dotyczącą SSN i MWW. Piąty rozdział zawiera opis autorskiego algorytmu SSN prognozującego wpływ drgań komunikacyjnych na budynki mieszkalne, zaś w szóstym rozdziale opisano zaproponowany algorytm z wykorzystaniem MWW. W siódmym rozdziale pracy zestawiono wnioski z przeprowadzonych badań i analiz, przedstawiono propozycję dalszych badań w kontekście podjętego problemu, a także zestawiono elementy oryginalne pracy. Na końcu zestawiono bibliografię, a także umieszczono spis rysunków i tabel.

### **1.3.2. Teza naukowa rozprawy**

„Na podstawie zaproponowanego algorytmu opartego na SSN oraz na MWW można, z zadowalająco dużym prawdopodobieństwem, prognozować wpływ drgań komunikacyjnych na budynki mieszkalne”.

## **2. DRGANIA KOMUNIKACYJNE**

### **2.1. Definicja i geneza drgań**

Pojęcie drgań budynku ściśle związane jest z dynamiką budowli. Drgania to zjawisko przemieszczania się cząsteczek konstrukcji budowlanej wywołane najczęściej falami rozprzestrzeniającymi się w gruncie, czyli w ośrodku sprężystym i docierającymi do fundamentów (Dulińska i in., 2014). Istotne jest określenie źródła drgań, drogi propagacji oraz wskazanie odbiornika drgań, którym może być obiekt budowlany, człowiek lub urządzenia znajdujące się w budynku.

#### **2.1.1. Przepisy prawne dotyczące drgań komunikacyjnych**

Dulińska i in. (2014) zwracają uwagę na narastający problem związany z wpływem drgań komunikacyjnych na budynki, ze szczególnym podkreśleniem obiektów projektowanych. Kryterium oceny oddziaływań, zarówno na obiekty budowlane jak i na ludzi, nie jest powszechnie znane i wykorzystywane w budownictwie. W przepisach prawnych również brak jest zapisu związanego z obowiązkiem przeprowadzania oceny wpływów dynamicznych. Istnieją jednak pewne regulacje prawne w Polsce, które dotyczą analizowanego zagadnienia. Istotnym jest tutaj ustawa „Prawo budowlane” z dnia 7 lipca 1994r., w którym w artykule 5 pkt.1 zobowiązuje się do projektowania i budowania obiektów budowlanych, zapewniając między innymi (zob. podpunkt e) spełnienie wymagań podstawowych dotyczących ochrony przed hałasem i drganiami. Jednak nie istnieje żadna weryfikacja tego przepisu podczas wydawania zgody na rozpoczęcie robót lub zgody na zamieszkanie. W związku z tym, analiza wpływów drgań na budynki i na przebywających w nim ludzi nie jest wykonywana, jeśli nie zostanie zgłoszona taka potrzeba ze strony inwestora.

Więcej wymagań znaleźć można w innych przepisach polskich, które określają drgania i hałas jako zanieczyszczenie środowiska. Mowa tutaj o ustawie „Prawo ochrony środowiska” z dnia 27 kwietnia 2001r., w której to w artykule 3 znaleźć można informacje o zanieczyszczeniu, przez które rozumie się emisję (bezpośrednio lub pośrednio), w wyniku działalności człowieka, do powietrza, wody, gleby lub ziemi m.in. hałasu i wibracji. Emisja ta nazwana jest dalej zanieczyszczeniem, które może być szkodliwe dla zdrowia ludzi lub stanu środowiska, może powodować szkodę w dobrach materialnych, może pogarszać walory estetyczne środowiska lub może kolidować z innymi, uzasadnionymi sposobami korzystania ze środowiska. W kolejnych artykułach ustawy „Prawo ochrony środowiska” (art. 6, 7, 137, 139, 147a) mowa jest o odpowiedzialności za środowisko, a także o odpowiedzialności finansowej za usunięcie szkody

oraz o odpowiedzialności prawnej. Istnieje również zapis, aby przeciwdziałać zanieczyszczeniom, co ma polegać na zapobieganiu lub ograniczaniu wprowadzania do środowiska substancji lub energii. Przestrzeganie wymagań ochrony środowiska związanych z eksploatacją dróg, linii kolejowych, linii tramwajowych, lotnisk oraz portów zapewniają zarządzający tymi obiektami (art. 139). Z kolei, w artykule 147a mowa jest o tym, że pomiary „zanieczyszczeń”, w tym drgań, mogą być dokonywane jedynie przez uprawnione i akredytowane laboratoria.

### 2.1.2. Rodzaje oddziaływań przenoszonych przez grunt

Drgania przenoszące się przez grunt, ze względu na pochodzenie, można podzielić na: sejsmiczne (niezależne od działalności człowieka, spowodowane trzęsieniem ziemi, zob. np. Jankowski, 2015; Jankowski i Mahmoud, 2015, 2016; Naderpour i in., 2016) oraz parasejsmiczne wywołane działaniem człowieka (zob. np. Jakubczyk–Gałczyńska i in., 2014, 2016a, 2016b). W ramach drgań parasejsmicznych można wyróżnić (Dulińska i in., 2014):

- wstrząsy górnicze,
- oddziaływania komunikacyjne, spowodowane przejazdem pojazdów kołowych i szynowych (także podziemnych),
- oddziaływania związane z wybuchami kontrolowanymi (np. wyburzenia),
- oddziaływania towarzyszące pracom budowlanym (np. wbijanie pali, ścianek szczelnych),
- oddziaływania powstałe wskutek eksploatacji ciężkich maszyn i urządzeń,
- oddziaływania związane z upadkiem dużych elementów (np. upadek wyburzanego kolumny).

Fale, które rozprzestrzeniają się w ośrodku sprężystym, jakim jest grunt, to fale podłużne i poprzeczne (Dulińska i in., 2014). Oprócz tego występują również fale powierzchniowe tak zwane fale Rayleigha i fale Love'a. Prędkość rozchodzenia się fal można wyznaczyć ze wzorów (Dulińska i in., 2014):

$$V_P = \sqrt{\frac{E(1-\nu)}{(1+\nu)(1-2\nu)\rho}} \quad (2.1)$$

$$V_S = \sqrt{\frac{E}{2(1+\nu)\rho}} = \sqrt{\frac{G}{\rho}} \quad (2.2)$$

$$V_L = 0,9 \sqrt{\frac{G}{\rho}} \quad (2.3)$$

gdzie:

$V_P$  – prędkość fali podłużnej [ $\frac{m}{s}$ ];

$V_S$  – prędkość fali poprzecznej [ $\frac{m}{s}$ ];

$V_L$  – prędkość fali powierzchniowej [ $\frac{m}{s}$ ];

$E$  – moduł sprężystości podłużnej [Pa];

$G$  – moduł sprężystości poprzecznej [Pa];

$\nu$  – liczba Poissona [-];

$\rho$  – gęstość ośrodka [ $\frac{kg}{m^3}$ ].

Na podstawie pomiarów *in situ*, w których mierzone są wartości ekstremalne w ustalonym czasie trwania drgań, lub też na podstawie wyników dla modelu obliczeniowego, sprawdza się oddziaływanie drgań na budynki (PN-85/B-02170), a także na ludzi (PN-88/B-02171). W przypadku rzeczywistych pomiarów i ich analizy, podstawą diagnozy są zarejestrowane za pomocą specjalistycznego sprzętu wibrogramy, czyli wykresy drgań pokazujące zależność przemieszczenia, prędkości lub przyspieszenia od czasu.

## **2.2. Wpływ drgań komunikacyjnych na budynki mieszkalne i przebywających w nich ludzi**

W związku z postępującą cywilizacją, mamy do czynienia ze zjawiskiem rozszerzania się obszarów zurbanizowanych. Buduje się coraz więcej osiedli, domów, budynków przemysłowych. Obiekty mieszkalne powstają często w miejscach, gdzie przebiegają szlaki komunikacyjne, po których nie rzadko poruszają się pojazdy o dużych gabarytach oraz ciężarze. Buduje się także coraz więcej dróg przejazdowych, które nieraz przebiegają w pobliżu istniejących zabudowań. W większości przypadków obiekty te były projektowane i posadowione bez uwzględnienia oddziaływań od drgań komunikacyjnych.

Na wielkość drgań od poruszających się pojazdów wpływ ma szereg czynników, które związane są z (Dulińska i in., 2014):

- odległością obiektu od źródła drgań (zasięg wpływu dynamicznego wynosi zwykle ok. 25 m od skrajnego pasa jezdni, przy czym wpływ zmniejsza się wraz ze wzrostem odległości),
- podłożem: przekrój geotechniczny, wody gruntowe, przegrody, studzienki (prędkość rozchodzenia się fal jest znacznie zależna od rodzaju gruntu, a także od występowania wód podziemnych),



- pojazdami: kształt, ciężar, stan techniczny, prędkość, liczba pojazdów przejeżdżających naraz, ruszanie, zatrzymywanie się,
- nawierzchnią: rodzaj, stan techniczny, nierówności (uszkodzenia, nierówności, wystające studzienki powodujące zmianę trajektorii jazdy pojazdu, uderzenie pionowe i poziome koła, co zwiększa emisję fal rozprzestrzeniających się w gruncie),
- budynkiem: typ, konstrukcja, sposób posadowienia, stan techniczny, tłumienie (wszystkie te czynniki mają wpływ na sposób przekazywania fal poprzez fundament na pozostałą konstrukcję, istotne jest także czy budynek jest w dobrym stanie, czy też posiada uszkodzenia, które wpływają na jego sztywność).

Ważnym aspektem jest również długość oddziaływań. W normie PN-85/B-02170 drgania podzielono na stałe (występujące powyżej 30 minut na dobę), długotrwałe (występujące minimum 3 minuty, maksimum 30 minut na dobę) oraz krótkotrwałe (występujące poniżej 3 minut na dobę). Od powyższych czynników zależy intensywność przekazywanych drgań na budynek. Im więcej drgań od ruchu kołowego przekazywanych jest na budynek, i im jest on bardziej narażony na wpływ tych wibracji, tym większe uszkodzenia mogą wystąpić (zob. np. Jakubczyk-Gałczyńska i Jankowski, 2014). Może pojawić się miejscowe uszkodzenie konstrukcji, ale może też dojść do poważniejszych zniszczeń (Rys. 2.1).



Rys. 2.1. Uszkodzenia powstałe na skutek drgań komunikacyjnych.



### 2.2.1. Rodzaj gruntu a oddziaływania pochodzenia komunikacyjnego

Bardzo ważnym czynnikiem przy analizie wpływu drgań komunikacyjnych na budynki, jest podłoże gruntowe, w którym następuje propagacja fal. Ciesielski (2002) i Dulińska i in. (2014) opisali dwa parametry fali, które mają istotne znaczenie – są to tłumienie i absorpcja. Oba te parametry w głównej mierze zależą od rodzaju ośrodka, w którym rozchodzą się fale. Tłumienie odpowiada za zmniejszenie amplitudy drgań w danym punkcie wraz z upływem czasu. Absorpcja, czyli pochłanianie, związana jest z odległością i oznacza, że wpływ drgań na obiekty będzie się zmniejszał wraz z odległością od źródła. Wartość absorpcji drgań wyznaczyć można na podstawie wzoru (Dulińska i in. 2014):

$$A_x = A_0 \sqrt{\frac{x_0}{x}} \exp[-K(x - x_0)] \quad (2.4)$$

gdzie:

$x$  – długość drogi propagacji drgań w gruncie od źródła drgań do odbiornika [m];

$x_0$  – długość drogi propagacji drgań w gruncie od źródła drgań do odbiornika znajdującego się w pobliżu źródła [m];

$A_x$  – amplituda drgań w odległości  $x$ , [ $\frac{m}{s^2}$ ];

$A_0$  – amplituda drgań w pobliżu źródła, [ $\frac{m}{s^2}$ ];

$K$  – współczynnik absorpcji drgań, zależny między innymi od podłoża gruntowego [ $m^{-1}$ ].

Ciesielski (2002) oraz Dulińska i in. (2014) zwracają uwagę, iż wartości współczynnika  $K$  należy traktować orientacyjnie i w celu jego wyznaczenia należy przeprowadzić badania drgań *in situ* mierząc wielkość drgań w różnych odległościach od źródła. W Tab. 2.1 zestawiono wartości współczynników absorpcji w zależności od rodzaju podłoża.

Tab. 2.1. Wartość współczynnika absorpcji (Ciesielski, 2002).

RODZAJ PODŁOŻA	$K [m^{-1}]$
Mokre, luźne piaski pylaste i drobne grunty spoiste w stanie plastycznym	0,01 – 0,03
Luźne, mokre piaski pylaste i drobne piaski gliniaste	0,03 – 0,04
Piaski średnio- i gruboziarniste, gliny zawilgocone, gliny	0,04 – 0,06
Piaski średnie i grube, grunty spoiste twardoplastyczne	0,04 – 0,06
Piaski zagęszczone, gliny suche	0,06 – 0,10
Grunty spoiste półzwarne i zwarte	0,06 – 0,10

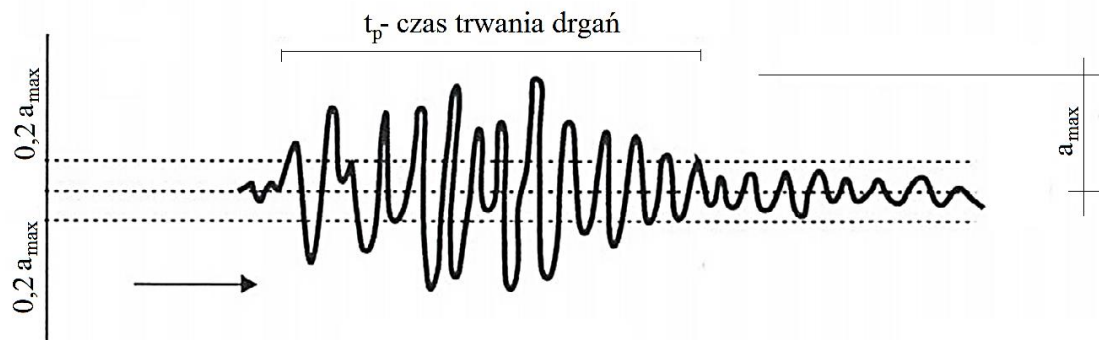
### 2.3. Metodyka pomiarowa wpływu drgań komunikacyjnych na budynki mieszkalne

Drgania komunikacyjne, w tym powodowane ruchem pojazdów kołowych (samochodów osobowych, autobusów, samochodów ciężarowych) mierzone są lub prognozowane zgodnie z PN-85/B-02170 w zależności od sytuacji pomiarowej. Metodykę pomiarową można podzielić na 4 przypadki, w zależności od istnienia (lub nie) obiektu budowlanego, oraz źródła drgań (Dulińska i in., 2014):

- budynek jest projektowany, źródło drgań jest projektowane,
- budynek jest projektowany, źródło drgań jest eksploatowane,
- budynek jest istniejący, źródło drgań jest projektowane,
- budynek jest istniejący, źródło drgań jest eksploatowane.

Pierwsza sytuacja wymaga utworzenia modelu obliczeniowego budynku i obciążenie go wymuszeniem kinematycznym, wykorzystując na przykład Metodę Elementów Skończonych. Druga możliwość to sytuacja, kiedy budynek jest projektowany, a źródło drgań jest znane, czyli na przykład istnieje droga eksploatowana, przy której będzie wznoszony budynek. W takim przypadku wykonuje się pomiary drgań podłoża w przyszłej lokalizacji, tak zwane pomiary tła dynamicznego. Trzeci przypadek to sytuacja, gdy źródło drgań jest projektowane, czyli projektowana jest droga, podczas gdy budynek już istnieje. W takim przypadku wykorzystuje się wi-brogramy z podobnej sytuacji pomiarowej. Ostatnim, najczęściej występującym przypadkiem jest sytuacja, kiedy zarówno budynek jest eksploatowany jak i źródło drgań jest znane. W tym przypadku skoncentrować się należy na wyznaczeniu wpływu drgań poprzez wykonanie rzeczywistych pomiarów polowych.

Czujniki pomiarowe (akcelerometry) należy zainstalować minimum w 3 miejscach na obiekcie od strony źródła drgań (Stypuła i Kawecki, 2008; Dulińska i in., 2014). Punkty pomiarowe należy zlokalizować na fundamencie lub na ścianie w poziomie gruntu. Nie należy umieszczać czujników w miejscach oddylatowanych od budynku, w miejscach z dużą amplitudą drgań, np. na murku pod spocznikiem schodów. Nie należy również umieszczać czujników na stropie nad piwnicą, gdyż wystąpią tam zawyżone wartości (Stypuła i Kawecki, 2008). Pomiar należy wykonać dla poziomych składowych drgań fundamentu lub ścian nośnych w poziomie terenu, oddzielnie dla kierunku podłużnego i poprzecznego. Przyjmuje się, iż miarodajny czas trwania drgań jest to czas, w którym wartości amplitud są większe niż 0,2 wartości ekstremalnej (zob. Rys. 2.2).



Rys. 2.2. Czas trwania drgań uwzględniany w analizie (Kawecki i Stypuła, 2013).

Wyniki pomiarów należy poddać filtracji w przedziale częstotliwości 1–100 Hz. Analizę wykonuje się w pasmach tercjowych<sup>3</sup> 1/3 oktawowych<sup>4</sup>, dla częstotliwości środkowych,  $f_0$ , wynoszących kolejno: 1; 1,25; 1,6; 2; 2,5; 3,15; 4; 5; 6,3; 8; 10; 12,5; 16; 20; 25; 31,5; 40; 50; 63; 80 i 100 Hz (PN–85/B–02170) oraz częstotliwości dolnych,  $f_d$  i częstotliwości górnych  $f_g$ , wyznaczonych ze wzorów (Zieliński, 2007):

$$f_d = f_0 \cdot \sqrt[6]{2} \quad (2.5)$$

$$f_g = f_0 \cdot \sqrt[6]{2} = f_d \cdot \sqrt[3]{2} \quad (2.6)$$

$$f_0 = f_d \cdot \sqrt[6]{2} = f_g \cdot \sqrt[6]{2} \quad (2.7)$$


Dla każdego budynku wykonuje się osobną szczegółową normową analizę. Należy zatem wyznaczyć ekstremalne wartości amplitud dla 21 różnych częstotliwości środkowych i nanieść je na wykres skali wpływów dynamicznych (SWD) (zob. Rys. 2.3), a następnie odczytać, w jakiej strefie znajduje się obiekt. Norma PN–85/B–02170 dotyczy obiektów mieszkalnych, murowanych, wznoszonych w technologii tradycyjnej, które podzielono na dwie grupy:

- 1) Budynki o kształcie zwartym, o małych wymiarach zewnętrznych rzutu poziomego (maksymalna długość 15 m) jedno–lub dwukondygnacyjne, wysokość budynku nie może przekraczać wymiarów rzutu poziomego,
- 2) Budynki do pięciu kondygnacji, wysokość budynku nie może przekraczać podwójnej najkrótszej szerokości.

<sup>3</sup> Pasma tercjowe to pasmo pomiędzy częstotliwościami: górną  $f_g$  i dolną  $f_d$ , których stosunek równa się  $\sqrt[3]{2}$

<sup>4</sup> Oktawa to trzy kolejne tercje (czyli tercja stanowi 1/3 część oktawy)

Dla obiektów mieszkalnych podlegających grupie pierwszej stworzono Skalę Wpływów Dynamicznych I (SWD I), zaś dla budynków spełniających założenia drugiej grupy, Skalę Wpływów Dynamicznych II (SWD II).



Rys. 2.3. Skale Wpływów Dynamicznych (PN-85/B-02170).

Strefy szkodliwości oznaczone są rzymskimi cyframi i są one zdefiniowane następująco (PN-85/B-02170):

- strefa I: drgania nieodczuwalne przez budynek; granica A – dolna granica odczuwalności drgań przez budynek i dolna granica uwzględniania wpływów dynamicznych; przy drganiach poniżej tej granicy można nie uwzględniać wpływów dynamicznych;
- strefa II – drgania odczuwalne przez budynek, ale nieszkodliwe dla konstrukcji; następuje przyspieszone zużycie budynku i pojawiają się pierwsze rysy w wyprawach i tynkach; granica B – granica sztywności budynku – dolna granica powstawania zarysowań i spękań w elementach konstrukcyjnych;
- strefa III – drgania szkodliwe dla budynku, powodują lokalne zarysowania i spękania, przez co osłabiają konstrukcję budynku i zmniejszają jego nośność oraz odporność na dalsze wpływy dynamiczne, może nastąpić odpadanie wypraw i tynków; granica C – granica wytrzymałości pojedynczych elementów budynku – dolna granica ciężkich szkód budowlanych;
- strefa IV – drgania o dużej szkodliwości dla budynku, stanowiące zagrożenie bezpieczeństwa ludzi; powstają liczne spękania, lokalne zniszczenia murów i innych pojedynczych

elementów budynku, istnieje możliwość spadania przedmiotów zawieszonych, odpadania płyt wypraw sufitów, wysuwania się belek stropowych z łożysk, itp., wymagane możliwie szybkie usunięcie źródła drgań lub zmniejszenie jego wpływów; granica D – granica stateczności konstrukcji – dolna granica awarii całego budynku, drgania powyżej tej granicy mogą spowodować awarię budynku i zagrażają bezpieczeństwu życia ludzkiego;

- strefa V – drgania powodujące awarię budynku przez zawalenie się murów, spadanie stropów itp., pełne zagrożenie bezpieczeństwa życia ludzkiego, w przypadku groźby powstania drgań tego typu budynek nie może być użytkowany.

Norma PN-85/B-02170 umożliwia zastosowanie różnych linii granicznych (A, B, C i D oraz A', B', C', D') oddzielających strefy. Tab. 2.2 przedstawia zasady doboru linii ograniczających strefy wpływu drgań.

Tab. 2.2. Zasady umożliwiające zastosowanie odpowiednich linii ograniczających strefy wpływu drgań (PN-85/B-02170).

OCENA WEDŁUG	CECHY UMOŻLIWIAJĄCE ZASTOSOWANIE LINII GRANICZNYCH	
	Niższej (linia ciągła: A, B, C, D)	Wyższej (linia przerywana: A', B', C', D')
STANU BUDYNKU	Budynki stare, z uszkodzeniami, budynki przerabiane lub wzmacniane	Budynki nieuszkodzone, bez przeróbek konstrukcyjnych
MATERIAŁÓW I KONSTRUKCJI BUDYNKÓW	Budynki z elementów murowych żużlobetonowych lub z kamienia, o niestarannym wykonaniu, brak fundamentów, brak wieńców, sklepienie stropu, duże otwory w ścianach lub otwory nieregularne	Ściany z cegły pełnej starannie wykonane, fundamenty żelbetowe lub betonowe, stropy masywne wiążące ściany z wieńcem stropowym
TYPU PODŁOŻA I SPOSOBU POSADOWIENIA	Podłoże o małej sztywności (np. piaski pyłaste, luźne), posadowienie nieciągłe (różne wysokości) albo pośrednie	Podłoże sztywne (np. ily i gliny twardoplastyczne), posadowienie płaskie
RODZAJU DRGAŃ	Drgania długotrwałe lub występujące stale	Drgania krótkotrwałe

#### 2.4. Wpływ drgań komunikacyjnych na przebywających w budynkach ludzi

Oprócz wpływu na budynek, istotny jest też wpływ drgań komunikacyjnych na ludzi przebywających w budynkach. Problem ten jest szczególnie zauważalny, kiedy ludzie są narażeni na długotrwałe obciążenia drganiami i hałasem (Kawecki i Stypuła, 2013). Drgania wywołane ruchem drogowym mogą powodować dyskomfort u ludzi znajdujących się w strefie wpływu. Wyniki badań pokazują (zob. Kawecki i Stypuła, 2013), że próg odczuwalności drgań przez człowieka jest niżej usytuowany niż granica, po przekroczeniu której mogą wystąpić uszkodzenia w samym budynku. Przy ocenie wpływu drgań na ludzi zakłada się, że drgania są odbierane w sposób bierny w dwóch stanach odbioru (Kawecki i Stypuła, 2013):

- 1) Pozycja siedząca lub stojąca – odbiór drgań przez powierzchnię stóp i siedzenia – oś Z przebiega wzdłuż kręgosłupa, osie X, Y przyjmują kierunki poziome;
- 2) Pozycja leżąca – odbiór drgań przez całą powierzchnię ciała – oś Z jest pozioma, oś X przebiega od pleców do klatki piersiowej, oś Y od jednego boku do drugiego boku.

#### **2.4.1. Parametry oceny i próg odczuwalności drgań**

W normach polskich PN-88/B-02171 i PN-87/B-02151/02, a także zagranicznych (zob. Directive 2002/49/EC; BS 6472-1, 2008; ISO 10137, 2007; DIN 4150-2, 1999) opisano trzy parametry oceny wpływu drgań komunikacyjnych: wartość skorygowana przyspieszenia (prędkości) drgań w paśmie częstotliwości 1–80 Hz, widmo (struktura częstotliwościowa) wartości skutecznej przyspieszenia lub prędkości w pasmach 1/3 oktaowych oraz dawka wibracji.

##### **2.4.1.1. Wartość skorygowana przyspieszenia (prędkości) drgań w paśmie częstotliwości 1–80Hz**

Wartość przyspieszenia (prędkości) drgań skorygowana w całym paśmie częstotliwości od 1 do 80 Hz wykorzystana jest w normie polskiej PN-88/B-02171, a także w normie niemieckiej DIN 4150-2 (1999). Skorygowanie następuje przez wprowadzenie do toru pomiarowego (między czujnikiem a rejestratorem) filtru korekcyjnego. Częstotliwościom środkowym pasm tercjowych przypisuje się odpowiednie współczynniki korekcji. Rezultatem oceny jest skorygowana wartość w postaci liczby. Próg odczuwalności przez człowieka dla tego parametru określono w PN-88/B-02171 i jest to wartość równa przyspieszeniu (prędkości):

- wzdłuż osi Z:  $0,005 \frac{\text{m}}{\text{s}^2}$  ( $0,0001 \frac{\text{m}}{\text{s}}$ ),
- wzdłuż osi X i Y wynosi  $0,0036 \frac{\text{m}}{\text{s}^2}$  ( $0,00029 \frac{\text{m}}{\text{s}}$ ).

Parametr ten jest jednak niewystarczający do pełnej analizy komfortu wibracyjnego, ponieważ podczas jego określania nie ustala się pasma częstotliwości, w którym wartości dopuszczalne zostały przekroczone, tak więc nie wiadomo, dla jakiej częstotliwości powinna nastąpić redukcja (Kawecki i Stypuła, 2013).

##### **2.4.1.2. Widmo (struktura częstotliwościowa) wartości skutecznej przyspieszenia lub prędkości w pasmach 1/3 oktaowych**

Kolejnym parametrem wykorzystywanym do określania wpływu drgań jest widmo (struktura częstotliwościowa) wartości skutecznej przyspieszenia (prędkości) w pasmach 1/3 oktaowych. Kryterium tej oceny wpływu drgań na komfort ludzi zawarto w PN-88/B-02171 oraz



w ISO 10137:2007. Zarejestrowany wibrogram należy poddać filtracji i nanieść wyniki na wykres progu odczuwalności drgań przez ludzi (Rys. 2.4). Wielkością charakteryzującą drgania jest wartość skuteczna przyspieszenia (prędkości), w skrócie *RMS* (z ang. *Root Mean Square*) określona według wzoru (Kawecki i Stypuła, 2013):

$$a_{RMS} = \left[ \frac{1}{T_a} \int_{T_a} a^2(t) dt \right]^{0,5} \quad (2.8)$$

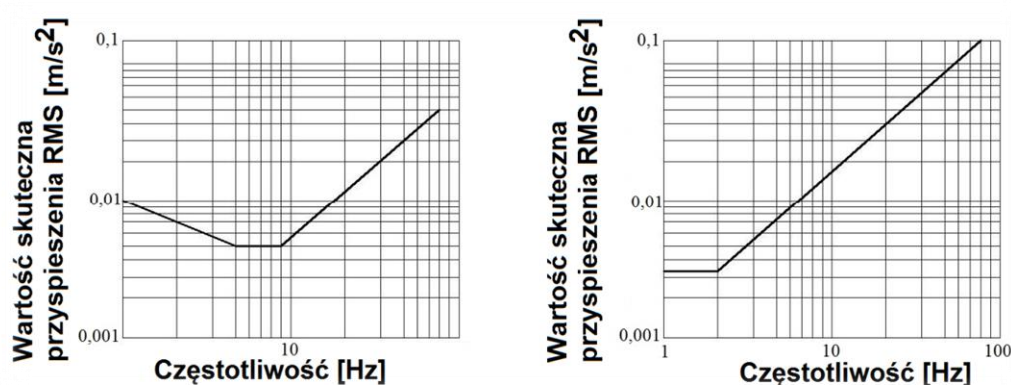
gdzie:

$a_{RMS}$  – wartość skuteczna przyspieszenia;

$a(t)$  – przyspieszenie drgań w funkcji czasu,  $[\frac{m}{s^2}]$ ;

$T_a$  – czas uśredniania, [s].

Pamiętać należy, że drgania wywołane ruchem drogowym mają charakter nieregularny. Dlatego, jako czas uśredniania przyjmuje się dla przedziału, dla którego wartości amplitud są większe od 0,2 wartości ekstremalnej.



Rys. 2.4. Próg odczuwalności drgań przez ludzi według PN-88/B-02171.

### 2.4.1.3. Dawka wibracji

Dawka wibracji opisana jest w normach: PN-87/B-02151/02, BS 6472-1:2008, Directive 2002/49/EC. Metoda ta (zob. Kawecki, 2011; Kawecki i Stypuła, 2013), umożliwia uściślenie oceny wpływu drgań przez odniesienie do pełnego czasu oddziaływania wibracyjnego. Dawkę wibracji *VDV* (z ang. *Vibration Dose Value*) oblicza się na podstawie wzoru (Kawecki i Stypuła, 2013):

$$VDV = \left[ \int_0^T a^4(t) dt \right]^{0,25} \quad (2.9)$$

gdzie:

$a(t)$  – przyspieszenie w funkcji czasu z wagami zależnymi od pasma częstotliwości oraz kierunku drgań,  $[\frac{m}{s^2}]$ ;

$T$  – całkowity czas trwania drgań, [s].

Należy podkreślić, że w przypadku tego parametru, nie występuje wyraźne określenie progu odczuwalności drgań. Można przyjąć podawane w literaturze (zob. np. Kawecki i Stypuła, 2013) interpretacje, że wartości odpowiadające wystąpieniu małego prawdopodobieństwa zgłoszenia uwag ze strony mieszkańców odpowiadają progowi odczuwalności. Na podstawie badań (Kawecki i Stypuła, 2013) wartości te określono na poziomie  $VDV = 0,2 - 0,4 \frac{m}{s^{1,75}}$  dla pory dziennej i  $VDV = 0,13 \frac{m}{s^{1,75}}$  dla pory nocnej.

## 2.5. Drgania komunikacyjne a hałas

Występowanie drgań komunikacyjnych wiąże się zazwyczaj z dyskomfortowym i niebezpiecznym dla ludzkiego ucha hałasem. Zgodnie z dyrektywą unijną Directive 2002/49/EC oraz polską normą PN-87/B-02151/02, dopuszczalny równoważny poziom dźwięku  $A^5$  od wszystkich źródeł, w tym hałasu od wyposażenia technicznego w budynku i poza budynkiem, przy hałasie nieustalonym nie powinien przekraczać:

- 40 dB dla pomieszczenia mieszkalnego w ciągu dnia, czyli w godzinach od 6:00 do 22:00,
- 30 dB dla pomieszczenia mieszkalnego w nocy, czyli od 22:00 do 6:00,
- 45 dB dla kuchni i pomieszczeń sanitarnych w ciągu całej doby.

## 2.6. Metody redukcji wpływu drgań

Ponieważ drgania, zwłaszcza długotrwałe, mogą powodować wiele szkód, ważna jest wiedza, które obiekty są zagrożone i odpowiednio szybko podjęte kroki redukujące negatywne skutki drgań. Jest wiele metod, które można zastosować (Niemas, 2004). Środki techniczne redukcji drgań mogą być umieszczane w źródle lub na drodze propagacji (ochrona czynna), czy też w budynku (ochrona bierna).

Ochrona czynna, w przypadku drgań komunikacyjnych, polega przede wszystkim na reorganizacji ruchu, między innymi poprzez zmniejszenie dopuszczalnej prędkości oraz masy po-

---

<sup>5</sup> poziom dźwięku A oznacza dźwięk, którego częstotliwość wynosi 440 Hz (Wesołowski, 2008).



jazdów, a także na poprawie stanu technicznego nawierzchni, poprzez usunięcie uskoków, pęknięć, odpływów wody opadowej, pokryw włazów do kanałów, łączeń, a także poprzez nowe asfaltowanie dróg. Stosowane są również przegrody umieszczane na drodze propagacji drgań, tak zwane ekrany antywibracyjne (Niemas, 2004). Największą ich skuteczność można osiągnąć lokalizując je jak najbliżej budynku. Najprostszym przykładem takiego ekranu jest wykonanie na drodze propagacji rowu (niewypełnionego lub wypełnionego materiałem, w którym prędkość rozchodzenia się fal jest znacznie mniejsza, a absorpcja drgań większa niż w podłożu (Niemas, 2004).

Ochrona bierna wprowadzana jest w przypadku braku możliwości zastosowania ochrony czynnej. Na etapie projektowania budynku podstawowym możliwym działaniem jest jego odsunięcie od źródła drgań i zmiana warunków posadowienia. Wprowadza się również zmiany charakterystyki dynamicznej konstrukcji, np. poprzez zmianę sztywności (Lewandowski, 2012). Można również zastosować wibroizolację w postaci mat czy łożysk lub sprężyste oddzielenie całego budynku pod stropem powyżej kondygnacji podziemnej (zob. np. Stypuła, 2009; Falborski i Jankowski, 2013, 2017; Wilde i in., 2013).

### 3. BADANIA EKSPERYMENTALNE DRGAŃ KOMUNIKACYJNYCH

Badania przeprowadzono zgodnie z normą PN-85/B-02170. Analizie poddano 11 budynków mieszkalnych jednorodzinnych, zlokalizowanych w województwie pomorskim. Fotografie budynków przedstawiono na Rys. 3.1.



3



4





5



6









9



10





Rys. 3.1. Budynki poddane badaniom drgań komunikacyjnych.

Charakterystyka badanych obiektów jest różnorodna (Tab. 3.1). Pierwszy budynek to dom jednorodzinny, murowany, parterowy z poddaszem użytkowym, częściowo podpiwniczonym, wzniesiony w 1922r. Budynek ten ma wymiary zewnętrzne i wysokość nieprzekraczające 15 m. Fundamenty są kamienne, ściany wykonane z cegły pełnej grubości 38 cm, ocieplony płytami styropianowymi grubości 5 cm. Budynek nr 1 zlokalizowany jest przy drodze o nawierzchni bitumicznej w odległości 7 m od krawędzi drogi. Drugi budynek to dom jednorodzinny, murowany, parterowy z poddaszem użytkowym, wzniesiony w 1964r. (modernizacja w 1987r.), zlokalizowany w odległości 10 m od drogi o nawierzchni bitumicznej będącej w stanie dobrym. Budynek ten ma wymiary zewnętrzne przekraczające 15 m. Kolejny budynek to dom jednorodzinny, murowany, o fundamentach żelbetowych, parterowy z poddaszem użytkowym, wzniesiony w 2000r., znajdujący się w odległości 9 m od drogi z nawierzchnią bitumiczną, która jest w złym stanie. Budynek ten ma także wymiary zewnętrzne przekraczające 15 m. Budynek nr 4 zlokalizowany jest przy tej samej drodze, co budynek nr 3. Jest to dom jednorodzinny, murowany, parterowy z poddaszem użytkowym, wzniesiony w drugiej połowie XXw. Budynek ten ma wymiary zewnętrzne i wysokość poniżej 15 m. Budynek nr 5 to dom jednorodzinny, murowany, o fundamentach żelbetowych, piętrowy z poddaszem użytkowym, położony w odległości 20 m od krawędzi drogi o nawierzchni bitumicznej. Budynek ten ma





wymiary zewnętrzne i wysokość przekraczające 15 m. Budynek nr 6 to dom jednorodzinny, murowany, parterowy z poddaszem użytkowym, zlokalizowany przy drodze o nawierzchni bitumicznej. Rozpatrywany budynek mieszkalny ma wymiary zewnętrzne i wysokość poniżej 15 m. Budynek nr 7, zlokalizowany przy drodze z płyt jumbo będącej w bardzo złym stanie, to dom jednorodzinny murowany z bloków betonowych, o fundamentach żelbetowych, nowo wybudowany, jego wymiary przekraczają 15 m. Budynek nr 8, zlokalizowany także przy drodze z płyt jumbo będącej w złym stanie, to dom nowo wybudowany dwurodzinny murowany z bloków betonowych, o fundamentach żelbetowych, jego wymiary przekraczają 15 m. Budynek nr 9 to dom jednorodzinny murowany z cegły, wzniesiony w połowie XXw. Budynek ten ma wymiary zewnętrzne powyżej 15 m i jest zlokalizowany przy drodze asfaltowej będącej w średnim stanie. Budynek nr 10, zlokalizowany także przy drodze o nawierzchni bitumicznej w średnim stanie, to dom jednorodzinny, nowo wybudowany murowany z bloków betonowych, o fundamentach żelbetowych, jego wymiary zewnętrzne przekraczają 15 m. Budynek nr 11 wybudowano w 2014 roku, jest to dom czterorodzinny murowany z bloczków gazobetonowych, o fundamentach żelbetowych, jego wymiary zewnętrzne przekraczają 15 m, zlokalizowany w odległości 12 m od krawędzi drogi gruntowej, będącej w średnim stanie.



Tab. 3.1. Charakterystyka badanych budynków.

NUMER BUDYNKU	ZDJĘCIE POGLĄDOWE	LOKALIZACJA	GRUNT	PRZYBLIŻONA ODLEGŁOŚĆ OD KRAWĘDZI DROGI	STAN TECHNICZNY BUDYNKU	RODZAJ NAWIERZCHNI	STAN NAWIERZCHNI	SKALA WPŁYWÓW DYNAMICZNYCH
1		Polchowo	Gliny zwałowe, ich zwietrzliny oraz piaski i żwiry lodowcowe	7 m	średni	bitumiczna	bardzo dobry	SWD I
2		Gdańsk-Wrzeszcz	Piasek gliniasty 1 m, glina piaszczysta/pylasta 3 m	10 m	dobry	bitumiczna	dobry	SWD I
3		Gdańsk-Morena	Nasyp (żużel+gruz) 0,8 m, piasek drobny, piasek średni + żwir 1,6 m wilgotny, średniozagęszczony	9 m	dobry	bitumiczna	zły	SWD II
4		Gdańsk-Morena	Nasyp (żużel+gruz) 0,8 m, piasek drobny, piasek średni + żwir 1,6 m wilgotny, średniozagęszczony	15 m	dobry	bitumiczna	średni	SWD I
5		Roszkowo	Piasek gliniasty 4 m	20 m	dobry	bitumiczna	dobry	SWD II
6		Roszkowo	Piasek gliniasty 4 m	8 m	średni	bitumiczna	dobry	SWD I
7		Słupsk	Gliny zwałowe, ich zwietrzliny oraz piaski i żwiry lodowcowe	15 m	dobry	płyty jumbo	zły	SWD II
8		Słupsk	Gliny zwałowe, ich zwietrzliny oraz piaski i żwiry lodowcowe	15 m	dobry	płyty jumbo	zły	SWD II
9		Olszynka	Piaski, żwiry, mady rzeczne oraz torfy i namuły	22,5 m	dobry	bitumiczna	średni	SWD II
10		Olszynka	Piaski, żwiry, mady rzeczne oraz torfy i namuły	20 m	dobry	bitumiczna	średni	SWD II
11		Banino	Piaski i żwiry sandrowe, Gliny zwałowe, ich zwietrzliny oraz piaski i żwiry lodowcowe	12 m	dobry	gruntowa	średni	SWD II

Pomiary wykonano przy użyciu sprzętu *Vimea Alitec* (zob. Rys. 3.2). Do aparatury pomiarowej podłączano piezoelektryczne czujniki przyspieszeń *Vibrasens* w przydzielonych im gniazdach, które wcześniej odpowiednio skonfigurowano. W badaniach używano 6 czujników montowanych na ścianie fundamentowej budynku równoległej do ulicy, tuż nad poziomem gruntu (zob. Rys. 3.3) zgodnie z PN-85/B-02170 tak, aby umożliwić pomiar w dwóch prostopadłych do siebie kierunkach poziomych (zob. Stypuła i Kawecki, 2008). Po podłączeniu czujników i ustawieniu aparatury, przeprowadzano kalibrację. Na komputerze podłączonym do aparatury pomiarowej rejestrowano przebiegi czasowe przyspieszeń dla różnych pojazdów: samochodów osobowych, autobusów o dwóch osiach, samochodów dostawczych i ciężarowych o masie całkowitej do 10 t oraz dla autobusów i samochodów ciężarowych o masie ponad 10 t i o więcej niż 2 osiach.



Rys. 3.2. Aparatura pomiarowa do badań drgań.





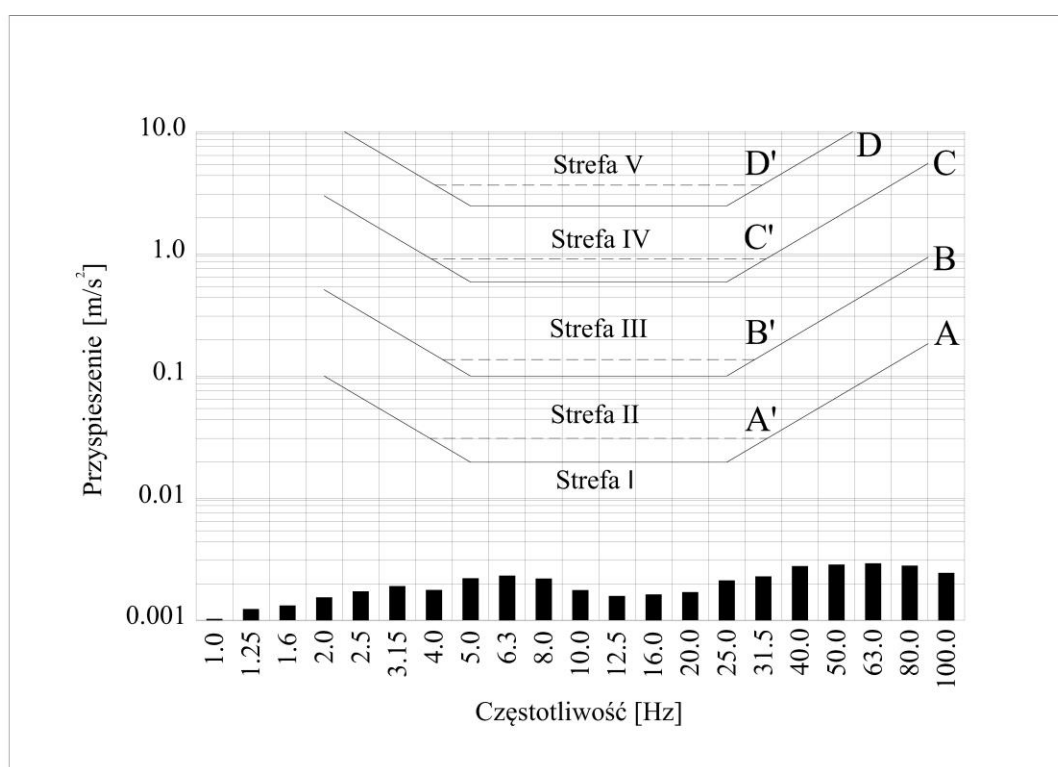
Rys. 3.3. Sposób montażu czujników piezoelektrycznych do budynku.

W zależności od pory dnia oraz intensywności ruchu odbywającego się przy budynku rejestrowano od 15 do 50 przejazdów różnego typu pojazdów. Każdy z nich trwał 6–10 sekund. Po wykonaniu pomiarów w terenie, każdorazowo dla każdego badanego budynku, wykonywano dogłębną analizę w programie *Matlab* poddając przebiegi czasowe filtracji zgodnie z PN–85/B–02170 uwzględniając czas trwania drgań, dla którego amplituda jest nie mniejsza niż  $0,2a_{max}$ .

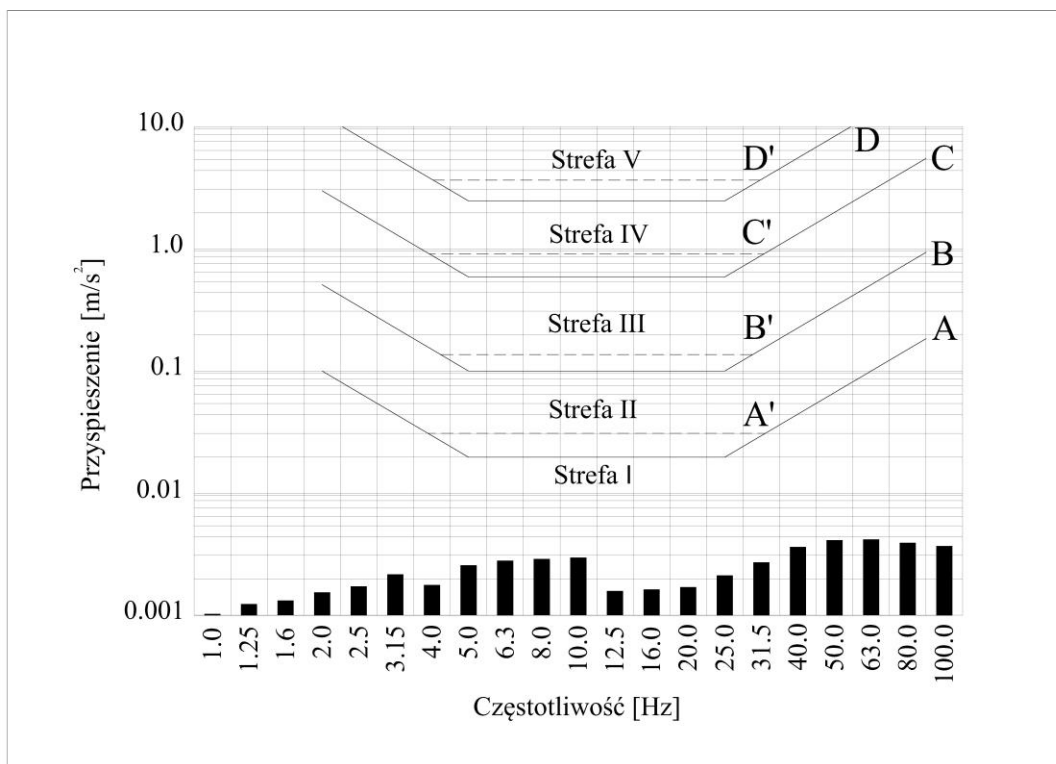
Analizie poddano pomiary dla 11 budynków, filtrując każdy pomiar w 21 pasmach tercjowych (w każdym pomiarze uzyskano niezależne wartości dla kilku czujników lecz ostatecznie wybrano ten czujnik, który wykazywał największe amplitudy), otrzymując 693 przebiegów

czasowych. Na podstawie analizy określono ekstremalne przyspieszenie dla każdej z częstotliwości środkowych pasma tercjowego i wyniki naniesiono na normowe diagramy skali wpływów dynamicznych. Na Rys. 3.4–3.36 przedstawiono wyniki dla każdego z budynków. Norma PN–85/B–02170 obliuguje do uwzględniania jedynie ekstremalnych przyspieszeń drgań, jednak na potrzeby niniejszej rozprawy i utworzenia autorskiego algorytmu prognozowania przedstawiono wyniki analiz dla trzech różnych typów pojazdów (zob. również rozdział 5.2.6):


- samochód osobowy do 3,5 t,
- samochód dostawczy do 10 t lub autobus o dwóch osiach,
- samochód ciężarowy powyżej 10 t lub autobus o trzech osiach.




Rys. 3.4. Wyniki analizy dla budynku nr 1 wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I.




Rys. 3.5. Wyniki analizy dla budynku nr 1 wykonanej dla przejazdu autobusu o dwóch osiach, naniesione na SWD I.



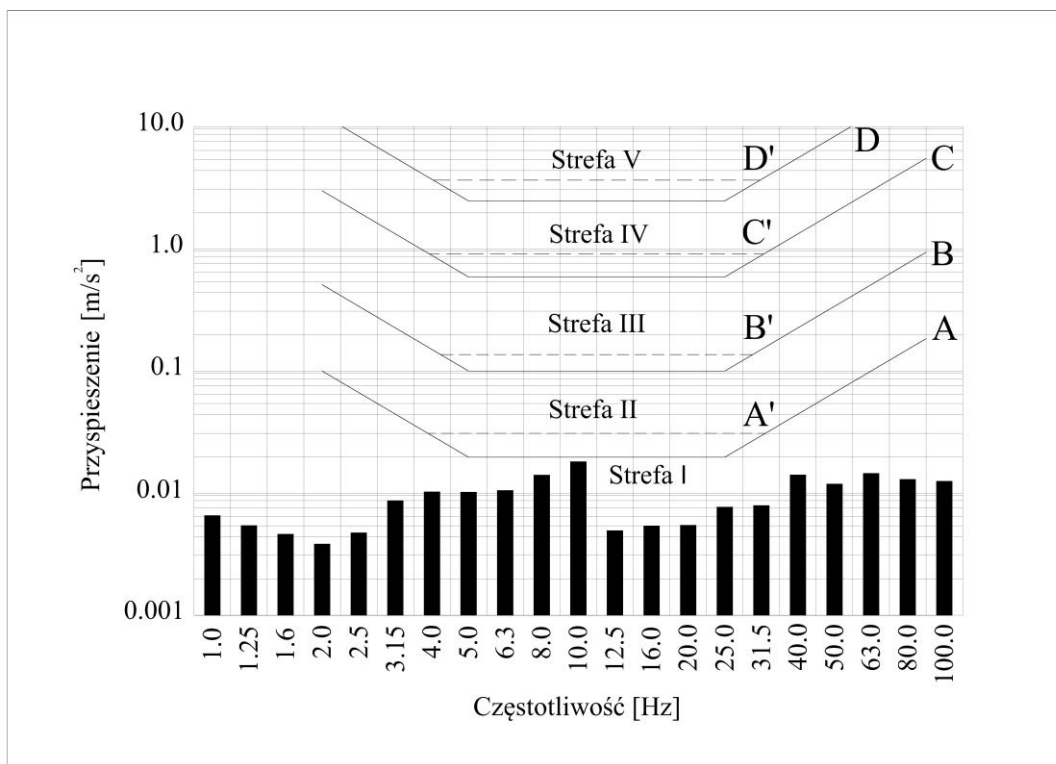
Rys. 3.6. Wyniki analizy dla budynku nr 1, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD I.




Rys. 3.7. Wyniki analizy dla budynku nr 2, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I.



Rys. 3.8. Wyniki analizy dla budynku nr 2, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD I.

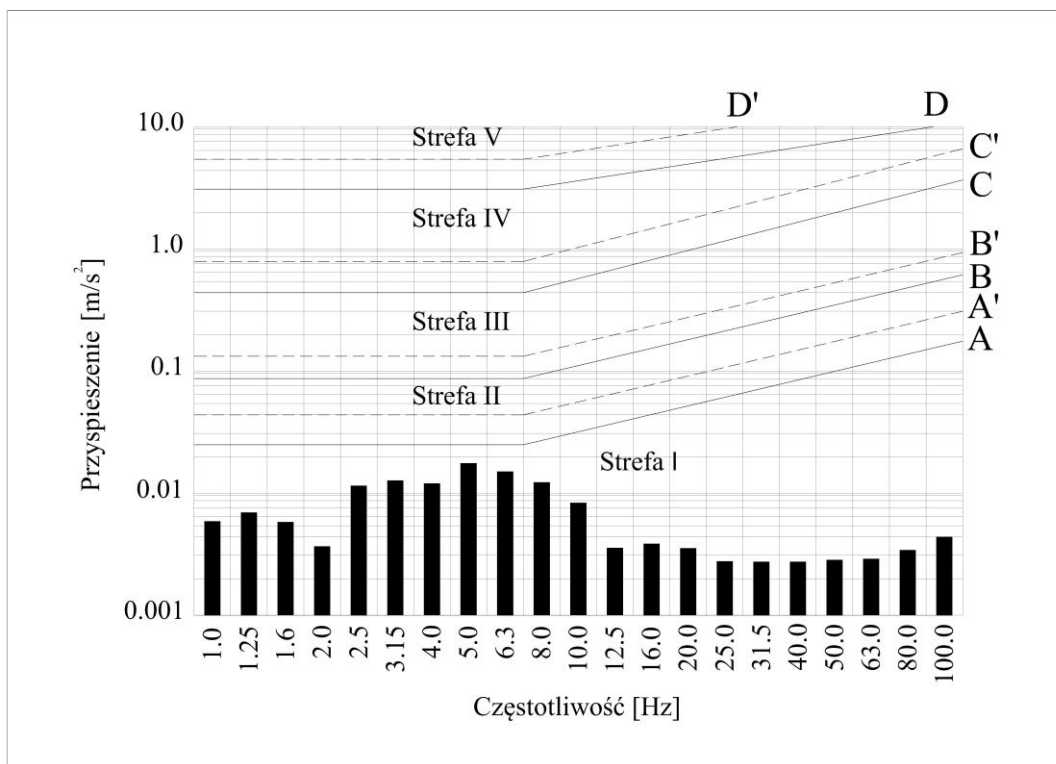


Rys. 3.9. Wyniki analizy dla budynku nr 2, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniezione na SWD I.




Rys. 3.10. Wyniki analizy dla budynku nr 3, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniezione na SWD II.







Rys. 3.11. Wyniki analizy dla budynku nr 3, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.




Rys. 3.12. Wyniki analizy dla budynku nr 3, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD II.




Rys. 3.13. Wyniki analizy dla budynku nr 4, wykonanej dla przejazdu samochodu osobowego do 3,5 t, nanesione na SWD I.




Rys. 3.14. Wyniki analizy dla budynku nr 4, wykonanej dla przejazdu samochodu dostawczego do 10 t, nanesione na SWD I.




Rys. 3.15. Wyniki analizy dla budynku nr 4, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD I.




Rys. 3.16. Wyniki analizy dla budynku nr 5, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.




Rys. 3.17. Wyniki analizy dla budynku nr 5, wykonanej dla przejazdu autobusu o dwóch osiach, naniesione na SWD II.




Rys. 3.18. Wyniki analizy dla budynku nr 5, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.




Rys. 3.19. Wyniki analizy dla budynku nr 6, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I




Rys. 3.20. Wyniki analizy dla budynku nr 6, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD I.




Rys. 3.21. Wyniki analizy dla budynku nr 6, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD I.



Rys. 3.22. Wyniki analizy dla budynku nr 7, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.

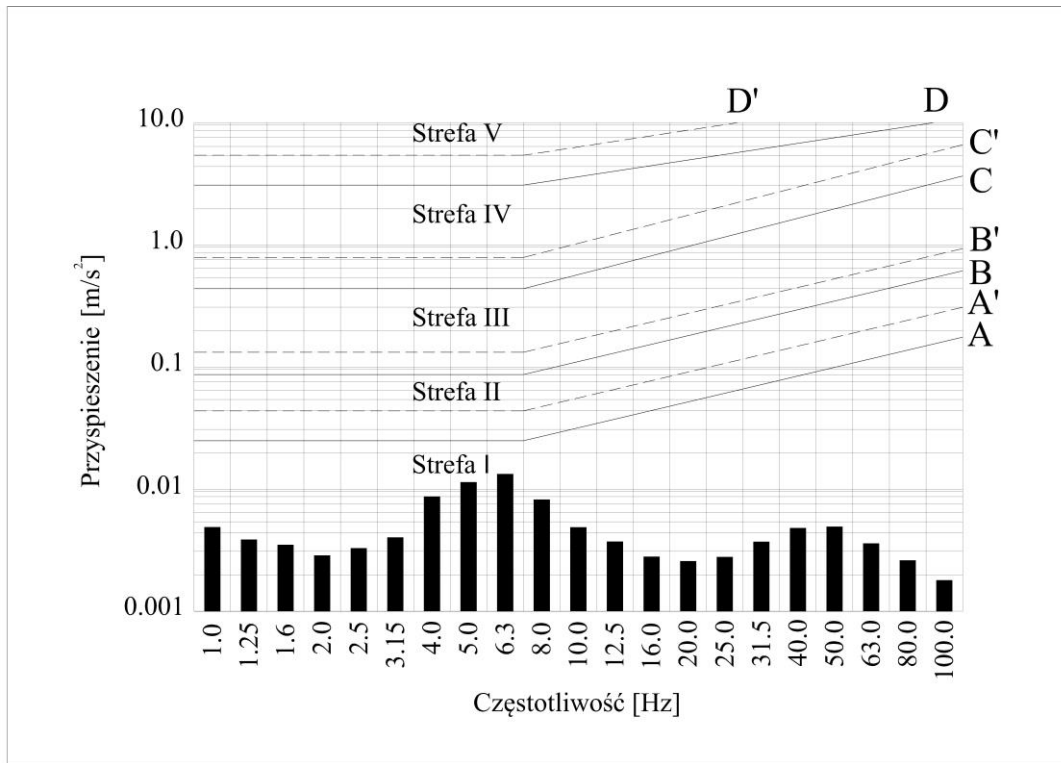


Rys. 3.23. Wyniki analizy dla budynku nr 7, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.

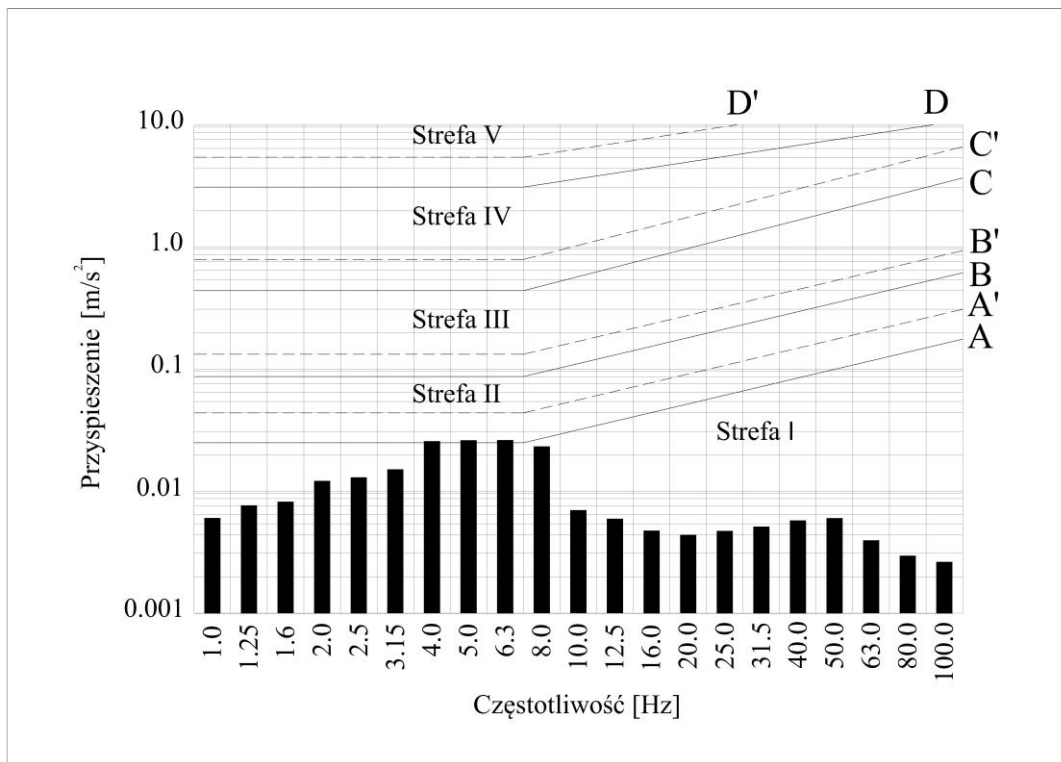


Rys. 3.24. Wyniki analizy dla budynku nr 7, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.







Rys. 3.25. Wyniki analizy dla budynku nr 8, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.




Rys. 3.26. Wyniki analizy dla budynku nr 8, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.




Rys. 3.27. Wyniki analizy dla budynku nr 8, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.




Rys. 3.28. Wyniki analizy dla budynku nr 9, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.




Rys. 3.29. Wyniki analizy dla budynku nr 9, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.




Rys. 3.30. Wyniki analizy dla budynku nr 9, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD II.




Rys. 3.31. Wyniki analizy dla budynku nr 10, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.




Rys. 3.32. Wyniki analizy dla budynku nr 10, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.




Rys. 3.33. Wyniki analizy dla budynku nr 10, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.



Rys. 3.34. Wyniki analizy dla budynku nr 11, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.



Rys. 3.35. Wyniki analizy dla budynku nr 11, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.



Rys. 3.36. Wyniki analizy dla budynku nr 11, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.

Wyniki badań pokazują, iż wszystkie z analizowanych budynków umiejscowione są w I lub II strefie wpływu drgań. Stwierdzenie II strefy w przypadku części budynków oznacza co prawda mały wpływ oddziaływań, jednak drgania są odczuwalne, a zużycie tynków jest przyspieszone (Dulińska i in., 2014), co w kolejnych okresach eksploatacji może doprowadzić do pogorszenia się stanu budynku, a w efekcie wpływ drgań komunikacyjnych może być jeszcze większy.



## 4. RYZYKO I ALGORYTMY WSPOMAGAJĄCE PODEJMOWANIE DECYZJI

Dzisiejsza nauka i wciąż rozwijająca się technologia pozwala na rozwiązywanie problemów inżynierskich nie tylko za pomocą badań terenowych na danych obiektach i obliczeń wprost. Istnieje wiele algorytmów wspomagających diagnozę i podjęcie wstępnych, a nawet ostatecznych decyzji. Metody te są z reguły probabilistyczne, ale ten fakt sprawia, że mogą być o wiele tańsze i łatwiejsze w zastosowaniu, bez konieczności wykonywania czasem bardzo kosztownych i pracochłonnych badań. Podstawą tego rodzaju algorytmów są najczęściej obserwacje z przeszłości, wartości deterministyczne. Elementem wspólnym wszelkich metod jest operowanie zmiennymi, czyli wielkościami które są mierzalne i które mogą być zmieniane w trakcie badań (zmiennie niezależne) lub są wielkościami określającymi skutek badań nad zmiennymi niezależnymi (zmiennie zależne).

Zmienne, które są podstawowym składem każdego algorytmu mogą pochodzić z wszelkiego rodzaju badań, eksperymentów, pomiarów, ankiet, analiz, wywiadów czy wiedzy pochodzącej od cieszących się dużym zaufaniem ekspertów. Wszelkie źródła danych mogą mieć charakter korelacyjny, co oznacza, że badacz mierzy istniejące zjawiska bez wprowadzania sztucznych, nieistniejących zjawisk, lub też eksperymentalny, w którym celowo manipuluje się wartościami wejściowymi, aby określić jak sztucznie wprowadzona wartość zmiennej niezależnej wpływa w efekcie na zmiennie zależne. W niniejszej rozprawie podstawą analiz są badania pomiarowe drgań komunikacyjnych. Przeprowadzone analizy mają zatem charakter czysto korelacyjny, ponieważ nie wprowadzono sztucznie zmian na zmiennych niezależnych, a jedynie sprawdzano zależności przyczynowo – skutkowe zjawiska drgań budynków w sposób deterministyczny (rozdział 3), a także szacunkowy (obarczony pewnym ryzykiem), za pomocą metod opisanych w rozdziale 5 i 6, w których wykonano dogłębną analizę wybranych algorytmów.

### 4.1. Ryzyko i metody jego szacowania

Pojęcie ryzyka towarzyszy człowiekowi od samego początku istnienia. Sama obecność ryzyka nie powoduje jego identyfikacji i zmniejszenia, a jedynie próba jego zarządzania może zmienić stan rzeczy. Pojęcie zarządzania ryzykiem, choć może nieudokumentowane w historii, rozpoczęło swoje istnienie w chwili, w której człowiek przed podjęciem decyzji zaczął zastanawiać się nad jej skutkiem. Sytuacja taka mogła mieć miejsce tysiące lat przed naszą erą. W czasach współczesnych wielokrotnie podejmowano próbę definicji, analizy i minimalizacji ryzyka. Pierwsza nowożytna literatura na ten temat to opublikowana na początku XX wieku książka Willetta (1901). Autor przedstawia w niej ryzyko jako niepewność danego zdarzenia,


która nie zmienia się wraz ze zmianą prawdopodobieństwa. Jednak kilkanaście lat później, Knight (1921) w swojej pracy określił kluczową różnicę pomiędzy ryzykiem, które jest niemierzalne, a niepewnością, którą zmierzyć można. Zgodnie z encyklopedią Pasiecznego (1981) ryzyko jest to możliwość zajścia sytuacji, dla której przynajmniej jeden element jest nieznan, ale znane jest prawdopodobieństwo jego wystąpienia. Niepewność zaś występuje, gdy elementów, od których zależy dane zdarzenie nie można przewidzieć ani określić dla nich prawdopodobieństwa wystąpienia (Kristowski, 2005). Niepewność to pojęcie o węższym zakresie rozważań. Nie wiąże się z nim określanie prawdopodobieństwa czy tworzenia procesu zarządzania, tak jak w przypadku określania ryzyka badanych zdarzeń będących przedmiotem niniejszego opracowania.

Niezależnie w jakim celu i w jakiej branży przeprowadza się badania i obliczenia ryzyka, proces zarządzania i podejmowania decyzji jest pracochłonny i skomplikowany, a zarządzanie tym zjawiskiem jest zawsze trudne i wiąże się z dodatkowym nakładem pracy. Nie mniej jednak, zainwestowanie w początkowej fazie przedmiotowych zdarzeń może przynieść korzyści w późniejszym czasie i uchronić od wszelkiego rodzaju zwykle przykrych konsekwencji, nie tylko tych finansowych (Grzyl, 2013).

Metodyka zarządzania ryzykiem jest wciąż poszerzana. Wszelkie metody, które mają na celu zmniejszenie zajścia nieprzychylnych zdarzeń i opierają się na szacowaniu i analizach przyczynowo – skutkowych można nazwać zarządzaniem ryzykiem (Kaczmarek, 2005). Są to zarówno proste analizy statystyczne, jak i o wiele bardziej rozbudowane systemy bazujące na osiągnięciach współczesnej nauki, np. algorytmy sztucznej inteligencji, chociażby uczenie maszynowe, co dokładniej omówiono w rozdziale 5 i 6.

#### **4.2. Ryzyko uszkodzeń budynków spowodowanych drganiami komunikacyjnymi**

Zarządzanie ryzykiem polega na określeniu celu i stworzeniu schematu działania, jakie trzeba podjąć (lub nie podejmować), aby zaistniało dane zdarzenie. W tym rozdziale przedstawiono ideę zastosowania algorytmów SSN i MWW do prognozowania ryzyka zaistnienia uszkodzeń w budynkach mieszkalnych zlokalizowanych w pobliżu dróg kołowych. Na Rys. 4.1 przedstawiono schemat postępowania, który prowadzi do wyznaczenia przedmiotowego ryzyka. Algorytm ten można stosować zarówno do obiektów istniejących, jak i projektowanych.



Rys. 4.1. Podział na etapy postępowania podczas prognozowania ryzyka uszkodzeń spowodowanych drganiami komunikacyjnymi.

Zgodnie ze schematem na Rys. 4.1 proces zarządzania ryzykiem podzielono na 3 etapy. W pierwszym etapie należy ustalić parametry i czynniki sytuacyjne. Drugi etap to wprowadzenie zebranych danych (o budynku, jego lokalizacji, parametrów drogi) do algorytmów sztucznych sieci neuronowych (rozdział 5) i algorytmów maszyny wektorów wspierających (rozdział 6). W trzecim etapie, na podstawie otrzymanych dzięki tym dwóm niezależnym metodom wyników, należy podjąć decyzję o dalszym postępowaniu, mając do dyspozycji jedną z czterech możliwości: akceptacja ryzyka, łagodzenie ryzyka, transfer ryzyka lub unikanie ryzyka (Grzyl i Apollo, 2011).

### 4.3. Sztuczne sieci neuronowe

#### 4.3.1. Geneza sztucznych sieci neuronowych

Formalnego początku istnienia sztucznych sieci neuronowych doszukiwać się należy w pracy McCulloch'a i Pitts'a (1943), w której autorzy jako prekursorzy późniejszego uczenia maszynowego opracowali matematyczny model neuronu występującego w mózgu ludzkim i zwierzęcym, a także opisali problem przetwarzania w nim danych.

W 1949 roku Donald Hebb przedstawił metodę uczenia za pomocą zmiany wag sygnałów wejściowych (Hebb, 1949). W latach 50. XX wieku powstały pierwsze SSN. Pierwsza działająca sztuczna sieć neuronowa została opisana przez Franka Rosenblatta w 1958 (Rosenblatt, 1958 i 1962) i miała na celu rozpoznawanie liter alfabetu łacińskiego. Wprowadził on też pojęcie perceptronu. Założenia koncepcji perceptronu zwięźle opisał również Korbicz i in. (1994) zwracając uwagę na fakt, że ten najprostszy typ sieci przydaje się przede wszystkim do problemów klasyfikacji i rozpoznawania wzorów, choćby z uwagi na fakt, że neurony są aktywowane

za pomocą funkcji typu unipolarnego (wartość 1 lub 0) czy też bipolarnego (wartość 1 lub -1). Kolejnym założeniem jest to, że w sieci można wydzielić wzajemnie rozłączne warstwy: wejściową, wyjściową i pozostałe, które nazwano ukrytymi. Elementy znajdujące się w zasięgu jednej warstwy nie są w żaden sposób połączone, a neurony kolejnych warstw są połączone jednokierunkowo, to znaczy sygnał nie może zostać przekazany w odwrotnym kierunku (Korbicz i in., 1994).

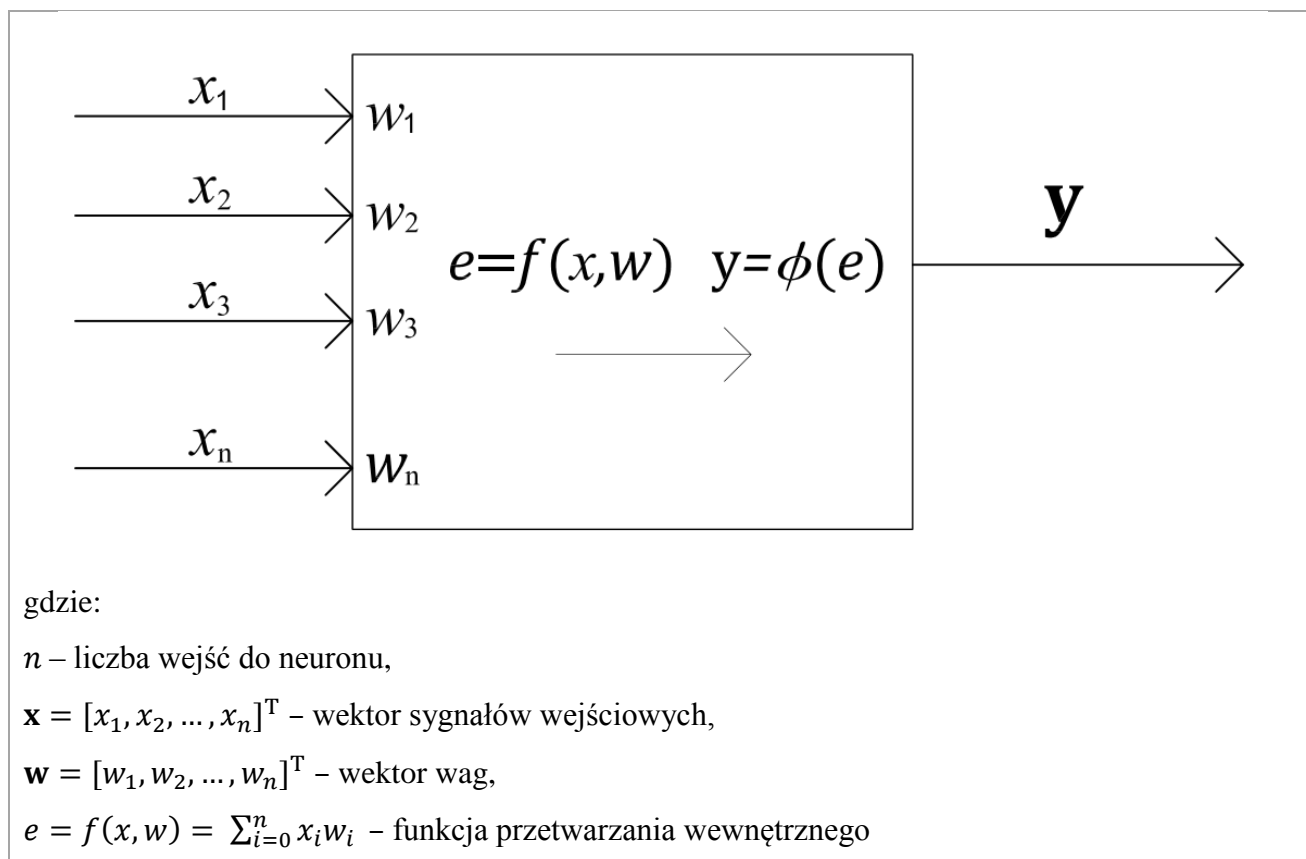
Niespełna 10 lat po opublikowaniu idei perceptronu, powstała publikacja Minsky'ego i Paperta (1969), w której przedstawiono szereg wątpliwości dotyczących wąskiego zastosowania perceptronu. Książka ta miała duży wpływ na dalsze badania naukowe nad sztucznymi algorytmami.

Pomimo negatywnych ocen Rosenblatta (1958 i 1962), inni naukowcy, którzy rozwijali i ulepszali sztuczne sieci, m.in. Bernard Widrow wraz ze swoim zespołem badawczym (zob. np. Widrow i Steinbuch, 1964) stworzyli regułę uczenia sieci opartą na minimalizacji błędów stosując metodę najmniejszych kwadratów. Metodę tę wykorzystali do uczenia zbudowanej sieci ADALINE – *Adaptive Linear Element*, która różniła się od perceptronu, ponieważ wykorzystano w niej liniową funkcję aktywacji, co oznaczało, że sygnał wyjściowy może mieć dowolną wartość, a nie jedynie wartość funkcji unipolarnej czy bipolarnej. Sieć ta składała się z pojedynczych elementów, które powielone i połączone utworzyły układ MADALINE – *Many Adaptive Linear Element* (Widrow i Steinbuch, 1964).

#### 4.3.2. Definicja sztucznych sieci neuronowych

Sztuczne sieci neuronowe to algorytm liczenia maszynowego oparty na zasadzie prosperowania ludzkiego mózgu (Tadeusiewicz, 1993). Mózg składa się z ok.  $10^{10}$  komórek nerwowych, tak zwanych neuronów, i wykonuje nawet  $10^{18}$  operacji na sekundę. Neuron składa się z ciała zwanego somą i z wypustek. Kluczowym elementem somy jest jądro, w którym zachodzą wszystkie procesy kluczowe dla funkcjonowania neuronu (Haykin, 2009). Wypustki dzielą się na dendryty (mogą być ich tysiące) wprowadzające informację do neuronu oraz akson – jedna wypustka wyprowadzająca informację z somy. Impulsy są przekazywane do innych neuronów za pomocą synaps (będących wejściami dendrytów) w trakcie procesów chemiczno-elektrycznych, których dzisiejsza nauka do dzisiaj nie jest w stanie całkowicie opisać i wytłumaczyć. Komórki te przyjmują i wysyłają sygnały o częstotliwości 1–100 Hz (Tadeusiewicz, 1993).

Niezbędna do powstania algorytmu jest budowa sztucznego neuronu (zob. Rys. 4.2). Działanie sztucznych sieci opiera się na zasadzie funkcjonowania sieci ludzkich neuronów. Pewna informacja dociera do tych komórek, one przetwarzają ją, zapamiętują, by wykorzystać w przyszłości. Sztuczne systemy działają w ten sam sposób. Informacje są podawane, przetwarzane i zapamiętywane, a nawet poprawiane przez system. Tak samo jak w rzeczywistej sieci neuronów, komórki mogą łączyć się ze sobą tworząc sieci wielowarstwowe i jednocześnie powiększając możliwości obliczeniowe algorytmu (Osowski, 1996).




Rys. 4.2. Model sztucznego neuronu (perceptronu):  $x_i$  – sygnały wejściowe;  $\mathbf{y}$  – wektor (sygnał) wyjściowy;  $w_i$  – wagi;  $e$  – funkcja wewnętrznego przetwarzania;  $\phi$  – funkcja aktywacji (Tadeusiewicz, 1993).

Aby neurony mogły działać prawidłowo, zgodnie ze swoim przeznaczeniem, muszą najpierw się wszystkiego nauczyć. Potem następuje etap sprawdzania, testowania zdobytej wiedzy, poprawy błędnie nauczonych informacji, by w końcu móc wykorzystać swe umiejętności w praktyce. Dziecko rodząc się posiada „nienauczone” komórki nerwowe, by podczas dojrzewania nauczyć je i będąc dorosłym człowiekiem móc je wykorzystywać. Dokładnie na takiej samej zasadzie oparta jest sztuczna sieć neuronowa. Neurony muszą najpierw przejść etap nauki, tak zwany etap uczenia sieci (Tadeusiewicz, 1993).



Sztuczne sieci neuronowe można podzielić ze względu na kierunek przesyłanego sygnału a także ze względu na strukturę (Korbicz i in., 1994; Kacprzak i Ślot, 1995), co przedstawiono na Rys. 4.3.

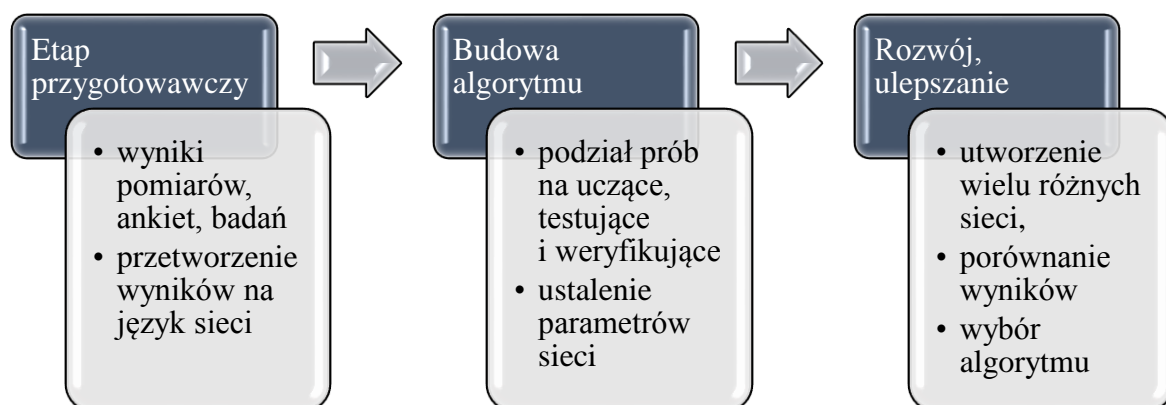


Rys. 4.3. Klasyfikacja sztucznych sieci neuronowych (Tadeusiewicz, 1993).

Do pracy nad sztucznymi sieciami neuronowymi niezbędne są programy komputerowe oraz obszerna wiedza na temat algorytmu. W problemach klasyfikacyjnych najbardziej powszechnymi typami SSN są perceptrony wielowarstwowe. Są to podstawowe sieci neuronowe, oparte na zasadzie wejście – przetwarzanie za pomocą funkcji przetwarzania i aktywacji – wyjście (Osowski, 1996). Jest to aproksymacja globalna. Innym narzędziem są radialne funkcje bazowe, które umożliwiają aproksymacje typu lokalnego. W warstwie ukrytej, neuron jest poddawany działaniu funkcji zmieniających się radialnie wokół wybranego centrum  $c$ . Funkcje te oznaczyć można wzorem ogólnym:  $\varphi(\|x - c\|)$ .

### 4.3.3. Ogólny opis etapów powstawania sieci

Budowę każdej sztucznej sieci neuronowej należy podzielić na kilka etapów (Tadeusiewicz, 1993 i 1998; Korbicz i in., 1994; Osowski, 1996). Podział na fazy obrazuje Rys. 4.4.



Rys. 4.4. Etapy budowy algorytmu sztucznych sieci neuronowych (opracowanie własne na podstawie publikacji: Tadeusiewicz (1993), Korbicz i in. (1994), Osowski (1996)).

Początkowym zadaniem jest sformułowanie problemu, jaki ma być rozwiązany za pomocą algorytmu SSN. Następnie należy zgromadzić dane początkowe, czyli wejściowe. Mogą być to wyniki pomiarów, obserwacji, badań laboratoryjnych, ankietowych i innych. Na tej podstawie tworzy się bazę danych, która będzie podstawą przyszłego algorytmu. Należy przygotować wyniki do dalszej analizy. Najwygodniejszą formą jest stabelaryzowanie wyników z podziałem na kolejne przypadki, rodzaje czy kategorie.

Kluczowym etapem jest budowa algorytmu. Należy określić czynniki, które mają (lub mogą mieć) wpływ na wyniki otrzymane w badaniach podczas tworzenia bazy. Wyniki stanowiąc będą sygnały (wektory) wejściowe  $\mathbf{x}$ . Logicznie rzecz biorąc należałoby określić, które czynniki mają duży wpływ na wynik, a które mniejszy. Jest to właśnie zadanie sieci, która na początku wagi kolejnych czynników przyjmuje losowo. W kolejnych etapach obliczeń wagi zostaną poprawione przez sieć – jest to tak zwana faza uczenia sieci. W celu odpowiedniego zastosowania wag w systemie obliczeń wprowadza się funkcję wewnętrznej aktywacji  $f$ . Funkcja ta może być liniowa, bipolarna, unipolarna, sigmoidalna lub radialna (Osowski, 2000). Należy przyjąć taką funkcję, aby pasowała najlepiej do problemu. Funkcja ta ma za zadanie obliczenie sygnału wyjściowego  $\mathbf{y}$  na podstawie sygnałów wejściowych i podanych wag tych sygnałów.

Niezależnie należy prowadzić fazę weryfikującą. Spośród danych należy wybrać pewną grupę wyników (także poddanych działaniu sieci) i samodzielnie, lub przy pomocy ekspertów, wyznaczyć dla nich wynik. Otrzymane w ten sposób wyniki są porównywane z wynikami otrzymanymi przez sieć (faza weryfikująca), dzięki czemu możliwe jest poprawienie wagi w ten sposób, aby otrzymać wyniki zbliżone do tych podanych przez człowieka. Znane są różne

metody uczenia, na przykład algorytm *Broyden–Fletcher–Goldfarb–Shanno* (w skrócie BFGS), metoda wstecznej propagacji błędu, czy też algorytm *Levenberga–Marquardta* (Rutkowski, 2009). Proces poprawiania wag zwany jest procesem uczenia sieci. Im więcej sprawdzonych i pewnych informacji, tym sieć lepiej się „nauczy” i będzie podawać bardziej wiarygodne wyniki. Oprócz tego, przed stworzeniem sieci, należy wyznaczyć próbki testujące. Wyników tych nie poddajemy działaniu sieci, kiedy jest ona w fazie „uczenia”. Dopiero w końcowej postaci algorytmu wprowadzamy wyniki testujące. Sygnał wyjściowy porównujemy z wyznaczonym poza siecią i określamy, jaki procent próbek testujących oznaczony został poprawnie. Jeśli procent jest dla autora zadowalający, proces tworzenia sieci zostaje ukończony (Mitchell, 1997).

#### **4.4. Maszyny wektorów wspierających**

##### **4.4.1. Geneza maszyny wektorów wspierających**


Początku istnienia maszyny wektorów wspierających szukać należy w pracy Vapnika i Lerner (1963), w której wprowadzono pojęcie wektorów wspierających (ang. *support vectors*) służących do wyznaczania hiperpłaszczyzny podczas klasyfikacji przy rozpoznawaniu obrazu. Rok później, Vapnik i Chervonenkis (1964) przedstawili ideę liniowej klasyfikacji metody MWW. Cover (1965) omówił z kolei kwestie dużego marginesu zakładanego w przestrzeni wartości wejściowych, przeanalizował także problem dużego rozproszenia zmiennych. W 1974 roku powstała pierwsza publikacja zawierająca teorię rozpoznawania wzorców (Vapnik i Chervonenkis, 1974). Metoda wektorów wspierających po raz pierwszy w podobnej do obecnej formie została przedstawiona przez Boser i in. (1992). Trzy lata później, Cortes i Vapnik (1995) przedstawili pojęcie miękkiego marginesu, wykorzystywanego wtedy, gdy dane w ogóle nie są separowalne. W tym samym roku ukazała się publikacja, w której Vapnik (1995) skupił się głównie na problemach regresji. Trzy lata później, Shawe–Taylor i in. (1998) sprecyzowali uogólnienie szerokich marginesów i przedstawili uproszczenie danych wejściowych, aby uzyskać lepszy wynik algorytmu MWW. Dwa lata później, Cristianini i Shawe–Taylor i opublikowali książkę, w której opisali podstawowe zasady i podstawy metody MWW (Cristianini i Shawe–Taylor, 2000).

##### **4.4.2. Charakterystyka metody maszyny wektorów wspierających**

Celem MWW jest analiza i przetwarzanie danych. Przy teraźniejszej technologii i wiedzy na temat programowania komputerowego nie jest problemem, czy są to dane ilościowe (czyli będące konkretną wartością liczbową) czy też jakościowe (informacje opisowe, określające na

przykład jakąś cechę danej próbki czy przypadku lub też wskazujące przynależność do pewnej grupy czy przedziału). W związku z tym, nie ma potrzeby normalizacji danych ani subiektywnego przetwarzania zmiennych jakościowych na ilościowe, co wpływa na wzrost efektywności technik uczenia maszynowego (Conway i White, 2012).

Maszyna wektorów nośnych stworzona została do rozpoznawania wzorców i klasyfikacji ich do danej podgrupy (Vapnik i Lerner, 1963). Dzisiejsza MWW pozwala na rozwiązywanie dwóch podstawowych zagadnień inżynierskich, czyli budowę algorytmu klasyfikacji lub regresji (zob. Rys. 4.5). Są to problemy, które są rozwiązywane poprzez uczenie nadzorowane. Jest to technika, w której na podstawie bazy danych zawierających zmienne niezależne i ich wpływie na zmienne zależne można wyznaczyć odpowiedź dla nieznanego przypadku, dla którego nie była wyznaczona wartość zmiennej zależnej w sposób, na przykład, empiryczny, a odpowiedź tę poznaje się dzięki „nauczanej maszynie”. Z przypadkiem regresji mamy do czynienia wtedy, gdy zmiennym można przyporządkować pewną funkcję ciągłą, aby możliwe było wyznaczenie zmiennej zależnej dla dowolnie wybranej wartości wstępnej.




Rys. 4.5. Modelowe rozwiązanie problemu regresji MWW: po lewej – problem do rozwiązania; po prawej – wyznaczona funkcja ciągła (Cherkassky i Ma, 2004).

Drugim, bardziej powszechnym i częściej implementowanym typem zadań rozwiązywanych przez MWW jest klasyfikacja (zob. Cortes i Vapnik, 1995). Celem takiego algorytmu jest (jak sama nazwa wskazuje) sklasyfikowanie zmiennych i przydzielenie ich do pewnych podgrup. Zadanie MWW sprowadza się do wyznaczenia granicy – separatora, który rozdzieli dane w oczywisty sposób na zadane podzbiory. Celem takiego działania jest stworzenie możliwości klasyfikacji nowych danych, dla których nie jest znana przynależność. W metodzie MWW zakłada się, że zmienne wejściowe są wzajemnie niezależne i mają taki sam rozkład prawdopo-

dobieństwa. Dotyczy to zarówno próbek uczących jak i testowych. W tego typu zadaniach metoda wektorów wspierających okazuje się bardzo dobrym algorytmem. Oceną wiarygodności systemu jest tak zwana generalizacja (Cortes i Vapnik, 1995).

Najprostszy problem klasyfikacyjny można przedstawić na płaszczyźnie jako zbiór punktów (zmiennych) o dwóch różnych właściwościach, który należy podzielić na dwa podzbiory segregujące. Jest to klasyfikator binarny. Na Rys. 4.6 przedstawiono schemat, w którym zaznaczono punkty koloru czarnego i szarego. Rozdzielenie punktów polega na wyznaczeniu hiperpłaszczyzny, która sklasyfikuje punkty do dwóch niezależnych obszarów (Haykin, 2009).



Rys. 4.6. Modelowe rozwiązanie problemu klasyfikacji MWW: po lewej – problem do rozwiązania; po prawej – wyznaczona hiperpłaszczyzna  $g(x)$  separująca klasy (Haykin, 2009).

Są to najprostsze przypadki klasyfikacji, do których nie jest konieczne stosowanie skomplikowanych algorytmów uczenia maszynowego, np. MWW. Warto zauważyć, że większość problemów inżynierskich nie można przedstawić w przestrzeni dwuwymiarowej dzieląc zmienne jedynie na dwa podzbiory. W takich sytuacjach zastosowanie ma MWW, która umożliwia klasyfikację za pomocą hiperpłaszczyzny na większą liczbę podzbiorów – jest to tak zwany klasyfikator wieloklasowy (Fumera i Roli, 2005). Metoda ta sprawdza się zarówno w zadaniach przedstawionych powyżej, które można rozdzielić linią ciągłą, a także innych, dla których nie można wyznaczyć prostego wzoru matematycznego dla hiperpłaszczyzny.

Jeżeli funkcja rozdzielająca zbiory jest liniową funkcją ciągłą (lub hiperpłaszczyzną sprowadzoną do funkcji liniowej), nazywa się ten zbiór separowalnym liniowo (Vapnik i Lerner, 1963). A więc, zgodnie z definicją, zbiory są separowalne liniowo, gdy istnieje taka hiperpłaszczyzna  $g(x)$  (Cortes i Vapnik, 1995):

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (4.1)$$



gdzie:

$\mathbf{w}$  – wektor współczynników (wektor normalny płaszczyzny):  $\mathbf{w} = [w_1, w_2, \dots, w_n]$ ;

$\mathbf{x}$  – wektor wejściowy:  $\mathbf{x} = [x_1, x_2, \dots, x_n]$ ;

$b$  – próg, wyraz wolny;


dla:

$$\begin{cases} \mathbf{w} \cdot \mathbf{x}_i + b \geq 0 & \text{dla } y_i = +1 \\ \mathbf{w} \cdot \mathbf{x}_i + b < 0 & \text{dla } y_i = -1 \end{cases} \quad (4.2)$$

Zatem hiperpłaszczyzna, deklarująca optymalny margines zapisana może być jako (Cortes i Vapnik, 1995):


$$\mathbf{w}_0 \cdot \mathbf{x} + b_0 = 0 \quad (4.3)$$

W zależności od liczby zmiennych i ich rozrzutu może istnieć jedna lub nieskończenie wiele funkcji ciągłych rozdzielających zmienne, co przedstawia schematyczny wykres na Rys. 4.7.




Rys. 4.7. Możliwe rozwiązanie problemu klasyfikacji MWW: po lewej – wyznaczona jedna hiperpłaszczyzna separująca dane; po prawej – wiele hiperpłaszczyzn separujących dane.

W przypadku problemów separowalnych liniowo, rozwiązanie zaproponowali Vapnik i Lerner (1963). Polega ono na określeniu maksymalnego marginesu, który definiuje klasyfikację zmiennych (Rys. 4.8, 4.9). Istnieje również klasyfikator słabego marginesu, który jest wykorzystywany w przypadku zaszumionych danych (Cortes i Vapnik, 1995).



Rys. 4.8. Możliwe rozwiązanie problemu klasyfikacji MWW z maksymalnym marginesem (Vapnik i Lerner, 1963).


Marginesem geometrycznym nazywa się odległość hiperpłaszczyzny do najbliższych punktów danych podzbiorów. Punkty, które leżą na linii marginesu są nazywane wektorami wspierającymi. W klasyfikacji maksymalnego marginesu znajduje się taką hiperpłaszczyznę, która rozdziela zmienne na podzbiory w taki sposób, że maksymalizowany jest margines geometryczny dla wszystkich danych (zob. Vapnik i Lerner, 1963).



Rys. 4.9. Możliwe rozwiązanie problemu klasyfikacji MWW z maksymalnym marginesem i zaznaczonymi wektorami wspierającymi ( $w_1$ – $w_5$ ) (Vapnik i Lerner, 1963).

#### 4.4.3. Problemy klasyfikacji nieseparowalnej liniowo

W przypadku, gdy problem jest nieseparowalny liniowo (Rys. 4.10) należy dokonać transformacji problemu do innej przestrzeni, na przykład z przestrzeni  $X$  do  $Z$ .



Rys. 4.10. Porównanie problemów klasyfikacji: po lewej – problem nieseparowalny liniowo; po prawej – problem separowalny liniowo (Boser i in., 1992).

Wektory nośne będą wtedy leżeć w przestrzeni  $Z$ , a w przestrzeni  $X$  widać tylko ich rzuty – punkty (Rys. 4.11). Funkcja celu maszyny wektorów nośnych w przestrzeni  $X$  przedstawiona w postaci (Boser i in. 1992; Cortes i Vapnik, 1995; Bennett i Campbell, 2000):

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n [y_i y_j \lambda_i \lambda_j x_i x_j] - \sum_{i=1}^n \lambda_i \quad (4.4)$$

przekształcona zostaje w funkcję celu dla wektorów w przestrzeni  $Z$ :

$$\min_{\lambda} Q(\lambda) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n [y_i y_j \lambda_i \lambda_j z_i z_j] - \sum_{i=1}^n \lambda_i \quad (4.5)$$


gdzie (przy ograniczeniach):

$$\lambda_i \geq 0, i = 1, \dots, n \quad (4.6)$$

$$\sum_{i=1}^n \lambda_i y_i = 0 \quad (4.7)$$

otrzymujemy:

$$f(x) = \text{sign}(\mathbf{w}_0 \mathbf{z} + b_0) \quad (4.8)$$



Rys. 4.11. Możliwe rozwiązanie problemu klasyfikacji nieseparowalnej liniowo z zaznaczonymi wektorami wspierającymi ( $w_1$ – $w_4$ ) (Bennett i Campbell, 2000).

Matematyczna postać optymalizacji kształtuje się następująco (Cortes i Vapnik, 1995; Haykin, 2009):

$$FC = \frac{1}{2} \mathbf{w} \cdot \mathbf{w} + C \sum_{i=1}^n \xi_i \rightarrow \min \quad (4.9)$$

przy ograniczeniach:

$$\begin{aligned} y_i \mathbf{w}^T \varphi(x_i) &\geq 1 - \xi_i \\ \xi_i &\geq 0 \\ i &= 1, \dots, n \end{aligned} \quad (4.10)$$

gdzie:

$\mathbf{w}$  – wektor współczynników;

$C$  – parametr (pojemność) decydujący o sile kary<sup>6</sup>,  $C \geq 0$ ;

$(1 - \xi_i)$  – odległość punktu od hiperpłaszczyzny;

$\xi_i$  – zmienne słabości marginesu, przyjmujące wartości:

- Jeżeli  $\xi_i = 0$ ,  $x_i$  jest klasyfikowany poprawnie i leży poza marginesem lub na jego granicy,
- Jeżeli  $0 < \xi_i \leq 1$ ,  $x_i$  jest klasyfikowany poprawnie i leży na marginesie,
- Jeżeli  $\xi_i > 1$ ,  $x_i$  jest klasyfikowany błędnie;

$y_i$  – zmienna zależna (klasa przynależności),  $y_i \in \{-1, 1\}$ ;

<sup>6</sup> jest to kara, jaką musi ponieść model za każdy błędnie określony przypadek (czyli ten, dla którego  $\xi_i > 1$ );  $C$  przyjmuje się ze zbioru  $[10^{-6}, 10^{-5}, \dots, 10^6]$ ; za duża wartość  $C$  prowadzi do przeuczenia i maksymalizacji marginesu, za mała prowadzi do niedouczenia (EPS, 2017).

$\varphi(x_i) = K(x,y)$  – funkcja jądrowa (liniowa, wielomianowa, potencjalna funkcja bazowa, sigmoidalna), tzw. kernel (Souza, 2010):

- $K(x, y) = \mathbf{x} \cdot \mathbf{y} + c$  – kernel liniowy,
- $K(x, y) = (\alpha \mathbf{x} \cdot \mathbf{y} + c)^d$  – kernel wielomianowy,
- $K(x, y) = \exp(-\frac{\|\mathbf{x}-\mathbf{y}\|^2}{2\sigma^2})$  – kernel potencjalnych funkcji bazowych,
- $K(x, y) = \tanh(\alpha \mathbf{x} \cdot \mathbf{y} + c)$  – kernel sigmoidalny,

gdzie:

$c$  – opcjonalna stała;

$\alpha$  – nachylenie,  $\alpha = 1/N$ , gdzie  $N$  jest wymiarem danych;

$d$  – stopień wielomianu;

$\sigma$  – parametr regulujący zaszumienie danych i zapewniający nieliniowość funkcji.



## 5. BUDOWA ALGORYTMU SZTUCZNYCH SIECI NEURONOWYCH

### 5.1. Informacje wejściowe i wyjściowe

Celem algorytmu opisanego w niniejszym rozdziale jest wykorzystanie SSN do prognozowania wpływu drgań komunikacyjnych wywołanych ruchem drogowym na budynki mieszkalne. Procedurę badawczą zbierania danych wejściowych szczegółowo opisano w rozdziale 3 niniejszej rozprawy. Wyniki badań eksperymentalnych wykorzystano do budowy SSN. Oprócz własnych badań posłużono się również wynikami badań wykonanymi przez innych badaczy.

Sygnały wejściowe przyjęto na podstawie normy PN–85/B–02170 oraz publikacji (np. Duńska i in., 2014) i były to: odległość budynku od krawędzi drogi (zmienna ilościowa), stan i rodzaj nawierzchni, stan budynku, typ pojazdu oraz absorpcja drgań w gruncie (zmiennie jakościowe). Tworząc sieci wykorzystywano różną kombinację tych parametrów.

Sygnałem wyjściowym była informacja, czy istnieje zagrożenie negatywnego oddziaływania drgań na budynki czy nie. Niebezpieczeństwo wyznaczono na podstawie kryteriów zawartych w normie PN–85/B–02170. Brak zagrożenia wskazuje na I strefę wpływu drgań, według SWD I lub SWD II, czyli brak oddziaływań komunikacyjnych na budynki. Jeżeli algorytm prognozuje możliwe zagrożenie, jest to wskazanie do wykonania pomiarów *in situ*, ponieważ może to oznaczać, że dany budynek znajduje się w strefie II lub w wyższej.

### 5.2. Informacje techniczne tworzenia SSN

Budowę sieci przeprowadzono na podstawie zasad opisanych w literaturze (Tadeusiewicz, 1993; Korbicz i in., 1994; Osowski, 1996; Haykin, 2009). Pierwszym krokiem było utworzenie bazy danych niezbędnych do rozpoczęcia budowy algorytmu, czyli wykonanie pomiarów drgań na budynkach. Zgromadzono 63 próbki, w tym 33 próbki danych wejściowych wykonując samodzielne pomiary (opisane w rozdziale 3) i 30 próbek na podstawie pomiarów innych badaczy (Chyży i in., 2009; Kawecki i Stypuła, 2009; Czech i in., 2015; Stypuła, 2015). Określono, jakie parametry mogą wpływać na wyniki otrzymane w badaniach podczas tworzenia bazy. Czynniki, które wykorzystano jako sygnały wejściowe do sieci to: stan techniczny budynku, odległość budynku od krawędzi drogi, absorpcja drgań w gruncie, rodzaj nawierzchni, stan nawierzchni, typ pojazdu.

#### 5.2.1. Stan techniczny budynku

Pierwszym parametrem związanym z budynkiem jest jego stan techniczny. Nie są brane pod uwagę szczególne indywidualne rozwiązania, wymiary czy też materiały, z których wykonany jest budynek, ponieważ norma PN–85/B–02170 wyraźnie opisuje zakres zastosowań

skal SWD do budynków murowanych oraz z elementów wielkopłytowych. W związku z tym w przeprowadzonej analizie uwzględniano jedynie fakt przynależności do skali SWD I lub SWD II oraz stan budynku, który może mieć wpływ na odczuwalność drgań i tym samym przyspieszać zużycie eksploatacyjne obiektu. Określanie stanu budynku przedstawiono w Tab. 5.1, w której wykorzystano ogólne wytyczne przeprowadzania okresowej oceny stanu technicznego budynków (Michalik, 2014).

Tab. 5.1. Kryterium określania stanu technicznego budynku (Michalik, 2014).

<b>STAN TECHNICZNY</b> (zużycie w [%])	<b>ROZMIAR USZKODZEŃ LUB ZNISZCZEŃ ELEMENTÓW OBIEKTU BUDOWLANEGO NA SKUTEK ZUŻYCIA – OCENA WIZUALNA POPRZEZ OGLĘDZINY</b>
<b>DOBRY</b> (zużycie od 0% do 25%)	<ul style="list-style-type: none"> <li>– elementy obiektu budowlanego (konstrukcja, wykończenie, wyposażenie, instalacje) są dobrze utrzymane, konserwowane i nie wykazują widocznego zużycia i uszkodzeń lub w elementach tych występują niewielkie uszkodzenia i ubytki niezagrażające bezpieczeństwu użytkowania,</li> <li>– wskazane jest wykonanie prac konserwacyjnych lub napraw bieżących polegających na remoncie wytypowanych elementów obiektu,</li> <li>– cechy i właściwości wbudowanych materiałów i urządzeń odpowiadają wymogom norm i przepisów,</li> </ul>
<b>ŚREDNI</b> (zużycie od 26% do 60%)	<ul style="list-style-type: none"> <li>– elementy obiektu budowlanego (konstrukcja, wykończenie, wyposażenie, instalacje) utrzymane są w stopniu zadowalającym,</li> <li>– w elementach występują średnie uszkodzenia,</li> <li>– celowy jest remont bieżący polegający na drobnych naprawach, uzupełnieniach, konserwacji, impregnacji,</li> </ul>
<b>ZŁY</b> (zużycie od 61%)	<ul style="list-style-type: none"> <li>– w elementach obiektu budowlanego (konstrukcja, wykończenie, wyposażenie, instalacje) występują znaczne ubytki, które mogą zagrażać bezpieczeństwu użytkowania,</li> <li>– cechy i właściwości wbudowanych materiałów i urządzeń utraciły swoje pierwotne właściwości,</li> <li>– wymagane jest wykonanie remontu kapitalnego, czyli remontu polegającego na wymianie wielu elementów obiektu budowlanego lub rozebranie budynku.</li> </ul>

### 5.2.2. Odległość budynku od drogi

Norma PN–85/B–02170 podaje, że wpływ drgań komunikacyjnych ma znaczenie przede wszystkim dla budynków oddalonych mniej niż o 15 metrów od osi drogi. W niniejszej rozprawie rozpatrzono budynki usytuowane w różnych odległościach. Odległość jest jedyną zmienną ilościową występującą w niniejszym algorytmie i jest podawana w metrach, w zakresie 1,91 – 22,5 m od krawędzi drogi.

### 5.2.3. Absorpcja drgań w gruncie

Bardzo ważnym czynnikiem, który należy wziąć pod uwagę, jest rodzaj gruntu, w którym przenoszą się drgania. Ponieważ każdy grunt inaczej absorbuje fale (zob. podrozdział 2.2.1), można w przybliżeniu ustalić korelację pomiędzy rodzajem podłoża gruntowego a absorpcją drgań stosując trójstopniowe kryterium według Tab. 5.2 (Ciesielski, 2002, Dulińska i in., 2014).

Tab. 5.2. Kryterium określania absorpcji drgań przez podłoże gruntowe (Ciesielski, 2002).

<b>ABSORPCJA</b>	<b>RODZAJ PODŁOŻA GRUNTOWEGO</b>
<b>ZŁA</b>	Mokre, luźne piaski pylaste, drobne piaski gliniaste i drobne grunty spoiste w stanie plastycznym.
<b>ŚREDNIA</b>	Piaski średnio- i gruboziarniste, gliny zawilgocone, gliny, grunty spoiste twardoplastyczne.
<b>DOBRA</b>	Piaski zagęszczone, gliny suche, grunty spoiste półzwarne i zwarte.

### 5.2.4. Rodzaj nawierzchni

Budynki mieszkalne lokalizowane są przy drogach o różnych rodzajach nawierzchni. Najczęściej jest to nawierzchnia bitumiczna, betonowa z płyt, z kostki brukowej lub droga gruntowa.

### 5.2.5. Stan techniczny nawierzchni

W zależności od rodzaju nawierzchni stosować należy różne wytyczne w ocenie stanu technicznego. Ogólne kryterium przedstawiono w Tab. 5.3 (Saganowski, 2002).

Tab. 5.3. Kryterium oceny stanu technicznego nawierzchni (Saganowski, 2002).

<b>STAN TECHNICZNY</b>	<b>CHARAKTERYSTYKA</b>
<b>DOBRY</b> (klasa A i B)	Nawierzchnie nowe, odnowione i eksploatowane, dopuszczalne występowanie sporadycznych uszkodzeń, nawierzchnie niewymagające remontów.
<b>ŚREDNI</b> (klasa C)	Nawierzchnie z kilkoma uszkodzeniami, wymagane zaplanowanie remontu.
<b>ZŁY</b> (klasa D)	Nawierzchnie z licznymi i rozległymi uszkodzeniami, wymagany natychmiastowy remont.

Do zastosowania algorytmu prognozowania drgań przyjęto bardziej szczegółową ocenę stosując podział kryterium osobno dla nawierzchni bitumicznych, betonowych i gruntowych, co opisano poniżej.

### 5.2.5.1. Stan techniczny nawierzchni bitumicznych

Autorski sposób oceny wykonano na podstawie dostępnej literatury (Czarnecki i Janowski, 2002). Przy ocenie stanu nawierzchni bitumicznych należy wziąć pod uwagę następujące parametry (na podstawie oględzin): pęknięcia (poprzeczne i podłużne), łaty, wyboje, ubytki ziaren lub lepiszcza. Aby ocenić stan nawierzchni drogi przy badanym budynku, należy wyliczyć ze wzoru wartość  $S_{NBit}$  (w odniesieniu do oceny przedstawionej w Tab. 5.4):

$$S_{NBit} = P_{pd} + P_{pp} + L + W + U \quad (5.1)$$

gdzie:

$S_{NBit}$  – stan nawierzchni bitumicznej: 0: stan dobry, 1–3: stan średni, 4–5: stan zły;

$P_{pd}$  – pęknięcia podłużne: 0: szkodliwość mała, 1: szkodliwość duża;

$P_{pp}$  – pęknięcia poprzeczne: 0: szkodliwość mała, 1: szkodliwość duża;

$L$  – łaty: 0: szkodliwość mała, 1: szkodliwość duża;

$W$  – wyboje: 0: szkodliwość mała, 1: szkodliwość duża;

$U$  – ubytki ziaren lub lepiszcza: 0: szkodliwość mała, 1: szkodliwość duża.

Tab. 5.4. Kryterium oceny stanu technicznego nawierzchni bitumicznych (Czarnecki i Janowski, 2002).

PARAMETR	OPIS	SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
<b>PEKNIĘCIA PODŁUŻNE</b>	przebiegające prosto lub krzywoliniowo pojedyncze pęknięcia warstwy bitumicznej o kierunku równoległym lub ukośnym do osi jezdni (w tym również spojenia technologiczne).	pęknięcia zalane i szczelne oraz pęknięcia nieszczelne, ale bez wykruszeń na krawędziach.	pęknięcia nieszczelne z wykruszeniami na krawędziach lub z siatką pęknięć.
<b>PEKNIĘCIA POPRZECZNE</b>	przebiegające prosto lub krzywoliniowo pojedyncze pęknięcia warstwy bitumicznej o kierunku prostopadłym do osi jezdni.	pęknięcia poprzeczne występujące łącznie na nie więcej niż 50% szerokości ocenianego pasa ruchu.	pęknięcia poprzeczne występujące łącznie na więcej niż 50% szerokości ocenianego pasa ruchu.
<b>ŁATY</b>	miejsca nawierzchni, na których dokonano wymiany nawierzchni, uzupełnienia ubytków, wypełnienia zapadnięć lub naprawy wybojów.	łata szczelnie połączona z nawierzchnią lub z niewielkimi pęknięciami na połączeniach, łata o małej szerokości występująca łącznie na nie więcej niż 50% szerokości ocenianego pasa ruchu.	łata połączona z nawierzchnią nieszczelnie (pęknięcia i wykruszenia), łata o dużej szerokości występująca łącznie na więcej niż 50% szerokości ocenianego pasa ruchu.

<b>WYBOJE</b>	miejsca nawierzchni, gdzie występuje ubytek masy warstwy jezdnej o wymiarach nie mniejszych niż 15 cm × 15 cm i o głębokości większej niż grubość warstwy ścieralnej.	wyboje występują łącznie na nie więcej niż 50% powierzchni ocenianego pasa ruchu.	wyboje występują łącznie na więcej niż 50% powierzchni ocenianego pasa ruchu.
<b>UBYTKI ZIAREN LUB LEPISZCZA</b>	miejsca nawierzchni, na których nastąpił ubytek materiału warstwy ścieralnej bez naruszenia warstw niżej leżących; do uszkodzeń tego typu zaliczają się również rozstępy warstwy ścieralnej pochodzenia wykonawczego oraz powierzchnie po zabiegu frezowania.	ubytki występują łącznie na nie więcej niż 50% szerokości ocenianego pasa ruchu.	ubytki występują łącznie na więcej niż 50% szerokości ocenianego pasa ruchu.

#### 5.2.5.2. Stan techniczny nawierzchni betonowych

Autorski sposób oceny stanu nawierzchni z płyt betonowych wykonano na podstawie dostępnej literatury (Radzikowski i Foryś, 2007). Przy ocenie stanu nawierzchni betonowych należy wziąć pod uwagę następujące parametry (na podstawie oględzin): pęknięcia pojedyncze podłużne, ukośne, poprzeczne, złamanie płyty, pęknięcie przy krawędzi, uszkodzone zbrojenie, wadliwe uszczelnienie, uszkodzenie narożnika, wykruszenie szczeliny, uszkodzenia powierzchni (pęknięcia powierzchniowe, złuszczenia, ubytki), łąta bitumiczna (zob. Tab. 5.5 – 5.11). W przypadku stwierdzenia szkodliwości małej przydziela się 0 pkt, w przypadku dużej 1 pkt. Aby ocenić stan nawierzchni drogi przy badanym budynku należy wyliczyć ze wzoru wartość  $S_{NBet}$ :

$$S_{NBet} = P_{pdu} + P_{pp} + P_k + U_n + W_s + U_z + W_u \quad (5.2)$$

gdzie:

$S_{NBet}$  – stan nawierzchni betonowej: 0: stan dobry, 1–4: stan średni, 5–7: stan zły;

$P_{pdu}$  – pęknięcia podłużne i ukośne: 0: szkodliwość mała, 1: szkodliwość duża;

$P_{pp}$  – pęknięcia poprzeczne: 0: szkodliwość mała, 1: szkodliwość duża;

$P_k$  – pęknięcia przy krawędzi: 0: szkodliwość mała, 1: szkodliwość duża;

$U_n$  – uszkodzenia narożnika: 0: szkodliwość mała, 1: szkodliwość duża;

$W_s$  – wykruszenie szczeliny: 0: szkodliwość mała, 1: szkodliwość duża;

$U_z$  – uszkodzenie zbrojenia: 0: szkodliwość mała, 1: szkodliwość duża;

$W_u$  – wadliwe uszczelnienie: 0: szkodliwość mała, 1: szkodliwość duża.



Tab. 5.5. Określenie szkodliwości uszkodzenia w postaci pęknięcia pojedynczego podłużnego i ukośnego (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
<ul style="list-style-type: none"> <li>– szerokość pęknięcia mniejsza niż 3 mm, szerokość obszaru wykruszeń i towarzyszących pęknięć mniejsza niż 10 cm, uskok między krawędziami pęknięcia mniejsza niż 5 mm,</li> <li>– prawidłowo uszczelnione pęknięcie o nieokreślonej szerokości.</li> </ul>	<ul style="list-style-type: none"> <li>– szerokość pęknięcia co najmniej 3 mm,</li> <li>– szerokość obszaru wykruszeń i towarzyszących pęknięć co najmniej 10 cm,</li> <li>– uskok między krawędziami pęknięcia co najmniej 5 mm.</li> </ul>

Tab. 5.6. Określenie szkodliwości uszkodzenia w postaci pęknięcia pojedynczego poprzecznego (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
<ul style="list-style-type: none"> <li>– szerokość pęknięcia mniejsza niż 3 mm, szerokość obszaru wykruszeń i towarzyszących pęknięć mniejsza niż 10 cm</li> <li>– uskok między krawędziami pęknięcia mniejszy niż 5 mm,</li> <li>– prawidłowo uszczelnione pęknięcie o nieokreślonej szerokości, brak wysadziny przy pęknięciu i tylko jedno pęknięcie.</li> </ul>	<ul style="list-style-type: none"> <li>– szerokość pęknięcia co najmniej 3 mm,</li> <li>– szerokość obszaru wykruszeń i towarzyszących pęknięć co najmniej 10 cm,</li> <li>– uskok między krawędziami pęknięcia co najmniej 5 mm,</li> <li>– wysadzina towarzysząca pęknięciu,</li> <li>– dwa pęknięcia, niezależnie od stopnia szkodliwości każdego z nich osobno.</li> </ul>

Tab. 5.7. Określenie szkodliwości uszkodzenia w postaci pęknięcia przy krawędzi (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
<ul style="list-style-type: none"> <li>– pęknięcia występują wzdłuż na mniej niż 25% długości lub szerokości płyty, fragmenty mocno trzymające się, mogą być lekko przemieszczone, otoczone pęknięciami małej szkodliwości i wpływ na równość nawierzchni jest niewielki.</li> </ul>	<ul style="list-style-type: none"> <li>– pęknięcia występują na znacznej części krawędzi płyty (ponad 25% długości lub szerokości),</li> <li>– fragmenty są wyraźnie określone i łatwo dają się wyjmować,</li> <li>– fragmenty mają znaczący wpływ na równość.</li> </ul>

Tab. 5.8. Określenie szkodliwości uszkodzenia narożnika (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
<ul style="list-style-type: none"> <li>– pojedyncze pęknięcie bez wykruszeń oraz luźnego materiału,</li> <li>– szerokość pęknięcia mniejsza niż 3 mm,</li> <li>– prawidłowo uszczelnione pęknięcie o nieokreślonej szerokości.</li> </ul>	<ul style="list-style-type: none"> <li>– pęknięcie silnie wykruszone z luźnymi lub brakującymi fragmentami,</li> <li>– szerokość pęknięcia co najmniej 3 mm,</li> <li>– wielokrotne pęknięcia,</li> <li>– wykruszenie narożnika.</li> </ul>

Tab. 5.9. Określenie szkodliwości wykruszenia szczeliny (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
<ul style="list-style-type: none"> <li>– krawędź jest odłamana pęknięciami małej szkodliwości,</li> <li>– w szczelinie nie ma dużej liczby ruchomych fragmentów.</li> </ul>	<ul style="list-style-type: none"> <li>– krawędź jest odłamana pęknięciami dużej szkodliwości,</li> <li>– w szczelinie jest duża liczba ruchomych fragmentów.</li> </ul>

Tab. 5.10. Określenie szkodliwości uszkodzenia zbrojenia (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
– brak widocznych elementów zbrojenia.	– poluzowanie, odsłonięcie lub pęknięte elementy zbrojenia.

Tab. 5.11. Określenie szkodliwości wadliwego uszczelnienia (Radzikowski i Foryś, 2007).

SZKODLIWOŚĆ MAŁA	SZKODLIWOŚĆ DUŻA
– brak widocznych wad w uszczelnieniu.	– brak uszczelnienia w szczelinie umożliwiający gromadzenie się w szczelinie nieściśliwych materiałów i przedostawanie się wody, – wyrwanie, wypchnięcie, lub wciśnięcie uszczelnienia, porośnięcie roślinnością, stwardnienie wypełniacza, odklejenie od brzegów płyt, rozsunięcie się płyt.

### 5.2.5.3. Stan techniczny nawierzchni z kostki brukowej i drogi gruntowej

Ocenę nawierzchni należy przeprowadzić na podstawie oględzin i opisać jej stan jako: „dobry”, „średni” lub „zły” na podstawie następujących przesłanek (Łój, 2007, Trzeciński i Kaczmarzyk, 2006):

- jeżeli nawierzchnia (droga gruntowa) jest równa, bez uszkodzeń, wybojów, wystających studzienek to można zakwalifikować ją do stanu dobrego,
- jeżeli nawierzchnia (droga gruntowa) ma niewiele uszkodzeń lub pofalowań to można zakwalifikować ją do stanu średniego,
- jeżeli występuje więcej niż kilka uszkodzeń, jeżeli nawierzchnia (droga gruntowa) jest pofalowana, występują widoczne dylatacje, wystające studzienki to należy zakwalifikować ją do stanu złego.

### 5.2.6. Typ pojazdów poruszających się po drodze

Dopuszczalne masy pojazdów należy ustalić w oparciu o ustawę o drogach publicznych (Ustawa z dnia 21 marca 1985r. o drogach publicznych). Typy pojazdów przedstawiono w Tab. 5.12.

Tab. 5.12. Możliwe typy pojazdów (Ustawa o drogach publicznych, 2007).

TYP POJAZDU	CHARAKTERYSTYKA POJAZDU
<b>TYP 1</b>	– pojazdy samochodowe o dopuszczalnej masie całkowitej nieprzekraczającej 3,5 t (z wyjątkiem autobusów), oraz zespoły tych pojazdów
<b>TYP 2</b>	– autobusy o dwóch osiach, ciągniki samochodowe bez naczep – samochody dostawcze do 10 t
<b>TYP 3</b>	– zespoły pojazdów składające się z samochodu ciężarowego o dopuszczalnej masie całkowitej przekraczającej 10 t i przyczepy albo z autobusu i przyczepy – pojazdy członowe o całkowitej liczbie osi powyżej pięciu – samochody ciężarowe o dopuszczalnej masie całkowitej przekraczającej 10 t – autobusy o trzech (i więcej) osiach, pojazdy członowe o całkowitej liczbie osi do pięciu

### 5.3. Utworzone sztuczne sieci neuronowe

W niniejszym podrozdziale analizie poddano problem klasyfikacji zdefiniowany w ten sposób, aby algorytm SSN (na podstawie kilku parametrów podanych przez użytkownika) dokonał prognozy wpływu oddziaływań komunikacyjnych na budynek z zadowalającym prawdopodobieństwem. Za sygnały wejściowe (neurony) przyjęto czynniki (zmiennie niezależne) ustalone podczas pomiarów polowych, tj.:

- $B_{ST}$  – stan budynku;
- $B_{DO}$  – odległość budynku od krawędzi drogi;
- $G_A$  – absorpcja gruntu;
- $D_N$  – rodzaj nawierzchni drogi;
- $D_{STN}$  – stan nawierzchni drogi;
- $P$  – typ pojazdu.

Wektory wejścia dla kolejnych sieci przyjęto w sposób losowy, w postaci:

- SSN nr I:  $\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$ ;
- SSN nr II:  $\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$ ;
- SSN nr III:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$ ;
- SSN nr IV:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, D_N, P\}$ ;
- SSN nr V:  $\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$ .

Jako sygnał wyjściowy ustalono dwa neurony o wartościach:

- 0 – brak wpływu drgań na budynek – I strefa według SWD I lub SWD II zgodnie z normą PN-85/B-02170;
- 1 – prawdopodobny wpływ drgań na budynek – II strefa lub wyższa.

W zależności od rodzaju SSN zastosowano algorytm uczenia BFGS, który jest silnym algorytmem drugiego rzędu o szybkiej zbieżności i znajdowania ekstremów lokalnych funkcji (Rutkowski, 2009). W przypadku sieci radialnych zastosowano (w procesie uczenia) radialne funkcje bazowe. W utworzonych algorytmach wykorzystano funkcje aktywacji podane w Tab. 5.13 (Haykin, 2009).

Tab. 5.13. Funkcje aktywacji wykorzystane podczas budowy SSN.

NAZWA FUNKCJI	WZÓR FUNKCJI
<b>SIGMOIDALNA UNIPOLARNA</b>	$F(u_i) = \frac{1}{1 + \exp(-u_i)} \in (0, 1)$
<b>SINUS</b>	$F(u_i) = \sin(u_i) \in [0, 1]$
<b>GAUSSA</b>	$F(u_i) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(u_i-\mu)^2}{2\sigma^2}\right] \in (0, +\infty)$
<b>LINIOWA</b>	$F(u_i) = a u_i + b \in (-\infty, +\infty)$
<b>WYKŁADNICZA</b>	$F(u_i) = e^{-u} \in (0, +\infty)$
<b>REGRESJA WIELORAKA</b>	$F(u_i) = \frac{\exp(u_i)}{\sum \exp(u_i)}$
<b>TANGENS HIPERBOLICZNY</b>	$F(u_i) = \operatorname{tgh}(u_i) \in [0, 1]$

W procesie uczenia, do ustalania wag neuronów wejściowych, wykorzystano dwie funkcje oceny błędu: funkcję błędu sumy kwadratów różnic  $E_{SOS}$  (Rutkowski, 2009):

$$E_{SOS} = \sum_{i=1}^n (y_i - t_i)^2 \quad (5.3)$$

gdzie:

$n$  – liczba przypadków użytych do uczenia,

$y_i$  – predykcja,

$t_i$  – wartość rzeczywista,

oraz funkcję błędu w postaci entropii wzajemnej (*Cross Entropy*)  $E_{CE}$  (Rubinstein i in., 2004):

$$E_{CE} = -\sum_{i=1}^n t_i \ln\left(\frac{y_i}{t_i}\right) \quad (5.4)$$

gdzie:

$n$  – liczba przypadków użytych do uczenia,

$y_i$  – predykcja,

$t_i$  – wartość rzeczywista.

Algorytm SSN wykonano w programie *Statistica 12*. Tab. 5.14 przedstawia wszystkie informacje o próbkach wykorzystanych do budowy algorytmu. Tabela zestawia ponadto informacje wejściowe oraz informację wyjściową dotyczącą zagrożenia (otrzymaną z pomiarów rzeczywistych). Z kolei, w Tab. 5.15 zestawiono informacje pomocnicze odnośnie utworzonych sieci, wariantu próbek i numeru rozdziału niniejszej dysertacji, w którym umieszczono szczegółowe opisy i wyniki. Przedstawiono również strukturę każdej utworzonej sieci, czyli liczbę neuronów w warstwie wejściowej – liczbę neuronów w warstwie ukrytej – liczbę neuronów w warstwie wyjściowej.

Tab. 5.14. Charakterystyka danych wejściowych wykorzystanych do utworzenia algorytmu SSN oraz informacja wyjściowa dotycząca zagrożenia (otrzymana z pomiarów rzeczywistych).

NR PRZY-PADKU	NR BUDYNKU	STAN BUDYNKU	ODLEGŁOŚĆ OD KRAWĘDZI DROGI [m]	ABSORPCJA DRGAŃ	RODZAJ NAWIERZCHNI	STAN NAWIERZCHNI	TYP POJAZDU	ZAGROŻENIE
1	1	zły	7	dobra	bitumiczna	dobry	typ1	nie
2	1	zły	7	dobra	bitumiczna	dobry	typ2	nie
3	1	zły	7	dobra	bitumiczna	dobry	typ3	nie
4	2	dobry	10	dobra	bitumiczna	dobry	typ1	nie
5	2	dobry	10	dobra	bitumiczna	dobry	typ2	nie
6	2	dobry	10	dobra	bitumiczna	dobry	typ3	nie
7	3	dobry	9	średnia	bitumiczna	zła	typ1	nie
8	3	dobry	9	średnia	bitumiczna	zła	typ2	nie
9	3	dobry	9	średnia	bitumiczna	zła	typ3	<b>tak</b>
10	4	dobry	15	średnia	bitumiczna	średnia	typ1	nie
11	4	dobry	15	średnia	bitumiczna	średni	typ2	nie
12	4	dobry	15	średnia	bitumiczna	średni	typ3	nie
13	5	dobry	20	średnia	bitumiczna	zła	typ1	nie

14	5	dobry	20	średnia	bitumiczna	zła	typ2	nie
15	5	dobry	20	średnia	bitumiczna	zła	typ3	<b>tak</b>
16	6	średni	8	średnia	bitumiczna	dobry	typ1	nie
17	6	średni	8	średnia	bitumiczna	dobry	typ2	nie
18	6	średni	8	średnia	bitumiczna	dobry	typ3	<b>tak</b>
19	7	dobry	15	dobra	plyty jumbo	zły	typ1	nie
20	7	dobry	15	dobra	plyty jumbo	zły	typ2	<b>tak</b>
21	7	dobry	15	dobra	plyty jumbo	zły	typ3	<b>tak</b>
22	8	dobry	15	dobra	plyty jumbo	zły	typ1	nie
23	8	dobry	15	dobra	plyty jumbo	zły	typ2	<b>tak</b>
24	8	dobry	15	dobra	plyty jumbo	zły	typ3	<b>tak</b>
25	9	dobry	22,5	zła	bitumiczna	średni	typ1	nie
26	9	dobry	22,5	zła	bitumiczna	średni	typ2	nie
27	9	dobry	22,5	zła	bitumiczna	średni	typ3	nie
28	10	dobry	20	zła	bitumiczna	średni	typ1	nie
29	10	dobry	20	zła	bitumiczna	średni	typ2	nie
30	10	dobry	20	zła	bitumiczna	średni	typ3	<b>tak</b>
31	11	dobry	12	średnia	gruntowa	zły	typ1	nie
32	11	dobry	12	średnia	gruntowa	zły	typ2	nie
33	11	dobry	12	średnia	gruntowa	zły	typ3	<b>tak</b>
34	12	średni	14	średnia	bitumiczna	dobry	typ3	nie
35	12	średni	14	średnia	bitumiczna	zła	typ3	nie
36	13	dobry	4,4	zła	bitumiczna	dobry	typ3	nie
37	13	dobry	4,4	zła	bitumiczna	dobry	typ2	nie
38	14	średni	7,85	zła	kostka granitowa	zła	typ3	<b>tak</b>
39	14	średni	7,85	zła	kostka granitowa	dobry	typ3	nie
40	15	średni	3,07	zła	kostka granitowa	zła	typ3	<b>tak</b>



41	15	średni	3,07	zła	kostka granitowa	dobry	typ3	nie
42	16	średni	2,78	zła	kostka granitowa	zła	typ3	nie
43	16	średni	2,78	zła	kostka granitowa	dobry	typ3	nie
44	17	średni	1,91	zła	kostka granitowa	zła	typ3	nie
45	17	średni	1,91	zła	kostka granitowa	dobry	typ3	nie
46	18	dobry	5,14	zła	kostka granitowa	zła	typ3	<b>tak</b>
47	18	dobry	5,14	zła	kostka granitowa	zła	typ2	nie
48	19	dobry	7,4	zła	kostka granitowa	zła	typ3	<b>tak</b>
49	19	dobry	7,4	zła	kostka granitowa	zła	typ2	nie
50	20	dobry	2,4	zła	kostka granitowa	zła	typ3	nie
51	20	dobry	2,4	zła	kostka granitowa	zła	typ2	nie
52	21	dobry	2,4	zła	kostka granitowa	zła	typ3	nie
53	21	dobry	2,4	zła	kostka granitowa	zła	typ2	nie
54	22	dobry	2,4	zła	kostka granitowa	zła	typ3	<b>tak</b>
55	22	dobry	2,4	zła	kostka granitowa	zła	typ2	nie
56	23	dobry	3,5	zła	kostka granitowa	zła	typ3	<b>tak</b>
57	23	dobry	3,5	zła	kostka granitowa	zła	typ2	nie
58	24	dobry	2,4	zła	kostka granitowa	zła	typ3	nie
59	24	dobry	2,4	zła	kostka granitowa	zła	typ2	nie
60	25	dobry	6	zła	kostka granitowa	zła	typ3	<b>tak</b>
61	25	dobry	6	zła	kostka granitowa	zła	typ2	nie
62	26	dobry	10	zła	kostka granitowa	zła	typ3	nie
63	26	dobry	10	zła	kostka granitowa	zła	typ2	nie

Tab. 5.15. Lista pomocnicza utworzonych sztucznych sieci neuronowych.

SIEĆ	NR SIECI	WEKTOR WEJŚCIOWY	STRUKTURA SIECI	WARIANT PODZIAŁU PRÓBEK	ROZDZIAŁ
I	1	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-7-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.1.1
	2	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.1.1
	3	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-10-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.1.1
	4	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.1.1
	5	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-4-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.1.1
	1	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-9-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.1.2
	2	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-2-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.1.2
	3	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-8-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.1.2
	4	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-11-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.1.2
	5	$\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$	6-7-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.1.2
II	1	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.2.1
	2	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-7-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.2.1
	3	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-10-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.2.1
	4	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.2.1
	5	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.2.1
	1	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-10-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.2.2
	2	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-9-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.2.2
	3	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-11-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.2.2
	4	$\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-3-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.2.2

	5	$\mathbf{x}_{(5x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$	5-3-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.2.2
III	1	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.3.1
	2	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-4-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.3.1
	3	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-10-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.3.1
	4	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-8-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.3.1
	5	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-11-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.3.1
	1	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-4-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.3.2
	2	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-7-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.3.2
	3	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-10-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.3.2
	4	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-9-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.3.2
	5	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$	4-8-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.3.2
IV	1	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-5-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.4.1
	2	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.4.1
	3	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-1-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.4.1
	4	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-8-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.4.1
	5	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-11-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.4.1
	1	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-9-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.4.2
	2	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-4-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.4.2
	3	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-2-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.4.2
	4	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-6-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.4.2
	5	$\mathbf{x}_{(4x1)} = \{B_{ST}, B_{DO}, D_N, P\}$	4-8-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.4.2
V	1	$\mathbf{x}_{(4x1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.5.1

2	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-1-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.5.1
3	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-12-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.5.1
4	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-9-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.5.1
5	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-1-2	44 uczące, 10 weryfikujące, 9 testujące	5.3.5.1
1	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-4-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.5.2
2	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-7-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.5.2
3	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-6-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.5.2
4	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-4-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.5.2
5	$\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$	4-7-2	30 uczące, 16 weryfikujące, 17 testujące	5.3.5.2

### 5.3.1. Sztuczna sieć neuronowa nr I

W pierwszej sieci uwzględniono wszystkie parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Zatem wektor wejścia miał postać:  $\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ ;
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_N \in \{\text{bitumiczna, gruntowa, kostka brukowa, płyty jumbo}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Wszystkie próbki podzielono losowo na 3 zbiory, tj. na zbiór uczący, weryfikujący i testowy. Wykonano 2 warianty podziału:

- **1 wariant:** do zbioru uczącego przydzielono losowo 44 próbki (69,84% wszystkich próbek), 10 przypadków przydzielono do zbioru weryfikującego (15,87% wszystkich przypadków) oraz 9 próbek dla zbioru testującego (14,29% ogółu);

- **2 wariant:** do zbioru uczącego przydzielono losowo 30 próbek (47,62% wszystkich próbek), 16 przypadków przydzielono do zbioru weryfikującego (25,40% wszystkich przypadków) oraz 17 próbek dla zbioru testującego (26,98% ogółu).

### 5.3.1.1. Sztuczna sieć neuronowa nr I, wariant 1

Wykonano obliczenia i utworzono 100 sieci dla 1 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.16) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testowych. W Tab. 5.17 – 5.20 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.16. Rezultaty i charakterystyka sieci (sieć I, wariant 1).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKU UCZĄCE	PRÓBKU TESTUJĄCE	PRÓBKU WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	6-7-2	81,82	77,78	90,00	BFGS	Suma kwadratów różnic	Sigmoidalna unipolarna	Sinus
2	6-9-2	95,45	66,67	80,00	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
3	6-10-2	86,36	66,67	90,00	BFGS	Entropia wzajemna	Sinus	Regresja wieloraka
4	6-9-2	86,36	66,67	90,00	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
5	6-4-2	79,55	66,67	60,00	RBF	Suma kwadratów różnic	Gausa	Liniowa

Uzyskane dla wariantu 1 wyniki pokazują, iż cztery najlepsze sieci to perceptrony wielowarstwowe o 7, 9 i 10 neuronach w warstwie ukrytej. Ostatnia sieć to sieć radialna o strukturze 6-4-2 co oznacza, że w warstwie ukrytej przyjęto 4 neurony. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronu o budowie 6-7-2. Algorytm uczenia tej sieci to metoda BFGS. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję sigmoidalną unipolarną, zaś w warstwie wyjściowej funkcję sinus. Dla próbek uczących osiągnięto poprawność 81,82%, w przypadku próbek weryfikujących 90%, zaś dla próbek testujących 77,78%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: od 79,55% do 95,45% poprawności próbek uczących, od 60% do 90% poprawności w przypadku próbek weryfikujących oraz 66,67% dla próbek testowych.

Tab. 5.17. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć I, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	8,00	52,00
	Niepoprawne	3,00	8,00	11,00
	Poprawne (%)	93,62	50,00	82,54
	Niepoprawne (%)	6,38	50,00	17,46
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	12,00	56,00
	Niepoprawne	3,00	4,00	7,00
	Poprawne (%)	93,62	75,00	88,89
	Niepoprawne (%)	6,38	25,00	11,11
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	42,00	11,00	53,00
	Niepoprawne	5,00	5,00	10,00
	Poprawne (%)	89,36	68,75	84,13
	Niepoprawne (%)	10,64	31,25	15,87
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	42,00	11,00	53,00
	Niepoprawne	5,00	5,00	10,00
	Poprawne (%)	89,36	68,75	84,13
	Niepoprawne (%)	10,64	31,25	15,87
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	0,00	47,00
	Niepoprawne	0,00	16,00	16,00
	Poprawne (%)	100,00	0,00	74,60
	Niepoprawne (%)	0,00	100,00	25,40

Tab. 5.18. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć I, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	35,00	9,00	44,00
	Poprawne	32,00	4,00	36,00
	Niepoprawne	3,00	5,00	8,00
	Poprawne (%)	91,43	44,44	81,82
	Niepoprawne (%)	8,57	55,56	18,18
<b>2</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	7,00	42,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	77,78	95,45
	Niepoprawne (%)	0,00	22,22	4,55
<b>3</b>	Razem	35,00	9,00	44,00
	Poprawne	33,00	5,00	38,00
	Niepoprawne	2,00	4,00	6,00
	Poprawne (%)	94,29	55,56	86,36
	Niepoprawne (%)	5,71	9,00	13,64
<b>4</b>	Razem	35,00	5,00	44,00
	Poprawne	33,00	4,00	38,00
	Niepoprawne	2,00	55,56	6,00
	Poprawne (%)	94,29	9,00	86,36
	Niepoprawne (%)	5,71	5,00	13,64
<b>5</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	0,00	35,00
	Niepoprawne	0,00	9,00	9,00
	Poprawne (%)	100,00	0,00	79,55
	Niepoprawne (%)	0,00	100,00	20,45



Tab. 5.19. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć I, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	33,33	77,78
	Niepoprawne (%)	0,00	66,67	22,22
<b>2</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33
<b>3</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33
<b>4</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33
<b>5</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33

Tab. 5.20. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć I, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	3,00	9,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	75,00	90,00
	Niepoprawne (%)	0,00	25,00	10,00
<b>2</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	2,00	8,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	50,00	80,00
	Niepoprawne (%)	0,00	50,00	20,00
<b>3</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	3,00	9,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	75,00	90,00
	Niepoprawne (%)	0,00	25,00	10,00
<b>4</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	3,00	9,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	75,00	90,00
	Niepoprawne (%)	0,00	25,00	10,00
<b>5</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00

W drugim etapie wykonano analizę wrażliwości. Jej celem było ustalenie, które czynniki wejściowe nie mają wpływu na wartość wyjściową. Dla danego zbioru, dla każdej zmiennej wejściowej, jej wartość zamieniono na średnią. Po wprowadzeniu nowej uśrednionej zmiennej, sprawdzono wynik i dokonano interpretacji zmiany sygnału wyjściowego. Zmiana wartości wyjściowej pod wpływem tej modyfikacji oznacza, że algorytm jest wrażliwy na daną zmienną. Jeżeli modyfikacja nie powoduje zmian w sygnale wyjściowym oznacza to, że parametr wejściowy nie jest istotny dla uczenia algorytmu i można go usunąć, aby uniknąć zaszumienia danych. Dla porównania, obliczany był też iloraz błędu sieci bez analizowanej zmiennej do błędu sieci uwzględniającego wszystkie zmienne na wejściu. Wynik równy lub większy od jedności oznacza, że zmienna jest istotna, natomiast wynik poniżej jedności wskazuje na możliwość usunięcia zmiennej z algorytmu. W Tab. 5.21 – 5.24 przedstawiono ilorazy błędów, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.21. Analiza wrażliwości wszystkich próbek (sieć I, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	D <sub>N</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	1,494820	1,277501	1,062213	1,075801	1,003543	1,009528
2	5,356253	4,788845	2,834196	1,108345	1,196041	1,066833
3	4,232848	2,989730	1,602411	1,172676	1,064734	0,995897
4	4,726822	3,172817	1,428609	1,216463	1,104711	0,996141
5	1,000000	1,000000	1,000000	1,000000	1,000000	1,000000
<b>Średnia</b>	<b>3,362149</b>	<b>2,645778</b>	<b>1,585486</b>	<b>1,114657</b>	<b>1,073806</b>	<b>1,013680</b>

Tab. 5.22. Analiza wrażliwości próbek uczących (sieć I, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	D <sub>N</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	1,401325	1,311178	1,148507	1,051323	1,011312	1,001426
2	9,591536	7,968625	5,325616	1,647311	1,450523	1,259756
3	4,026217	3,004680	1,900653	1,273464	1,051867	1,015910
4	4,364955	3,259257	1,627091	1,241082	1,125239	1,022699
5	1,000000	1,000000	1,000000	1,000000	1,000000	1,000000
<b>Średnia</b>	<b>4,076806</b>	<b>3,308748</b>	<b>2,200374</b>	<b>1,242636</b>	<b>1,127788</b>	<b>1,059958</b>

Tab. 5.23. Analiza wrażliwości próbek testujących (sieć I, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	D <sub>N</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	1,330601	1,143731	0,975297	1,114116	0,974722	1,016543
2	4,776049	4,849418	2,312685	1,213622	0,979470	0,939912
3	3,460552	2,469503	1,426255	1,152732	0,987679	0,964879
4	3,552610	2,324640	1,204054	1,211154	0,954252	0,950973
5	1,000000	1,000000	1,000000	1,000000	1,000000	1,000000
<b>Średnia</b>	<b>2,823962</b>	<b>2,357459</b>	<b>1,383658</b>	<b>1,138325</b>	<b>0,979225</b>	<b>0,974461</b>

Tab. 5.24. Analiza wrażliwości próbek weryfikacyjnych (sieć I, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	D <sub>N</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	1,945152	1,317638	0,896703	1,010662	1,026271	1,108421
2	3,089006	2,870847	1,578850	1,138834	1,007260	0,741930
3	5,645182	3,564206	1,080084	1,186701	0,983398	0,949664
4	7,643619	4,210659	1,163673	1,272850	0,983934	1,148957
5	1,000000	1,000000	1,000000	1,000000	1,000000	1,000000
<b>Średnia</b>	<b>3,864592</b>	<b>2,592670</b>	<b>1,143862</b>	<b>1,121810</b>	<b>1,000173</b>	<b>0,989794</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.21), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Zdecydowanie największy wpływ na wynik predykcji ma czynnik związany z typem przejeżdżającego pojazdu P. Kolejny bardzo istotny parametr to stan nawierzchni drogi D<sub>STN</sub>. Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.23), z której wynika, że biorąc pod uwagę zespół pięciu sieci można pominąć czynnik związany ze stanem budynku B<sub>ST</sub> i odległością B<sub>DO</sub>. Z drugiej jednak strony, można założyć, że pierwsza sieć wykazująca najlepsze rezultaty wskazuje optymalne wartości wrażliwości, a z tego wynika, że parametrami, na które sieć jest mało wrażliwa są: rodzaj nawierzchni D<sub>N</sub> i stan budynku B<sub>ST</sub>. Jednak zauważyć również należy, że wartości dla tych dwóch czynników są bliskie jedności dla próbek testowych oraz przekraczają wartość wrażliwości dla pozostałych próbek, dlatego warto uwzględnić je podczas budowania modelu.

### 5.3.1.2. Sztuczna sieć neuronowa nr I, wariant 2

Wykonano obliczenia i utworzono 100 sieci dla 2 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.25) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.26 – 5.29 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio, dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.25. Rezultaty i charakterystyka sieci (sieć I, wariant 2).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKI UCZĄCE	PRÓBKI TESTUJĄCE	PRÓBKI WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	6-9-2	76,67	82,35	75,00	RBF	Entropia wzajemna	Gausa	Regresja wieloraka
2	6-2-2	76,67	88,24	81,25	BFGS	Suma kwadratów różnic	Sinus	Wykładnicza
3	6-8-2	83,33	88,24	87,50	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
4	6-11-2	83,33	88,24	81,25	BFGS	Suma kwadratów różnic	Liniowa	Sinus
5	6-7-2	96,67	76,47	87,50	BFGS	Entropia wzajemna	Wykładnicza	Regresja wieloraka

Uzyskane dla wariantu 2 wyniki pokazują, iż pięć najlepszych sieci to: sieć radialna o strukturze 6-9-2 (w warstwie ukrytej przyjęto 9 neuronów) oraz cztery perceptrony wielowarstwowe o 2, 7, 8 i 11 neuronach w warstwie ukrytej. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronu o budowie 6-8-2. Jako algorytm uczenia tej sieci przyjęto metodę BFGS. Funkcja błędu to entropia wzajemna. Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję sigmoidalną unipolarną, zaś w warstwie wyjściowej regresję wieloraką. Dla próbek uczących osiągnięto poprawność 83,33%, w przypadku próbek weryfikujących 87,50%, zaś dla próbek testujących 88,24%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: od 76,67% do 96,67% poprawności próbek uczących, od 75% do 87,50% poprawności w przypadku próbek weryfikujących oraz od 76,47% do 88,24% dla próbek testowych.

Tab. 5.26. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć I, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	2,00	49,00
	Niepoprawne	0,00	14,00	14,00
	Poprawne (%)	100,00	12,50	77,78
	Niepoprawne (%)	0,00	87,50	22,22
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	8,00	51,00
	Niepoprawne	4,00	8,00	12,00
	Poprawne (%)	91,49	50,00	80,95
	Niepoprawne (%)	8,51	50,00	19,05
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	41,00	13,00	54,00
	Niepoprawne	6,00	3,00	9,00
	Poprawne (%)	87,23	81,25	85,71
	Niepoprawne (%)	12,77	18,75	14,29
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	10,00	53,00
	Niepoprawne	4,00	6,00	10,00
	Poprawne (%)	91,49	62,50	84,13
	Niepoprawne (%)	8,51	37,50	15,87
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	12,00	56,00
	Niepoprawne	3,00	4,00	7,00
	Poprawne (%)	93,62	75,00	88,89
	Niepoprawne (%)	6,38	25,00	11,11

Tab. 5.27. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć I, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	1,00	23,00
	Niepoprawne	0,00	7,00	7,00
	Poprawne (%)	100,00	12,50	76,67
	Niepoprawne (%)	0,00	87,50	23,33
<b>2</b>	Razem	22,00	8,00	30,00
	Poprawne	20,00	3,00	23,00
	Niepoprawne	2,00	5,00	7,00
	Poprawne (%)	90,91	37,50	76,67
	Niepoprawne (%)	9,09	62,50	23,33
<b>3</b>	Razem	22,00	8,00	30,00
	Poprawne	18,00	7,00	25,00
	Niepoprawne	4,00	1,00	5,00
	Poprawne (%)	81,82	87,50	83,33
	Niepoprawne (%)	18,18	12,50	16,67
<b>4</b>	Razem	22,00	8,00	30,00
	Poprawne	20,00	5,00	25,00
	Niepoprawne	2,00	3,00	5,00
	Poprawne (%)	90,91	62,50	83,33
	Niepoprawne (%)	9,09	37,50	16,67
<b>5</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	7,00	29,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	87,50	96,67
	Niepoprawne (%)	0,00	12,50	3,33

Tab. 5.28. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć I, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	0,00	14,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	82,35
	Niepoprawne (%)	0,00	100,00	17,65
<b>2</b>	Razem	14,00	3,00	17,00
	Poprawne	13,00	2,00	15,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	92,86	66,67	88,24
	Niepoprawne (%)	7,14	33,33	11,76
<b>3</b>	Razem	14,00	3,00	17,00
	Poprawne	13,00	2,00	15,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	92,86	66,67	88,24
	Niepoprawne (%)	7,14	33,33	11,76
<b>4</b>	Razem	14,00	3,00	17,00
	Poprawne	13,00	2,00	15,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	92,86	66,67	88,24
	Niepoprawne (%)	7,14	33,33	11,76
<b>5</b>	Razem	14,00	3,00	17,00
	Poprawne	11,00	2,00	13,00
	Niepoprawne	3,00	1,00	4,00
	Poprawne (%)	78,57	66,67	76,47
	Niepoprawne (%)	21,43	33,33	23,53

Tab. 5.29. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć I, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	1,00	12,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	20,00	75,00
	Niepoprawne (%)	0,00	80,00	25,00
<b>2</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	3,00	13,00
	Niepoprawne	1,00	2,00	3,00
	Poprawne (%)	90,91	60,00	81,25
	Niepoprawne (%)	9,09	40,00	18,75
<b>3</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	4,00	14,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	90,91	80,00	87,50
	Niepoprawne (%)	9,09	20,00	12,50
<b>4</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	3,00	13,00
	Niepoprawne	1,00	2,00	3,00
	Poprawne (%)	90,91	60,00	81,25
	Niepoprawne (%)	9,09	40,00	18,75
<b>5</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50



W drugim etapie wykonano analizę wrażliwości. Procedurę wykonano jak dla sieci I wariantu 1 (zob. rozdział 5.3.1.1). W Tab. 5.30 – 5.33 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.30. Analiza wrażliwości wszystkich próbek (sieć I, wariant 2).

NUMER SIECI	B <sub>DO</sub>	P	B <sub>ST</sub>	D <sub>STN</sub>	D <sub>N</sub>	G <sub>A</sub>
1	44,64149	1,12173	22,79653	12,01424	1,07499	1,05455
2	1,01828	1,73819	1,08022	1,23313	1,06951	1,00856
3	1,01920	2,16662	1,06447	1,32499	1,02594	1,01405
4	1,02537	1,48515	1,03577	1,13634	1,06875	1,01391
5	1,08465	24,49158	2,56855	5,70992	1,03479	0,86193
<b>Średnia</b>	<b>9,75780</b>	<b>6,20065</b>	<b>5,70911</b>	<b>4,28372</b>	<b>1,05480</b>	<b>0,99060</b>

Tab. 5.31. Analiza wrażliwości próbek uczących (sieć I, wariant 2).

NUMER SIECI	P	B <sub>DO</sub>	D <sub>STN</sub>	B <sub>ST</sub>	D <sub>N</sub>	G <sub>A</sub>
1	1,097558	90,97966	12,34788	23,46911	1,06568	1,04926
2	1,66745	1,03861	1,19389	1,08547	1,03490	0,97540
3	2,25068	1,02860	1,29886	1,06482	1,10361	1,01984
4	1,51593	1,04814	1,11504	1,04586	1,06975	1,01975
5	976,89046	32,44083	109,41954	3,14854	24,53327	5,27902
<b>Średnia</b>	<b>196,68442</b>	<b>25,30717</b>	<b>25,07504</b>	<b>5,96276</b>	<b>5,76144</b>	<b>1,86865</b>

Tab. 5.32. Analiza wrażliwości próbek testujących (sieć I, wariant 2).

NUMER SIECI	B <sub>ST</sub>	P	D <sub>STN</sub>	G <sub>A</sub>	D <sub>N</sub>	B <sub>DO</sub>
1	44,29344	1,07707	1,01510	1,01351	1,02701	1,03081
2	1,06076	1,56514	1,16066	1,12164	1,23389	0,99533
3	1,01988	1,07355	1,07145	0,99423	0,80574	1,01301
4	0,99205	1,13434	1,03177	1,03478	1,03110	1,02020
5	2,61752	4,26433	3,12293	0,76179	0,73035	0,71271
<b>Średnia</b>	<b>9,99673</b>	<b>1,82288</b>	<b>1,48038</b>	<b>0,98519</b>	<b>0,96562</b>	<b>0,95441</b>

Tab. 5.33. Analiza wrażliwości próbek weryfikacyjnych (sieć I, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	D <sub>N</sub>	B <sub>ST</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	1,20891	21,91701	1,13804	1,00216	1,10353	0,97838
2	2,01701	1,36727	0,98878	1,08770	0,96995	1,00151
3	4,15311	1,90092	1,27282	1,15326	1,03927	1,00791
4	1,86072	1,30670	1,11348	1,07057	0,97687	0,98816
5	225,12153	35,34209	2,04328	1,44952	1,92063	1,73565
<b>Średnia</b>	<b>46,87226</b>	<b>12,36680</b>	<b>1,31128</b>	<b>1,15264</b>	<b>1,20205</b>	<b>1,14232</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić, że w zasadzie wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności, poza jednym parametrem (absorpcja drgań w gruncie  $G_A$ ), który okazał się niewrażliwy dla ostatniej sieci uzyskując wartość 0,86193. Analizując wszystkie próbki zdecydowanie największy wpływ na wynik predykcji ma czynnik związany z odległością  $B_{DO}$ . Kolejny bardzo istotny parametr to stan nawierzchni drogi  $D_{STN}$ . Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.32), z której wynika, że biorąc pod uwagę zespół pięciu sieci najistotniejszy jest czynnik związany ze stanem budynku  $B_{ST}$ .

### 5.3.2. Sztuczna sieć neuronowa nr II

W drugiej sieci uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia miał postać:  $\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Wszystkie próbki podzielono losowo na 3 zbiory, tj. na zbiór uczący, weryfikujący i testowy. Wykonano 2 warianty podziału podobnie jak dla sieci nr I (zob. rozdział 5.3.1).

#### 5.3.2.1. Sztuczna sieć neuronowa nr II, wariant 1

Wykonano obliczenia i utworzono 100 sieci dla 1 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.34) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.35 – 5.38 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.



Tab. 5.34. Rezultaty i charakterystyka sieci (sieć II, wariant 1).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKU UCZĄCE	PRÓBKU TESTUJĄCE	PRÓBKU WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	5-9-2	88,64	66,67	100,00	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
2	5-7-2	88,64	88,89	100,00	BFGS	Suma kwadratów różnic	Sinus	Tangens hiperboliczny
3	5-10-2	88,64	77,78	100,00	BFGS	Suma kwadratów różnic	Wykładnicza	Sinus
4	5-9-2	88,64	66,67	100,00	BFGS	Suma kwadratów różnic	Sigmoidalna unipolarna	Sigmoidalna unipolarna
5	5-9-2	88,64	66,67	90,00	BFGS	Entropia wzajemna	Liniowa	Regresja wieloraka

Uzyskane dla wariantu 1 wyniki pokazują, iż pięć najlepszych sieci to perceptrony wielowarstwowe o 7, 9 i 10 neuronach w warstwie ukrytej. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronu o budowie 5-7-2, co oznacza, że w warstwie ukrytej przyjęto 7 neuronów. Jako algorytm uczenia tej sieci przyjęto metodę BFGS. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji w warstwie ukrytej przyjęto sinus, zaś w warstwie wyjściowej tangens hiperboliczny. Dla próbek uczących osiągnięto poprawność 88,64%, w przypadku próbek weryfikujących 100%, zaś dla próbek testujących 88,89%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: wszystkie wykazały 88,64% poprawności próbek uczących, od 90% do 100% poprawności w przypadku próbek weryfikujących oraz od 66,67% do 77,78% dla próbek testowych.

Tab. 5.35. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć II, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	12,00	55,00
	Niepoprawne	4,00	4,00	8,00
	Poprawne (%)	91,49	75,00	87,30
	Niepoprawne (%)	8,51	25,00	12,70
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	46,00	11,00	57,00
	Niepoprawne	1,00	5,00	6,00
	Poprawne (%)	97,87	68,75	90,48
	Niepoprawne (%)	2,13	31,25	9,52
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	46,00	10,00	56,00
	Niepoprawne	1,00	6,00	7,00
	Poprawne (%)	97,87	62,50	88,89
	Niepoprawne (%)	2,13	37,50	11,11
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	12,00	55,00
	Niepoprawne	4,00	4,00	8,00
	Poprawne (%)	91,49	75,00	87,30
	Niepoprawne (%)	8,51	25,00	12,70
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	11,00	54,00
	Niepoprawne	4,00	5,00	9,00
	Poprawne (%)	91,49	68,75	85,71
	Niepoprawne (%)	8,51	31,25	14,29

Tab. 5.36. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć II, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	5,00	39,00
	Niepoprawne	1,00	4,00	5,00
	Poprawne (%)	97,14	55,56	88,64
	Niepoprawne (%)	2,86	44,44	11,36
<b>2</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	5,00	39,00
	Niepoprawne	1,00	4,00	5,00
	Poprawne (%)	97,14	55,56	88,64
	Niepoprawne (%)	2,86	44,44	11,36
<b>3</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	5,00	39,00
	Niepoprawne	1,00	4,00	5,00
	Poprawne (%)	97,14	55,56	88,64
	Niepoprawne (%)	2,86	44,44	11,36
<b>4</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	5,00	39,00
	Niepoprawne	1,00	4,00	5,00
	Poprawne (%)	97,14	55,56	88,64
	Niepoprawne (%)	2,86	44,44	11,36
<b>5</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	5,00	39,00
	Niepoprawne	1,00	4,00	5,00
	Poprawne (%)	97,14	55,56	88,64
	Niepoprawne (%)	2,86	44,44	11,36

Tab. 5.37. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć II, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33
<b>2</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	2,00	8,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	66,67	88,89
	Niepoprawne (%)	0,00	33,33	11,11
<b>3</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	33,33	77,78
	Niepoprawne (%)	0,00	66,67	22,22
<b>4</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33
<b>5</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33

Tab. 5.38. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć II, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	4,00	10,00
	Niepoprawne	0,00	0,00	0,00
	Poprawne (%)	100,00	100,00	100,00
	Niepoprawne (%)	0,00	0,00	0,00
<b>2</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	4,00	10,00
	Niepoprawne	0,00	0,00	0,00
	Poprawne (%)	100,00	100,00	100,00
	Niepoprawne (%)	0,00	0,00	0,00
<b>3</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	4,00	10,00
	Niepoprawne	0,00	0,00	0,00
	Poprawne (%)	100,00	100,00	100,00
	Niepoprawne (%)	0,00	0,00	0,00
<b>4</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	4,00	10,00
	Niepoprawne	0,00	0,00	0,00
	Poprawne (%)	100,00	100,00	100,00
	Niepoprawne (%)	0,00	0,00	0,00
<b>5</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	3,00	9,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	75,00	90,00
	Niepoprawne (%)	0,00	25,00	10,00

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.39 – 5.42 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.39. Analiza wrażliwości wszystkich próbek (sieć II, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	5,078877	3,518551	2,245941	1,145960	0,994605
2	1,264063	1,286851	1,092633	0,984032	1,010922
3	2,187979	1,677466	1,333076	1,052484	1,001243
4	2,713609	2,114445	1,567456	1,087297	1,000718
5	5,356378	4,979791	6,012418	1,064701	0,974031
<b>Średnia</b>	<b>3,320181</b>	<b>2,715421</b>	<b>2,450305</b>	<b>1,066895</b>	<b>0,996304</b>

Tab. 5.40. Analiza wrażliwości próbek uczących (sieć II, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	5,118642	3,951107	2,408746	1,223183	1,002370
2	1,275855	1,394673	1,099275	0,967173	1,000544
3	2,155380	1,787373	1,401920	1,051951	1,001914
4	2,454146	2,214645	1,559358	1,092618	1,000164
5	6,220611	6,652778	7,814255	1,078851	1,018834
<b>Średnia</b>	<b>3,444927</b>	<b>3,200115</b>	<b>2,856711</b>	<b>1,082755</b>	<b>1,004765</b>

Tab. 5.41. Analiza wrażliwości próbek testujących (sieć II, wariant 1).

NUMER SIECI	P	G <sub>A</sub>	D <sub>STN</sub>	B <sub>DO</sub>	B <sub>ST</sub>
1	3,410930	1,806931	2,230200	0,983330	0,961714
2	1,101258	1,050622	1,074904	1,022701	1,004574
3	1,674098	1,255167	1,279033	1,001492	1,001256
4	1,760882	1,333679	1,351320	1,000838	0,951053
5	4,002810	5,172846	3,386301	0,913002	0,970256
<b>Średnia</b>	<b>2,389996</b>	<b>2,123849</b>	<b>1,864352</b>	<b>0,984273</b>	<b>0,977771</b>

Tab. 5.42. Analiza wrażliwości próbek weryfikacyjnych (sieć II, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	7,610621	4,201993	2,430043	1,195065	0,987985
2	1,394222	1,178660	1,115412	1,013761	1,030104
3	2,979384	1,824709	1,198504	1,122009	0,998601
4	6,541472	3,510789	2,205501	1,404725	1,003414
5	5,146856	3,716250	3,919050	1,121670	0,955530
<b>Średnia</b>	<b>4,734511</b>	<b>2,886480</b>	<b>2,173702</b>	<b>1,171446</b>	<b>0,995127</b>



Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.39), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Zdecydowanie największy wpływ na wynik predykcji ma czynnik związany z typem przejeżdżającego pojazdu P. Kolejny bardzo istotny parametr to stan nawierzchni drogi  $D_{STN}$ . Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.41), z której wynika, że biorąc pod uwagę zespół pięciu sieci można pominąć czynnik związany z odległością  $B_{DO}$  i ze stanem budynku  $B_{ST}$ . Druga sieć wykazująca najlepsze rezultaty wskazuje optymalne wartości wrażliwości, co oznacza, że parametrami, na które sieć jest mało wrażliwa są: odległość  $B_{DO}$  i stan budynku  $B_{ST}$ . Jednak zauważyć również należy, że wartości dla tych dwóch czynników są bliskie jedności dla próbek testowych, zaś dla pozostałych próbek przekraczają wartość wrażliwości, dlatego warto uwzględnić je podczas budowania modelu.

### 5.3.2.2. Sztuczna sieć neuronowa nr II, wariant 2

Wykonano obliczenia i utworzono 100 sieci dla 2 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.43) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.44– 5.47 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.43. Rezultaty i charakterystyka sieci (sieć II, wariant 2).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKI UCZĄCE	PRÓBKI TESTUJĄCE	PRÓBKI WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	5–10–2	96,67	82,35	87,50	BFGS	Suma kwadratów różnic	Tangens hiperboliczny	Liniowa
2	5–9–2	96,67	76,47	87,50	BFGS	Entropia wzajemna	Sinus	Regresja wieloraka
3	5–11–2	96,67	82,35	87,50	BFGS	Entropia wzajemna	Liniowa	Regresja wieloraka
4	5–3–2	83,33	82,35	87,50	BFGS	Suma kwadratów różnic	Liniowa	Sigmoidalna unipolarna
5	5–3–2	93,33	82,35	87,50	BFGS	Suma kwadratów różnic	Sinus	Tangens hiperboliczny

Uzyskane dla wariantu 2 wyniki pokazują, iż pięć najlepszych sieci to perceptrony wielowarstwowe o 3, 9, 10 i 11 neuronach w warstwie ukrytej. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronów o budowie 5–10–2 (w warstwie ukrytej przyjęto 10 neuronów) oraz o budowie 5–11–2 (w warstwie ukrytej przyjęto 11 neuronów), ponieważ uzyskały one najwyższą wiarygodność predykcji (82,35% dla próbek testujących). W przypadku perceptronu 5–10–2 jako algorytm uczenia sieci przyjęto metodę BFGS. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji w warstwie ukrytej przyjęto tangens hiperboliczny, zaś w warstwie wyjściowej funkcję liniową. Dla perceptronu 5–11–2 jako algorytm uczenia sieci przyjęto metodę BFGS. Funkcja błędu to entropia wzajemna. Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję liniową, zaś w warstwie wyjściowej regresję wieloraką. W obu przypadkach dla próbek uczących osiągnięto poprawność 96,67%, w przypadku próbek weryfikujących 87,50%, zaś dla próbek testujących 82,35%. Pozostałe 3 rodzaje sieci wykazały dobre rezultaty: od 83,33% do 96,67% poprawności próbek uczących, 87,50% poprawności w przypadku próbek weryfikujących oraz od 76,47% do 82,35% dla próbek testowych.

Tab. 5.44. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć II, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	12,00	57,00
	Niepoprawne	2,00	4,00	6,00
	Poprawne (%)	95,74	75,00	90,48
	Niepoprawne (%)	4,26	25,00	9,52
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	12,00	56,00
	Niepoprawne	3,00	4,00	7,00
	Poprawne (%)	93,62	75,00	88,89
	Niepoprawne (%)	6,38	25,00	11,11
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	12,00	57,00
	Niepoprawne	2,00	4,00	6,00
	Poprawne (%)	95,74	75,00	90,48
	Niepoprawne (%)	4,26	25,00	9,52
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	10,00	53,00
	Niepoprawne	4,00	6,00	10,00
	Poprawne (%)	91,49	62,50	84,13
	Niepoprawne (%)	8,51	37,50	15,87
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	12,00	56,00
	Niepoprawne	3,00	4,00	7,00
	Poprawne (%)	93,62	75,00	88,89
	Niepoprawne (%)	6,38	25,00	11,11

Tab. 5.45. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć II, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	7,00	29,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	87,50	96,67
	Niepoprawne (%)	0,00	12,50	3,33
<b>2</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	7,00	29,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	87,50	96,67
	Niepoprawne (%)	0,00	12,50	3,33
<b>3</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	7,00	29,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	87,50	96,67
	Niepoprawne (%)	0,00	12,50	3,33
<b>4</b>	Razem	22,00	8,00	30,00
	Poprawne	20,00	5,00	25,00
	Niepoprawne	2,00	3,00	5,00
	Poprawne (%)	90,91	62,50	83,33
	Niepoprawne (%)	9,09	37,50	16,67
<b>5</b>	Razem	22,00	8,00	30,00
	Poprawne	21,00	7,00	28,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	95,45	87,50	93,33
	Niepoprawne (%)	4,55	12,50	6,67

Tab. 5.46. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć II, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65
<b>2</b>	Razem	14,00	3,00	17,00
	Poprawne	11,00	2,00	13,00
	Niepoprawne	3,00	1,00	4,00
	Poprawne (%)	78,57	66,67	76,47
	Niepoprawne (%)	21,43	33,33	23,53
<b>3</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65
<b>4</b>	Razem	14,00	3,00	17,00
	Poprawne	13,00	1,00	14,00
	Niepoprawne	1,00	2,00	3,00
	Poprawne (%)	92,86	33,33	82,35
	Niepoprawne (%)	7,14	66,67	17,65
<b>5</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65

Tab. 5.47. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć II, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50
<b>2</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50
<b>3</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50
<b>4</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	4,00	14,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	90,91	80,00	87,50
	Niepoprawne (%)	9,09	20,00	12,50
<b>5</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.48 – 5.51 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.48. Analiza wrażliwości wszystkich próbek (sieć II, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	B <sub>DO</sub>	G <sub>A</sub>	B <sub>ST</sub>
<b>1</b>	2,781496	2,532102	1,495788	1,355272	1,087784
<b>2</b>	4,192324	3,370041	1,469307	1,743168	1,454341
<b>3</b>	5,691637	4,063459	1,426105	1,173800	1,066212
<b>4</b>	1,487954	1,254755	1,012262	1,072692	1,027223
<b>5</b>	3,112965	1,907770	1,394217	1,226124	1,033628
<b>Średnia</b>	<b>3,453275</b>	<b>2,625626</b>	<b>1,359536</b>	<b>1,314211</b>	<b>1,133837</b>

Tab. 5.49. Analiza wrażliwości próbek uczących (sieć II, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	B <sub>DO</sub>	G <sub>A</sub>	B <sub>ST</sub>
1	9,54542	6,49615	5,262574	3,031464	1,864064
2	26,14068	18,73388	9,732630	8,043861	7,362594
3	25,25244	14,32486	6,418133	2,798050	1,357010
4	1,51793	1,26425	1,031407	1,068964	1,044783
5	5,29460	2,69354	2,300445	1,710222	1,159653
<b>Średnia</b>	<b>13,55021</b>	<b>8,70254</b>	<b>4,949038</b>	<b>3,330512</b>	<b>2,557621</b>

Tab. 5.50. Analiza wrażliwości próbek testujących (sieć II, wariant 2).

NUMER SIECI	D <sub>STN</sub>	P	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	1,453170	1,015677	1,047217	0,955100	0,778595
2	1,080397	0,955815	1,097745	0,900870	0,729875
3	1,902821	1,516183	1,109785	0,982208	0,787293
4	1,064965	1,162194	1,128299	0,990525	1,005964
5	1,218515	1,425698	0,978515	0,962365	1,071295
<b>Średnia</b>	<b>1,343973</b>	<b>1,215113</b>	<b>1,072312</b>	<b>0,958214</b>	<b>0,874604</b>

Tab. 5.51. Analiza wrażliwości próbek weryfikacyjnych (sieć II, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	2,86524	2,66229	1,137582	0,968593	1,052464
2	17,52106	12,93946	2,751283	1,885544	1,728108
3	8,27558	5,34431	0,679171	1,159641	1,014882
4	1,84004	1,47578	1,009820	1,038606	0,982053
5	3,83019	2,31051	1,160720	1,028648	1,022771
<b>Średnia</b>	<b>6,86642</b>	<b>4,94647</b>	<b>1,347715</b>	<b>1,216207</b>	<b>1,160056</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.48), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Analizując wszystkie próbki zdecydowanie największy wpływ na wynik predykcji ma czynnik związany z typem przejeżdżającego pojazdu P. Kolejny bardzo istotny parametr to stan nawierzchni drogi D<sub>STN</sub>. Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.50), z której wynika, że biorąc pod uwagę zespół pięciu sieci najistotniejszy jest parametr stanu nawierzchni drogi D<sub>STN</sub>. Czynniki, na które sieci nie są wrażliwe to stan budynku B<sub>ST</sub> oraz odległość B<sub>DO</sub>.

### 5.3.3. Sztuczna sieć neuronowa nr III

W trzeciej sieci uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia miał postać:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Wszystkie próbki podzielono losowo na 3 zbiory, tj. na zbiór uczący, weryfikujący i testowy. Wykonano 2 warianty podziału podobnie jak dla sieci nr I (zob. rozdział 5.3.1).

#### 5.3.3.1. Sztuczna sieć neuronowa nr III, wariant 1

Wykonano obliczenia i utworzono 100 sieci dla 1 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.52) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.53 – 5.56 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.52. Rezultaty i charakterystyka sieci (sieć III, wariant 1).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKU UCZĄCE	PRÓBKU TESTUJĄCE	PRÓBKU WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	4-9-2	84,09	66,67	60,00	BFGS	Entropia wzajemna	Wykładnicza	Regresja wieloraka
2	4-4-2	86,36	66,67	60,00	BFGS	Suma kwadratów różnic	Wykładnicza	Sigmoidalna unipolarna
3	4-10-2	79,55	66,67	60,00	RBF	Entropia wzajemna	Gausa	Regresja wieloraka
4	4-8-2	79,55	66,67	60,00	RBF	Entropia wzajemna	Gausa	Regresja wieloraka
5	4-11-2	84,09	66,67	60,00	RBF	Suma kwadratów różnic	Gausa	Liniowa



Uzyskane dla wariantu 1 wyniki pokazują, iż dwie najlepsze sieci to perceptrony wielowarstwowe o 4 i 9 neuronach w warstwie ukrytej, trzy kolejne to sieci radialne o 8, 10, 11 neuronach w warstwie ukrytej. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronu o budowie 4–4–2, co oznacza, że warstwie ukrytej przyjęto 4 neurony. Jako algorytm uczenia tej sieci przyjęto metodę BFGS. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję wykładniczą, zaś w warstwie wyjściowej funkcję sigmoidalną unipolarną. Dla próbek uczących osiągnięto poprawność 86,36%, w przypadku próbek weryfikujących 60%, zaś dla próbek testujących 66,67%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: od 79,55% do 84,09% poprawności próbek uczących, 60% poprawności w przypadku próbek weryfikujących oraz 66,67% dla próbek testowych.

Tab. 5.53. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć III, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	42,00	7,00	49,00
	Niepoprawne	5,00	9,00	14,00
	Poprawne (%)	89,36	43,75	77,78
	Niepoprawne (%)	10,64	56,25	22,22
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	6,00	50,00
	Niepoprawne	3,00	10,00	13,00
	Poprawne (%)	93,62	37,50	79,37
	Niepoprawne (%)	6,38	62,50	20,63
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	0,00	47,00
	Niepoprawne	0,00	16,00	16,00
	Poprawne (%)	100,00	0,00	74,60
	Niepoprawne (%)	0,00	100,00	25,40
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	0,00	47,00
	Niepoprawne	0,00	16,00	16,00
	Poprawne (%)	100,00	0,00	74,60
	Niepoprawne (%)	0,00	100,00	25,40
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	4,00	49,00
	Niepoprawne	2,00	12,00	14,00
	Poprawne (%)	95,74	25,00	77,78
	Niepoprawne (%)	4,26	75,00	22,22

Tab. 5.54. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć III, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	35,00	9,00	44,00
	Poprawne	30,00	7,00	37,00
	Niepoprawne	5,00	2,00	7,00
	Poprawne (%)	85,71	77,78	84,09
	Niepoprawne (%)	14,29	22,22	15,91
<b>2</b>	Razem	35,00	9,00	44,00
	Poprawne	32,00	6,00	38,00
	Niepoprawne	3,00	3,00	6,00
	Poprawne (%)	91,43	66,67	86,36
	Niepoprawne (%)	8,57	33,33	13,64
<b>3</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	0,00	35,00
	Niepoprawne	0,00	9,00	9,00
	Poprawne (%)	100,00	0,00	79,55
	Niepoprawne (%)	0,00	100,00	20,45
<b>4</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	0,00	35,00
	Niepoprawne	0,00	9,00	9,00
	Poprawne (%)	100,00	0,00	79,55
	Niepoprawne (%)	0,00	100,00	20,45
<b>5</b>	Razem	35,00	9,00	44,00
	Poprawne	33,00	4,00	37,00
	Niepoprawne	2,00	5,00	7,00
	Poprawne (%)	94,29	44,44	84,09
	Niepoprawne (%)	5,71	55,56	15,91

Tab. 5.55. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć III, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>2</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>3</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>4</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>5</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33

Tab. 5.56. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć III, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00
<b>2</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00
<b>3</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00
<b>4</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00
<b>5</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.57 – 5.60 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.57. Analiza wrażliwości wszystkich próbek (sieć III, wariant 1).

NUMER SIECI	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>	B <sub>ST</sub>
<b>1</b>	23,66608	11,14232	1,433058	1,184006
<b>2</b>	1,61433	1,73592	1,035055	1,211112
<b>3</b>	1,00000	1,00000	1,000000	1,000000
<b>4</b>	1,00000	1,00000	1,000000	1,000000
<b>5</b>	1,36865	1,09423	1,000691	1,060209
<b>Średnia</b>	<b>5,72981</b>	<b>3,19449</b>	<b>1,093761</b>	<b>1,091065</b>

Tab. 5.58. Analiza wrażliwości próbek uczących (sieć III, wariant 1).

NUMER SIECI	$G_A$	$D_{STN}$	$B_{ST}$	$B_{DO}$
1	137,7617	102,6303	7,265252	1,567024
2	2,7248	2,4849	1,594610	1,203407
3	1,0000	1,0000	1,000000	1,000000
4	1,0000	1,0000	1,000000	1,000000
5	1,2570	1,4159	1,097878	1,003828
<b>Średnia</b>	<b>28,7487</b>	<b>21,7062</b>	<b>2,391548</b>	<b>1,154852</b>

Tab. 5.59. Analiza wrażliwości próbek testujących (sieć III, wariant 1).

NUMER SIECI	$D_{STN}$	$B_{DO}$	$G_A$	$B_{ST}$
1	24,49170	1,865589	0,690403	0,563984
2	1,03477	1,010944	1,178811	0,890649
3	1,00000	1,000000	1,000000	1,000000
4	1,00000	1,000000	1,000000	1,000000
5	1,36860	0,997348	0,963714	0,979073
<b>Średnia</b>	<b>5,77902</b>	<b>1,174776</b>	<b>0,966586</b>	<b>0,886741</b>

Tab. 5.60. Analiza wrażliwości próbek weryfikacyjnych (sieć III, wariant 1).

NUMER SIECI	$D_{STN}$	$B_{DO}$	$B_{ST}$	$G_A$
1	13,23063	1,188655	0,739800	0,601042
2	1,02466	0,858094	0,997991	0,993784
3	1,00000	1,000000	1,000000	1,000000
4	1,00000	1,000000	1,000000	1,000000
5	1,27732	0,997107	1,047663	0,876296
<b>Średnia</b>	<b>3,50652</b>	<b>1,008771</b>	<b>0,957091</b>	<b>0,894224</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.57), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Zdecydowanie największy wpływ na wynik predykcji ma czynnik związany ze stanem nawierzchni drogi  $D_{STN}$ . Kolejny bardzo istotny parametr to absorpcja gruntu  $G_A$ . Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.59), z której wynika, że biorąc pod uwagę zespół pięciu sieci można pominąć czynnik związany z absorpcją gruntu  $G_A$ . Z drugiej jednak strony, można założyć, że druga sieć wykazująca najlepsze rezultaty wskazuje optymalne wartości wrażliwości, co oznacza, że jedynym parametrem, na które sieć jest mało wrażliwa jest stan budynku  $B_{ST}$ . Jednak zauważyć również należy, że wartości dla tych dwóch czynników są bliskie jedności dla próbek testowych, zaś dla pozostałych próbek przekraczają wartość wrażliwości, dlatego warto uwzględnić je podczas budowania modelu.

### 5.3.3.2. Sztuczna sieć neuronowa nr III, wariant 2

Wykonano obliczenia i utworzono 100 sieci dla 2 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.61) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.62 – 5.65 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.61. Rezultaty i charakterystyka sieci (sieć III, wariant 2).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKI UCZĄCE	PRÓBKI TESTUJĄCE	PRÓBKI WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	4-4-2	76,67	88,24	68,75	BFGS	Suma kwadratów różnic	Tangens hiperboliczny	Tangens hiperboliczny
2	4-7-2	76,67	82,35	75,00	RBF	Entropia wzajemna	Gaussa	Regresja wieloraka
3	4-10-2	73,33	82,35	68,75	RBF	Suma kwadratów różnic	Gaussa	Liniowa
4	4-9-2	76,67	88,24	68,75	BFGS	Suma kwadratów różnic	Sigmoidalna unipolarna	Sinus
5	4-8-2	73,33	82,35	68,75	RBF	Suma kwadratów różnic	Gaussa	Liniowa

Uzyskane dla wariantu 2 wyniki pokazują, iż pierwsza sieć to perceptron o 4 neuronach ukrytych, dwie kolejne to sieci radialne o 7 i 10 neuronach ukrytych, następna to perceptron o 9 neuronach w warstwie ukrytej. Ostatnia sieć to sieć radialna o 8 neuronach ukrytych. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla dwóch perceptronów o budowie 4-4-2, (w warstwie ukrytej przyjęto 4 neurony) i 4-9-2 (9 neuronów w warstwie ukrytej). Jako algorytm uczenia obu sieci przyjęto metodę BFGS. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji w warstwie ukrytej przyjęto w pierwszym przypadku tangens hiperboliczny, w drugim funkcję sigmoidalną unipolarną, zaś w warstwie wyjściowej kolejno tangens hiperboliczny i sinus. Dla próbek uczących osiągnięto poprawność 76,67%, w przypadku próbek weryfikujących 68,75%, zaś dla próbek testujących 88,24%. Pozostałe 3 rodzaje sieci wykazały dobre rezultaty: od 73,33% do 76,67% poprawności próbek uczących, od 68,75% do 75% poprawności w przypadku próbek weryfikujących oraz 82,35% dla próbek testowych.

Tab. 5.62. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć III, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	4,00	49,00
	Niepoprawne	2,00	12,00	14,00
	Poprawne (%)	95,74	25,00	77,78
	Niepoprawne (%)	4,26	75,00	22,22
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	2,00	49,00
	Niepoprawne	0,00	14,00	14,00
	Poprawne (%)	100,00	12,50	77,78
	Niepoprawne (%)	0,00	87,50	22,22
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	0,00	47,00
	Niepoprawne	0,00	16,00	16,00
	Poprawne (%)	100,00	0,00	74,60
	Niepoprawne (%)	0,00	100,00	25,40
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	4,00	49,00
	Niepoprawne	2,00	12,00	14,00
	Poprawne (%)	95,74	25,00	77,78
	Niepoprawne (%)	4,26	75,00	22,22
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	0,00	47,00
	Niepoprawne	0,00	16,00	16,00
	Poprawne (%)	100,00	0,00	74,60
	Niepoprawne (%)	0,00	100,00	25,40

Tab. 5.63. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć III, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	22,00	8,00	30,00
	Poprawne	20,00	3,00	23,00
	Niepoprawne	2,00	5,00	7,00
	Poprawne (%)	90,91	37,50	76,67
	Niepoprawne (%)	9,09	62,50	23,33
<b>2</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	1,00	23,00
	Niepoprawne	0,00	7,00	7,00
	Poprawne (%)	100,00	12,50	76,67
	Niepoprawne (%)	0,00	87,50	23,33
<b>3</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	0,00	22,00
	Niepoprawne	0,00	8,00	8,00
	Poprawne (%)	100,00	0,00	73,33
	Niepoprawne (%)	0,00	100,00	26,67
<b>4</b>	Razem	22,00	8,00	30,00
	Poprawne	20,00	3,00	23,00
	Niepoprawne	2,00	5,00	7,00
	Poprawne (%)	90,91	37,50	76,67
	Niepoprawne (%)	9,09	62,50	23,33
<b>5</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	0,00	22,00
	Niepoprawne	0,00	8,00	8,00
	Poprawne (%)	100,00	0,00	73,33
	Niepoprawne (%)	0,00	100,00	26,67



Tab. 5.64. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć III, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	1,00	15,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	33,33	88,24
	Niepoprawne (%)	0,00	66,67	11,76
<b>2</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	0,00	14,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	82,35
	Niepoprawne (%)	0,00	100,00	17,65
<b>3</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	0,00	14,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	82,35
	Niepoprawne (%)	0,00	100,00	17,65
<b>4</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	1,00	15,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	33,33	88,24
	Niepoprawne (%)	0,00	66,67	11,76
<b>5</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	0,00	14,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	82,35
	Niepoprawne (%)	0,00	100,00	17,65

Tab. 5.65. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć III, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	0,00	11,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	0,00	68,75
	Niepoprawne (%)	0,00	100,00	31,25
<b>2</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	1,00	12,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	20,00	75,00
	Niepoprawne (%)	0,00	80,00	25,00
<b>3</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	0,00	11,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	0,00	68,75
	Niepoprawne (%)	0,00	100,00	31,25
<b>4</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	0,00	11,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	0,00	68,75
	Niepoprawne (%)	0,00	100,00	31,25
<b>5</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	0,00	11,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	0,00	68,75
	Niepoprawne (%)	0,00	100,00	31,25

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.66 – 5.69 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.66. Analiza wrażliwości wszystkich próbek (sieć III, wariant 2).

NUMER SIECI	B <sub>ST</sub>	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	0,99492	1,22928	1,033509	0,991916
2	54,50690	11,80977	1,050442	1,102725
3	0,50027	0,24943	0,500000	0,000776
4	1,06682	1,69588	1,175387	1,013426
5	1,00000	1,00000	1,000000	1,000000
<b>Średnia</b>	<b>11,61378</b>	<b>3,19687</b>	<b>0,951868</b>	<b>0,821769</b>

Tab. 5.67. Analiza wrażliwości próbek uczących (sieć III, wariant 2).

NUMER SIECI	B <sub>ST</sub>	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	1,01319	1,23911	1,024999	1,005389
2	23,47255	12,35638	1,063210	1,126340
3	0,50026	0,24973	0,500000	0,000351
4	1,09029	1,70795	1,182402	1,085845
5	1,00000	1,00000	1,000000	1,000000
<b>Średnia</b>	<b>5,41526</b>	<b>3,31063</b>	<b>0,954122</b>	<b>0,843585</b>

Tab. 5.68. Analiza wrażliwości próbek testujących (sieć III, wariant 2).

NUMER SIECI	B <sub>ST</sub>	G <sub>A</sub>	D <sub>STN</sub>	B <sub>DO</sub>
1	0,9308	1,094417	1,060405	1,003513
2	125,7256	0,993314	0,982243	1,000139
3	0,5000	0,500000	0,247704	0,002639
4	0,9836	1,425648	1,444212	1,007671
5	1,0000	1,000000	1,000000	1,000000
<b>Średnia</b>	<b>25,8280</b>	<b>1,002676</b>	<b>0,946913</b>	<b>0,802792</b>

Tab. 5.69. Analiza wrażliwości próbek weryfikacyjnych (sieć III, wariant 2).

NUMER SIECI	B <sub>ST</sub>	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	1,02252	1,36728	0,992206	0,958302
2	41,23956	21,30355	1,082818	1,159633
3	0,50057	0,24949	0,500000	0,001326
4	1,10151	1,89443	0,947765	0,903450
5	1,00000	1,00000	1,000000	1,000000
<b>Średnia</b>	<b>8,97283</b>	<b>5,16295</b>	<b>0,904558</b>	<b>0,804542</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.66), że mało wrażliwe są parametry wejściowe związane z absorpcją gruntu  $G_A$  i czynnik związany z odległością  $B_{DO}$ . Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.68), z której wynika, że biorąc pod uwagę zespół pięciu sieci najistotniejszy jest czynnik związany ze stanem budynku  $B_{ST}$ , mało istotne są natomiast: stan nawierzchni  $D_{STN}$  i odległość  $B_{DO}$ . Z drugiej jednak strony, można założyć, że druga i czwarta sieć wykazują najlepsze rezultaty i zwrócić należy uwagę na sieć nr 2, w której to najistotniejszy jest parametr związany ze stanem budynku  $B_{ST}$ .

#### 5.3.4. Sztuczna sieć neuronowa nr IV

W czwartej sieci uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia miał postać:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, D_N, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $D_N \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Wszystkie próbki podzielono losowo na 3 zbiory: uczący, weryfikujący i testowy. Wykonano 2 warianty podziału podobnie jak dla sieci nr I (zob. rozdział 5.3.1).

##### 5.3.4.1. Sztuczna sieć neuronowa nr IV, wariant 1

Wykonano obliczenia i utworzono 100 sieci dla 1 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.70) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testowych w kolejnych podzbiórach. W Tab. 5.71 – 5.74 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.70. Rezultaty i charakterystyka sieci (sieć IV, wariant 1).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKU UCZĄCE	PRÓBKU TESTUJĄCE	PRÓBKU WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	4-5-2	88,64	66,67	60,00	BFGS	Suma kwadratów różnic	Sigmoidalna unipolarna	Liniowa
2	4-9-2	86,36	66,67	90,00	BFGS	Entropia wzajemna	Sinus	Regresja wieloraka
3	4-1-2	88,64	66,67	70,00	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
4	4-8-2	88,64	66,67	70,00	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
5	4-11-2	79,55	66,67	60,00	RBF	Entropia wzajemna	Gausa	Regresja wieloraka

Uzyskane dla wariantu 1 wyniki pokazują, iż cztery najlepsze sieci to perceptrony wielowarstwowe o 1, 5, 8 i 9 neuronach w warstwie ukrytej. Ostatnia sieć to sieć radialna o strukturze 4-11-2, co oznacza, że w warstwie ukrytej przyjęto 11 neuronów. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla dwóch perceptronów o budowie 4-1-2 (w warstwie ukrytej przyjęto 1 neuron) oraz 4-8-2 (w warstwie ukrytej przyjęto 8 neuronów). Jako algorytm uczenia tej obu sieci przyjęto metodę BFGS. W przypadku obu perceptronów funkcja błędu to entropia wzajemna. Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję sigmoidalną unipolarną, zaś w warstwie wyjściowej funkcję regresję wieloraką. Dla próbek uczących osiągnięto poprawność dla obu perceptronów 88,64%, w przypadku próbek weryfikujących 70%, zaś dla próbek testujących 66,67%. Pozostałe 3 rodzaje sieci wykazały dobre rezultaty: od 79,55% do 88,64% poprawności próbek uczących, od 60% do 90% poprawności w przypadku próbek weryfikujących oraz 66,67% dla próbek testowych.

Tab. 5.71. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć IV, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	4,00	51,00
	Niepoprawne	0,00	12,00	12,00
	Poprawne (%)	100,00	25,00	80,95
	Niepoprawne (%)	0,00	75,00	19,05
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	10,00	53,00
	Niepoprawne	4,00	6,00	10,00
	Poprawne (%)	91,49	62,50	84,13
	Niepoprawne (%)	8,51	37,50	15,87
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	5,00	52,00
	Niepoprawne	0,00	11,00	11,00
	Poprawne (%)	100,00	31,25	82,54
	Niepoprawne (%)	0,00	68,75	17,46
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	5,00	52,00
	Niepoprawne	0,00	11,00	11,00
	Poprawne (%)	100,00	31,25	82,54
	Niepoprawne (%)	0,00	68,75	17,46
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	0,00	47,00
	Niepoprawne	0,00	16,00	16,00
	Poprawne (%)	100,00	0,00	74,60
	Niepoprawne (%)	0,00	100,00	25,40

Tab. 5.72. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć IV, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	4,00	39,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	44,44	88,64
	Niepoprawne (%)	0,00	55,56	11,36
<b>2</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	4,00	38,00
	Niepoprawne	1,00	5,00	6,00
	Poprawne (%)	97,14	44,44	86,36
	Niepoprawne (%)	2,86	55,56	13,64
<b>3</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	4,00	39,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	44,44	88,64
	Niepoprawne (%)	0,00	55,56	11,36
<b>4</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	4,00	39,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	44,44	88,64
	Niepoprawne (%)	0,00	55,56	11,36
<b>5</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	0,00	35,00
	Niepoprawne	0,00	9,00	9,00
	Poprawne (%)	100,00	0,00	79,55
	Niepoprawne (%)	0,00	100,00	20,45

Tab. 5.73. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć IV, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>2</b>	Razem	6,00	3,00	9,00
	Poprawne	3,00	3,00	6,00
	Niepoprawne	3,00	0,00	3,00
	Poprawne (%)	50,00	100,00	66,67
	Niepoprawne (%)	50,00	0,00	33,33
<b>3</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>4</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>5</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33

Tab. 5.74. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć IV, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00
<b>2</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	3,00	9,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	75,00	90,00
	Niepoprawne (%)	0,00	25,00	10,00
<b>3</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	25,00	70,00
	Niepoprawne (%)	0,00	75,00	30,00
<b>4</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	25,00	70,00
	Niepoprawne (%)	0,00	75,00	30,00
<b>5</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	4,00	4,00
	Poprawne (%)	100,00	0,00	60,00
	Niepoprawne (%)	0,00	100,00	40,00



W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.75 – 5.78 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.75. Analiza wrażliwości wszystkich próbek (sieć IV, wariant 1).

NUMER SIECI	P	D <sub>N</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	2,25929	1,809133	1,103661	1,006651
2	2,66554	1,587920	1,123379	1,047434
3	1,99163	1,497651	1,051513	0,976653
4	2,58354	1,388602	1,109869	0,997248
5	42,05222	1,037421	1,037905	1,006189
<b>Średnia</b>	<b>10,31044</b>	<b>1,464145</b>	<b>1,085266</b>	<b>1,006835</b>

Tab. 5.76. Analiza wrażliwości próbek uczących (sieć IV, wariant 1).

NUMER SIECI	P	D <sub>N</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	2,53017	2,640026	1,144470	1,001551
2	2,07219	1,868411	1,083275	1,004906
3	1,96840	1,852393	1,032081	1,007959
4	2,32366	1,684466	1,070342	0,994866
5	51,43235	1,066022	1,043774	1,004785
<b>Średnia</b>	<b>12,06535</b>	<b>1,822264</b>	<b>1,074789</b>	<b>1,002813</b>

Tab. 5.77. Analiza wrażliwości próbek testujących (sieć IV, wariant 1).

NUMER SIECI	P	B <sub>ST</sub>	D <sub>N</sub>	B <sub>DO</sub>
1	1,964846	1,025030	1,014977	1,026253
2	2,848599	1,097932	1,081106	1,090767
3	1,636453	1,055842	1,012275	0,890610
4	2,468102	1,089507	0,956270	0,995305
5	1,000042	1,000006	0,961719	0,999949
<b>Średnia</b>	<b>1,983609</b>	<b>1,053664</b>	<b>1,005270</b>	<b>1,000577</b>

Tab. 5.78. Analiza wrażliwości próbek weryfikacyjnych (sieć IV, wariant 1).

NUMER SIECI	P	B <sub>ST</sub>	B <sub>DO</sub>	D <sub>N</sub>
1	2,03361	1,097756	0,999376	1,027474
2	4,77523	1,313817	1,160422	1,122296
3	2,45039	1,101509	0,983663	1,034923
4	3,54311	1,259021	1,007057	0,940052
5	50,05396	1,053435	1,015661	1,019193
<b>Średnia</b>	<b>12,57126</b>	<b>1,165108</b>	<b>1,033236</b>	<b>1,028787</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.75), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Zdecydowanie największy wpływ na wynik predykcji ma czynnik związany z typem przejeżdżającego pojazdu P. Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.77), z której wynika, że biorąc pod uwagę zespół pięciu sieci wszystkie parametry wejściowe są istotne. Z drugiej jednak strony, można założyć, że czwarta sieć wykazująca najlepsze rezultaty wskazuje optymalne wartości wrażliwości, co oznacza, że parametrami, na które sieć jest mało wrażliwa są: rodzaj nawierzchni  $D_N$  i odległość  $B_{DO}$ . Jednak zauważyć również należy, że wartości dla tych dwóch czynników są bliskie jedności dla próbek testowych, zaś dla pozostałych próbek przekraczają wartość wrażliwości, dlatego warto uwzględnić je podczas budowania modelu.

#### 5.3.4.2. Sztuczna sieć neuronowa nr IV, wariant 2

Wykonano obliczenia i utworzono 100 sieci dla 2 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.79) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testowych. W Tab. 5.80 – 5.83 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.79. Rezultaty i charakterystyka sieci (sieć IV, wariant 2).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKU UCZĄCE	PRÓBKU TESTUJĄCE	PRÓBKU WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	4-9-2	83,33	88,24	81,25	BFGS	Entropia wzajemna	Tangens hiperboliczny	Regresja wieloraka
2	4-4-2	93,33	82,35	87,50	BFGS	Entropia wzajemna	Sinus	Regresja wieloraka
3	4-2-2	93,33	82,35	87,50	BFGS	Entropia wzajemna	Wykładnicza	Regresja wieloraka
4	4-6-2	93,33	82,35	87,50	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
5	4-8-2	93,33	82,35	87,50	BFGS	Entropia wzajemna	Wykładnicza	Regresja wieloraka

Uzyskane dla wariantu 2 wyniki pokazują, iż pięć najlepszych sieci to perceptrony wielowarstwowe o 2, 4, 6, 8 i 9 neuronach w warstwie ukrytej. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronu o budowie 4–9–2, co oznacza, że w warstwie ukrytej przyjęto 9 neuronów. Jako algorytm uczenia tej sieci przyjęto metodę BFGS. Funkcja błędu to entropia wzajemna. Jako funkcję aktywacji w warstwie ukrytej przyjęto tangens hiperboliczny, zaś w warstwie wyjściowej regresję wieloraką. Dla próbek uczących osiągnięto poprawność 83,33%, w przypadku próbek weryfikujących 81,25%, zaś dla próbek testujących 88,24%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: 93,33% poprawności próbek uczących, 87,50% poprawności w przypadku próbek weryfikujących oraz 82,35% dla próbek testowych.

Tab. 5.80. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć IV, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	43,00	10,00	53,00
	Niepoprawne	4,00	6,00	10,00
	Poprawne (%)	91,49	62,50	84,13
	Niepoprawne (%)	8,51	37,50	15,87
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	11,00	56,00
	Niepoprawne	2,00	5,00	7,00
	Poprawne (%)	95,74	68,75	88,89
	Niepoprawne (%)	4,26	31,25	11,11
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	12,00	56,00
	Niepoprawne	3,00	4,00	7,00
	Poprawne (%)	93,62	75,00	88,89
	Niepoprawne (%)	6,38	25,00	11,11
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	45,00	11,00	56,00
	Niepoprawne	2,00	5,00	7,00
	Poprawne (%)	95,74	68,75	88,89
	Niepoprawne (%)	4,26	31,25	11,11
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	12,00	56,00
	Niepoprawne	3,00	4,00	7,00
	Poprawne (%)	93,62	75,00	88,89
	Niepoprawne (%)	6,38	25,00	11,11

Tab. 5.81. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć IV, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	22,00	8,00	30,00
	Poprawne	20,00	5,00	25,00
	Niepoprawne	2,00	3,00	5,00
	Poprawne (%)	90,91	62,50	83,33
	Niepoprawne (%)	9,09	37,50	16,67
<b>2</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	6,00	28,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	75,00	93,33
	Niepoprawne (%)	0,00	25,00	6,67
<b>3</b>	Razem	22,00	8,00	30,00
	Poprawne	21,00	7,00	28,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	95,45	87,50	93,33
	Niepoprawne (%)	4,55	12,50	6,67
<b>4</b>	Razem	22,00	8,00	30,00
	Poprawne	22,00	6,00	28,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	75,00	93,33
	Niepoprawne (%)	0,00	25,00	6,67
<b>5</b>	Razem	22,00	8,00	30,00
	Poprawne	21,00	7,00	28,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	95,45	87,50	93,33
	Niepoprawne (%)	4,55	12,50	6,67

Tab. 5.82. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć IV, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	14,00	3,00	17,00
	Poprawne	13,00	2,00	15,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	92,86	66,67	88,24
	Niepoprawne (%)	7,14	33,33	11,76
<b>2</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65
<b>3</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65
<b>4</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65
<b>5</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65

Tab. 5.83. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć IV, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	3,00	13,00
	Niepoprawne	1,00	2,00	3,00
	Poprawne (%)	90,91	60,00	81,25
	Niepoprawne (%)	9,09	40,00	18,75
<b>2</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50
<b>3</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50
<b>4</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50
<b>5</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.84 – 5.87 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.84. Analiza wrażliwości wszystkich próbek (sieć IV, wariant 2).

NUMER SIECI	P	D <sub>N</sub>	B <sub>ST</sub>	B <sub>DO</sub>
<b>1</b>	2,22419	1,336464	1,346567	1,024123
<b>2</b>	2,49177	1,626111	1,228274	1,064936
<b>3</b>	10,60589	1,769524	1,058817	1,057041
<b>4</b>	5,36240	2,129798	1,669535	1,218773
<b>5</b>	8,34012	2,269844	1,073234	1,190650
<b>Średnia</b>	<b>5,80487</b>	<b>1,826348</b>	<b>1,275285</b>	<b>1,111105</b>

Tab. 5.85. Analiza wrażliwości próbek uczących (sieć IV, wariant 2).

NUMER SIECI	P	D <sub>N</sub>	B <sub>DO</sub>	B <sub>ST</sub>
1	2,4322	1,4336	1,06454	1,42150
2	3,1380	1,8283	1,23562	1,30787
3	931,5497	120,9542	17,27950	3,17586
4	14,6000	5,0802	2,67251	3,57845
5	995,0099	228,2156	49,94262	13,93294
<b>Średnia</b>	<b>389,3460</b>	<b>71,5024</b>	<b>14,43896</b>	<b>4,68333</b>

Tab. 5.86. Analiza wrażliwości próbek testujących (sieć IV, wariant 2).

NUMER SIECI	P	B <sub>ST</sub>	D <sub>N</sub>	B <sub>DO</sub>
1	1,397231	1,235024	1,099335	0,992468
2	1,399638	1,096114	1,469975	0,968863
3	1,632695	0,998176	0,669944	0,998896
4	1,595029	1,069253	1,313192	0,985122
5	1,497331	0,969345	0,568970	0,971286
<b>Średnia</b>	<b>1,504385</b>	<b>1,073583</b>	<b>1,024283</b>	<b>0,983327</b>

Tab. 5.87. Analiza wrażliwości próbek weryfikacyjnych (sieć IV, wariant 2).

NUMER SIECI	P	D <sub>N</sub>	B <sub>ST</sub>	B <sub>DO</sub>
1	2,97161	1,484543	1,364589	0,995417
2	2,83441	1,517976	1,267742	0,932176
3	59,69006	7,313247	1,696055	0,612146
4	6,87382	1,887672	1,647740	0,783205
5	32,81019	9,312988	1,550260	1,123014
<b>Średnia</b>	<b>21,03602</b>	<b>4,303285</b>	<b>1,505277</b>	<b>0,889191</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.84), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.86), z której wynika, że biorąc pod uwagę zespół pięciu sieci najmniej istotny jest czynnik związany z odległością B<sub>DO</sub>, a pozostałe posiadają wartości większe od 1. Wyniki dla najlepszej (pierwszej) sieci są w tym przypadku analogiczne jak dla zespołu sieci.

### 5.3.5. Sztuczna sieć neuronowa nr V

W piątej sieci uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia miał postać:  $\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$ .



- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Wszystkie próbki podzielono losowo na 3 zbiory, tj. na zbiór uczący, weryfikujący i testowy. Wykonano 2 warianty podziału podobnie jak dla sieci nr I (zob. rozdział 5.3.1).

### 5.3.5.1. Sztuczna sieć neuronowa nr V, wariant 1

Wykonano obliczenia i utworzono 100 sieci dla 1 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.88) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.89 – 5.92 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.88. Rezultaty i charakterystyka sieci (sieć V, wariant 1).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKU UCZĄCE	PRÓBKU TESTUJĄCE	PRÓBKU WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	4-9-2	81,82	88,89	80,00	RBF	Entropia wzajemna	Gausa	Regresja wieloraka
2	4-1-2	88,64	66,67	70,00	BFGS	Entropia wzajemna	Sinus	Regresja wieloraka
3	4-12-2	84,09	77,78	70,00	RBF	Entropia wzajemna	Gausa	Regresja wieloraka
4	4-9-2	95,45	77,78	80,00	BFGS	Entropia wzajemna	Wykładnicza	Regresja wieloraka
5	4-1-2	86,36	88,89	90,00	RBF	Suma kwadratów różnic	Wykładnicza	Sigmoidalna unipolarna

Uzyskane dla wariantu 1 wyniki pokazują, iż pierwsza, trzecia i piąta sieć to radialne sieci neuronowe o 1, 9, 12 neuronach w warstwie ukrytej. Druga i czwarta sieć to perceptrony wielowarstwowe o 1 i 9 neuronach w warstwie ukrytej. Z grona najlepszych sieci, najwyższą pre-

dykcję uzyskano dla sieci radialnej nr 5 o budowie 4–1–2. Jako algorytm uczenia tej sieci przyjęto metodę radialnych funkcji bazowych. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję wykładniczą, zaś w warstwie wyjściowej funkcję sigmoidalną unipolarną. Dla próbek uczących osiągnięto poprawność 86,36%, w przypadku próbek weryfikujących 90%, zaś dla próbek testujących 88,89%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: od 81,82% do 95,45% poprawności próbek uczących, od 70% do 80% poprawności w przypadku próbek weryfikujących oraz od 66,67% do 88,89% dla próbek testowych.

Tab. 5.89. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć V, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	46,00	6,00	52,00
	Niepoprawne	1,00	10,00	11,00
	Poprawne (%)	97,87	37,50	82,54
	Niepoprawne (%)	2,13	62,50	17,46
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	47,00	5,00	52,00
	Niepoprawne	0,00	11,00	11,00
	Poprawne (%)	100,00	31,25	82,54
	Niepoprawne (%)	0,00	68,75	17,46
<b>3</b>	Razem	47,00	14,00	61,00
	Poprawne	47,00	4,00	51,00
	Niepoprawne	0,00	10,00	10,00
	Poprawne (%)	100,00	28,57	83,61
	Niepoprawne (%)	0,00	71,43	16,39
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	46,00	11,00	57,00
	Niepoprawne	1,00	5,00	6,00
	Poprawne (%)	97,87	68,75	90,48
	Niepoprawne (%)	2,13	31,25	9,52
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	44,00	11,00	55,00
	Niepoprawne	3,00	5,00	8,00
	Poprawne (%)	93,62	68,75	87,30
	Niepoprawne (%)	6,38	31,25	12,70

Tab. 5.90. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć V, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	2,00	36,00
	Niepoprawne	1,00	7,00	8,00
	Poprawne (%)	97,14	22,22	81,82
	Niepoprawne (%)	2,86	77,78	18,18
<b>2</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	4,00	39,00
	Niepoprawne	0,00	5,00	5,00
	Poprawne (%)	100,00	44,44	88,64
	Niepoprawne (%)	0,00	55,56	11,36
<b>3</b>	Razem	35,00	9,00	44,00
	Poprawne	35,00	2,00	37,00
	Niepoprawne	0,00	7,00	7,00
	Poprawne (%)	100,00	22,22	84,09
	Niepoprawne (%)	0,00	77,78	15,91
<b>4</b>	Razem	35,00	9,00	44,00
	Poprawne	34,00	8,00	42,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	97,14	88,89	95,45
	Niepoprawne (%)	2,86	11,11	4,55
<b>5</b>	Razem	35,00	9,00	44,00
	Poprawne	32,00	6,00	38,00
	Niepoprawne	3,00	3,00	6,00
	Poprawne (%)	91,43	66,67	86,36
	Niepoprawne (%)	8,57	33,33	13,64

Tab. 5.91. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć V, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	2,00	8,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	66,67	88,89
	Niepoprawne (%)	0,00	33,33	11,11
<b>2</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	0,00	6,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	66,67
	Niepoprawne (%)	0,00	100,00	33,33
<b>3</b>	Razem	6,00	2,00	8,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	50,00	87,50
	Niepoprawne (%)	0,00	50,00	12,50
<b>4</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	33,33	77,78
	Niepoprawne (%)	0,00	66,67	22,22
<b>5</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	2,00	8,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	66,67	88,89
	Niepoprawne (%)	0,00	33,33	11,11

Tab. 5.92. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć V, wariant 1).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	2,00	8,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	50,00	80,00
	Niepoprawne (%)	0,00	50,00	20,00
<b>2</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	25,00	70,00
	Niepoprawne (%)	0,00	75,00	30,00
<b>3</b>	Razem	6,00	3,00	9,00
	Poprawne	6,00	1,00	7,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	33,33	77,78
	Niepoprawne (%)	0,00	66,67	22,22
<b>4</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	2,00	8,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	50,00	80,00
	Niepoprawne (%)	0,00	50,00	20,00
<b>5</b>	Razem	6,00	4,00	10,00
	Poprawne	6,00	3,00	9,00
	Niepoprawne	0,00	1,00	1,00
	Poprawne (%)	100,00	75,00	90,00
	Niepoprawne (%)	0,00	25,00	10,00

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.93. – 5.96. przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.93. Analiza wrażliwości wszystkich próbek (sieć V, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
<b>1</b>	12,72124	1,234735	0,998727	1,013228
<b>2</b>	2,35278	1,813333	1,357512	0,998016
<b>3</b>	1,49862	1,739654	0,525302	0,064784
<b>4</b>	8,54455	4,602187	2,731647	0,990480
<b>5</b>	2,81522	2,385607	2,138213	1,000686
<b>Średnia</b>	<b>5,58648</b>	<b>2,355103</b>	<b>1,550280</b>	<b>0,813439</b>

Tab. 5.94. Analiza wrażliwości próbek uczących (sieć V, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	18,8794	1,2292	0,9839	1,009460
2	2,3163	1,9482	1,5068	0,998317
3	41,0927	41,1167	1,1434	1,420935
4	643,9649	286,1141	317,3092	2,185977
5	2,5849	2,3430	2,3316	0,996957
<b>Średnia</b>	<b>141,7676</b>	<b>66,5503</b>	<b>64,6550</b>	<b>1,322329</b>

Tab. 5.95. Analiza wrażliwości próbek testujących (sieć V, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	1,2246	1,2096	1,030175	1,032484
2	2,0283	1,4725	1,192181	0,994587
3	0,0085	0,5067	0,504435	0,015311
4	298,7334	142,5448	3,854165	1,356787
5	2,1280	1,8277	1,538026	1,030676
<b>Średnia</b>	<b>60,8246</b>	<b>29,5123</b>	<b>1,623796</b>	<b>0,885969</b>

Tab. 5.96. Analiza wrażliwości próbek weryfikacyjnych (sieć V, wariant 1).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	1,56370	1,27464	1,022370	1,009749
2	2,80803	1,82884	1,140955	1,000993
3	67,34036	34,35115	1,237124	2,113420
4	2,53154	1,88802	0,517813	0,980128
5	5,05528	3,56946	2,359994	0,963515
<b>Średnia</b>	<b>15,85978</b>	<b>8,58242</b>	<b>1,255651</b>	<b>1,213561</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.93), że wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności. Zdecydowanie największy wpływ na wynik predykcji ma czynnik związany z typem przejeżdżającego pojazdu P. Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.95), z której wynika, że biorąc pod uwagę zespół pięciu sieci wszystkie parametry wejściowe są istotne. Z drugiej jednak strony, można założyć, że czwarta sieć wykazująca najlepsze rezultaty wskazuje optymalne wartości wrażliwości, co oznacza, że parametrami, na które sieć jest mało wrażliwa są: rodzaj nawierzchni D<sub>N</sub> i odległość B<sub>DO</sub>. Jednak zauważyć również należy, że wartości dla tych dwóch czynników są bliskie jedności dla próbek testowych, zaś dla pozostałych próbek przekraczają wartość wrażliwości, dlatego warto uwzględnić je podczas budowania modelu.

### 5.3.5.2. Sztuczna sieć neuronowa nr V, wariant 2

Wykonano obliczenia i utworzono 100 sieci dla 2 wariantu podziału na podzbiory. Wybrano 5 najlepiej rokujących sieci (zob. Tab. 5.97) i wyniki przedstawiono w niniejszym podrozdziale. Jako kryterium oceny sieci przyjęto wiarygodność, czyli procent prawidłowo określonych próbek testujących. W Tab. 5.98 – 5.101 przedstawiono podsumowanie predykcji w postaci macierzy pomyłek, odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.97. Rezultaty i charakterystyka sieci (sieć V, wariant 2).

NUMER SIECI	STRUKTURA SIECI	WIARYGODNOŚĆ [%]			ALGORYTM UCZENIA	FUNKCJA		
		PRÓBKI UCZĄCE	PRÓBKI TESTUJĄCE	PRÓBKI WERYFIKUJĄCE		BŁĘDU	AKTYWACJI (NEURONY UKRYTE)	AKTYWACJI (NEURONY WYJŚCIOWE)
1	4-4-2	83,33	88,24	87,50	BFGS	Suma kwadratów różnic	Sigmoidalna unipolarna	Sigmoidalna unipolarna
2	4-7-2	83,33	82,35	87,50	BFGS	Entropia wzajemna	Sigmoidalna unipolarna	Regresja wieloraka
3	4-6-2	86,67	76,47	93,75	BFGS	Suma kwadratów różnic	Sigmoidalna unipolarna	Sigmoidalna unipolarna
4	4-4-2	80,00	70,59	93,75	BFGS	Entropia wzajemna	Sinus	Regresja wieloraka
5	4-7-2	73,33	82,35	87,50	RBF	Entropia wzajemna	Gausa	Regresja wieloraka

Uzyskane dla wariantu 2 wyniki pokazują, iż cztery najlepsze sieci to perceptrony wielowarstwowe o 4, 6 i 7 neuronach w warstwie ukrytej. Piątą jest sieć radialna o budowie 4-7-2. Z grona najlepszych sieci, najwyższą predykcję uzyskano dla perceptronu o budowie 4-4-2 (pierwszego na liście), co oznacza, że warstwie ukrytej przyjęto 2 neurony. Jako algorytm uczenia tej sieci przyjęto metodę BFGS. Funkcja błędu to suma kwadratów różnic. Jako funkcję aktywacji zarówno w warstwie ukrytej jak i wyjściowej przyjęto funkcję sigmoidalną unipolarną. Dla próbek uczących osiągnięto poprawność 83,33%, w przypadku próbek weryfikujących 87,50%, zaś dla próbek testujących 88,24%. Pozostałe 4 rodzaje sieci wykazały dobre rezultaty: od 73,33% do 86,67% poprawności próbek uczących, od 87,5% do 93,75% poprawności w przypadku próbek weryfikujących oraz od 70,59% do 82,35% dla próbek testowych.



Tab. 5.98. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć V, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	47,00	16,00	63,00
	Poprawne	41,00	13,00	54,00
	Niepoprawne	6,00	3,00	9,00
	Poprawne (%)	87,23	81,25	85,71
	Niepoprawne (%)	12,77	18,75	14,29
<b>2</b>	Razem	47,00	16,00	63,00
	Poprawne	40,00	13,00	53,00
	Niepoprawne	7,00	3,00	10,00
	Poprawne (%)	85,11	81,25	84,13
	Niepoprawne (%)	14,89	18,75	15,87
<b>3</b>	Razem	47,00	16,00	63,00
	Poprawne	39,00	15,00	54,00
	Niepoprawne	8,00	1,00	9,00
	Poprawne (%)	82,98	93,75	85,71
	Niepoprawne (%)	17,02	6,25	14,29
<b>4</b>	Razem	47,00	16,00	63,00
	Poprawne	39,00	12,00	51,00
	Niepoprawne	8,00	4,00	12,00
	Poprawne (%)	82,98	75,00	80,95
	Niepoprawne (%)	17,02	25,00	19,05
<b>5</b>	Razem	47,00	16,00	63,00
	Poprawne	46,00	4,00	50,00
	Niepoprawne	1,00	12,00	13,00
	Poprawne (%)	97,87	25,00	79,37
	Niepoprawne (%)	2,13	75,00	20,63

Tab. 5.99. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć V, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	22,00	8,00	30,00
	Poprawne	18,00	7,00	25,00
	Niepoprawne	4,00	1,00	5,00
	Poprawne (%)	81,82	87,50	83,33
	Niepoprawne (%)	18,18	12,50	16,67
<b>2</b>	Razem	22,00	8,00	30,00
	Poprawne	18,00	7,00	25,00
	Niepoprawne	4,00	1,00	5,00
	Poprawne (%)	81,82	87,50	83,33
	Niepoprawne (%)	18,18	12,50	16,67
<b>3</b>	Razem	22,00	8,00	30,00
	Poprawne	18,00	8,00	26,00
	Niepoprawne	4,00	0,00	4,00
	Poprawne (%)	81,82	100,00	86,67
	Niepoprawne (%)	18,18	0,00	13,33
<b>4</b>	Razem	22,00	8,00	30,00
	Poprawne	18,00	6,00	24,00
	Niepoprawne	4,00	2,00	6,00
	Poprawne (%)	81,82	75,00	80,00
	Niepoprawne (%)	18,18	25,00	20,00
<b>5</b>	Razem	22,00	8,00	30,00
	Poprawne	21,00	1,00	22,00
	Niepoprawne	1,00	7,00	8,00
	Poprawne (%)	95,45	12,50	73,33
	Niepoprawne (%)	4,55	87,50	26,67

Tab. 5.100. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć V, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	14,00	3,00	17,00
	Poprawne	13,00	2,00	15,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	92,86	66,67	88,24
	Niepoprawne (%)	7,14	33,33	11,76
<b>2</b>	Razem	14,00	3,00	17,00
	Poprawne	12,00	2,00	14,00
	Niepoprawne	2,00	1,00	3,00
	Poprawne (%)	85,71	66,67	82,35
	Niepoprawne (%)	14,29	33,33	17,65
<b>3</b>	Razem	14,00	3,00	17,00
	Poprawne	11,00	2,00	13,00
	Niepoprawne	3,00	1,00	4,00
	Poprawne (%)	78,57	66,67	76,47
	Niepoprawne (%)	21,43	33,33	23,53
<b>4</b>	Razem	14,00	3,00	17,00
	Poprawne	11,00	1,00	12,00
	Niepoprawne	3,00	2,00	5,00
	Poprawne (%)	78,57	33,33	70,59
	Niepoprawne (%)	21,43	66,67	29,41
<b>5</b>	Razem	14,00	3,00	17,00
	Poprawne	14,00	0,00	14,00
	Niepoprawne	0,00	3,00	3,00
	Poprawne (%)	100,00	0,00	82,35
	Niepoprawne (%)	0,00	100,00	17,65

Tab. 5.101. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć V, wariant 2).

NUMER SIECI	PREDYKCJA PRÓBEK	Y-NIE	Y-TAK	Y-WSZYSTKIE
<b>1</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	4,00	14,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	90,91	80,00	87,50
	Niepoprawne (%)	9,09	20,00	12,50
<b>2</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	4,00	14,00
	Niepoprawne	1,00	1,00	2,00
	Poprawne (%)	90,91	80,00	87,50
	Niepoprawne (%)	9,09	20,00	12,50
<b>3</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	5,00	15,00
	Niepoprawne	1,00	0,00	1,00
	Poprawne (%)	90,91	100,00	93,75
	Niepoprawne (%)	9,09	0,00	6,25
<b>4</b>	Razem	11,00	5,00	16,00
	Poprawne	10,00	5,00	15,00
	Niepoprawne	1,00	0,00	1,00
	Poprawne (%)	90,91	100,00	93,75
	Niepoprawne (%)	9,09	0,00	6,25
<b>5</b>	Razem	11,00	5,00	16,00
	Poprawne	11,00	3,00	14,00
	Niepoprawne	0,00	2,00	2,00
	Poprawne (%)	100,00	60,00	87,50
	Niepoprawne (%)	0,00	40,00	12,50

W drugim etapie wykonano analizę wrażliwości. Analizę wykonano identycznie jak dla sieci nr I (zobacz podrozdział 5.3.1.1). W Tab. 5.102 – 5.105 przedstawiono ilorazy błędów odpowiednio dla wszystkich próbek, dla próbek uczących, dla próbek testujących i dla próbek weryfikujących.

Tab. 5.102. Analiza wrażliwości wszystkich próbek (sieć V, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	2,932100	2,280706	1,288772	1,077498
2	3,966193	2,383148	1,157226	1,031133
3	2,465818	1,835321	1,156238	1,021737
4	1,823685	1,410708	1,078738	1,011209
5	0,641758	0,392860	0,512670	0,025340
<b>Średnia</b>	<b>2,365911</b>	<b>1,660549</b>	<b>1,038729</b>	<b>0,833384</b>

Tab. 5.103. Analiza wrażliwości próbek uczących (sieć V, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	3,422486	2,553308	1,478756	1,299973
2	5,092597	2,830279	1,392148	1,162604
3	2,600514	1,913531	1,223069	1,053119
4	1,746175	1,357440	1,055446	1,008469
5	0,012280	0,136225	0,506243	0,012486
<b>Średnia</b>	<b>2,574810</b>	<b>1,758157</b>	<b>1,131132</b>	<b>0,907330</b>

Tab. 5.104. Analiza wrażliwości próbek testujących (sieć V, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	G <sub>A</sub>	B <sub>DO</sub>
1	1,66872	1,626983	1,382193	0,903129
2	1,54521	1,462184	1,066636	0,952085
3	1,40531	1,309920	1,153322	0,993772
4	1,27361	1,234814	1,099134	1,016394
5	64,93724	0,991208	1,000000	1,000000
<b>Średnia</b>	<b>14,16602</b>	<b>1,325022</b>	<b>1,140257</b>	<b>0,973076</b>

Tab. 5.105. Analiza wrażliwości próbek weryfikacyjnych (sieć V, wariant 2).

NUMER SIECI	P	D <sub>STN</sub>	B <sub>DO</sub>	G <sub>A</sub>
1	3,91085	2,75358	0,936977	0,813566
2	7,46365	3,67725	0,960612	0,912048
3	4,16202	2,64792	0,999215	1,000300
4	2,87834	1,81878	1,009902	1,104711
5	62,88613	62,88613	1,786543	1,393272
<b>Średnia</b>	<b>16,26020</b>	<b>14,75673</b>	<b>1,138650</b>	<b>1,044779</b>

Podsumowując wykonaną analizę wrażliwości należy zwrócić uwagę na wyniki dla pojedynczych sieci, a także na średnią otrzymaną dla wszystkich pięciu sieci. W przypadku analizy wszystkich próbek można stwierdzić (zob. Tab. 5.102), że w zasadzie wszystkie parametry wejściowe są istotne, ponieważ wartości nie są mniejsze od jedności, poza jednym parametrem związanym z odległością  $B_{DO}$ , który okazał się niewrażliwy (średnia 0,83338). Analizując wszystkie próbki, największy wpływ na wynik predykcji ma czynnik związany z typem przejeżdżającego pojazdu P. Najbardziej wiarygodną ocenę sieci przedstawia tabela wrażliwości dla próbek testowych (Tab. 5.104), z której wynika, że istotny parametr to typ przejeżdżającego pojazdu P i stan nawierzchni drogi  $D_{STN}$ . Dla najlepszej sieci analiza wykazuje, że najmniej wrażliwy jest czynnik odległości  $B_{DO}$ , który osiąga wartość poniżej jedności.

## 6. BUDOWA ALGORYTMU MASZYN WEKTORÓW WSPIERAJĄCYCH

### 6.1. Informacje wejściowe i wyjściowe

Celem algorytmu opisanego w niniejszym rozdziale jest wykorzystanie MWW do prognozowania wpływu drgań komunikacyjnych wywołanych ruchem drogowym na budynki mieszkalne. Procedurę badawczą zbierania danych wejściowych szczegółowo opisano w rozdziale 3 niniejszej rozprawy. Wyniki badań eksperymentalnych wykorzystano do budowy MWW. Oprócz własnych badań posłużono się również wynikami badań wykonanymi przez innych badaczy.

Sygnały wejściowe przyjęto na podstawie normy PN–85/B–02170 oraz publikacji (np. Duńska i in., 2014) i były to: odległość budynku od krawędzi drogi (zmienna ilościowa), stan i rodzaj nawierzchni, stan budynku, typ pojazdu oraz absorpcja drgań w gruncie (zmiennie jakościowe). Tworząc MWW wykorzystywano różną kombinację tych parametrów.

Sygnałem wyjściowym była informacja, czy istnieje zagrożenie negatywnego oddziaływania drgań na budynki czy nie. Niebezpieczeństwo wyznaczono na podstawie kryteriów zawartych w normie PN–85/B–02170. Brak zagrożenia wskazuje na I strefę wpływu drgań, według SWD I lub SWD II, czyli brak oddziaływań komunikacyjnych na budynki. Jeżeli algorytm prognozuje możliwe zagrożenie, jest to wskazanie do wykonania pomiarów *in situ*, ponieważ może to oznaczać, że dany budynek znajduje się w strefie II lub w wyższej.

Informacje wejściowe przyjęto identycznie jak dla SSN. Opis poszczególnych parametrów znaleźć można w analogicznym rozdziale dotyczącym SSN (zob. rozdział 5.2). Ponadto Tab. 5.14 przedstawia wszystkie informacje o próbkach wykorzystanych do budowy algorytmu. Tabela zestawia informacje wejściowe oraz informację wyjściową dotyczącą zagrożenia (otrzymaną z pomiarów rzeczywistych).

### 6.2. Informacje techniczne tworzenia MWW

Budowę maszyn przeprowadzono na podstawie zasad opisanych w literaturze (Cover, 1965; Boser i in., 1992; Cortes i Vapnik, 1995; Bennett i Campbell, 2000; Cristianini i Shawe–Taylor, 2000; Haykin, 2009; Souza, 2010). Pierwszym krokiem było utworzenie bazy danych niezbędnych do rozpoczęcia budowy algorytmu, czyli wykonanie pomiarów drgań na budynkach. Zgromadzono 63 próbki, w tym 33 próbki danych wejściowych wykonując samodzielne pomiary (opisane w rozdziale 3) i 30 próbek na podstawie pomiarów innych badaczy (Chyży i in., 2009; Kawecki i Stypuła, 2009; Czech i in., 2015; Stypuła, 2015). Określono, jakie parametry mogą wpływać na wyniki otrzymane w badaniach podczas tworzenia bazy.

### 6.3. Utworzone maszyny wektorów wspierających

W niniejszym podrozdziale analizie poddano problem klasyfikacji zdefiniowany w ten sposób, aby algorytm (na podstawie kilku parametrów podanych przez użytkownika) dokonał prognozy wpływu oddziaływań komunikacyjnych na budynek z zadowalającym prawdopodobieństwem. Za sygnały wejściowe przyjęto czynniki (zmiennie niezależne) ustalone podczas pomiarów polowych, tj.:

- $B_{ST}$  – stan budynku;
- $B_{DO}$  – odległość budynku od krawędzi drogi;
- $G_A$  – absorpcja gruntu;
- $D_N$  – rodzaj nawierzchni drogi;
- $D_{STN}$  – stan nawierzchni drogi;
- $P$  – typ pojazdu.

Wektory wejścia dla kolejnych maszyn przyjęto w sposób losowy w postaci:

- MWW nr 1:  $\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$ ;
- MWW nr 2:  $\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$ ;
- MWW nr 3:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$ ;
- MWW nr 4:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, D_N, P\}$ ;
- MWW nr 5:  $\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$ .

Jako sygnał wyjściowy ustalono dwie klasy o wartościach:

- 0 – brak wpływu drgań na budynek – I strefa według SWD I lub SWD II zgodnie z normą PN-85/B-02170;
- 1 – prawdopodobny wpływ drgań na budynek – II strefa lub wyższa według normy.

Algorytm MWW wykonano w programie *Statistica 12*. Informacje techniczne budowy algorytmu zaczerpnięto z podręczników Haykin'a (2009) oraz EPS (2017). W autorskiej maszynie wektorów wspierających rozwiązywany był problem optymalizacyjny, w którym minimalizowany był margines (słaby margines), ponieważ był nieseparowalny liniowo. Był to algorytm klasyfikacji binarnej, ponieważ założono dwie klasy zbiorów: zbiór przypadków, dla których istnieje zagrożenie wpływu drgań komunikacyjnych na budynki oraz zbiór przypadków bezpiecznych. Podzielono losowo wszystkie przypadki na 2 zbiory: uczący i testowy. Do zbioru uczącego przydzielono losowo 47 próbek, co stanowi 74,6% wszystkich próbek oraz 16 próbek dla zbioru testującego, stanowiących 25,4% ogółu.



Aby wyznaczyć optymalne wartości stałych uczenia (w tym przypadku stałej  $C$  – zob. wzór 4.9) zastosowano sprawdzian krzyżowy (Conway i White, 2012; Setlak i Paško, 2013). Dane podzielono losowo na rozłączne podzbiory. Wykonano analizę, aby ustalić przewidywanie dla  $n$ -tego podzbioru, wykorzystując pozostałe  $n-1$  podzbiory do uczenia. Predykcję dla  $n$ -tego zbioru porównano z wartością rzeczywistą, w związku z tym można było obliczyć błąd predykcji. Ponieważ, w istocie, dysponowano wartościami zmiennej zależnej w grupie danych, dla których wykonano predykcję, można było wyznaczyć błąd predykcji poprzez obliczenie procentu przypadków zaklasyfikowanych poprawnie. Procedurę powtórzono dla wszystkich  $n$  podzbiorów danych. Następnie błędy predykcji były uśredniane, otrzymując optymalne wartości parametru (na końcu każdego cyklu obliczeń dla danego podzbioru uśredniano błędy, otrzymując miarę jakości modelu).

Ponieważ przypadki nierównomiernie rozkładały się na klasy (w przypadku 47 próbek określono empirycznie podczas pomiarów brak zagrożenia wpływem drgań na budynek – klasa „0” oraz dla 16 próbek otrzymano wynik oznaczający zagrożenie wpływem drgań – klasa „1“, zob. Tab. 5.14) zastosowano karę, aby uniknąć niepoprawnego klasyfikowania przypadków klasy „1” do klasy liczniejszej, czyli „0”. Dlatego na klasę „0” nałożono karę w wysokości 3, zaś dla klasy „1” kara wynosiła 1 (brak wpływu na wynik). Funkcje jądrowe przyjęto kolejno jako funkcję liniową, wielomianową, radialną funkcję bazową i sigmoidalną (Souza, 2010). W algorytmach maszyn wektorów wspierających przyjęto kombinacje czynników identyczne jak dla sieci neuronowych, aby możliwe było obiektywne porównanie obu metod.

### 6.3.1. Maszyna wektorów wspierających nr 1

W pierwszej maszynie uwzględniono wszystkie parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Zatem wektor wejścia miał postać:  $\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_N \in \{\text{bitumiczna, gruntowa, kostka brukowa, płyty jumbo}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Algorytm MWW nr 1 przetestowano dla czterech różnych funkcji jądrowych, tak zwanych kerneli, co przedstawiono w kolejnych podrozdziałach.

### 6.3.1.1. Maszyna wektorów wspierających nr 1.1

Do budowy pierwszego algorytmu, jako funkcję jądrową  $K(x, y)$  przyjęto funkcję liniową postaci (Souza, 2010):

$$K(x, y) = x^T y + c \quad (6.1)$$

Zgodnie z zasadą opisaną w rozdziale 6.3 oraz w publikacji Conway'a i White'a (2012), wykonano 10-krotny sprawdzian krzyżowy, którego trafność wyniosła 78,72%. Dzięki temu wyznaczono optymalną wartość parametru  $C$  (zob. wzór 4.9), która wyniosła  $C = 2$ . Wyznaczono 21 wektorów wspierających (9 na klasę „0”, 12 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 82,98%, a w zbiorze testowym 81,25%. Ogólna zaś trafność (biorąc pod uwagę wszystkie próbki) wyniosła 82,54% (jest to średnia ważona uwzględniająca liczebność próby w danym zbiorze). Wiarygodność działania algorytmu oceniono na podstawie błędów, z jakimi rozpoznał on przynależność obiektów ze zbioru wszystkich danych oraz zbioru danych uczących i testowych do zdefiniowanych wcześniej wzorców. Uzyskano w ten sposób tak zwaną macierz pomyłek, z której odczytać można w ilu przypadkach model poprawnie sklasyfikował dane (EPS, 2017). Macierze te, dla różnych zbiorów danych, przedstawiono w Tab. 6.1 – 6.3.

Tab. 6.1. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 1.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	45	2
	tak	9	7

Tab. 6.2. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 1.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	8	5

Tab. 6.3. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 1.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	11	2
	tak	1	2

### 6.3.1.2. Maszyna wektorów wspierających nr 1.2

Do budowy algorytmu jako funkcję jądrową  $K(x, y)$  przyjęto funkcję wielomianową stopnia trzeciego (Souza, 2010):

$$K(x, y) = (\alpha x^T y + c)^3 \quad (6.2)$$

Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 78,72%. Dzięki temu wyznaczono optymalną wartość parametru  $C$  (zob. wzór 4.9), która wyniosła  $C = 3$ . Wyznaczono 27 wektorów wspierających (14 na klasę „0”, 13 na klasę „1”), w tym 10 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.4 – 6.6.

Tab. 6.4. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 1.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.5. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 1.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	7	6

Tab. 6.6. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 1.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.1.3. Maszyna wektorów wspierających nr 1.3

Do budowy algorytmu jako funkcję jądrową  $K(x, y)$  przyjęto radialną funkcję bazową (Souza, 2010):

$$K(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (6.3)$$

Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność

sprawdzianu krzyżowego wyniosła 78,72%. Dzięki temu wyznaczona została optymalna wartość parametru  $C$  (zob. wzór 4.9), która wyniosła  $C = 3$ . Wyznaczono 24 wektory wspierające (11 na klasę „0”, 13 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.7 – 6.9.

Tab. 6.7. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 1.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.8. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 1.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	7	6

Tab. 6.9. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 1.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

#### 6.3.1.4. Maszyna wektorów wspierających nr 1.4

Do budowy algorytmu jako funkcję jądrową  $K(x, y)$  przyjęto funkcję sigmoidalną (Souza, 2010):

$$K(x, y) = \tanh(ax^T y + c) \quad (6.4)$$

Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 76,60%. Dzięki temu wyznaczona została optymalna wartość parametru  $C$  (zob. wzór 4.9), która wyniosła  $C = 9$ . Wyznaczono 21 wektorów wspierających (8 na klasę „0”, 13 na klasę „1”), w tym 13 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 74,47%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 76,19%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.10 – 6.12.

Tab. 6.10. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 1.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	14	2

Tab. 6.11. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 1.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	12	1

Tab. 6.12. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 1.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.1.5. Maszyna wektorów wspierających nr 1 – zestawienie wyników

W Tab. 6.13 przedstawiono podsumowanie predykcji dla maszyny wektorów wspierających nr 1. Biorąc pod uwagę cztery wykorzystane do budowy funkcje jądrowe należy zauważyć, że w zbiorze testowym wszystkie osiągnęły tę samą poprawność (81,25%). Natomiast, w przypadku próbek uczących, kernel wielomianowy stopnia trzeciego i radialna funkcja bazowa osiągnęły lepszą predykcję, która wyniosła 85,11%. Tab. 6.13 pokazuje jednocześnie, iż najlepszą trafność ogólną (84,13% predykcji) otrzymano przy wykorzystaniu wielomianu stopnia trzeciego i radialnej funkcji bazowej.

Tab. 6.13. Podsumowanie predykcji dla MWW nr 1.

RODZAJ FUNKCJI JĄDROWEJ	TRAFNOŚĆ KLASYFIKACJI [%]		
	ZBIÓR UCZĄCY	ZBIÓR TESTOWY	OGÓLNA
LINIOWA	82,98	81,25	82,54
WIELOMIANOWA	85,11	81,25	84,13
RADIALNA BAZOWA	85,11	81,25	84,13
SIGMOIDALNA	74,47	81,25	76,19

### 6.3.2. Maszyna wektorów wspierających nr 2

W drugiej maszynie uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia w tym przypadku miał postać:  $\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Algorytm MWW nr 2 przetestowano dla czterech różnych funkcji jądrowych, tak zwanych kerneli, co przedstawiono w kolejnych podrozdziałach.

#### 6.3.2.1. Maszyna wektorów wspierających nr 2.1

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję liniową zgodnie ze wzorem (6.1). Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 76,60%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 4$ . Wyznaczono 21 wektorów wspierających (9 na klasę „0”, 12 na klasę „1”), w tym 10 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.14 – 6.16.

Tab. 6.14. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 2.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.15. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 2.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	79	6



Tab. 6.16. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 2.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.2.2 Maszyna wektorów wspierających nr 2.2

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję wielomianową stopnia trzeciego zgodnie ze wzorem (6.2). Sprawdzenia krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 78,72%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 3$ . Wyznaczono 25 wektorów wspierających (12 na klasę „0”, 13 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.17 – 6.19.

Tab. 6.17. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 2.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.18. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 2.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	1
	tak	7	6

Tab. 6.19. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 2.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.2.3. Maszyna wektorów wspierających nr 2.3

Do budowy algorytmu jako funkcję jądrową przyjęto radialną funkcję bazową zgodnie ze wzorem (6.3). Sprawdzenia krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1).

Trafność sprawdzianu krzyżowego wyniosła 76,60%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 4$ . Wyznaczono 25 wektorów wspierających (12 na klasę „0”, 13 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.20 – 6.22.

Tab. 6.20. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 2.3)

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.21. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 2.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	7	6

Tab. 6.22. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 2.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

#### 6.3.2.4. Maszyna wektorów wspierających nr 2.4

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję sigmoidalną zgodnie ze wzorem (6.4). Sprawdzenie krzyżowe oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 78,72%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 9$ . Wyznaczono 22 wektory wspierające (9 na klasę „0”, 13 na klasę „1”), w tym 13 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 74,47%, a w zbiorze testowym 87,50%. Ogólna zaś trafność wyniosła 77,78%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.23 – 6.25.

Tab. 6.23. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 2.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	14	2

Tab. 6.24. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 2.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	12	1

Tab. 6.25. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 2.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	2	1

### 6.3.2.5. Maszyna wektorów wspierających nr 2 – zestawienie wyników

W Tab. 6.26 przedstawiono podsumowanie predykcji dla maszyny wektorów wspierających nr 2. Biorąc pod uwagę cztery wykorzystane do budowy funkcje jądrowe należy zauważyć, że w zbiorze testowym najlepszą poprawność otrzymano wykorzystując funkcję sigmoidalną (87,50%). Natomiast, w przypadku próbek uczących, kernel liniowy, wielomianowy stopnia trzeciego i radialna funkcja bazowa osiągnęły najlepszą predykcję, która wyniosła 85,11%. Tab. 6.26 pokazuje jednocześnie, iż najlepszą trafność ogólną (84,13% predykcji) otrzymano przy wykorzystaniu właśnie tych trzech kerneli.

Tab. 6.26. Podsumowanie predykcji dla MWW nr 2.

RODZAJ FUNKCJI JĄDROWEJ	TRAFNOŚĆ KLASYFIKACJI [%]		
	ZBIÓR UCZĄCY	ZBIÓR TESTOWY	OGÓLNA
LINIOWA	85,11	81,25	84,13
WIELOMIANOWA	85,11	81,25	84,13
RADIALNA BAZOWA	85,11	81,25	84,13
SIGMOIDALNA	74,47	87,50	77,78

### 6.3.3. Maszyna wektorów wspierających nr 3

W trzeciej maszynie uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia w tym przypadku miał postać:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;

- $G_A \in \{\text{zła, średnia, dobra}\}$ ;
- $D_{STN} \in \{\text{zły, średni, dobry}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Algorytm MWW nr 3 przetestowano dla czterech różnych funkcji jądrowych, tak zwanych kerneli, co przedstawiono w kolejnych podrozdziałach.

### 6.3.3.1 Maszyna wektorów wspierających nr 3.1

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję liniową zgodnie ze wzorem (6.1). Sprawdzenia krzyżowe oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 70,21%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 1$ . Wyznaczono 21 wektorów wspierających (8 na klasę „0”, 13 na klasę „1”), w tym 14 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 72,34%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 74,60%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.27 – 6.29.

Tab. 6.27. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 3.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	16	0

Tab. 6.28. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 3.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	13	0

Tab. 6.29. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 3.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	3	0

### 6.3.3.2. Maszyna wektorów wspierających nr 3.2

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję wielomianową stopnia trzeciego zgodnie ze wzorem (6.2). Sprawdzenia krzyżowe oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob.

podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 70,21%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 1$ . Wyznaczono 25 wektorów wspierających (12 na klasę „0”, 13 na klasę „1”), w tym 13 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 72,34%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 74,60%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.30 – 6.32.

Tab. 6.30. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 3.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	16	0

Tab. 6.31. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 3.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	13	0

Tab. 6.32. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 3.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	3	0

### 6.3.3.3. Maszyna wektorów wspierających nr 3.3

Do budowy algorytmu jako funkcję jądrową przyjęto radialną funkcję bazową zgodnie ze wzorem (6.3). Sprawdzenie krzyżowe oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 70,21%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 1$ . Wyznaczono 27 wektorów wspierających (14 na klasę „0”, 13 na klasę „1”), w tym 14 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 72,34%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 74,60%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.33 – 6.35.

Tab. 6.33. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 3.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	16	0

Tab. 6.34. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 3.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	13	0

Tab. 6.35. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 3.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	3	0

#### 6.3.3.4. Maszyna wektorów wspierających nr 3.4

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję sigmoidalną zgodnie ze wzorem (6.4). Sprawdzenia krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 72,34%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 1$ . Wyznaczono 22 wektory wspierające (9 na klasę „0”, 13 na klasę „1”), w tym 15 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 72,34%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 74,60%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab.6.36 – 6.38.

Tab. 6.36. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 3.4)..

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	16	0

Tab. 6.37. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 3.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	13	0

Tab. 6.38. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 3.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	3	0

### 6.3.3.5. Maszyna wektorów wspierających nr 3 – zestawienie wyników

W Tab. 6.39 przedstawiono podsumowanie predykcji dla maszyny wektorów wspierających nr 3. Biorąc pod uwagę cztery wykorzystane do budowy funkcje jądrowe należy zauważyć, że niezależnie od wyboru, osiągnięto identyczne wyniki zarówno w zbiorze uczącym (72,34%) jak i testowym (81,25%). Jednocześnie ogólna poprawność, niezależnie od wyboru funkcji jądrowej, wyniosła 74,60% predykcji.

Tab. 6.39. Podsumowanie predykcji dla MWW nr 3.

RODZAJ FUNKCJI JĄDROWEJ	TRAFNOŚĆ KLASYFIKACJI [%]		
	ZBIÓR UCZĄCY	ZBIÓR TESTOWY	OGÓLNA
LINIOWA	72,34	81,25	74,60
WIELOMIANOWA	72,34	81,25	74,60
RADIALNA BAZOWA	72,34	81,25	74,60
SIGMOIDALNA	72,34	81,25	74,60

### 6.3.4. Maszyna wektorów wspierających nr 4

W czwartej maszynie uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia w tym przypadku miał postać:  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, D_N, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $B_{ST} \in \{\text{zły, średni, dobry}\}$ ;
  - $D_N \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Algorytm MWW nr 4 przetestowano dla czterech różnych funkcji jądrowych, tak zwanych kerneli, co przedstawiono w kolejnych podrozdziałach.

#### 6.3.4.1 Maszyna wektorów wspierających nr 4.1

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję liniową zgodnie ze wzorem (6.1). Sprawdzenie krzyżowe oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 74,47%. Dzięki temu wyznaczono optymalną



wartość parametru  $C$ , która wyniosła  $C = 1$ . Wyznaczono 23 wektory wspierające (10 na klasę „0”, 13 na klasę „1”), w tym 13 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 78,72%, a w zbiorze testowym 87,50%. Ogólna zaś trafność wyniosła 80,95%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.40 – 6.42.

Tab. 6.40. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 4.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	12	4

Tab. 6.41. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 4.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	10	3

Tab. 6.42. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 4.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	2	1

### 6.3.4.2. Maszyna wektorów wspierających nr 4.2

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję wielomianową stopnia trzeciego zgodnie ze wzorem (6.2). Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 78,72%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 5$ . Wyznaczono 30 wektorów wspierających (18 na klasę „0”, 12 na klasę „1”), w tym 9 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 80,85%, a w zbiorze testowym 87,50%. Ogólna zaś trafność wyniosła 82,54%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.43 – 6.45.

Tab. 6.43. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 4.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	11	5

Tab. 6.44. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 4.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	9	4

Tab. 6.45. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 4.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	2	1

### 6.3.4.3. Maszyna wektorów wspierających nr 4.3

Do budowy algorytmu jako funkcję jądrową przyjęto radialną funkcję bazową zgodnie ze wzorem (6.3). Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 74,47%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 3$ . Wyznaczono 26 wektorów wspierających (13 na klasę „0”, 13 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 80,85%, a w zbiorze testowym 87,50%. Ogólna zaś trafność wyniosła 82,54%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.46 – 6.48.

Tab. 6.46. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 4.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	11	5

Tab. 6.47. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 4.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	9	4

Tab. 6.48. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 4.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	2	1

#### 6.3.4.4. Maszyna wektorów wspierających nr 4.4

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję sigmoidalną zgodnie ze wzorem (6.4). Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 72,34%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 1$ . Wyznaczono 22 wektory wspierające (9 na klasę „0”, 13 na klasę „1”), w tym 15 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 72,34%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 74,60%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.49 – 6.51.

Tab. 6.49. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 4.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	16	0

Tab. 6.50. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 4.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	13	0

Tab. 6.51. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 4.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	3	0

#### 6.3.4.5. Maszyna wektorów wspierających nr 4 – zestawienie wyników

W Tab. 6.52 przedstawiono podsumowanie predykcji dla maszyny wektorów wspierających nr 4. Biorąc pod uwagę cztery wykorzystane do budowy funkcje jądrowe należy zauważyć, że w zbiorze testowym najlepszą poprawność otrzymano wykorzystując funkcję liniową, wielomianową i radialną (87,50%). Natomiast, w przypadku próbek uczących, kernel wielomianowy stopnia trzeciego i radialna funkcja bazowa osiągnęły najlepszą predykcję, która wyniosła 80,85%. Tab. 6.52 pokazuje jednocześnie, iż najlepszą trafność ogólną (82,54% predykcji) otrzymano przy wykorzystaniu właśnie tych dwóch kerneli.

Tab. 6.52. Podsumowanie predykcji dla MWW nr 4.

RODZAJ FUNKCJI JĄDROWEJ	TRAFNOŚĆ KLASYFIKACJI [%]		
	ZBIÓR UCZĄCY	ZBIÓR TESTOWY	OGÓLNA
LINIOWA	78,72	87,50	80,95
WIELOMIANOWA	80,85	87,50	82,54
RADIALNA BAZOWA	80,85	87,50	82,54
SIGMOIDALNA	72,34	81,25	74,60

### 6.3.5. Maszyna wektorów wspierających nr 5

W piątej maszynie uwzględniono wybrane parametry wejściowe (zmienna ilościowa i zmienne jakościowe scharakteryzowane w podrozdziale 5.2). Wektor wejścia w tym przypadku miał postać:  $\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$ .

- Zmienna ilościowa:
  - $B_{DO} \in \langle 1,91-22,5 \rangle$ .
- Zmienne jakościowe:
  - $G_A \in \{\text{zła, średnia, dobra}\}$ ;
  - $D_{STN} \in \{\text{zły, średni, dobry}\}$ ;
  - $P \in \{\text{typ1, typ2, typ3}\}$ .

Wektor wyjścia miał postać:  $\mathbf{y}_{(1 \times 1)} = \{y\}$ ;  $y \in \{0, 1\}$ .

Algorytm MWW nr 5 przetestowano dla czterech różnych funkcji jądrowych, tak zwanych kerneli, co przedstawiono w kolejnych podrozdziałach.

#### 6.3.5.1. Maszyna wektorów wspierających nr 5.1

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję liniową zgodnie ze wzorem (6.1). Sprawdzenie krzyżowe oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 76,60%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 4$ . Wyznaczono 21 wektorów wspierających (9 na klasę „0”, 12 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.53 – 6.55.

Tab. 6.53. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 5.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.54. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 5.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	7	6

Tab. 6.55. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 5.1).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.5.2. Maszyna wektorów wspierających nr 5.2

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję wielomianową stopnia trzeciego zgodnie ze wzorem (6.2). Sprawdzian krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 76,60%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 3$ . Wyznaczono 27 wektorów wspierających (14 na klasę „0”, 13 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.56 – 6.58.

Tab. 6.56. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 5.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.57. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 5.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	7	6

Tab. 6.58. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 5.2).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.5.3. Maszyna wektorów wspierających nr 5.3

Do budowy algorytmu jako funkcję jądrową przyjęto radialną funkcję bazową zgodnie ze wzorem (6.3). Sprawdzenia krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1). Trafność sprawdzianu krzyżowego wyniosła 78,72%. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 3$ . Wyznaczono 25 wektorów wspierających (12 na klasę „0”, 13 na klasę „1”), w tym 11 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 85,11%, a w zbiorze testowym 81,25%. Ogólna zaś trafność wyniosła 84,13%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.59 – 6.61.

Tab. 6.59. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 5.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	46	1
	tak	9	7

Tab. 6.60. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 5.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	7	6

Tab. 6.61. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 5.3).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	12	1
	tak	2	1

### 6.3.5.4. Maszyna wektorów wspierających nr 5.4

Do budowy algorytmu jako funkcję jądrową przyjęto funkcję sigmoidalną zgodnie ze wzorem (6.4). Sprawdzenia krzyżowy oraz wiarygodność działania algorytmu przeprowadzono tak samo, jak w przypadku maszyny wektorów wspierających nr 1.1 (zob. podrozdział 6.3.1.1).

Trafność sprawdzianu krzyżowego wyniosła 74,47. Dzięki temu wyznaczono optymalną wartość parametru  $C$ , która wyniosła  $C = 5$ . Wyznaczono 22 wektory wspierające (9 na klasę „0”, 13 na klasę „1”), w tym 15 związanych. Trafność klasyfikacji w zbiorze uczącym wyniosła 74,47%, a w zbiorze testowym 87,50%. Ogólna zaś trafność wyniosła 77,78%. Macierze pomyłek, dla różnych zbiorów danych, przedstawiono w Tab. 6.62 – 6.64.

Tab. 6.62. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 5.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	47	0
	tak	14	2

Tab. 6.63. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 5.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	34	0
	tak	12	1

Tab. 6.64. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 5.4).

MACIERZ POMYŁEK		PREDYKCJA	
		nie	tak
OBSERWOWANE	nie	13	0
	tak	2	1

### 6.3.5.5. Maszyna wektorów wspierających nr 5 – zestawienie wyników

W Tab. 6.65 przedstawiono podsumowanie predykcji dla maszyny wektorów wspierających nr 5. Biorąc pod uwagę cztery wykorzystane do budowy funkcje jądrowe należy zauważyć, że w zbiorze testowym najlepszą poprawność otrzymano wykorzystując funkcję liniową, wielomianową i radialną (81,25%). W przypadku próbek uczących, te same funkcje jądrowe osiągnęły najlepszą predykcję, która wyniosła 85,11%. Ogólnie najlepsze rezultaty (84,13% predykcji) otrzymano przy wykorzystaniu właśnie tych trzech kerneli.

Tab. 6.65. Podsumowanie predykcji dla MWW nr 5.

RODZAJ FUNKCJI JĄDROWEJ	TRAFNOŚĆ KLASYFIKACJI [%]		
	ZBIÓR UCZĄCY	ZBIÓR TESTOWY	OGÓLNA
LINIOWA	85,11	81,25	84,13
WIELOMIANOWA	85,11	81,25	84,13
RADIALNA BAZOWA	85,11	81,25	84,13
SIGMOIDALNA	74,47	87,50	77,78



## 7. PODSUMOWANIE i WNIOSKI KOŃCOWE

W niniejszej pracy przedstawiono algorytmy SSN oraz MWW do prognozowania wpływu drgań komunikacyjnych na budynki mieszkalne. W pierwszej części rozprawy przybliżono problem występowania drgań oraz scharakteryzowano metodykę pomiarową. W kolejnej części opisano wykonane badania pomiarowe i zestawiono wyniki analizy dla poszczególnych budynków. Zasadniczym elementem dysertacji jest autorski algorytm umożliwiający prognozowanie wpływu drgań na budynki przy użyciu SSN oraz MWW.

### 7.1. Wyniki dla sztucznych sieci neuronowych

W ramach analiz z wykorzystaniem SSN, utworzono 5 różnych charakterystyk sieci. W pierwszym przypadku jako sygnały wejściowe uwzględniono wszystkie pomierzone eksperymentalnie parametry, czyli: stan budynku  $B_{ST}$ , odległość między budynkiem a krawężnią drogi  $B_{DO}$ , absorpcję drgań w gruncie  $G_A$ , rodzaj nawierzchni, po której poruszają się pojazdy  $D_N$  oraz jej stan  $D_{STN}$ , a także typ przejeżdżających pojazdów  $P$ . W drugim wariantcie sygnały wejściowe stanowiły 5 czynników, wyłączając rodzaj nawierzchni  $D_N$ . Trzeci przypadek to uwzględnienie czterech parametrów: stanu budynku  $B_{ST}$ , odległości  $B_{DO}$ , absorpcji gruntu  $G_A$  oraz stanu nawierzchni  $D_{STN}$ . W przypadku czwartego wariantu, uwzględniono konfigurację czterech innych czynników: stanu budynku  $B_{ST}$ , odległości  $B_{DO}$ , rodzaju nawierzchni  $D_N$  oraz typu pojazdów  $P$ . W ostatnim rodzaju sieci przyjęto również cztery wejścia: odległość  $B_{DO}$ , absorpcję gruntu  $G_A$ , stan nawierzchni  $D_{STN}$  i typ pojazdów  $P$ .

Każdą z kombinacji czynników wejściowych (zmiennych niezależnych) rozpatrywano w dwóch wariantach podziału na próby. Sumaryczne zestawienie wyników poprawności wszystkich sieci przedstawiono w Tab. 7.1. Wiarygodność ogólną sieci obliczono jako średnią ważoną uwzględniającą liczebność próby uczącej, weryfikacyjnej i testowej.

Tab. 7.1. Zestawienie wiarygodności analizowanych sztucznych sieci neuronowych.

NUMER SIECI	WARIANT PODZIAŁU NA PRÓBY	WIARYGODNOŚĆ [%]			
		PRÓBA UCZĄCA	PRÓBA WERYFIKACYJNA	PRÓBA TESTOWA	OGÓLNE
SSN I	1	81,82	90,00	77,78	82,54
	2	76,67	81,25	88,24	80,96
SSN II	1	88,64	100,00	88,89	90,48
	2	96,67	87,50	82,35	90,48
SSN III	1	86,36	60,00	66,67	79,36
	2	76,67	68,75	88,24	77,78
SSN IV	1	88,64	70,00	66,67	82,54
	2	83,33	81,25	88,24	84,13
SSN V	1	86,36	90,00	88,89	87,30
	2	83,33	87,50	88,24	85,71

Biorąc pod uwagę wszystkie rozpatrzone kombinacje czynników w różnych wariantach można stwierdzić, że najlepszą predykcję, z wiarygodnością ogólną na poziomie 90,48%, osiągnęła sieć nr II, w której wektor wejścia ma postać:  $\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$ . Oznacza to, że najlepszą kombinacją czynników wejściowych dla analizowanych przypadków predykcji drgań komunikacyjnych jest: stan techniczny budynku, odległość między budynkiem i krawędzią drogi, absorpcja drgań w gruncie, stan techniczny nawierzchni oraz typ pojazdów poruszających się po drodze. Sieć nr II, zarówno w pierwszym jak i w drugim wariantcie podziału na próbki, wykazała bardzo dobre wyniki. W pierwszym wariantcie podziału przypadków, wiarygodność dla próby uczącej wyniosła 88,64%, próbki weryfikacyjne osiągnęły 100,00% poprawności, zaś dla przypadków testujących algorytm otrzymano 88,89% wyników poprawnych. Z kolei, w drugim wariantcie podziału przypadków, wiarygodność dla próby uczącej wyniosła 96,67%, dla próby weryfikacyjnej uzyskano 87,50% poprawności, zaś dla przypadków testujących algorytm otrzymano 82,35% wyników poprawnych.

Uzyskanie najlepszych wyników predykcji dla sieci nr II oznacza, że dla analizowanych przypadków najmniej istotny jest rodzaj nawierzchni  $D_N$ . Po wykonaniu analizy wrażliwości dla próbek poddanych działaniu testującemu (czyli przypadki niewykorzystane ani do budowy algorytmu ani do jego walidacji) można stwierdzić z kolei, że najważniejszy jest parametr dotyczący stanu nawierzchni drogi  $D_{STN}$  (zob. rozdział 5.3.2).

Wyniki z Tab. 7.1. pokazują również, iż wyróżniającym się algorytmem (choć nie tak dobrym jak sieć nr II) jest sieć nr V, dla której wiarygodność ogólna wynosi 87,30% i 85,71%, biorąc pod uwagę różne warianty podziału na próbki. Jest to sieć radialna o budowie 4–1–2, co oznacza, że w warstwie ukrytej przyjęto 1 neuron. W tym rodzaju sieci przyjęto cztery wejścia:

odległość  $B_{DO}$ , absorpcję gruntu  $G_A$ , stan nawierzchni  $D_{STN}$  i typ pojazdów  $P$ . W pierwszym wariancie podziału przypadków, wiarygodność dla próby uczącej wyniosła 86,36%, próbki weryfikacyjne osiągnęły 90,00% poprawności, zaś dla przypadków testujących algorytm otrzymano 88,89% wyników poprawnych. W drugim z kolei wariancie, wiarygodność dla próby uczącej wyniosła 83,33%, próbki weryfikacyjne osiągnęły 87,50% poprawności, zaś dla przypadków testujących algorytm otrzymano 88,24% wyników poprawnych. Wybór tej sieci oznacza, że najmniej istotny jest rodzaj nawierzchni  $D_N$  i stan techniczny budynku  $B_{ST}$ . W przypadku analizy wrażliwości próbek dla tej sieci można stwierdzić, że wszystkie wzięte pod uwagę parametry wejściowe okazały się być ważne (zob. podrozdział 5.3.5). Zdecydowanie największy wpływ na wynik predykcji miał jednak czynnik związany z typem przejeżdżającego pojazdu  $P$ . Kolejny bardzo istotny parametr to stan nawierzchni drogi  $D_{STN}$ .

## 7.2. Wyniki dla maszyn wektorów wspierających

W ramach testów z wykorzystaniem MWW, przeanalizowano 5 algorytmów. Każdy algorytm przetestowano dla czterech różnych funkcji jądrowych, tak zwanych kerneli, będących kolejno funkcją liniową, wielomianową, radialną bazową i sigmoidalną. Pierwszą maszynę wektorów wspierających utworzono dla wektora zmiennych wejściowych  $\mathbf{x}_{(6 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_N, D_{STN}, P\}$ . Z kolei, wektor zmiennych wejściowych  $\mathbf{x}_{(5 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}, P\}$  przyjęto w przypadku drugiej maszyny. Trzecią maszynę wektorów wspierających utworzono dla wektora zmiennych wejściowych  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, G_A, D_{STN}\}$ . Wektor wejściowy w przypadku czwartej maszyny wektorów wspierających przyjęto w postaci  $\mathbf{x}_{(4 \times 1)} = \{B_{ST}, B_{DO}, D_N, P\}$ . Piątą maszynę wektorów wspierających utworzono dla wektora zmiennych wejściowych  $\mathbf{x}_{(4 \times 1)} = \{B_{DO}, G_A, D_{STN}, P\}$ . Sumaryczne zestawienie wyników poprawności wszystkich maszyn przedstawiono w Tab. 7.2. Wiarygodność ogólną maszyn obliczono jako średnią ważoną uwzględniającą liczebność próby uczącej i testowej.

Tab. 7.2. Zestawienie wiarygodności analizowanych maszyn wektorów wspierających.

NR MASZINY	WIARYGODNOŚĆ [%]		
	PRÓBA UCZĄCA	PRÓBA TESTOWA	OGÓLNIE
MWW 1	85,11	81,25	84,13
MWW 2	85,11	81,25	84,13
MWW 3	72,34	81,25	74,60
MWW 4	80,85	87,50	82,54
MWW 5	85,11	81,25	84,13

Porównując pięć utworzonych algorytmów MWW widać wyraźnie, że najlepiej prognozujące maszyny to te z nr 1, 2 i 5, dla których wiarygodność ogólna wyniosła 84,13%. Oznacza to, że najlepszą kombinacją czynników wejściowych dla analizowanych przypadków predykcji drgań komunikacyjnych są (MWW 1): stan techniczny budynku  $B_{ST}$ , odległość między budynkiem i krawędzią drogi  $B_{DO}$ , absorpcja drgań w gruncie  $G_A$ , rodzaj nawierzchni  $D_N$ , stan techniczny nawierzchni  $D_{STN}$  oraz typ pojazdów poruszających się po drodze  $P$ . Równie dobrą predykcję otrzymano wyłączając z analizy czynnik opisujący rodzaj nawierzchni  $D_N$  (MWW 2) oraz dodatkowo parametr stanu technicznego budynku  $B_{ST}$  (MWW 5). Dla tych trzech maszyn wektorów wspierających (MWW 1, MWW 2 i MWW 5), wiarygodność dla próby uczącej wyniosła 85,11%, zaś dla przypadków testujących algorytm otrzymano 81,25% wyników poprawnych.

Patrząc na Tab. 7.2 warto też zwrócić uwagę na MWW nr 4, dla której osiągnięto największą poprawność dla próbek testujących wynoszącą 87,50%. W przypadku tego algorytmu uwzględniono inną konfigurację czterech czynników: stan budynku  $B_{ST}$ , odległość  $B_{DO}$ , rodzaj nawierzchni  $D_N$  oraz typ pojazdów  $P$ . Dla tej maszyny jednak, osiągnięto stosunkowo niską wartość (80,85%) poprawności w zakresie próbek uczących. Z kolei, wiarygodność ogólna w tym przypadku wyniosła 82,54%.

### 7.3. Porównanie wyników SSN – MWW

Obie analizowane w pracy metody dały zadowalające wyniki. Podkreślić jednak należy, że sztuczne sieci neuronowe uzyskały większą wiarygodność, która dla próbek testowych osiągnęła 88,89% poprawności, a ogólna ocena sieci po uwzględnieniu wszystkich zbiorów próbek (uczenie, test, walidacja) wyniosła 90,48%. Dla maszyny wektorów wspierających otrzymano nieco gorsze wyniki. Poprawność dla przypadków testowych wyniosła maksymalnie 87,50%, zaś ogólna wiarygodność (uczenie, test) osiągnęła wartość 84,13%.

Podsumowując rezultaty otrzymane dzięki utworzonym algorytmom należy zwrócić szczególną uwagę na następujące czynniki: stan techniczny budynku, odległość budynku od drogi, absorpcja drgań w gruncie, stan techniczny nawierzchni oraz typ przejeżdżających pojazdów. Przyjęcie takich sygnałów wejściowych sprawiło, że zarówno dla SSN jak i MWW otrzymano najlepsze wyniki predykcji. Zdecydowanie najgorszym wariantem było przyjęcie czterech parametrów wejściowych: stan techniczny budynku, odległość budynku od drogi, absorpcja drgań w gruncie oraz stan techniczny nawierzchni. Zestaw takich sygnałów spowodował otrzymanie najmniej efektywnych wyników zarówno dla algorytmu SSN jak i MWW. Ciekawym przypadkiem jest wariant z uwzględnieniem parametrów: stan techniczny budynku, odległość budynku

od drogi, rodzaj nawierzchni oraz typ przejeżdżających pojazdów. Warto zwrócić na ten przykład uwagę, ponieważ wyniki otrzymane dla obu rodzajów algorytmów są rozbieżne. Sieci neuronowe dały średnie rezultaty, natomiast w przypadku maszyn wektorów wspierających otrzymano najlepszą predykcję biorąc pod uwagę próbki testowe.

#### 7.4. Uwagi ogólne

Na podstawie otrzymanych wyników można twierdzić, że zarówno sztuczne sieci neuronowe jak i maszyny wektorów wspierających mogą być dobrymi narzędziami do prognozowania wpływu drgań komunikacyjnych na budynki mieszkalne. Przedstawione wyniki pokazują, iż na podstawie zaproponowanego algorytmu można, z zadowalająco dużym prawdopodobieństwem, prognozować wpływ drgań komunikacyjnych na budynki mieszkalne, co potwierdza tezę niniejszej dysertacji. Ponadto, opracowany algorytm można zastosować zarówno do budynków istniejących jak i budynków projektowanych, dla których źródło drgań już występuje lub może pojawić się w przyszłości.

Zgodnie z procedurą analizy ryzyka opisaną w rozdziale 4.2 pierwszym etapem jest ustalenie parametrów i czynników sytuacyjnych. Drugi etap to wprowadzenie zebranych danych (o budynku, jego lokalizacji, parametrów drogi) do algorytmów sztucznych sieci neuronowych i maszyn wektorów wspierających. W trzecim etapie, na podstawie otrzymanych wyników dzięki prognozie za pomocą SSN i MWW, należy podjąć decyzję o dalszym postępowaniu mając do dyspozycji jedną z czterech możliwości:

- akceptacja ryzyka – jeśli ryzyko wystąpienia jakichkolwiek uszkodzeń wskutek drgań komunikacyjnych jest bardzo małe, to można nie podejmować żadnych czynności;
- łagodzenie ryzyka – podejmuje się działania prowadzące do zmniejszenia ryzyka wystąpienia zdarzenia poprzez zmniejszenie wartości możliwych parametrów wpływających na drgania, zastosowanie ochrony czynnej, np. ograniczenie tonażu i prędkości pojazdów, naprawa nawierzchni;
- transfer ryzyka – przenosi się odpowiedzialność za możliwe zdarzenie na inną instytucję, poprzez wykonanie pomiarów przez akredytowane laboratorium i wykazanie zarządcy drogi, że przejazdy pojazdów wywołują uszkodzenia budynku;
- unikanie ryzyka – usunięcie przyczyn obaw, np. poprzez podjęcie decyzji o rezygnacji z danej lokalizacji lub też o zastosowaniu ochrony biernej, np. przebudowa budynku, użycie wibroizolacji.

Przedstawiony w niniejszej pracy algorytm spełnia wymagania, aby być pomocnym przy podjęciu decyzji o lokalizacji projektowanej inwestycji, a w przypadku budynków istniejących

daje podstawę do wykonania specjalistycznych pomiarów drgań w celu potwierdzenia, bądź wykluczenia zagrożenia.

### **7.5. Kierunki dalszych badań**

Problem prognozowania wpływu drgań komunikacyjnych na budynki będzie rozwijany podczas dalszej pracy badawczej. Jednym z celów badań będzie rozszerzenie zakresu zainteresowań do drgań wywołanych ruchem pojazdów szynowych, zarówno naziemnych jak i podziemnych. Kolejnym celem jest utworzenie kompleksowego systemu oceny wpływu drgań na budynku na podstawie autorskiego algorytmu opartego zarówno na sztucznych sieciach neuronowych, maszynie wektorów wspierających jak i na autorskiej analizie ryzyka wykorzystującej powszechnie znane metody np. AHP, 5 kroków, PHA itp. (zob. np. Neathey i in. 2006; Jaśkowski i in., 2011). Kolejną metodą, którą planuje się wykorzystać w dalszych badaniach, jest zastosowanie algorytmów genetycznych, które należą do szerszej grupy metod ewolucyjnych i oparte są na podstawowych zasadach genetyki (zob. Goldberg, 1995). Jest to metoda poszukiwania najlepszych rozwiązań spośród wszystkich dostępnych. Do szacowania wpływu drgań komunikacyjnych na budynki mieszkalne planowane jest również wykorzystanie różnych metod probabilistycznych. Do metod tych należy m.in. sieć bayesowska polegająca na przedstawieniu zależności przyczynowo–skutkowych na podstawie teorii prawdopodobieństwa (zob. np. Siemaszko i Kembłowski, 2016; Asefa i Kembłowski, 2006). Do innych metod probabilistycznych, należą na przykład: metoda K–najbliższych sąsiadów, klasyfikacyjne drzewa decyzyjne, entropia informacji, czy metody simpleksowe (Kowalczyk, 1975). Wszystkie te metody planuje się wykorzystać w celu poszukiwania optymalnych rozwiązań dotyczących analizowanego zagadnienia.

### **7.6. Elementy oryginalne pracy**

W opinii autorki, do elementów oryginalnych rozprawy można zaliczyć:

- opracowanie i realizacja programu badań *in situ* wpływu drgań komunikacyjnych na wybranej grupie budynków mieszkalnych o określonych parametrach i w określonych sytuacjach pomiarowych;
- budowa autorskiego programu postępowania podczas prognozowania ryzyka uszkodzeń powodowanych drganiami komunikacyjnymi;
- opracowanie autorskiej metody doboru i oceny czynników wejściowych do analizy ryzyka z wykorzystaniem algorytmów sztucznej inteligencji, w tym uczenia maszynowego;

- opracowanie autorskiego algorytmu SSN w odniesieniu do zastosowania szeregu kombinacji sieci o różnych strukturach, parametrach i różnych podziałach na podzbiory oraz wybór optymalnych rozwiązań w oparciu o badania eksperymentalne drgań;
- opracowanie autorskiego algorytmu MWW w odniesieniu do zastosowania szeregu kombinacji o różnych funkcjach jądrowych oraz wybór optymalnych rozwiązań w oparciu o badania eksperymentalne drgań.



## 8. BIBLIOGRAFIA

### Literatura:

- Asefa, T., Kębłowski, M., McKee, M., Khalil, A., 2006. Multi-time scale stream flow predictions: the support vector machines approach. *Journal of Hydrology*, 318 (1–4), 7–16.
- Bani, H.K., Ghaboussi, J., Schneider, S.P., 1999a. Experimental study of identification and control of structures using neural network Part 1: Identification. *Earthquake Engineering and Structural Dynamics*, 28(9), 995–1018.
- Bani, H.K., Ghaboussi, J., Schneider, S.P., 1999b. Experimental study of identification and control of structures using neural network. Part 2: Control. *Earthquake Engineering and Structural Dynamics*, 28(9), 1019–1040.
- Bennett, K.P., Campbell, C., 2000. Support vector machines: hype or hallelujah? *ACM SIGKDD Explorations Newsletter*, 2(2), 1–13.
- Boser, B.E., Guyon, I.M., Vapnik, V.N., 1992. A training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, Pittsburgh, USA, 144–152.
- Budziski, R., Misztal, L., 2009. Zastosowanie algorytmu maszyny wektorów wspierających do klasyfikacji podatników z wykorzystaniem bazy danych Oracle 11g. *Studia i Materiały*, 19, 28–37.
- Chen, W.H., Hsu, S.H., Shen, H.P., 2005. Application of SVM and ANN for intrusion detection. *Computers and Operations Research*, 32(10), 2617–2634.
- Cherkassky, V., Ma, Y., 2004. Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, 17(1), 113–126.
- Chudyba, Ł., 2011. Wpływ typu sieci neuronowej na dokładność prognozowania przekazywania drgań pochodzenia górniczego z gruntu na budynek. *Czasopismo Techniczne*, 108(1–B), 3–12.
- Chyży, T., Czech, K.R., Malesza, M., Miedziałowski, C., 2009. Badania i ocena wpływów drgań drogowych w zespole budynków zabytkowych. *Wiadomości Konserwatorskie*, 26(2009), 499–509.
- Ciesielski, R., 2002. Podstawy i nowości naukowe w inżynierii parasejsmicznej. *Zeszyty Naukowe Politechniki Rzeszowskiej. Mechanika*, 60(197), 85–115.
- Ciesielski, R., Maciąg, E., 1990. *Drgania drogowe i ich wpływ na budynki*. Wydawnictwa Komunikacji i Łączności, Warszawa.
- Conway, D., White J. 2012. *Machine Learning for Hackers*. O'Reilly Media, Inc., Sebastopol, USA.
- Copeland, B.J., Proudfoot, D., 2000. What Turing did after he invented the universal Turing machine. *Journal of Logic, Language and Information*, 9(4), 491–509.
- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20, 273–297.
- Cover, T.M., 1965. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE Transactions on Electronic Computers*, 3, 326–334.
- Cristianini, N., Shawe-Taylor, J., 2000. *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press, UK.

- Czech, R., Miedziałowski, C., Chyży, T., 2015. Wpływ poprawy stanu drogi na redukcję drgań w zabytkowym kompleksie budynków. *Materiały Budowlane*, 6, 105–106.
- De Stefano, A., Sabia, D., Sabia, L., 1999. Probabilistic neural networks for seismic damage mechanisms prediction. *Earthquake Engineering and Structural Dynamics*, 28(8), 807–821.
- Domaradzki, R., 2007. *Zastosowanie sieci neuronowych do generowania strategii decyzyjnych (inwestycyjnych) na przykładzie Giełdy Papierów Wartościowych*. Rozprawa doktorska, Akademia Górniczo–Hutnicza w Krakowie, Kraków.
- Duch, W., 2000. Sieci neuronowe w modelowaniu zaburzeń neuropsychologicznych i chorób psychicznych. *Biocybernetyka*, 6, 589–616.
- Dulińska, J., Kawecki, J., Kozioł, K., Stypuła, K., Tatar, T., 2014. *Oddziaływania Parasejsmiczne Przekazywane na Obiekty Budowlane*. Wydawnictwo Politechniki Krakowskiej, Kraków.
- Falborski T., Jankowski R., 2013. Polymeric bearings – a new base isolation system to reduce structural damage during earthquakes, *Key Engineering Materials*, 569–570, 143–150.
- Falborski T., Jankowski R., 2017. Experimental study on effectiveness of a prototype seismic isolation system made of polymeric bearings, *Applied Sciences*, 7(808), 1–18.
- Firek K., Rusek J., Wodyński A., 2016. Wybrane metody eksploracji danych i uczenia maszynowego w analizie stanu uszkodzeń oraz zużycia technicznego zabudowy terenów górniczych. *Przegląd Górniczy*, 72(1), 50–55.
- Fumera G., Roli F., 2005. A theoretical and experimental analysis of linear combiners for multiple classifier systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(6), 942–956.
- Ghaboussi, J., Lin, C.C.J., 1998. New method of generating spectrum compatible accelerograms using neural networks. *Earthquake Engineering and Structural Dynamics*, 27(4), 377–396.
- Goldberg, D.E., 1995. *Algorytmy Genetyczne i ich Zastosowania*. Wydawnictwa Naukowo–Techniczne, Warszawa.
- Goszczyński, J., 2006. Klasyfikacja tekstur za pomocą SVM – Maszyny Wektorów Wspierających. *Inżynieria Rolnicza*, 13(2006), 119–126.
- Grzyl, B., 2013. Ryzyko, identyfikacja i ocena ryzyka przedsięwzięcia inwestycyjnego w aspekcie działań logistycznych. *Autobusy: Technika, Eksploatacja, Systemy Transportowe*, 14(3), 601–610.
- Grzyl, B., Apollo, M., 2011. Zarządzanie ryzykiem jako element wspomaganie działań logistycznych w przedsiębiorstwie budowlanym. *Logistyka*, 6(2011), 1307–1317.
- Grzyl, B., Kristowski, A., 2016. BIM jako narzędzie wspomagające zarządzanie ryzykiem przedsięwzięcia inwestycyjnego. *Materiały Budowlane*, 6(2016), 52–54.
- Haykin, S., 2009. *Neural Networks and Machine Learning*. Pearson Prentice Hall, New Jersey, USA.
- Hebb, D.O., 1949. *The Organization of Behavior a Neuropsychological Theory*. Chapman and Hall Limited, London, John Wiley and Sons Inc., New York, USA.
- Huang, C.S., Hung, S.L., Wen, C.M., Tu, T.T., 2003. A neural network approach for structural identification and diagnosis of a building from seismic response data. *Earthquake Engineering and Structural Dynamics*, 32(2), 187–206.

- Hunaidi, O., 2000. Traffic vibrations in buildings. *Construction Technology Update*, 39, National Research Council of Canada, 1–6.
- Jakubczyk–Gałczyńska, A., Jankowski, R., 2014. Traffic-induced vibrations. The impact on buildings and people. *Environmental Engineering. Proceedings of the International Conference on Environmental Engineering*, Vilnius, Lithuania, 1–8.
- Jakubczyk–Gałczyńska, A., Jankowski, R., Kristowski, A., 2016a. The application of neural networks in forecasting the influence of traffic-induced vibrations on residential buildings. *Czasopismo Techniczne*, 9(3–B), 75–82.
- Jakubczyk–Gałczyńska, A., Kristowski, A., Jankowski, R., 2014. Koncepcja szacowania wpływu drgań komunikacyjnych na budynki i na ludzi przy użyciu sztucznych sieci neuronowych. *Inżynieria Morska i Geotechnika*, 5(2014), 523–527.
- Jakubczyk–Gałczyńska, A., Kristowski, A., Jankowski, R., 2016b. Wykorzystanie sztucznych sieci neuronowych do szacowania wpływu drgań na budynki jednorodzinne. *Materiały Budowlane*, 6(2016), 116–117.
- Jakubczyk–Gałczyńska, A., Kristowski, A., Jankowski, R., 2017. Comparing the effectiveness of ANNs and SVMs in forecasting the impact of traffic-induced vibrations on building. *Geodetic Congress (BGC Geomatics)*, Gdańsk, Poland, 121–125.
- Jakubczyk–Gałczyńska, A., Kristowski, A., Jankowski, R., 2018. Application of support vector machine for determination of impact of traffic-induced vibrations on buildings. *Advances in Intelligent Systems and Computing*, 637, 161–167.
- Janas, L., Miller, B., 2011. Zastosowanie sieci neuronowych do wspomaganie zarządzania obiektami mostowymi. *Zeszyty Naukowe Politechniki Rzeszowskiej. Budownictwo i Inżynieria Środowiska*, 58 (3/III), 181–190.
- Jankowski, R., 2015. Pounding between superstructure segments in multi-supported elevated bridge with three-span continuous deck under 3D non-uniform earthquake excitation. *Journal of Earthquake and Tsunami*, 9(4), paper no.1550012.
- Jankowski, R., Mahmoud, S., 2015. *Earthquake-Induced Structural Pounding*, Springer, Switzerland.
- Jankowski, R., Mahmoud, S., 2016. Linking of adjacent three-storey buildings for mitigation of structural pounding during earthquakes, *Bulletin of Earthquake Engineering*, 14(11), 3075–3097.
- Jaśkowski, P., Biruk, S., 2011. The conceptual framework for construction project risk assessment. *Reliability: Theory and Applications*, 3(1), 27–35.
- Jaśkowski, P., Biruk, S., Painting, N., 2011. Using of fuzzy AHP for assessing risk of construction projects. *International Journal of Arts and Sciences*, 4(19), 257–268.
- Jaśkowski, P., Sobotka, A., 2006. Scheduling construction projects using evolutionary algorithm. *Journal of Construction Engineering and Management*, 132(8), 861–870.
- Joachims, T., 1998. Text categorization with support vector machines: Learning with many relevant features. *Machine Learning, ECML-98*, 137–142.
- Jurczyk, K., 2011. Zastosowanie sztucznych sieci neuronowych jako narzędzia wspomagającego zarządzanie zapasami i planowanie popytu na przykładzie przedsiębiorstwa dystrybucyjnego. *Logistyka*, 2(2011), 233–244.
- Kacprzak, T., Ślot, K., 1995. *Sieci Neuronowe Komórkowe: Teoria, Projektowanie, Zastosowania*, PWN, Warszawa.

- Kaczmarek, T. T., 2005. *Ryzyko i Zarządzanie Ryzykiem: Ujęcie Interdyscyplinarne*. Difin, Warszawa,
- Kasprzak, W., 2009. *Rozpoznawanie Obrazów i Sygnałów Mowy*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Kawecki, J., 2015. Kryteria oceny wpływu drgań komunikacyjnych na budynki zabytkowe i ludzi w budynkach w ujęciu normowym. *Przegląd Budowlany*, 86(11), 43–50.
- Kawecki J., Stypuła K., 2009. Diagnozy a posteriori wpływów drgań drogowych na budynki. *XXIV Konferencja Naukowo–Techniczna Awarie Budowlane*, Szczecin–Międzyzdroje, 539–546.
- Kawecki, J., 2011. Oddziaływania dynamiczne na obiekty budowlane. *Zeszyty Naukowe Politechniki Rzeszowskiej. Budownictwo i Inżynieria Środowiska*, 58(3/I), 115–134.
- Kawecki, J., Stypuła, K., 2013. *Zapewnienie Komfortu Wibracyjnego Ludziom w Budynkach Narazonych na Oddziaływania Komunikacyjne*. Wydawnictwo Politechniki Krakowskiej, Kraków.
- Kim, S., 2016. Weighted K –means support vector machine for cancer prediction. *SpringerPlus*, 5(1), 1162.
- Knight, F.H., 1921. *Risk, Uncertainty and Profit*. Hart, Schaffner and Marx, New York, USA.
- Kogut, J., 1999. *Analiza Spektrum Odpowiedzi Drgań Drogowych*. Rozprawa doktorska, Politechnika Krakowska, Kraków.
- Kołodziej, M., Majkowski, A., Rak, R.J., 2011. Wykorzystanie maszyny wektorów wspierających (SVM) do klasyfikacji sygnału EEG na użytek interfejsu mózg–komputer. *Pomiary Automatyka Kontrola*, 57(12/2011), 1546–1548.
- Korbicz, J., Obuchowicz, A., Uciński, D., 1994. *Sztuczne Sieci Neuronowe: Podstawy i Zastosowania*. Akademicka Oficyna Wydawnicza, Warszawa.
- Koszela, K., Boniecki, P., Weres, J., 2005. Ocena efektywności neuronowego prognozowania w oparciu o wybrane metody na przykładzie dystrybucji produktów rolniczych. *Inżynieria Rolnicza*, 9(2), 69–76.
- Kowalczyk, Z., 1975. *Metody Matematyczne w Ekonomice, Organizacji i Zarządzaniu w Budownictwie*. Wydawnictwo Politechniki Gdańskiej, Gdańsk.
- Kowalski, C.T., Ewert, P., 2009. Zastosowanie sieci neuronowych do monitorowania nieosiowości napędów elektrycznych z silnikami indukcyjnymi. *Maszyny Elektryczne: Zeszyty Problemowe*, 83/2009, 189–194.
- Kristowski, A., 2005. Bezpieczeństwo planowania procesu budowy z uwzględnieniem ryzyka, niepewności i zakłóceń. *Przegląd Budowlany*, 76(4), 48–50.
- Kuźniar, K., 2011. Neural networks for the analysis of mine–induced building vibrations. *Computer Assisted Methods in Engineering and Science*, 18(3), 147–159.
- Kuźniar, K., 2002. Estimation of dynamic response of buildings with load bearing walls using response spectra and neural networks. *Journal of Theoretical and Applied Mechanics*, 40(2), 483–495.
- Kuźniar, K., Chudyba, Ł., 2013. Interakcja dynamiczna podłoże–budynek w przypadku przekazywania prędkości oraz przyspieszeń drgań od wstrząsów pochodzenia górniczego. *Budownictwo i Inżynieria Środowiska*, 4(1), 37–45.

- Kuźniar, K., Waszczyszyn, Z., 2003. Neural simulation of dynamic response of prefabricated buildings subjected to paraseismic excitations. *Computers and Structures*, 81(24), 2353–2360.
- Lewandowski, R., 2012. Problemy redukcji drgań konstrukcji budowlanych z wiskotycznymi i lepkośćprężystymi tłumikami drgań. *Biuletyn Wojskowej Akademii Technicznej*, 61(4), 169–196.
- Łój, G. 2007. Betonowa kostka brukowa–trwałość i estetyka. *Czasopismo Techniczne*, 104(4–A), 139–144.
- Martínez–Rego, D., Fontenla–Romero, O., Alonso–Betanzos, A., 2011. Power wind mill fault detection via one–class v–SVM vibration signal analysis. *The 2011 International Joint Conference*, California, USA, 511–518.
- McCarthy, J., 1956. The inversion of functions defined by turing machines. *Automata Studies*, Stanford, Canada, 177–181.
- McCulloch, W.S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.
- Michalik, K., 2014, *Ekspertyzy Techniczne i Diagnostyka w Budownictwie*. Wydawnictwo Prawo i Budownictwo, Chrzanów.
- Michalski, R.S., Carbonell, J.G., Mitchell, T.M., 1983. *Machine Learning: An Artificial Intelligence Approach*. Springer–Verlag, New York, USA.
- Minsky, M., Papert, S., 1969. *Perceptrons*. MIT Press, Cambridge, USA.
- Mitchell, T.M., 1997. *Machine Learning*. McGraw–Hill Science, Columbus, USA.
- Naderpour, H., Barros, R.C., Khatami, S.M., Jankowski, R., 2016. Numerical study on pounding between two adjacent buildings under earthquake excitation. *Shock and Vibration*, article ID 1504783.
- Neathey, F., Sinclair, A., Rick, J., Ballard, J., Hunt, W., Denvir, A., 2006. An evaluation of the five steps to risk assessment. *Health and Safety Executive Research Report*, 476, 1–157.
- Niemas, M., 2004. Ciężki ruch kołowy i jego wpływ na klimat wibroakustyczny w budynkach mieszkalnych. *Prace Instytutu Techniki Budowlanej*, 33(2), 43–54.
- Osowski, S., 1996. *Sieci Neuronowe w Ujęciu Algorytmicznym*. Wydawnictwa Naukowo–Techniczne, Warszawa.
- Osowski, S., 2000. *Sieci Neuronowe do Przetwarzania Informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Pal, M., 2006. Support vector machines–based modelling of seismic liquefaction potential. *International Journal for Numerical and Analytical Methods in Geomechanics*, 30(10), 983–996.
- Pasieczny, L., 1981. *Encyklopedia Organizacji i Zarządzania*. Państwowe Wydawnictwa Ekonomiczne, Warszawa.
- Romanowska, A., Jamroz, K., Kustra, W., 2017. Pedestrian safety management using the risk–based approach. *MATEC Web of Conferences*, 122, paper no. 01007.
- Rosenblatt, F., 1962. *Principles of Neurodynamics; Perceptrons and the Theory of Brain Mechanisms*. Spartan Books, Washington, USA.
- Rosenblatt, F., 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.



- Rubinstein R.Y., Kroese D.P., 2004. *The Cross-Entropy Method: A Unified Approach to Combinatorial Optimization, Monte Carlo Simulation and Machine Learning*. Springer-Verlag, New York, USA.
- Rutkowski, L. 2009. *Metody i Techniki Sztucznej Inteligencji*. Wydawnictwo Naukowe PWN, Warszawa.
- Schmidt, M., Gish, H., 1996. Speaker identification via support vector classifiers. *International Conference on Acoustics, Speech, and Signal Processing Conference Proceedings*, Atlanta, USA, vol. 1, 105–108.
- Setlak, G., Paško, Ł. 2013. Application of data mining methods on markets segmentation. *Studia Informatica*, 34(2A), 311–323.
- Shawe–Taylor, J., Bartlett, P.L., Williamson, R.C., Anthony, M., 1998. Structural risk minimization over data–dependent hierarchies. *IEEE Transactions on Information Theory*, 44(5), 1926–1940.
- Siemaszko, A., Kembłowski, M.W., 2016. Ocena efektywności monitoringu obiektów inżynierskich za pomocą sieci Bayesa. *Materiały Budowlane*, 6(2016), 137–138.
- Souza, C. R., 2010. Kernel functions for machine learning applications. *Creative Commons Attribution–Noncommercial–Share Alike*, 3, 29.
- Stypuła, K., 2009. Wybrane problemy ochrony zabudowy powierzchniowej przed drganiami generowanymi przez komunikację podziemną. *Górnictwo i Geoinżynieria*, 33, 351–362.
- Stypuła, K., Kawecki, J., 2008. Błędy w prognozowaniu i diagnostyce wpływów dynamicznych na budynki. *Czasopismo Techniczne*, 105(1–M), 127–136.
- Szer, J. 2012. Analiza ryzyka w budownictwie i jego skutki. *Przegląd Budowlany*, 83(9), 42–49.
- Tadeusiewicz, R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz, R., 1998. *Elementarne Wprowadzenie do Sieci Neuronowych z Przykładowymi Programami*. Akademicka Oficyna Wydawnicza, Warszawa.
- Trzeciński, G., Kaczmarzyk, S., 2006. Ocena nośności gruntowych dróg leśnych. *Sylwan*, 150(04), 65–72.
- Urbański, P., 2004. Zastosowanie sztucznych sieci neuronowych do oceny stopnia zużycia technicznego wybranej grupy budynków mieszkalnych. *Statystyka i Data Mining w Badaniach Naukowych–Seminarium Statsoft*, Warszawa–Kraków, 105–119.
- Vanajakshi, L., Rilett, L.R., 2004. A comparison of the performance of artificial neural networks and support vector machines for the prediction of traffic speed. *IEEE Intelligent Vehicles Symposium*, Parma, Italy, 194–199.
- Vapnik, V., Chervonenkis, A., 1964. A note on one class of perceptrons. *Automation and Remote Control*, 25, 103.
- Vapnik, V., Lerner, A.J., 1963. Generalized portrait method for pattern recognition. *Automation and Remote Control*, 24, 774–780.
- Vapnik, V.N., Chervonenkis, A.J., 1974. *Theory of Pattern Recognition*. Nauka, Moskwa.
- Wabik, W., 2012. Monitoring system to detect potential dangerous situations. *Studia Informatica*, 33(2B), 497–508.
- Wesołowski, F., 2008. *Zasady Muzyki*. Kraków, Polskie Wydawnictwo Muzyczne, Kraków.

- Widrow, B., Steinbuch, K., 1964. *A Critical Comparison of Two Kinds of Adaptive Classification Networks*. Stanford Univ. CA Stanford Electronics Labs, California, USA.
- Wilde, K., Rucka, M., Chróścielewski, J., Niedostatkiewicz, M., 2013. Rozwiązanie przegrody wibroizolacyjnej w budynku zabytkowym narażonym na drgania wywołane ruchem kołowym i szynowym. *Inżynieria Morska i Geotechnika*, 5, 408–411.
- Willett, A.H., 1901. *The Economic Theory of Risk and Insurance*. The Columbia University Press, New York, USA.
- Yeung, W.T., Smith, J.W., 2005. Damage detection in bridges using neural networks for pattern recognition of vibration signatures. *Engineering Structures*, 27(5), 685–698.
- Yun, C.-B., Yi, J.-H., Bahng, E.Y., 2001. Joint damage assessment of framed structures using a neural networks technique. *Engineering Structures*, 23(5), 425–435.
- Zieliński, T.P., 2007. *Cyfrowe Przetwarzanie Sygnałów: od Teorii do Zastosowań*. Wydawnictwa Komunikacji i Łączności, Warszawa.

### **Normy, dokumenty i strony internetowe:**

- BS 6472-1:2008. Guide to evaluation of human exposure to vibration in buildings. Part 1: Vibration sources other than blasting.
- Czarnecki K., Janowski A., 2002. System oceny stanu nawierzchni SOSN. Wytyczne stosowania. Załącznik A: Zasady ciągłego obmiaru uszkodzeń i oceny stanu nawierzchni bitumicznych metodą oceny wizualnej w Systemie Oceny Stanu Nawierzchni SOSN. Warszawa, 2002.
- DIN 4150-2, Structural vibration, Part 2: Human exposure to vibration in buildings, 1999.
- Directive 2002/49/EC of the European parliament and the Council of 25 June 2002 relating to the assessment and management of environmental noise. Official Journal, 189, 2002.
- EPS, Elektroniczny Podręcznik Statystyki, 2017. StatSoft, Kraków. [on-line], [dostęp 1 lipca 2017]. <https://www.statsoft.pl/textbook/stathome.html>
- ISO 10137:2007 – Bases for design of structures – Serviceability of buildings and walkways against vibrations, 2007.
- PN-85/B-02170. Ocena szkodliwości drgań przekazanych przez podłoże na budynki, 1988.
- PN-87/B-02151/02. Akustyka budowlana. Ochrona przed hałasem pomieszczeń w budynkach. Dopuszczalne wartości poziomu dźwięku w pomieszczeniach, 1987.
- PN-88/B-02171. Ocena wpływu drgań na ludzi w budynkach, 1989.
- Prawo ochrony środowiska z dnia 27 kwietnia 2001r., Dz.U. 2001 nr 62 poz. 627.
- Radzikowski M., Foryś G., 2007. Wytyczne stosowania „Systemu oceny stanu nawierzchni betonowych /SOSN-B?”. Załącznik 2: Katalog typowych uszkodzeń nawierzchni betonowych dla potrzeb ciągłego obmiaru uszkodzeń metodą oceny wizualnej w Systemie Oceny Stanu Nawierzchni Betonowych. Warszawa, 2007.
- Saganowski, C., 2002. Załącznik do Zarządzenia Nr 9 Generalnego Dyrektora Dróg Publicznych z dnia 4 marca 2002r.: System oceny stanu nawierzchni SOSN. Wytyczne stosowania. Warszawa, 2002.
- Stypuła, K., 2015. Wpływ drgań na budynki i ludzi w budynkach – rola badań in situ. [on-line], [dostęp 17 grudnia 2017r.]. <http://www.map.piib.org.pl/materialy-szkoleniowe>.
- Ustawa Prawo budowlane z dnia 7 lipca 1994r., Dz.U.10.243.1623.
- Ustawa z dnia 21 marca 1985r. o drogach publicznych, Dz.U. 1985 nr 14 poz. 60.



## 9. SPIS RYSUNKÓW

- Rys. 2.1. Uszkodzenia powstałe na skutek drgań komunikacyjnych.
- Rys. 2.2. Czas trwania drgań uwzględniany w analizie (Kawecki i Stypuła, 2013).
- Rys. 2.3. Skale Wpływów Dynamicznych (PN-85/B-02170).
- Rys. 2.4. Próg odczuwalności drgań przez ludzi według PN-88/B-02171.
- Rys. 3.1. Budynki poddane badaniom drgań komunikacyjnych.
- Rys. 3.2. Aparatura pomiarowa do badań drgań.
- Rys. 3.3. Sposób montażu czujników piezoelektrycznych do budynku.
- Rys. 3.4. Wyniki analizy dla budynku nr 1 wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I.
- Rys. 3.5. Wyniki analizy dla budynku nr 1 wykonanej dla przejazdu autobusu o dwóch osiach, naniesione na SWD I.
- Rys. 3.6. Wyniki analizy dla budynku nr 1, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD I.
- Rys. 3.7. Wyniki analizy dla budynku nr 2, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I.
- Rys. 3.8. Wyniki analizy dla budynku nr 2, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD I.
- Rys. 3.9. Wyniki analizy dla budynku nr 2, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD I.
- Rys. 3.10. Wyniki analizy dla budynku nr 3, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.11. Wyniki analizy dla budynku nr 3, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.
- Rys. 3.12. Wyniki analizy dla budynku nr 3, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD II.
- Rys. 3.13. Wyniki analizy dla budynku nr 4, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I.
- Rys. 3.14. Wyniki analizy dla budynku nr 4, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD I.
- Rys. 3.15. Wyniki analizy dla budynku nr 4, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD I.
- Rys. 3.16. Wyniki analizy dla budynku nr 5, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.17. Wyniki analizy dla budynku nr 5, wykonanej dla przejazdu autobusu o dwóch osiach, naniesione na SWD II.
- Rys. 3.18. Wyniki analizy dla budynku nr 5, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.
- Rys. 3.19. Wyniki analizy dla budynku nr 6, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD I.
- Rys. 3.20. Wyniki analizy dla budynku nr 6, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD I.
- Rys. 3.21. Wyniki analizy dla budynku nr 6, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD I.
- Rys. 3.22. Wyniki analizy dla budynku nr 7, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.23. Wyniki analizy dla budynku nr 7, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.
- Rys. 3.24. Wyniki analizy dla budynku nr 7, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.
- Rys. 3.25. Wyniki analizy dla budynku nr 8, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.26. Wyniki analizy dla budynku nr 8, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.

- Rys. 3.27. Wyniki analizy dla budynku nr 8, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.
- Rys. 3.28. Wyniki analizy dla budynku nr 9, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.29. Wyniki analizy dla budynku nr 9, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.
- Rys. 3.30. Wyniki analizy dla budynku nr 9, wykonanej dla przejazdu autobusu o trzech osiach, naniesione na SWD II.
- Rys. 3.31. Wyniki analizy dla budynku nr 10, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.32. Wyniki analizy dla budynku nr 10, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.
- Rys. 3.33. Wyniki analizy dla budynku nr 10, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.
- Rys. 3.34. Wyniki analizy dla budynku nr 11, wykonanej dla przejazdu samochodu osobowego do 3,5 t, naniesione na SWD II.
- Rys. 3.35. Wyniki analizy dla budynku nr 11, wykonanej dla przejazdu samochodu dostawczego do 10 t, naniesione na SWD II.
- Rys. 3.36. Wyniki analizy dla budynku nr 11, wykonanej dla przejazdu samochodu ciężarowego powyżej 10 t, naniesione na SWD II.
- Rys. 4.1. Podział na etapy postępowania podczas prognozowania ryzyka uszkodzeń spowodowanych drganiami komunikacyjnymi.
- Rys. 4.2. Model sztucznego neuronu (perceptronu):  $x_i$  – sygnały wejściowe;  $\mathbf{y}$  – wektor (sygnał) wyjściowy;  $w_i$  – wagi;  $e$  – funkcja wewnętrzznego przetwarzania;  $\phi$  – funkcja aktywacji (Tadeusiewicz, 1993).
- Rys. 4.3. Klasyfikacja sztucznych sieci neuronowych (Tadeusiewicz, 1993).
- Rys. 4.4. Etapy budowy algorytmu sztucznych sieci neuronowych (opracowanie własne na podstawie publikacji: Tadeusiewicz (1993), Korbicz i in. (1994), Osowski (1996)).
- Rys. 4.5. Modelowe rozwiązanie problemu regresji MWW: po lewej – problem do rozwiązania; po prawej – wyznaczona funkcja ciągła (Cherkassky i Ma, 2004).
- Rys. 4.6. Modelowe rozwiązanie problemu klasyfikacji MWW: po lewej – problem do rozwiązania; po prawej – wyznaczona hiperpłaszczyzna  $g(x)$  separująca klasy (Haykin, 2009).
- Rys. 4.7. Możliwe rozwiązanie problemu klasyfikacji MWW: po lewej – wyznaczona jedna hiperpłaszczyzna separująca dane; po prawej – wiele hiperpłaszczyzn separujących dane.
- Rys. 4.8. Możliwe rozwiązanie problemu klasyfikacji MWW z maksymalnym marginesem (Vapnik i Lerner, 1963).
- Rys. 4.9. Możliwe rozwiązanie problemu klasyfikacji MWW z maksymalnym marginesem i zaznaczonymi wektorami wspierającymi ( $\mathbf{w}_1$ – $\mathbf{w}_5$ ) (Vapnik i Lerner, 1963).
- Rys. 4.10. Porównanie problemów klasyfikacji: po lewej – problem nieseparowalny liniowo; po prawej – problem separowalny liniowo (Boser i in., 1992).
- Rys. 4.11. Możliwe rozwiązanie problemu klasyfikacji nieseparowalnej liniowo z zaznaczonymi wektorami wspierającymi ( $\mathbf{w}_1$ – $\mathbf{w}_4$ ) (Bennett i Campbell, 2000).

## 10. SPIS TABEL

- Tab. 2.1. Wartość współczynnika absorpcji (Ciesielski, 2002).
- Tab. 2.2. Zasady umożliwiające zastosowanie odpowiednich linii ograniczających strefy wpływu drgań (PN-85/B-02170).
- Tab. 3.1. Charakterystyka badanych budynków.
- Tab. 5.1. Kryterium określania stanu technicznego budynku (Michalik, 2014).
- Tab. 5.2. Kryterium określania absorpcji drgań przez podłoże gruntowego (Ciesielski, 2002).
- Tab. 5.3. Kryterium oceny stanu technicznego nawierzchni (Saganowski, 2002).
- Tab. 5.4. Kryterium oceny stanu technicznego nawierzchni bitumicznych (Czarnecki i Janowski, 2002).
- Tab. 5.5. Określenie szkodliwości uszkodzenia w postaci pęknięcia pojedynczego podłużnego i ukośnego (Radzikowski i Foryś, 2007).
- Tab. 5.6. Określenie szkodliwości uszkodzenia w postaci pęknięcia pojedynczego poprzecznego (Radzikowski i Foryś, 2007).
- Tab. 5.7. Określenie szkodliwości uszkodzenia w postaci pęknięcia przy krawędzi (Radzikowski i Foryś, 2007).
- Tab. 5.8. Określenie szkodliwości uszkodzenia narożnika (Radzikowski i Foryś, 2007).
- Tab. 5.9. Określenie szkodliwości wykruszenia szczeliny (Radzikowski i Foryś, 2007).
- Tab. 5.10. Określenie szkodliwości uszkodzenia zbrojenia (Radzikowski i Foryś, 2007).
- Tab. 5.11. Określenie szkodliwości wadliwego uszczelnienia (Radzikowski i Foryś, 2007).
- Tab. 5.12. Możliwe typy pojazdów (Ustawa o drogach publicznych, 2007).
- Tab. 5.13. Funkcje aktywacji wykorzystane podczas budowy SSN.
- Tab. 5.14. Charakterystyka danych wejściowych wykorzystanych do utworzenia algorytmu SSN oraz informacja wyjściowa dotycząca zagrożenia (otrzymana z pomiarów rzeczywistych).
- Tab. 5.15. Lista pomocnicza utworzonych sztucznych sieci neuronowych.
- Tab. 5.16. Rezultaty i charakterystyka sieci (sieć I, wariant 1).
- Tab. 5.17. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć I, wariant 1).
- Tab. 5.18. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć I, wariant 1).
- Tab. 5.19. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć I, wariant 1).
- Tab. 5.20. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć I, wariant 1).
- Tab. 5.21. Analiza wrażliwości wszystkich próbek (sieć I, wariant 1).
- Tab. 5.22. Analiza wrażliwości próbek uczących (sieć I, wariant 1).
- Tab. 5.23. Analiza wrażliwości próbek testujących (sieć I, wariant 1).
- Tab. 5.24. Analiza wrażliwości próbek weryfikacyjnych (sieć I, wariant 1).
- Tab. 5.25. Rezultaty i charakterystyka sieci (sieć I, wariant 2).
- Tab. 5.26. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć I, wariant 2).
- Tab. 5.27. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć I, wariant 2).
- Tab. 5.28. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć I, wariant 2).
- Tab. 5.29. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć I, wariant 2).
- Tab. 5.30. Analiza wrażliwości wszystkich próbek (sieć I, wariant 2).
- Tab. 5.31. Analiza wrażliwości próbek uczących (sieć I, wariant 2).
- Tab. 5.32. Analiza wrażliwości próbek testujących (sieć I, wariant 2).
- Tab. 5.33. Analiza wrażliwości próbek weryfikacyjnych (sieć I, wariant 2).
- Tab. 5.34. Rezultaty i charakterystyka sieci (sieć II, wariant 1).
- Tab. 5.35. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć II, wariant 1).
- Tab. 5.36. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć II, wariant 1).
- Tab. 5.37. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć II, wariant 1).
- Tab. 5.38. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć II, wariant 1).
- Tab. 5.39. Analiza wrażliwości wszystkich próbek (sieć II, wariant 1).
- Tab. 5.40. Analiza wrażliwości próbek uczących (sieć II, wariant 1).
- Tab. 5.41. Analiza wrażliwości próbek testujących (sieć II, wariant 1).
- Tab. 5.42. Analiza wrażliwości próbek weryfikacyjnych (sieć II, wariant 1).
- Tab. 5.43. Rezultaty i charakterystyka sieci (sieć II, wariant 2).
- Tab. 5.44. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć II, wariant 2).
- Tab. 5.45. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć II, wariant 2).
- Tab. 5.46. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć II, wariant 2).
- Tab. 5.47. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć II, wariant 2).
- Tab. 5.48. Analiza wrażliwości wszystkich próbek (sieć II, wariant 2).
- Tab. 5.49. Analiza wrażliwości próbek uczących (sieć II, wariant 2).
- Tab. 5.50. Analiza wrażliwości próbek testujących (sieć II, wariant 2).
- Tab. 5.51. Analiza wrażliwości próbek weryfikacyjnych (sieć II, wariant 2).

- Tab. 5.52. Rezultaty i charakterystyka sieci (sieć III, wariant 1).
- Tab. 5.53. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć III, wariant 1).
- Tab. 5.54. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć III, wariant 1).
- Tab. 5.55. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć III, wariant 1).
- Tab. 5.56. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć III, wariant 1).
- Tab. 5.57. Analiza wrażliwości wszystkich próbek (sieć III, wariant 1).
- Tab. 5.58. Analiza wrażliwości próbek uczących (sieć III, wariant 1).
- Tab. 5.59. Analiza wrażliwości próbek testujących (sieć III, wariant 1).
- Tab. 5.60. Analiza wrażliwości próbek weryfikacyjnych (sieć III, wariant 1).
- Tab. 5.61. Rezultaty i charakterystyka sieci (sieć III, wariant 2).
- Tab. 5.62. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć III, wariant 2).
- Tab. 5.63. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć III, wariant 2).
- Tab. 5.64. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć III, wariant 2).
- Tab. 5.65. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć III, wariant 2).
- Tab. 5.66. Analiza wrażliwości wszystkich próbek (sieć III, wariant 2).
- Tab. 5.67. Analiza wrażliwości próbek uczących (sieć III, wariant 2).
- Tab. 5.68. Analiza wrażliwości próbek testujących (sieć III, wariant 2).
- Tab. 5.69. Analiza wrażliwości próbek weryfikacyjnych (sieć III, wariant 2).
- Tab. 5.70. Rezultaty i charakterystyka sieci (sieć IV, wariant 1).
- Tab. 5.71. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć IV, wariant 1).
- Tab. 5.72. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć IV, wariant 1).
- Tab. 5.73. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć IV, wariant 1).
- Tab. 5.74. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć IV, wariant 1).
- Tab. 5.75. Analiza wrażliwości wszystkich próbek (sieć IV, wariant 1).
- Tab. 5.76. Analiza wrażliwości próbek uczących (sieć IV, wariant 1).
- Tab. 5.77. Analiza wrażliwości próbek testujących (sieć IV, wariant 1).
- Tab. 5.78. Analiza wrażliwości próbek weryfikacyjnych (sieć IV, wariant 1).
- Tab. 5.79. Rezultaty i charakterystyka sieci (sieć IV, wariant 2).
- Tab. 5.80. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć IV, wariant 2).
- Tab. 5.81. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć IV, wariant 2).
- Tab. 5.82. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć IV, wariant 2).
- Tab. 5.83. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć IV, wariant 2).
- Tab. 5.84. Analiza wrażliwości wszystkich próbek (sieć IV, wariant 2).
- Tab. 5.85. Analiza wrażliwości próbek uczących (sieć IV, wariant 2).
- Tab. 5.86. Analiza wrażliwości próbek testujących (sieć IV, wariant 2).
- Tab. 5.87. Analiza wrażliwości próbek weryfikacyjnych (sieć IV, wariant 2).
- Tab. 5.88. Rezultaty i charakterystyka sieci (sieć V, wariant 1).
- Tab. 5.89. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć V, wariant 1).
- Tab. 5.90. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć V, wariant 1).
- Tab. 5.91. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć V, wariant 1).
- Tab. 5.92. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć V, wariant 1).
- Tab. 5.93. Analiza wrażliwości wszystkich próbek (sieć V, wariant 1).
- Tab. 5.94. Analiza wrażliwości próbek uczących (sieć V, wariant 1).
- Tab. 5.95. Analiza wrażliwości próbek testujących (sieć V, wariant 1).
- Tab. 5.96. Analiza wrażliwości próbek weryfikacyjnych (sieć V, wariant 1).
- Tab. 5.97. Rezultaty i charakterystyka sieci (sieć V, wariant 2).
- Tab. 5.98. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (sieć V, wariant 2).
- Tab. 5.99. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (sieć V, wariant 2).
- Tab. 5.100. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (sieć V, wariant 2).
- Tab. 5.101. Podsumowanie predykcji dla próbek weryfikujących – macierz pomyłek (sieć V, wariant 2).
- Tab. 5.102. Analiza wrażliwości wszystkich próbek (sieć V, wariant 2).
- Tab. 5.103. Analiza wrażliwości próbek uczących (sieć V, wariant 2).
- Tab. 5.104. Analiza wrażliwości próbek testujących (sieć V, wariant 2).
- Tab. 5.105. Analiza wrażliwości próbek weryfikacyjnych (sieć V, wariant 2).





- Tab. 6.61. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 5.3).  
Tab. 6.62. Podsumowanie predykcji dla wszystkich próbek – macierz pomyłek (maszyna 5.4).  
Tab. 6.63. Podsumowanie predykcji dla próbek uczących – macierz pomyłek (maszyna 5.4).  
Tab. 6.64. Podsumowanie predykcji dla próbek testujących – macierz pomyłek (maszyna 5.4).  
Tab. 6.65. Podsumowanie predykcji dla MWW nr 5.  
Tab. 7.1. Zestawienie wiarygodności analizowanych sztucznych sieci neuronowych.  
Tab. 7.2. Zestawienie wiarygodności analizowanych maszyn wektorów wspierających.