



POLITECHNIKA POZNAŃSKA

Wydział Inżynierii Lądowej i Transportu

Modelowanie trwałości nawierzchni drogowych z betonu cementowego

Łukasz RUDZIŃSKI

ROZPRAWA DOKTORSKA

Promotor: dr hab. inż. Mieczysław SŁOWIK, prof. PP
Promotor pomocniczy: dr inż. Przemysław GÓRNAŚ

Poznań, marzec 2024

STRESZCZENIE

Celem pracy badawczej była weryfikacja możliwości wykorzystania sztucznych sieci neuronowych (SSN) do prognozowania zmian stanu technicznego nawierzchni z betonu cementowego. Dysertacja zawiera opis i rezultaty badań terenowych, analizy i prognozę zmian stanu technicznego nawierzchni. Przedmiotem badań terenowych była ewidencja uszkodzeń powierzchniowych nawierzchni drogowych z betonu cementowego przy zastosowaniu zmodyfikowanej metody inwentaryzacji uszkodzeń. Program badań zrealizowano na odcinku autostrady A2 o sumarycznej długości jezdni o nawierzchni z betonu cementowego ok. 202 km i łącznej liczbie 120 438 sztuk płyt betonowych w okresie od roku 2016 do roku 2021. Przeprowadzone badania w ramach zmodyfikowanej oceny cech powierzchniowych nawierzchni umożliwiły analizę każdej pojedynczej płyty betonowej jako niezależnego obiektu oraz identyfikację wszystkich możliwych zmian występujących na jej powierzchni tj. zarówno uszkodzeń jak i dokonanych napraw. Dla tak zgromadzonych i usystematyzowanych danych, w oparciu o przeprowadzone badania, określono ich zmiany jakie zachodzą w dziedzinie czasu. Dokonano również wyodrębnienia odcinków jednorodnych badanej nawierzchni i ich sparametryzowania w ramach przyjętych założeń projektowych: technologii wykonania, zastosowanych materiałów, rzeczywistego obciążenia ruchem oraz warunków klimatycznych. Na podstawie zgromadzonych wyników badań terenowych i dokonanych analiz odcinków jednorodnych przystąpiono do opracowania szeregów czasowych z wykorzystaniem SSN do prognozowania uszkodzeń nawierzchni. W oparciu o narzędzie Statistica opracowano algorytm budowy modelu sieci neuronowych i przeprowadzono analizy wrażliwości zmiennych wejściowych w celu doboru danych istotnie wpływających na jakość uzyskanych modeli. Do prognoz wybrano dwa dostępne w programie typy sztucznych sieci neuronowych: o radialnych funkcjach bazowych (RBF) oraz wielowarstwowe perceptrony (MLP). Przedstawiono zależności pozwalające na określenie danych wejściowych wpływających na prognozowanie poszczególnych typów uszkodzenia nawierzchni. Dokładność wyuczenia, testowania oraz walidacji sieci neuronowych w odniesieniu do indywidualnego typu analizowanego uszkodzenia przeprowadzono za pomocą współczynnika determinacji R^2 . Przyjętym parametrem prognozy była ilość uszkodzonych płyt [%] a parametrem weryfikacyjnym w ramach potwierdzenia stawianej tezy była powierzchnia uszkodzonych płyt [%]. Efektem przeprowadzonych prac jest potwierdzenie skuteczności i bardzo wydajnej metody zastosowania SSN do przewidywania typów uszkodzeń nawierzchni z betonu cementowego w zakresie liczby uszkodzonych płyt na poziomie 94,7% a w odniesieniu do powierzchni uszkodzeń płyt na poziomie 93,3%.

ABSTRACT

The purpose of the research work was to verify the possibility of using Artificial Neural Networks (ANN) to forecast changes in the technical condition of cement concrete pavements. The thesis includes a description and the results of field tests, analyses and a forecast of future changes in the technical condition of pavement. The field tests were carried out to record the surface damages of cement concrete road pavement using a modified method of identification of damages. The research programme was carried out on a section of the A2 motorway with a total length of cement concrete carriageways of approx. 202 km and a total number of 120,438 concrete slabs, in the period between 2016 and 2021. Research carried out for the purposes of the modified assessment of surface properties of pavement allowed the author to analyse each single concrete slab as an independent object and to identify all possible changes in its surface, i.e. both damages as well as any repairs. These collected and catalogued data were then analysed on the basis of the performed tests in terms of changes in data over time. Homogeneous sections of the analysed pavement were also identified and characterised in terms of the implemented design assumptions: the technology of construction, used materials, actual traffic load and weather conditions. The obtained field test results and homogeneous section analyses were then used to develop time series using the ANN technology in order to forecast future pavement damage. An algorithm of the neural network model structure was developed using Statistica software and analyses of the sensitivity of input variables were carried out in order to select data that significantly affects the quality of the developed models. Two types of artificial neural networks available in the software were selected for the forecasts: the Radial Basis Function (RBF) and Multilayer Perceptrons (MLP). Dependencies that enable the identification of input data that affects the forecasting of individual types of pavement damage were demonstrated. The precision of learning, testing and validation of neural networks in the context of the individual types of analysed damages was carried out using the coefficient of determination R^2 . The quantity of damaged slabs [%] was used as the forecast parameter, while the surface of damaged slabs [%] was used as the verification parameter in the context of the confirmation of the expressed argument. The research resulted in the confirmation of the effectiveness and very high efficiency of the ANN technology in forecasting the types of cement concrete pavement damages in terms of the number of damaged slabs at the level of 94.7% and in terms of the surface of damages at the level of 93.3%.

Spis treści

1	Wprowadzenie	8
2	Studium literatury na temat trwałości i utrzymania nawierzchni betonowych	9
2.1	Charakterystyka nawierzchni betonowych	10
2.2	Trwałość nawierzchni betonowych	12
2.3	Utrzymanie nawierzchni betonowych	17
2.3.1	Diagnoza	18
2.3.2	Geneza	18
2.3.3	Prognoza	21
2.4	Przykłady systemów oceny stanu technicznego nawierzchni stosowanych w różnych krajach	27
2.4.1	Systemy stosowane w Polsce	27
2.4.2	Systemy stosowane w USA	32
2.4.3	Systemy stosowane w Niemczech	36
3	Teza, cel i zakres rozprawy	38
4	Charakterystyka analizowanych odcinków drogi o nawierzchni z betonu cementowego	39
4.1	Podział na odcinki jednorodne	39
4.2	Wykonanie nawierzchni	42
4.2.1	Założenia projektowe	42
4.2.2	Analiza ruchu na etapie projektowania	42
4.2.3	Przekrój poprzeczny jezdni	43
4.2.4	Metoda obliczeń trwałości	44
4.2.5	Projektowanie konstrukcji nawierzchni	45
4.2.6	Skład mieszanki betonowej	46
4.2.7	Technologia wykonania	49
5	Modyfikacja wizualnej metody oceny stanu technicznego nawierzchni betonowych	58
5.1	Realizacja prac	61
5.2	Wykonanie pomiarów	63
5.3	Przetwarzanie zdjęć	65
5.4	Identyfikacja uszkodzeń	67
6	Prognozowanie trwałości nawierzchni betonowej z wykorzystaniem sztucznych sieci neuronowych (SSN)	69
6.1	Sztuczne sieci neuronowe	69
6.2	Budowanie bazy danych do nauki	74
6.3	Warunki obciążenia ruchem	76
6.4	Zmienne klimatyczne na odcinkach objętych analizą	83
6.4.1	Warunki temperaturowe	84
6.4.2	Warunki hydrologiczne	90
6.5	Dane ze zmodyfikowanej wizualnej metody oceny stanu technicznego nawierzchni betonowych	92
6.6	Proces uczenia sieci neuronowych w programie STATISTICA	111
6.7	Wyniki modelowania [% płyt]	126
6.7.1	Pęknięcia podłużne	126
6.7.2	Pęknięcia poprzeczne	132

6.7.3	Pęknięcia krawędzi.....	137
6.7.4	Uszkodzenia naroży	143
6.7.5	Uszkodzenia powierzchni.....	148
6.7.6	Wykruszenia szczelin	154
6.8	Wyniki modelowania [% powierzchni]	160
6.8.1	Uszkodzenie naroży	160
6.8.2	Uszkodzenie powierzchni.....	166
6.8.3	Wykruszenie szczelin	172
6.9	Dyskusja	178
7	Wnioski	183
	Literatura.....	185
	Załącznik nr 1	
	Załącznik nr 2	

LISTA AKRONIMÓW

AASHTO	Amerykańskie Stowarzyszenie Specjalistów ds. Dróg i Transportu Stanowego
ANN/SSN	Sztuczne sieci neuronowe
AQC	Cechy jakościowe odbioru
ARAN	Automatyczny analizator dróg
ASTM	Amerykańskie Stowarzyszenie Badań i Materiałów
BFGS	Iteracyjna metoda rozwiązywania nieliniowych problemów optymalizacji
CMRA	Stowarzyszenie ds. Materiałów Budowlanych i Recyklingu
DOT	Długoterminowe Odcinki Testowe
DWB	Dolna warstwa betonu
DSN	Diagnostyka Stanu Nawierzchni
FHWA	Federalna Administracja Drogowa w Stanach Zjednoczonych
GDDKiA	Generalna Dyrekcja Dróg Krajowych i Autostrad
GIS	System informacji geograficznej
GWB	Górna warstwa betonu
HDM-4	Oprogramowanie do rozwoju i zarządzania autostradami
IBDiM	Instytut Badawczy Dróg i Mostów
iPAVe	Inteligentny pojazd do oceny nawierzchni
IRI	Międzynarodowy wskaźnik równości podłużnej
JPCP	Dyblowana nawierzchnia z betonu cementowego
KTKNS	Katalog typowych konstrukcji nawierzchni sztywnych
LCA	Analiza cyklu życia
LCM	Zarządzanie cyklem życia
LCMS	Laserowy system pomiaru pęknięć
LTPP	Program długoterminowej oceny stanu nawierzchni
MLP	Perceptron wielowarstwowy (typ sieci jednokierunkowej)
NCHRP	Krajowy Program Badań dot. Autostrad w Stanach Zjednoczonych
PCC	Nawierzchnie z betonu cementowego
PCI	Wskaźnik stanu nawierzchni
PK	Pęknięcia krawędzi
PKn	Pęknięcia krawędzi naprawione
PL	Pęknięcia podłużne
PLn	Pęknięcia podłużne naprawione
PMIS	Platforma analityczna do systemu zarządzania
PMS	System zarządzania nawierzchnią
PRS	Specyfikacje związane z trwałością nawierzchni
PT	Pęknięcia poprzeczne
PTn	Pęknięcia poprzeczne naprawione
RBF	Sieć o radialnych funkcjach bazowych
SDR	Średni Dobowy Ruch
SOS	funkcje błędu w postaci sumy kwadratów
SOSN	System Oceny Stanu Nawierzchni
SOSN-B	System Oceny Stanu Nawierzchni Betonowych
SOWA 2	Rejestrator uszkodzeń nawierzchni
SPDE	System oceny uszkodzeń nawierzchni

TAMP	Plan zarządzania elementami infrastruktury drogowej
TEN-T	Transeuropejska sieć transportowa
TTC	Cykl czasowy wykonania zabiegu utrzymaniowego
UN	Uszkodzenia naroży
Unn	Uszkodzenia naroży naprawione
UP	Uszkodzenia powierzchniowe
UPn	Uszkodzenia powierzchniowe naprawione
WK	Wykruszenia krawędzi
WKn	Wykruszenia krawędzi naprawione
WSn	Wykruszenia szczeliny naprawione
ZEB	Wytyczne dot. rejestracji i oceny stanu technicznego dróg federalnych Niemiec

1 Wprowadzenie

W ostatnich latach liczba projektów drogowych realizowanych przy wykorzystaniu technologii nawierzchni z betonu cementowego (sztywnych) systematycznie się zwiększa. Aktualnie 1 092 km autostrad i dróg ekspresowych w Polsce ma nawierzchnię z betonu cementowego, co stanowi blisko 21% sieci dróg szybkiego ruchu. Dominującą technologią realizacji tego typu nawierzchni jest rozwiązanie z zastosowaniem dyblowania i kotwienia a rozwiązaniem w zakresie wykańczania górnej powierzchni jest tzw. odkryte kruszywo [31]. W tego typu nawierzchniach w celu zapewnienia właściwej współpracy płyt w szczelinach, pod wpływem zwiększonego obciążenia stosuje się dyble (szczeliny poprzeczne) oraz kotwy (szczeliny podłużne). Poza dyblami na współpracę mają wpływ inne czynniki związane z podparciem płyty betonowej, zamocowaniem dybli i oddziaływaniem czynników degradujących szczeliny [92, 98, 106, 124].

W nadchodzącym czasie instytucje drogowe w Polsce będą zwiększać swoją koncentrację na utrzymaniu i ochronie istniejących dróg. Wybór odpowiedniej strategii utrzymania jest złożonym zadaniem, na które składają się czynniki takie jak ocena stanu technicznego nawierzchni, klasyfikacja drogi, natężenie ruchu itp. Określenie skutecznego utrzymania należy rozumieć jako działania prewencyjne mające na celu zapewnienie właściwego stanu technicznego w celu zapobiegania przedwczesnemu pogorszeniu się tego stanu. Jest to strategia utrzymania, która ma na celu minimalizowanie występowania kosztownych remontów, poprzez regularne monitorowanie i wykonywanie odpowiednich działań naprawczych. Nowoczesna diagnostyka, w szczególności identyfikacja cech powierzchniowych nawierzchni z betonu cementowego nie jest w Polsce powszechnie stosowana, jednak ze względu na systematyczny przyrost długości dróg o takiej nawierzchni powinna ona zostać w szerszym zakresie przedstawiona oraz tak przygotowana (ze względu na zróżnicowaną geometrię płyt betonowych oraz ich szerokość, która jest większa od szerokości pasa ruchu), aby zapewnić odpowiednią jakość danych o sieci drogowej przy jednoczesnym uzyskaniu dużej wydajności oraz nieinwazyjnego charakteru pomiarów.

Punktem wyjścia do opracowania funkcjonalnego algorytmu do analizy stanu technicznego nawierzchni betonowej powinny być obiektywne, precyzyjne i aktualne informacje o stanie nawierzchni drogowej, które stanowią nieodzowną podstawę systematycznego utrzymania dróg. Są one ponadto punktem wyjścia dla krótko- i średnioterminowego planowania zabiegów utrzymaniowych. Dostarczają informacji o efektywności różnych typów i technologii zabiegów utrzymaniowych. Umożliwiają ponadto prognozowanie stanu technicznego nawierzchni, niezbędne do opracowywania modeli degradacji płyt betonowych, stanowiących podstawę długoterminowego planowania zapotrzebowania na środki finansowe.

Należy zaznaczyć, że cenione administracje drogowe na całym świecie poddają opracowane kryteria zmęczeniowe nawierzchni drogowych ciągłej rewizji (w okresach kilkunastoletnich), w wyniku zmieniających się warunków lokalnych. Wynika to z możliwości przeprowadzania coraz bardziej zaawansowanych analiz

(optymalizacji konstrukcji) oraz ze zmian uwarunkowań lokalnych, dla których kryteria zostały opracowane np. dostosowane do zmieniających się warunków obciążeniowych poprzez zastosowanie nowych technologii oraz materiałów do ich realizacji. Dlatego już w latach siedemdziesiątych Federalna Administracja Drogowa Stanów Zjednoczonych (FHWA) opracowała długoterminowy program LTPP (Long-Term Pavement Performance), który skupia się na monitorowaniu i analizie długoterminowego zachowania się nawierzchni drogowych. Program ten został stworzony w celu gromadzenia danych i prowadzenia badań dotyczących eksploatacji i trwałości nawierzchni drogowych.

Wybór i harmonogram działań utrzymaniowych może znacznie wpłynąć na koszty i efektywność, jak na całkowity okres eksploatacji nawierzchni [86]. Opcje utrzymania mają swoje optymalne „okno” możliwości zastosowania, w którym można osiągnąć najlepsze rezultaty. Ogólnie rzecz biorąc, jeżeli mamy do czynienia z opóźnieniem działań utrzymaniowych nawierzchni drogowych, wówczas dochodzi do negatywnych konsekwencji tzn. mamy do czynienia ze zmniejszeniem wartości wskaźników i wartości aktywów w czasie, funkcjonalność sieci pogarsza się, a koszty zabiegów przywracających nawierzchnie do akceptowalnego stanu technicznego w przyszłości są znacznie większe [79].

Obecnie utrzymanie prewencyjne, które pojawia się w wielu sektorach, zwłaszcza w przemyśle, jest typowym sposobem inteligentnego utrzymania ruchu. Jako tryb utrzymania oparty na danych, jest to integracja technologii czujników, technologii przetwarzania sygnałów, analizy niezawodności, statystyk, uczenia maszynowego i innych metod określania potencjalnych wad, co stanowi podstawę bardziej rozsądnego i skutecznego planu utrzymania [115].

W ostatnich latach zauważono, że dotychczasowe, klasyczne doświadczenia w utrzymaniu dróg są niewystarczające, a do zarządzania nawierzchniami wprowadzane są nowe metody zbierania i przetwarzania danych [103]. Dzięki przyspieszonemu rozwojowi technologii informatycznych i sztucznej inteligencji otwierają się nieograniczone możliwości ich implementacji w drogownictwie.

2 Studium literatury na temat trwałości i utrzymania nawierzchni betonowych

Powtarzalne i wiarygodne dane o stanie technicznym nawierzchni odgrywają ważną rolę w opracowywaniu wskaźników stanu, modeli wydajności, zrozumieniu, w jaki sposób i dlaczego nawierzchnie sprawdzają się lepiej niż inne, a także w znalezieniu opłacalnych rozwiązań potrzeb w zakresie utrzymania nawierzchni [12]. Historia ostatnich ponad 20 lat w Polsce w zakresie implementacji różnych rodzajów rozwiązań oraz prowadzonych i zaprzestanych badań m.in. w ramach Długoterminowych Odcinków Testowych (DOT) w latach 1992 – 2010, do których po raz pierwszy w roku 2010 zostały włączone odcinki o nawierzchni z betonu cementowego dowodzi, że warunkiem koniecznym uzyskania rezultatu w postaci funkcjonującego systemu zarządzania infrastrukturą drogową jest konsekwencja i stabilność. Zgodnie z rekomendacjami z wykonanej XVII serii badań na Długoterminowych Odcinkach Testowych z roku 2010 [51] wskazano m.in. na

konieczność opracowania aktualizacji istniejących modeli degradacji nawierzchni oraz opracowanie nowych modeli dla nawierzchni wykonanych w najnowszych technologiach.

Rozwój badań nad trwałością jest obszarem badań o wysokim priorytecie w Federalnej Administracji Autostrad (FHWA) USA od 1987 roku. Niektóre z bardziej znaczących wczesnych wysiłków obejmują pionierskie prace nad PRS wykonane w New Jersey przez Weed, National Cooperative Highway Research Program (Sponsorowane przez NCHRP) badanie PRS dla nawierzchni z betonu asfaltowego (AC) oraz wstępne badanie FHWA dotyczące opracowania PRS dla nawierzchni z betonu portlandzkiego (PCC) [5, 47, 114]. W oparciu o obiecujące wyniki tych wczesnych projektów, FHWA sponsorowała dodatkowe badania na początku lat 90-tych, które koncentrowały się na opracowaniu bardziej praktycznego (i łatwego do wdrożenia) prototypu PRS dla nawierzchni PCC. W latach 1994-1998 przeprowadzono przez FHWA badania, które obejmowały swoim zakresem testy terenowe i laboratoryjne kilku zmiennych konstrukcyjnych nawierzchni PCC w zakresie ich trwałości [37, 38, 39, 40]. W ramach tych badań wstępnie określono typową zmienność kluczowych AQC (tj. pustki powietrzne, grubość płyty, początkowa gładkość, wytrzymałość betonu i inne) oraz podano zalecenia dotyczące domyślnych zmienności każdej AQC. Omawiany raport [36] jest pierwszym z dwóch tomów. Opisuje prace badawcze mające na celu ulepszenie modeli prognozowania wydajności. Ponieważ zarządcy dróg wykorzystują specyfikacje związane z trwałością i zbierają wynikające z niej dane dotyczące jakości, kosztów i wydajności, oczekuje się, że modele degradacji będą podlegać dalszym ulepszeniom i zwiększeniu dokładności przewidywania w zakresie trwałości nawierzchni. Badanie to koncentrowało się na ulepszeniu kluczowych modeli predykcji uszkodzeń i gładkości stosowanych w PRS dla dyblowanej nawierzchni z betonu cementowego (JPCP). Oceniono modele wydajności uskoków poprzecznych, pęknięć płyt poprzecznych, odprysków spoin poprzecznych i gładkości (International Roughness Index [IRI]), a następnie znacznie udoskonalono. Osiągnięto to za pomocą obszernej bazy danych zawierającej dane dotyczące wydajności JPCP, wraz z solidnymi technikami statystycznymi i inżynierskimi. Przewidywanie wydajności nawierzchni wymaga danych historycznych dotyczących stanu technicznego nawierzchni, obciążenia ruchem, charakterystyki strukturalnej i danych klimatycznych. Dane te można uzyskać z pojedynczego odcinka testowego lub z użytkowanych nawierzchni w celu uzyskania danych do bardziej praktycznych modeli prognostycznych. Jednak budowa i monitorowanie pojedynczych odcinków testowych jest kosztowne i nierealne dla małych i lokalnych zarządców dróg.

2.1 Charakterystyka nawierzchni betonowych

Za budową nawierzchni betonowych (sztywnych) przemawiają pozytywne doświadczenia ich użytkowników w Polsce i na świecie, jak również wiele publikacji naukowych i opracowań. CEMEX Polska jako największy producent betonu w kraju

od lat współtworzy polską sieć dróg betonowych. W dalszej części zaprezentowano zestawienie najmocniejszych stron nawierzchni sztywnych [59].

Wbrew obiegu opinii, przewaga nawierzchni betonowych nie polega tylko na dużo niższych kosztach utrzymania drogi – technologia betonowa okazuje się również tańsza na etapie budowy. Oszczędność liczona względem kosztu nawierzchni asfaltowej rośnie wraz z kategorią ruchu drogi. Podsumowanie najważniejszych zalet nawierzchni drogowych z betonu cementowego przedstawiono w tabeli 1.

Tabela 1 Zalety nawierzchni drogowych z betonu cementowego [52]

Zalety nawierzchni z betonu cementowego	Opis
Korzyści technologiczne	<ul style="list-style-type: none"> ▪ Trwałość – okres eksploatacji dobrze zaprojektowanej i wykonanej nawierzchni sięga nawet 80 lat i jest wielokrotnie większy niż w przypadku nawierzchni asfaltowych; ▪ Dobra nośność i podział obciążeń – obciążenia pojazdu rozkładają się na całą płytę; ▪ Relatywnie mały koszt utrzymania – brak konieczności remontów nawet przez 30 lat w sytuacji prowadzenia odpowiedniego utrzymania prewencyjnego; ▪ Odporność na zmienne warunki atmosferyczne, tj. wysokie temperatury, mróz, opady: deszcz, śnieg.
Korzyści użytkowe	<ul style="list-style-type: none"> ▪ Zużycie paliwa mniejsze o ok. 2–2,5 proc., dzięki sztywniejszej nawierzchni; ▪ Nieprzerwana przejezdność – ograniczenie liczby kolejek i utrudnień w ruchu spowodowanych robotami drogowymi: oszczędność czasu dla użytkowników drogi, oszczędność kosztów dla firm transportowych; ▪ Estetyka – beton jako materiał budowlany ma swoich gorących entuzjastów; zastosowanie betonu z eksponowanym kruszywem na chodnikach czy drogach dla rowerów ma kapitalny wpływ na walory estetyczne otoczenia.
Bezpieczeństwo	<ul style="list-style-type: none"> ▪ Krótsza droga hamowania, również na mokrej nawierzchni; ▪ Odporność na odkształcenia trwałe – brak kolein i innych trwałych deformacji jezdni; ▪ Jasna nawierzchnia, korzystnie wpływająca na widoczność; ▪ Dobre właściwości przeciwpoślizgowe, potwierdzone badaniami, mniejsza wypadkowość niż na nawierzchniach asfaltowych;

	<ul style="list-style-type: none"> ▪ Sprawne odprowadzanie wody deszczowej z powierzchni jezdni, dzięki równej nawierzchni.
Środowisko naturalne	<ul style="list-style-type: none"> ▪ Ograniczenie efektu „miejskiej wyspy ciepła” – zdolność jasnej nawierzchni betonowej do odbijania światła jest około trzy razy większa niż ciemnej nawierzchni asfaltowej; ▪ Możliwość całkowitego recyklingu zużytych płyt betonowych – <i>Construction Materials Recycling Association</i> (CMRA) uznała beton za materiał konstrukcyjny o największym na świecie potencjale recyklingowym; ▪ Lokalnie dostępne surowce ograniczają koszty środowiskowe związane z transportem.

2.2 Trwałość nawierzchni betonowych

Nawierzchnie drogowe z betonu cementowego w Polsce zgodnie z Katalogiem Typowych Konstrukcji Nawierzchni Sztywnych z 2014 r. projektuje się na okres eksploatacji nie krótszy niż 30 lat [57]. Aktualizacja katalogu z roku 2014 w stosunku do katalogu z roku 2001 wynikała ze znacznego rozwoju technologicznego w zakresie drogowych nawierzchni betonowych oraz dostosowania go do nowych kategorii obciążenia ruchem.

Trwałość w kontekście inżynierii drogowej i budownictwa odnosi się do zdolności materiału lub konstrukcji do wytrzymania warunków eksploatacyjnych przez długi czas bez znaczącego pogorszenia się jakości, wydajności lub bezpieczeństwa. Obejmuje to odporność na czynniki zewnętrzne, takie jak obciążenia ruchem, zmiany temperatury, wilgoć, działanie środków chemicznych (np. soli drogowej) oraz naturalne procesy starzenia.

Nawierzchnie betonowe są co prawda trudniejsze w wykonaniu i czasami droższe od nawierzchni asfaltowych, lecz ich wielką zaletą jest trwałość, która może sięgać nawet powyżej 50 lat. Natomiast konstrukcje podatne wymagają remontów już po kilku latach eksploatacji związanych z koniecznością wymiany m.in. warstwy ścieralnej oraz w dalszych okresach wymianą warstwy wiążącej.

W odniesieniu do nawierzchni z betonu cementowego zakłada się ogólnie, że w okresie 30 letniej eksploatacji (przy zakładanym obciążeniu ruchem 90 mln osi standardowych 115 kN) konieczne są do wykonania następujące prace remontowe [105]:


- po 9 latach wymiana uszczelnień szczelin podłużnych i poprzecznych;
- po 18 latach wymiana 5% płyt;
- po 18 latach wymiana uszczelnień szczelin podłużnych i poprzecznych;
- po 24 latach wymiana 3% płyt;
- po 27 latach wymiana uszczelnień szczelin podłużnych i poprzecznych;
- po 27 latach wymiana 5% płyt;

Dodatkowo poza wyżej wymienioną listą prac w ramach prowadzonych zabiegów utrzymaniowych wymagane jest przeprowadzanie w odpowiednich cyklicznych odstępach czasowych (tj. Treatment Timing Cycle: 7 – 8 lat) uzależnionych od lokalnych uwarunkowań konstrukcyjnych, materiałowych oraz klimatycznych prac związanych z zabezpieczeniem/uszczelnieniem zaobserwowanych uszkodzeń np. spękań [11].

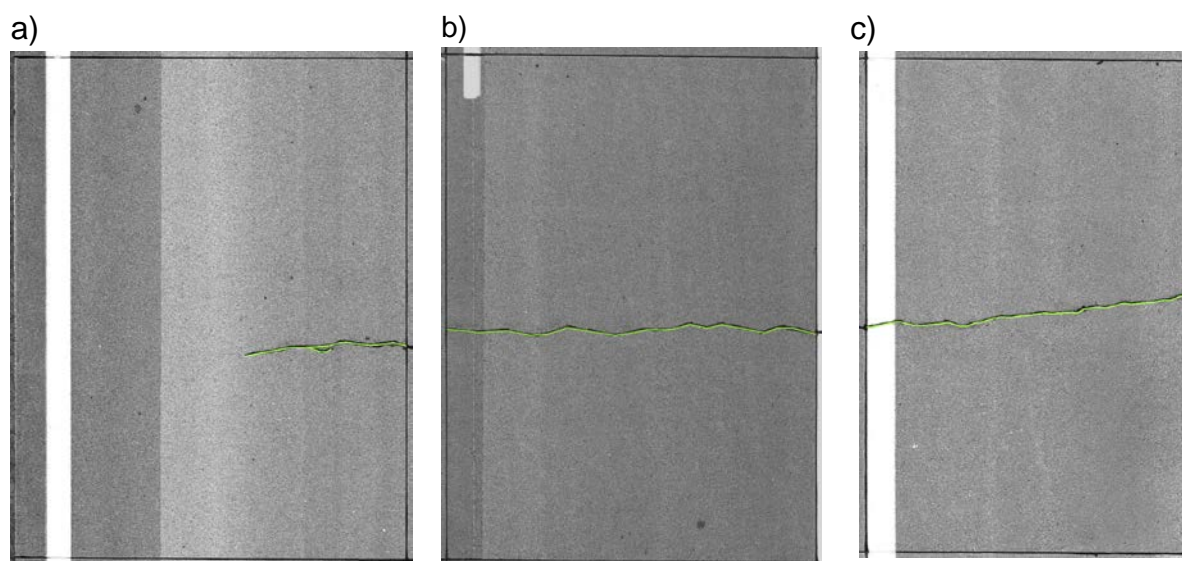
Należy jednak zwrócić uwagę na fakt, żeby zachować zakładany okres eksploatacji, to w początkowym okresie eksploatacji nawierzchni z betonu cementowego zakres prac związanych z utrzymaniem tego typu nawierzchni nie powinien ograniczać się jedynie do przeglądu ich stanu technicznego. W wielu przypadkach występuje wiele uszkodzeń o małej szkodliwości czy to powierzchniowych czy strukturalnych (tabela 2), które powinny podlegać naprawie w ramach utrzymania prewencyjnego (rys. 1-6).

Tabela 2 Typy i charakterystyka powierzchniowych oraz strukturalnych uszkodzeń nawierzchni z betonu cementowego


Lp.	Typ uszkodzenia	Charakterystyka	Nr. rysunku
1	Pęknięcia podłużne (PL)	Pęknięcia, które w przybliżeniu są równoległe do kierunku poruszania się pojazdów. Takie pęknięcia są na ogół proste, ale w niektórych przypadkach mogą być ukośne	1
2	Pęknięcia poprzeczne (PT)	Pęknięcia rozciągające się pod kątem prostym do osi drogi lub kierunku poruszania się pojazdów	2
3	Pęknięcia krawędzi (PK)	Pęknięcia, które rozciągają się od krawędzi do szczeliny. Pęknięcia tego typu znajdują się w odległości mniejszej niż 50 cm od krawędzi płyty	3
4	Uszkodzenie narożnika (UN)	Pęknięcia przecinające krawędzie płyty w odległościach od narożnika nie większych niż połowa długości odpowiedniego boku lub wykruszenia z towarzyszącymi im pęknięciami płyty w odległości do 50 cm od narożnika	4
5	Uszkodzenia powierzchniowe (UP)	Uszkodzenia górnej warstwy nawierzchni z betonu cementowego charakteryzujące się siatką pęknięć, ubytkami fragmentów materiału, złuszczeniami lub wybojami	5
6	Wykruszenia szczelin (WS)	Wykruszenia i odłamania w odległości do 10 cm od krawędzi szczeliny	6




Rysunek 1. Przykładowe zinwentaryzowane uszkodzenia podłużne/ukośne a) pas nr. 1 (szybki), pas nr. 2 (wolny), pas nr. 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych (patrz rozdział nr 5)




Rysunek 2. Przykładowe zinwentaryzowane uszkodzenia poprzeczne a) pas nr 1 (szybki), pas nr 2 (wolny), pas nr 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych




Rysunek 3. Przykładowe zinwentaryzowane uszkodzenia pęknięcia krawędzi a) pas nr 1 (szybki), b) pas nr 2 (wolny), c) pas nr 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych



Rysunek 4. Przykładowe zinwentaryzowane uszkodzenia naroży a) pas nr 1 (szybki), pas nr 2 (wolny), pas nr 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych



Rysunek 5. Przykładowe zinwentaryzowane uszkodzenia powierzchni a) pas nr 1 (szybki), b) pas nr 2 (wolny), c) pas nr 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych



Rysunek 6 Przykładowe zinwentaryzowane wykruszenia szczelin a) pas nr 1 (szybki), b) pas nr 2 (wolny), c) pas nr 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych

Wszystkie powyższe wady i uszkodzenia nawierzchni z betonu cementowego mogą wystąpić już we wczesnym okresie użytkowania jeżeli na poszczególnych etapach powstawania nawierzchni takich jak projektowanie lub wykonawstwo powstały błędy ze względu np. na nieodpowiedni dobór materiałów (kruszywa lub cementu), ich wbudowania lub niewłaściwą pielęgnację betonu nawierzchniowego [49]. Wszystkie te błędy poprzez ich skuteczne wykrycie i identyfikację mogą uchronić nawierzchnię przed skróceniem jej zakładanej trwałości.

Nawierzchnie drogowe z betonu cementowego poddawane są oddziaływaniu różnych czynników zewnętrznych, takich jak: temperatura (oddziałująca na poszczególne warstwy, a w szczególności na warstwę nawierzchniową, środki

chemiczne stosowane w zimowym utrzymaniu dróg, obciążenia ruchem pojazdów, działanie wód opadowych i gruntowych.

Reasumując, najważniejsza w utrzymaniu dróg betonowych jest ich stała obserwacja i szybka reakcja, gdy dojdzie do niewielkich uszkodzeń.

2.3 Utrzymanie nawierzchni betonowych

System zarządzania nawierzchniami (PMS – Pavement Management System) jest to zestaw narzędzi i metod, które pomagają w znalezieniu optymalnych strategii dotyczących oceny i utrzymania nawierzchni w określonym przedziale stanu technicznego przez określony okres [4]. Generalnie PMS w swoim zakresie obejmuje planowanie inwestycji, projektowanie, budowę, utrzymanie oraz elementy oceny stanu technicznego nawierzchni [23]. PMS wpływa na poprawę efektywności w zakresie podejmowania decyzji poprzez dostęp do różnych scenariuszy w zależności od oczekiwanych poziomów stanu technicznego lub dostępnych środków finansowych [60]. Ponadto, wykorzystując PMS, można zmniejszyć potencjalny wpływ ograniczonych środków finansowych poprzez optymalizację alokacji budżetu, ustalenie priorytetów projektów w procesie opartym na odpowiedniej jakości danych oraz zastosowania skutecznej strategii utrzymaniowej [34].

Głównym zadaniem systemów zarządzania nawierzchniami jest zapewnienie zarządcom drogowym takich możliwości jak m.in. [87]:

- ocena aktualnego i prognozowanego stanu technicznego nawierzchni;
- prognoza środków finansowych potrzebnych na poprawę stanu technicznego nawierzchni;
- określenie metod robót remontowych i prac utrzymaniowych w oparciu o poziom dostępnych środków finansowych.

Aby opracować tego typu narzędzie, niezbędne jest zrozumienie wszystkich składników PMS i ich zmiennych oraz dysponowanie zgromadzonymi danymi na temat modeli degradacji.

Nowoczesne PMS powinny zawierać takie składniki jak:

- inwentaryzacja informacji o nawierzchni,
- prezentowanie i generowanie informacji zwrotnych według ustalonych standardów,
- wykorzystanie zgromadzonych danych do analizy i prezentacji wyników w zakresie prognozy stanu technicznego nawierzchni,

W ramach podsumowania, systemy zarządzania nawierzchniami (PMS) [2] odgrywają istotną rolę w efektywnym zarządzaniu stanem technicznym sieci dróg w oparciu o efektywne kosztowo strategie utrzymania tego stanu nawierzchni na akceptowalnym poziomie w danym czasie, tak aby nawierzchnia mogła spełniać wymagania ruchu drogowego i środowiska przez cały okres użytkowania.

W systemach zarządzania ocena stanu technicznego nawierzchni należy do jednych z najważniejszych zagadnień i stanowi zasadniczy element. Ocena stanu

technicznego nawierzchni może być realizowana na poziomie sieci dróg lub na poziomie odcinka. Zagadnieniami szeroko pojętej oceny stanu technicznego nawierzchni drogowej zajmuje się diagnostyka nawierzchni drogowej. Na praktyczne zastosowanie diagnostyki nawierzchni składają się następujące zadania [104]:

- diagnoza – to określenie bieżącego stanu technicznego,
- geneza – to określenie przyczyn zaistnienia obecnego stanu technicznego,
- prognoza – czyli okres przyszłej zmiany stanu technicznego.

2.3.1 Diagnoza

Podstawowym zadaniem organów drogowych i podstawowym kierunkiem rozwoju ukształtowanej sieci dróg jest ulepszanie stanu technicznego istniejących nawierzchni dróg przez dostosowanie ich parametrów technicznych i transportowo-eksploatacyjnych do poziomu, który odpowiada wysokim wymaganiom współczesnych pojazdów przy jednoczesnym zapewnieniu efektywności ekonomicznej ponoszonych nakładów na utrzymanie dróg [2].

Stan techniczny nawierzchni dróg w trakcie eksploatacji ulega ciągłym zmianom pod wpływem obciążeń od ruchu pojazdów samochodowych i działania czynników zewnętrznych. Ocena wizualna stanu technicznego powierzchni jezdni dostarcza najbardziej przydatnych informacji w ustaleniu przyczyn jej defektów i pozwala na podjęcie decyzji o odpowiednim działaniu utrzymaniowym. Ocena stanu technicznego powierzchni służy do:

- rejestracji typów uszkodzeń;
- określenia zakresu prac utrzymaniowych lub dalszych badań;
- archiwizacji stanu powierzchni jezdni do wykorzystania w przyszłości;
- oceny stosowanych i prowadzonych prac naprawczych.

2.3.2 Geneza

Wybór technologii zabiegu utrzymaniowego poprzedzony jest analizą potencjalnych przyczyn zasięgu uszkodzeń nawierzchni. W diagnostyce drogowej ten etap określany jest jako geneza problemu. Nawierzchnie betonowe zapewniają większą trwałość konstrukcjom drogowym niż nawierzchnie z mieszanki mineralno-asfaltowej. Są jednak bardziej wrażliwe na błędy wykonawcze i eksploatacyjne, popełniane w trakcie realizacji nawierzchni betonowej oraz w trakcie cyklu jej życia. Tego typu błędy przekładają się na uszkodzenia powierzchniowe oraz strukturalne.

Do uszkodzeń powierzchniowych, można zaliczyć m.in.:

- ubytki powstające w wyniku ubytków ziaren kruszywa z powierzchni betonu. Najbardziej narażone na wykruszanie są ziarna otoczkowe ze względu na małe rozwinięcie powierzchni, zwłaszcza jeśli są mocno zapyłone [109],
- odpryski ziaren kruszywa, czyli niewielkie zagłębienia w powierzchni betonu, o kształcie zbliżonym do stożka, z widocznym najczęściej na jego dnie fragmentem rozłupanego ziarna kruszywa. Powstają, gdy ziarna kruszywa grubego zlokalizowane blisko powierzchni pęcznią, niszczą i odspajają się

wraz z fragmentami przyległej zaprawy. Najczęstszą przyczyną tego zjawiska jest brak dostatecznej odporności na działanie mrozu kruszywa [50],

- złuszczenia, czyli odspojenia fragmentów zaprawy i kruszywa grubego z powierzchni płyty betonowej, które prowadzą do powstawania zagłębień, nierówności oraz ograniczenia trwałości nawierzchni pod wpływem działania mrozu i środków odladzających [111],
- kraterę powstającą na skutek reakcji glinu z wodorotlenkiem wapnia, co prowadzi do wydzielania się lotnego wodoru [118],
- wadliwą teksturę, która wpływa na pogorszenie właściwości przeciwpoślizgowych co wpływa na zmniejszenie wartości współczynnika tarcia pomiędzy oponami pojazdów a nawierzchnią, a co za tym idzie wpływa na pogorszenie bezpieczeństwa; jest to spowodowane błędami wykonawczymi w zakresie wykańczania górnej warstwy betonu.

Natomiast do uszkodzeń strukturalnych zaliczamy:

- spękania poprzeczne i podłużne płyt betonowych przebiegające przez całą grubość płyty. Najczęstsze przyczyny powstawania spękań podłużnych/ukośnych to [53]:
 - niewłaściwe wykonanie szczeliny skurczowej – do uszkodzenia może dochodzić w sytuacjach zbyt płytkiego nacięcia nawierzchni (mniej niż 1/3 grubości nawierzchni) lub zbyt późnego jego wykonania (zalecany czas to nie później niż 24 h); pęknięcia tego rodzaju pojawiają się na wczesnym etapie eksploatacji nawierzchni, mają prosty kształt i są zlokalizowane równolegle do osi nawierzchni (płyty);
 - brak podparcia płyty – w takim przypadku do uszkodzenia dochodzi w wyniku niewłaściwego zagęszczenia podłoża i/lub ulepszanego podłoża albo w wyniku wnikania wody przez nieszczelne szczeliny dylatacyjne, czego efektem jest utrata podparcia i nierównomierne osiadanie. Taka sytuacja może powodować wystąpienie uszkodzenia z powodu naprężeń powstających w efekcie zginania. Uszkodzenia z tej przyczyny mogą pojawiać się na każdym etapie eksploatacji nawierzchni;
 - pęknięcia odbite od dolnej warstwy konstrukcji – uszkodzona dolna warstwa konstrukcji nawierzchni może powodować propagację pęknięcia w górę przez warstwę betonu. Pęknięcia z tego powodu zwykle występują we wczesnych fazach eksploatacji nawierzchni, w których dolne warstwy konstrukcyjne wykonane są z mieszanki związanej spoiwem hydraulicznym lub z gruntu stabilizowanego spoiwem hydraulicznym;
 - wypaczenie i deformacja płyty – mogą zapoczątkować pęknięcia podłużne. Różnice temperatur mogą powodować wypaczenie płyty, tworząc w ten sposób naprężenia rozciągające w górnej części płyty, które mogą powodować podłużne pęknięcia propagujące od góry do dołu. To podłużne pęknięcie zwykle tworzy się na środku płyty. Pęknięcia z tej przyczyny mogą wystąpić w dowolnym okresie eksploatacji, ale najczęściej mają miejsce w okresie dużych różnic temperatury. Czynnikiem przyczyniającymi się do tego

mogą być: brak odpowiedniego połączenia pomiędzy płytą a podłożem oraz duże wymiary płyty;

- klawiszowanie płyt betonowych, przejawia się nierównościami powierzchni na ich połączeniu; do tego zjawiska dochodzi w konstrukcjach niedyblowanych. Najczęstszą przyczyną takiego zjawiska jest [81]:
 - nieodpowiednie przygotowanie podłoża – do uszkodzeń może dochodzić w przypadku osiadania dolnych warstw konstrukcji nawierzchni lub w przypadku ich niejednorodności,
 - obciążenie dynamiczne – do uszkodzeń dochodzi w sytuacji występowania intensywnych obciążeń ruchem ciężkim oraz w przypadku zbyt małych grubości płyt betonowych,
 - nieszczelność połączeń pomiędzy płytami – poprzez nieszczelne połączenia i wnikanie wody oraz środków zimowego utrzymania dochodzi do erozji podbudowy oraz zjawiska pompowania.
- wysadziny, które skutkują najczęściej wybrzuszeniem nawierzchni są zwykle efektem przemieszczeń podłoża, często inicjowane przez czynniki klimatyczne. Główne przyczyny powstawania wysadzin związane są z [54]:
 - pęcznieniem podłoża, w wyniku zastosowania nieodpowiedniego materiału;
 - nieodpowiednim funkcjonowaniem szczelin dylatacyjnych, które poprzez zanieczyszczenia płyty nie mają możliwości odkształceń termicznych, w wyniku czego może dojść do wysadzenia ich w górę.
- pęknięcia motylkowe powstające w wyniku braku możliwości swobodnego odkształcenia termicznego (rozciągania) płyt betonowych, przyczyniając się tym samym do przyrostu naprężeń w przyległych płytach betonowych aż do przekroczenia stanu granicznego naprężeń wskutek m.in. zabrudzenia szczelin skurczowych [116].

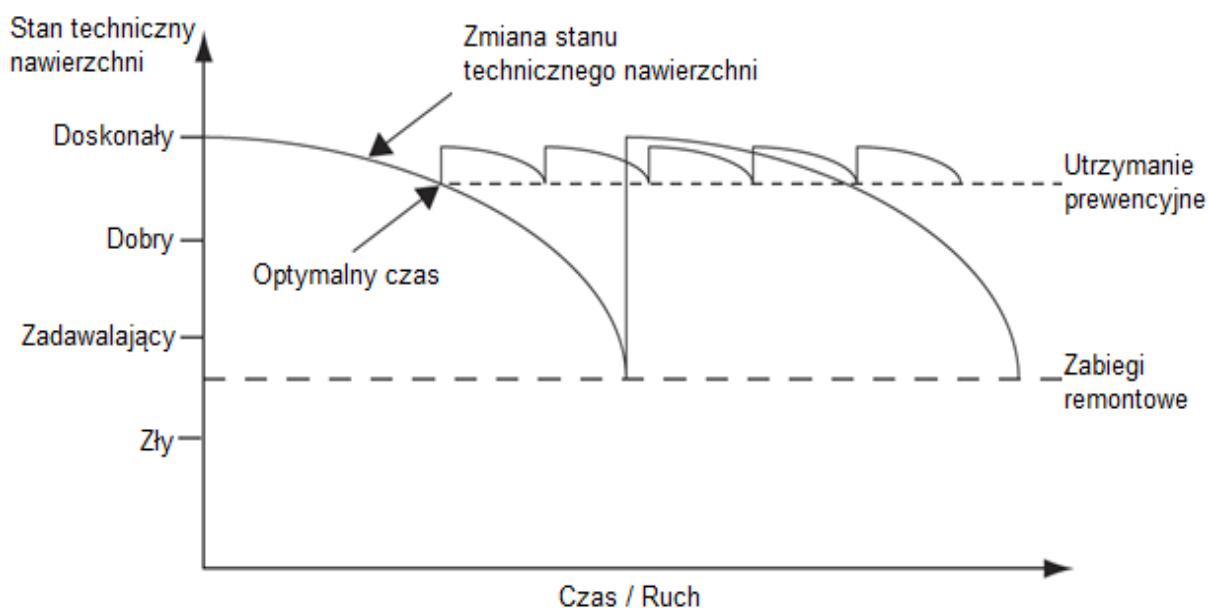
Nawierzchnie drogowe z betonu cementowego, podobnie jak inne rodzaje nawierzchni drogowych, mogą ulegać uszkodzeniom z różnych powodów. Kilka czynników, które mogą wpływać na uszkodzenia nawierzchni drogowej z betonu cementowego, to:

- obciążenie od ruchu - intensywny ruch pojazdów, w szczególności pojazdów ciężkich, może powodować uszkodzenia nawierzchni jezdni. Powtarzające się obciążenia dynamiczne, takie jak przejazd samochodu ciężarowego czy innych pojazdów, mogą prowadzić do zmęczenia materiału, pęknięć, wykruszeń oraz uszkodzeń powierzchniowych.
- warunki atmosferyczne - zarówno intensywne upały, jak i mrozy mogą wpływać na uszkodzenia nawierzchni z betonu cementowego. Długotrwałe ekstremalne warunki atmosferyczne, takie jak zmiany temperatury, obecność wilgoci, zamarzanie i rozmarzanie wody w szczelinach skurczowych mogą powodować spękania i powstawanie ubytków w nawierzchni.
- woda - może być jednym z głównych czynników wpływających na uszkodzenia betonowej nawierzchni drogi. Woda może wsiąkać w beton, co prowadzi do jego rozszerzenia podczas zamarzania lub korozji stali zbrojeniowej, co może prowadzić do pęknięcia betonu i degradacji nawierzchni.

- środki chemiczne - niektóre substancje chemiczne, takie jak sól drogowa, oleje silnikowe mogą działać na powierzchnię betonową jako czynniki korodujące, prowadzące do uszkodzeń betonu i zmniejszające jego trwałość.
- projektowanie konstrukcji - błędy w projektowaniu konstrukcji nawierzchni z betonu cementowego, takie jak nieodpowiednie wymiary płyt, niewłaściwe proporcje mieszanki betonowej, niewłaściwie umieszczone dyble/kotwy lub niewłaściwie zabezpieczone zbrojenie, mogą prowadzić do uszkodzeń nawierzchni.
- brak odpowiedniego utrzymania - niedostateczne lub niewłaściwe utrzymanie nawierzchni betonowej, takie jak zaniedbanie napraw pęknięć, uszkodzeń powierzchniowych, może prowadzić do dalszych uszkodzeń i degradacji nawierzchni.

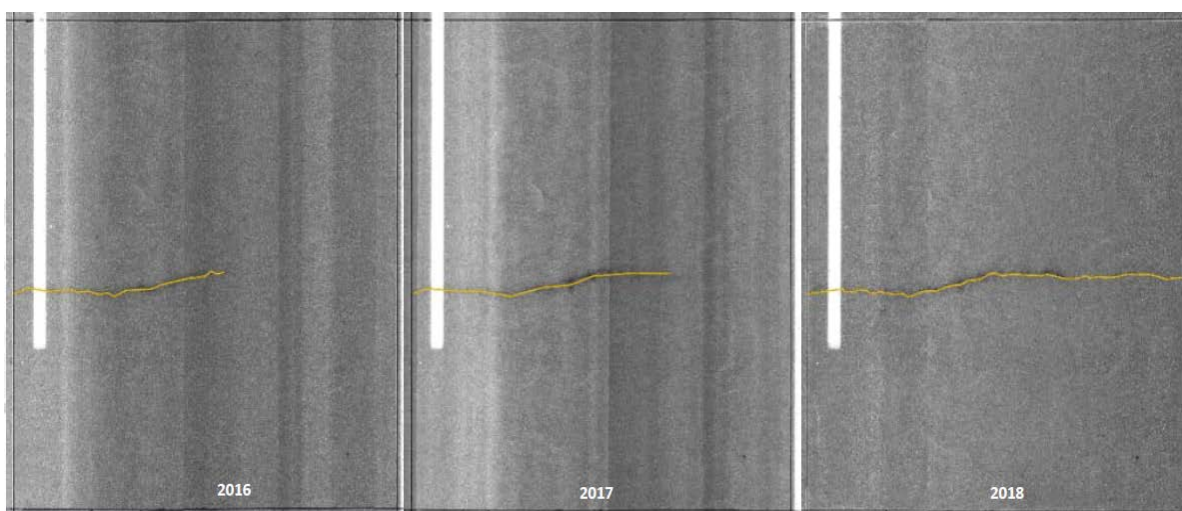
2.3.3 Prognoza

Każda nawierzchnia, bez względu na to, jak dobrze jest zaprojektowana i/lub wykonana, z czasem ulegnie zniszczeniu [96]. Na degradację nawierzchni mają wpływ natężenie ruchu, warunki klimatyczne, jakość konstrukcji, grubość warstw i jakość dotychczasowych działań utrzymaniowych i remontowych. Tempo pogorszenia się stanu technicznego nawierzchni jako funkcja powyżej wymienionych czynników i czasu nie jest liniowa. Zwykle w ciągu pierwszych 50-75% projektowanej trwałości stan techniczny nawierzchni pozostaje dobry, a procesy degradacji postępują powoli. Gdy stan techniczny nawierzchni zaczyna się pogarszać, procesy degradacji postępują znacznie szybciej [85, 123]. Właściwe działania utrzymaniowe podjęte w odpowiednim czasie, mogą spowolnić lub zresetować procesy degradacji nawierzchni. Dlatego tak ważne jest podejmowanie wyprzedzających działań proaktywnych tzw. utrzymania proaktywnego [24]. Korzyści z wdrożenia skutecznego programu utrzymaniowego nie są natychmiastowe, ale wzrastają z upływem czasu. Nawierzchnie, które generalnie są w dobrym stanie technicznym, nie odnotowują większych zmian w ocenie stanu po zastosowaniu działań progresywnych, wyprzedzających, ocena pozostaje na dobrym poziomie (rys. 7). Ważna jest jednak ocena stanu technicznego po kilku latach eksploatacji tzn. nawierzchnie poddawane prewencyjnym zabiegom utrzymaniowym są w lepszym stanie niż te pozostawione bez odpowiednich prac.



Rysunek 7. Terminowe i wielokrotne stosowanie działań zapobiegawczych (proaktywnych) w zakresie utrzymania nawierzchni począwszy od oddania jej do eksploatacji, gdy jest ona jeszcze w dobrym stanie technicznym i użytkowym. Dla porównania, na rysunku pokazano również scenariusz, w którym nawierzchnia może ulec uszkodzeniu, a następnie jest wymagany jest jej remont lub przebudowa [24].

Brak podejmowania terminowo działań w zakresie utrzymania prewencyjnego w sytuacji, kiedy nawierzchnia jest jeszcze w dobrym stanie technicznym prowadzi do powstawania uszkodzeń, których konsekwencje zaprezentowano na rysunku 8. Często powodem takiej sytuacji jest to, że służby utrzymaniowe bardzo często nie dysponują odpowiednią, dobrej jakości oraz wiarygodną informacją na temat występowania uszkodzeń i ich lokalizacji, dlatego podejmowane są ciągle usilne działania w zakresie modyfikacji modeli i narzędzi prognostycznych.



Rysunek 8. Przykład postępu uszkodzenia poprzecznego (PT) w okresie od 2016 do 2018 roku

Jednym z istotniejszych osiągnięć poprawnej strategii utrzymaniowej jest możliwość prognozowania zmiany stanu technicznego nawierzchni drogowej w czasie. W ramach tego typu narzędzi prognozy są wykorzystywane do przygotowania wytycznych/specyfikacji do projektowania i utrzymania, a także do planowania proaktywnych działań na sieci drogowej. Ponadto prognozowane zjawiska pozwalają oszacować bieżącą wartość kosztów związanych z alternatywnymi scenariuszami remontowymi. Dzięki takiemu oszacowaniu kosztów możliwe jest dobranie scenariusza optymalnego nie tylko ze względów ekonomicznych, ale także spełniającego cele strategiczne organizacji w zakresie utrzymania odpowiedniego poziomu technicznego. Organizacja zarządzająca, która ma zdefiniowaną strategię proaktywnego zarządzania aktywami, nie reaguje na pogorszenie stanu technicznego po fakcie, zamiast tego prognozuje i planuje optymalne działania w całym cyklu życia aktywów, aby zminimalizować koszty i zmaksymalizować ustalone wartości dla celów strategicznych. Oczywiście jest to funkcja czułości metod diagnostycznych i dostępnych danych o zadowalającej jakości. O ile jest to uwzględnione w celach strategicznych organizacji, pozyskiwanie aktualnych danych o stanie technicznym nawierzchni weryfikuje przyjęte strategie, umożliwia kalibrację modeli, a usprawnione procesy są ponownie wykorzystywane do wspomaganie decyzji dotyczących przyszłych czynności utrzymaniowych.

Ogólnie rzecz biorąc, modele prognostyczne wykorzystują albo metodę grupową, albo podejście do modelowania specyficznego dla danej sieci drogowej. Podejście oparte na metodzie grupowej polega na analizie aktywów o podobnych cechach (np. typ materiału, ruch drogowy i warunki klimatyczne) i generuje modele wydajności na podstawie zmiany w zbiorze danej grupy. Podejście do modelowania specyficznego dla danej sieci wykorzystuje oceny stanu technicznego na podstawie cech charakterystycznych dla poszczególnych składników aktywów. Podejście oparte na modelowaniu grupowym zmniejsza zapotrzebowanie na dane, ponieważ liczba zmiennych i specyficzność danych są zmniejszone w porównaniu z podejściem opartym na modelowaniu specyficznym dla sieci (AASHTO 2012b).

W literaturze można wymienić szereg różnych modeli prognostycznych [41, 42, 43, 64, 84, 99, 112, 122, 125, 126]. Do najciekawszych można zaliczyć:

- model przetrwania Weibulla;
- model hybrydowy Markowa-Weibulla (ang. hybryda Markov-Weibulla),
- stochastyczny proces gamma;
- modele sztucznej inteligencji;
- metoda wnioskowania na podstawie przypadków,
- modele Bayesowskie,
- modele eksperckie,
- modele oparte na stochastycznych pakietach informacji.

W zarządzaniu siecią drogową do prognozowania najczęściej wykorzystywane są następujące modele [119]:

- deterministyczne modele wydajności opracowywane są na podstawie obserwowanych danych o stanie technicznym nawierzchni z wykorzystaniem analiz statystycznych do formułowania równań matematycznych, które

przewidują stan aktywów (lub inną miarę wydajności) na podstawie wieku, użytkowania, czynników środowiskowych i właściwości użytkowych. Najczęściej używane deterministyczne formy modeli wydajności obejmują funkcje liniowe, wielomianowe i potęgowe.

- probabilistyczne modele wydajności, które przewidują zakres wartości, często jako procent grupy aktywów w wybranych stanach z zabiegami remontowymi i bez tych zabiegów. Generalnie przewidywany zakres wartości jest funkcją tych samych czynników, które stosuje się w modelach deterministycznych, ale może też opierać się na opiniach ekspertów. Probabilistyczne modele wydajności obejmują krzywe cyklu życia oraz procesy przejścia Markowa lub semi-Markowa. Krzywe cyklu życia graficznie przedstawiają prawdopodobieństwo stanu aktywów w czasie. Podejście Markowa uwzględnia aktualny stan i zakłada, że prawdopodobieństwo zmiany jednego stanu aktywów (lub innego stanu miernika wydajności) na inny jest niezależne od czasu. Podejście Markowa wymaga rzadszego gromadzenia danych, jednakże, ponieważ modele zależą tylko od aktualnego stanu, wykluczają wpływ innych zmiennych (np. ruchu lub klimatu). Podejście semi-Markowa usuwa założenie o niezależności czasu.
- modele wydajności oparte na ekspertach, które opierają się na subiektywnych danych lub ekspertyzie. Zazwyczaj modele te są używane jako uzupełnienie innych podejść do modelowania, gdy dane historyczne są ograniczone lub niedostępne.
- modele Bayesowskie wydajności, które łączą historyczne lub obiektywne dane z subiektywnymi informacjami od ekspertów.

Należy zaznaczyć, że prowadzenie odpowiedniej strategii utrzymania prewencyjnego odbywa się w przedziale oceny stanu technicznego nawierzchni pomiędzy stanem dobrym i zadowalającym, co w wielu przypadkach tego typu klasy oznaczają poziom, w którym nie podejmuje się działań związanych z prowadzeniem zabiegów. Taki poziom decyzyjny jest aktualnie stosowany m.in. w ramach obowiązującej Diagnostyki Stanu Nawierzchni (DSN) opisanej w pkt. 2 oraz przedstawionej w tabeli 3.

Tabela 3. Klasy techniczne i wartość stanu wg. DSN [17].

Lp.	Klasa techniczna	Wartość stanu	Opis
1	Klasa A – stan dobry	(75; 100]	nawierzchnie nowe lub przebudowane
2	Klasa B – stan zadowalający	(50; 75]	nawierzchnie odnowione, dopuszczalne występowanie uszkodzeń, nawierzchnie <u>nie wymagające zabiegów</u> na całej szerokości pasa ruchu (liniowych)
3	Klasa C – stan niezadowalający	(25; 50]	nawierzchnie z uszkodzeniami wymagające zaplanowania zabiegów liniowych
4	Klasa D – stan zły	[0; 25]	nawierzchnie z uszkodzeniami, wymagające niezwłocznych zabiegów liniowych

Należy zauważyć, że dane prognostyczne są obszerne, co wynika z literatury światowej, z pominięciem istotnych kwestii w zakresie ich celów, rozwoju, użytkowania i utrzymania. W tym miejscu należy wyjaśnić, że użyty termin "modele prognostyczne" został przyjęty na potrzeby niniejszej analizy. W polskiej literaturze można znaleźć również inne podobne koncepcje, takie jak modele degradacji czy wydajności. Zasadniczo „modele prognostyczne” są pojęciem szerszym i mogą odnosić się nie tylko do zjawisk związanych z degradacją powierzchni jezdni, ale także do innych zjawisk często modelowanych w systemach zarządzania nawierzchniami, takich jak obciążenie ruchem czy prognoza czynników środowiskowych (temperatura, wilgotność). Jeśli chodzi o degradację nawierzchni, można alternatywnie mówić o „modelu procesu pogarszania się” lub „modelu ewolucji pogarszania się” lub „modelu ewolucji stanu nawierzchni”. Można przytoczyć jeszcze bardziej szczegółowe terminy, takie jak „model utraty nośności” czy „model ewolucji cech funkcjonalnych”, które byłyby zgodne z kategoriami uzyskanych danych o stanie technicznym nawierzchni. Podstawowym celem modeli prognostycznych jest umożliwienie organizacji zarządzającej oceny, w jaki sposób jej decyzje mogą wpływać na wyznaczone cele strategiczne. W strategii umożliwiającej zachowanie odpowiedniego stanu technicznego oraz aby w jak największym stopniu kontrolować stan aktywów, organizacja zarządzająca powinna przewidywać te zdarzenia i procesy, które mogą kolidować z jej planami i realizacją celów strategicznych. Obecny stan praktyki w organizacjach zarządzających drogami skupia się na czterech kluczowych obszarach: odporność aktywów na zniszczenie, mobilność, bezpieczeństwo oraz efekty zewnętrzne (np. wpływ na środowisko). Dlatego przede wszystkim cele efektów modelu należy określić na podstawie analizy rozbieżności i TAMP, czyli m.in. jaką wartość wnoszą do procesu decyzyjnego. Na tym etapie należy rozróżnić, do czego przyczyniają się uzyskane dane o stanie technicznym nawierzchni i w jaki sposób modele mają z tych danych korzystać – czyli ważna jest

interakcja między danymi a modelami [127]. Patrząc na koncepcję systemu PMS/PMIS i mając na uwadze zarówno powyższe przesłanki, dla których zjawiska powinny być uwzględnione w modelach prognostycznych, jak i wnioski z przeglądu literatury, zaproponowano następującą listę pojęć, które można zdefiniować jako zmienne zależne:

- rodzaje uszkodzeń w aspekcie ich wielkości i/lub wartości;
- wskaźniki (ich wartości) stanu nawierzchni;
- powiązanie jakości wykonania i jakości materiałów z procesem niszczenia;
- liczba pojazdów; łącząc model natężenia ruchu i przepustowość
- bezpieczeństwo (prawdopodobieństwo i konsekwencje wypadku).

Modele prognostyczne są wymagane do przewidywania stanu technicznego nawierzchni w okresie analizy. Prognozy wydajności nawierzchni zwykle wykorzystują modele deterministyczne, które przewidują pojedynczą wartość analizowanego parametru. Alternatywnie, modele probabilistyczne mogą służyć do generowania zakresu wartości, które wyrażają prawdopodobieństwo wystąpienia określonego stanu warunku. Modele Bayesowskie łączą obiektywne i subiektywne dane w celu przewidywania przyszłych stanów, a modele eksperckie opierają się na opiniach ekspertów (AASHTO 2012). Te modele wydajności są używane głównie na poziomie zarządzania siecią a nie poszczególnymi elementami. Wszystkie te modele są oparte na wstępnych danych konstrukcyjnych lub projektowych. Dlatego należy je dostosować, aby odzwierciedlały indywidualne trendy wydajności obserwowane w czasie.

Idealnymi modelami przewidywania trwałości nawierzchni są te, które wyjaśniają mechanizm przyczynowo-skutkowy. W związku z tym wiążą one parametry materiałowe i wynikający z nich rozwój uszkodzeń poprzez mechanizmy zachodzące między konstrukcją nawierzchni/podłożem, obciążeniem ruchem i klimatem. Takie modele nazywane są modelami mechanistyczno-empirycznymi i prezentują podstawowe właściwości i zależności inżynierskie.

Poza wyżej wymienionymi modelami Alsugair i Al-Qudarih [3] wymienili cztery powody uzasadniające zastosowanie sieci neuronowych w systemach zarządzania nawierzchniami i są to:

- 1) wybór odpowiedniej strategii nie jest oparty na procedurach algorytmicznych i wzorach matematycznych;
- 2) warunki drogowe są liczbowo reprezentowane przez ruch i poziom dotkliwości każdego rodzaju uszkodzenia;
- 3) stan techniczny nawierzchni dla wyboru odpowiedniej strategii nie jest ściśle określony;
- 4) wybór strategii nie jest uzasadniony wyłącznie na podstawie danych statystycznych.

Dotychczas SSN zostały wykorzystane w zakresie oceny stanu technicznego nawierzchni podatnych na podstawie wskaźnika spękań i równości poprzecznej [22] oraz na podstawie oceny wizualnej [110]. Z przeprowadzonych badań wynika, że sieci neuronowe są w stanie dokładnie dokonać oceny stanu technicznego nawierzchni w sposób systematyczny i obiektywny.

2.4 Przykłady systemów oceny stanu technicznego nawierzchni stosowanych w różnych krajach

2.4.1 Systemy stosowane w Polsce

W Polsce do dnia 30 kwietnia 2015 r. obowiązującym dokumentem dotyczącym diagnostyki nawierzchni z betonu cementowego był System Oceny Stanu Nawierzchni (SOSN-B) wydany 29 stycznia 2007 r. Wraz z rozwojem możliwości technologicznych oraz zmian w programach komputerowych, po kilku latach stosowania systemu SOSN stał się on nieaktualny i zastąpiony wytycznymi pt. Diagnostyka Stanu Nawierzchni (DSN).

Celem metod oceny stanu technicznego nawierzchni jezdni jest uzyskanie danych, które pozwolą m.in. na:

- wstępne zlokalizowanie miejsc remontu,
- dokonanie właściwego rozdziału środków finansowych na zabiegi remontowe,
- kształtowanie polityki utrzymania dróg,
- ujednoczenie i wprowadzenie nowoczesnych metod badań diagnostycznych.

Zakres badanych właściwości nawierzchni w celu oceny jej stanu technicznego różni się w zależności od systemu. W tabeli 4 przedstawiono wykaz właściwości, które zostały uwzględnione jako obowiązkowe do wyznaczenia w danym systemie.

Tabela 4. Określane właściwości techniczno-eksploatacyjnych w zależności od systemu oceny stanu technicznego nawierzchni

Cecha	System	
	SOSN-B	DSN
Równość podłużna	X	X
Równość poprzeczna	X	X
Właściwości przeciwpoślizgowe	X	X
Nośność	-	X
Ocena Wizualna	X	X
Oznakowanie poziome	-	X

Każdy z dokumentów (wytycznych stosowania) opisujących poddane analizie systemy oceny stanu technicznego nawierzchni jest zbudowany inaczej (rys. 9):

- **System Oceny Stanu Nawierzchni SOSN**
Zawiera ogólne wytyczne i 5 załączników odnoszących się do każdej z badanych właściwości techniczno-eksploatacyjnych,
- **Diagnostyka Stanu Nawierzchni**
składa się z ogólnych wytycznych i 25 załączników zawierających m.in. instrukcje wykonania pomiarów poszczególnymi urządzeniami, procedury wykonania przedsezonowych badań porównawczych, procedury wykonania

badan na odcinkach testowych również z podziałem na urządzenia pomiarowe.

Przeszłość i Teraźniejszość


od 2007
do 2015

SOSN – B - ciągła ocena wizualna -
inwentaryzacja uszkodzeń za
pomocą urządzenia SOWA-2

od 2015

DSN – automatyczna ocena stanu
powierzchni nawierzchni
-zakres uszkodzeń obliczany jest na
podstawie zdjęć nawierzchni o długości

10 m i szerokości 4 m;



Rysunek 9. Schemat stosowanych wytycznych w zakresie oceny wizualnej nawierzchni drogowych

Podstawowym zadaniem SOSN jest zdefiniowanie wytycznych dla badań diagnostycznych nawierzchni drożowej i specyfikacji metod wnioskowania na uzyskanych danych z punktu widzenia planistycznego. Baza informacji SOSN pozwala na uzyskanie danych do kształtowania polityki utrzymania dróg, lokalizowania i zakresu remontów nawierzchni dróg.

W SOSN badania realizowane w ramach diagnostyki nawierzchni można podzielić na dwa rodzaje:

- badanie instrumentalne,
- badanie wizualne.

Badania instrumentalne obejmują wykonywanie pomiarów równości, nośności oraz właściwości przeciwpoślizgowych. Dokładny opis stanu technicznego nawierzchni zapewnia wykorzystanie cyfrowych przetworników pomiarowych. Łatwo dostępnym rodzajem badań w SOSN jest badanie wizualne. Mimo swej pozornej prostoty etap oceny jest skomplikowany i najtrudniejszy do wykonania. Procedura klasyfikacji defektu do grup oceny stanu technicznego nawierzchni stwarza dylematy.

W Systemie Oceny Stanu Nawierzchni rokrocznie zbierane były dane o następujących cechach techniczno-eksploatacyjnych nawierzchni:

- stan powierzchni,
- stan spękań,
- równość podłużna,

- równość poprzeczna (koleiny),
- właściwości przeciwpoślizgowe.

Szósty parametr - nośność, nie był początkowo uwzględniany, został wprowadzony w aktualizacji Systemu SOSN w 2010 r., jednak nie jako obowiązek przy ocenie stanu technicznego nawierzchni a jedynie jako pomoc przy wykorzystaniu posiadanych danych pomiarów ugięć [26]. Każdy z tych parametrów został szerzej opisany w poszczególnych załącznikach (od A do E).

Parametr opisu stanu technicznego nawierzchni jest wyznaczany dla całej długości odcinka pomiarowego, który jest definiowany tylko na najbardziej obciążonym pasie ruchu. W SOSN-B wykorzystane są rejestratory SOWA2 przeznaczone do oceny stanu technicznego nawierzchni z betonu cementowego oraz przetwarzania danych o uszkodzeniach. Dla funkcjonowania nawierzchni ma znaczenie zaawansowanie niektórych z inwentaryzowanych uszkodzeń, dlatego też część z nich charakteryzuje się małym lub dużym stopniem szkodliwości. Wszystkie uszkodzenia (tab. 5) nawierzchni z betonu cementowego są uszkodzeniami punktowymi tzn. są zliczane a ich rozmiar nie określa się.

Tabela 5. Uszkodzenia identyfikowane w systemie SOSN-B [91].

Lp.	Uszkodzenie	Rozróżnienie szkodliwości	Miara	Oznaczenie skrótowe
1	Pęknięcie pojedyncze podłużne/ukośne	TAK	szt.	PL
2	Pęknięcie pojedyncze poprzeczne	TAK	szt.	PT
3	Połamana płyta		szt.	BS
4	Pęknięcie przy krawędzi	TAK	szt.	PK
5	Uszkodzone zbrojenie		szt.	UZ
6	Wadliwe uszczelnienie		szt.	WU
7	Uszkodzenie narożnika	TAK	szt.	UN
8	Wykruszenie szczeliny	TAK	szt.	WS
9	Uszkodzenie powierzchni		szt.	UP
10	Łata		szt.	LA

W dokumencie SOSN-B każde z uszkodzeń opisano i dołączono schematyczne ilustracje. Natomiast w załączniku 2 umieszczono spis typowych uszkodzeń nawierzchni betonowych wraz z dokładnym opisem i przykładowymi zdjęciami.

Ocena wizualna wg. SOSN-B realizowana jest dwuetapowo. W pierwszej kolejności wykonuje się inwentaryzację uszkodzeń nawierzchni przy użyciu elektronicznego rejestratora. Zgromadzone dane są następnie poddawane przetwarzaniu, w wyniku którego otrzymywane są wartości wskaźników spękań n i stanu powierzchni p dla kolejnych lub wybranych hektometrów ocenianego odcinka. Inwentaryzacja wykonywana jest z samochodu pomiarowego, przy użyciu rejestratora uszkodzeń

nawierzchni. W samochodzie pomiarowym należy zainstalować oddzielny licznik dystansu i skrzynkę przyłączeniową. Inwentaryzację wykonują przeszkolone zespoły dwuosobowe składające się z kierowcy i operatora. Przy jednokrotnym przejeździe pomiarowym inwentaryzacji podlega nawierzchnia jednego pasa ruchu. Długość inwentaryzowanego odcinka podlegającego rejestracji w jednym pliku pomiarowym jest dowolna, jednak nie powinna być mniejsza niż 100 m. Zadaniem operatora jest obserwacja inwentaryzowanej nawierzchni i zapisywanie zauważonych uszkodzeń nawierzchni i punktów charakterystycznych, przy użyciu klawiatury w jaką wyposażony jest rejestrator. Zadaniem kierowcy jest prowadzenie samochodu na inwentaryzowanym pasie ruchu z prędkością dostosowaną do możliwości percepcyjnych operatora. Zalecana prędkość pomiarowa to $0 \div 20$ km/h, dostosowana do stanu inwentaryzowanej nawierzchni. Dopuszczalne jest zatrzymanie samochodu w czasie wykonywania inwentaryzacji bez potrzeby jednoczesnego zamykania pliku pomiarowego. Zespół pomiarowy wyposażony jest dodatkowo w przyrząd mierniczy w celu pomiaru długości płyt na inwentaryzowanym odcinku. Pomiar ten wykonuje się przed rozpoczęciem pracy na odcinku, a wyniki wprowadza się do rejestratora w trakcie wykonywania otwierania pliku pomiarowego. Jest to informacja niezbędna do przetwarzania danych zawartych w pliku [44]. Automatyczne zliczanie płyt zaczyna się od początku inwentaryzowanego odcinka oraz po każdym wprowadzeniu przez operatora kodu początku płyty. Jeśli wymagane jest precyzyjne przypisanie uszkodzeń do konkretnych płyt, operator powinien rejestrować początek każdej płyty.

Procedura obliczeniowa zinwentaryzowanych uszkodzeń uwzględnia do oceny tylko uszkodzenia o największej pozycji w hierarchii (tab. 6). Jeżeli na odcinku odpowiadającym długości płyty znajduje się więcej niż jedno uszkodzenie o tej samej pozycji w hierarchii, wszystkie są uwzględniane w obliczeniach.

Wprowadzone 30 kwietnia 2015 r. Wytyczne Diagnostyki Stanu Nawierzchni DSN zastąpiły wytyczne stosowania Systemu Oceny Stanu Nawierzchni Betonowej (SOSN-B). Wytyczne DSN zostały opracowane przez zespół składający się z przedstawicieli z różnych oddziałów GDDKiA na terenie całej Polski. Opierają się one na pracy badawczej wykonanej przez Instytut Badawczy Dróg i Mostów z 2012 r. przedstawiającej zasady diagnostyki nawierzchni dróg (DSN) lecz są dostosowane do bardziej znanej formy ich przedstawienia z wcześniej obowiązujących wytycznych. Założeniem Wytycznych DSN jest stosowanie sprzętu pomiarowego, który porusza się w normalnym ruchu lub takiego, aby zamknięcie pasa ruchu nie było dłuższe niż w przypadku robót szybko postępujących. Pomędzy Wytycznymi SOSN-B a DSN występuje kilka różnic w zakresie oceny stanu technicznego powierzchni jezdni z betonu cementowego, które polegają na wprowadzeniu rejestracji powierzchni jezdni za pomocą urządzenia LCMS, automatyczną i półautomatyczną interpretację uszkodzeń nawierzchni jezdni oraz wykonywanie pomiarów na wszystkich zasadniczych pasach ruchu.

Tabela 6. Hierarchia uszkodzeń nawierzchni z betonu cementowego

Ranking	Grupa uszkodzeń	Uszkodzenie
1	Uszkodzenie wpływające na stan strukturalny i funkcjonalny	Połamana płyta
		Pęknięcia pojedyncze poprzeczne dużej szkodliwości
		Uszkodzone zbrojenie
2	Uszkodzenia wpływające na stan strukturalny	Pęknięcia pojedyncze poprzeczne małej szkodliwości
		Pęknięcia pojedyncze podłużne/ukośne
3	Uszkodzenia związane z krawędziami	Pęknięcia przy krawędzi
		Uszkodzenie narożnika
		Wykruszenie szczeliny
		Wadliwe uszczelnienie
4	Wady powierzchni	Łata asfaltowa
		Uszkodzenia powierzchni

Ocena automatyczna nawierzchni polega na zarejestrowaniu obrazu pasa ruchu przy pomocy kamer 3D, a następnie na automatycznej analizie danych w celu identyfikacji uszkodzeń nawierzchni. Zakres uszkodzeń obliczany jest w sposób automatyczny dla każdego zdjęcia pomiarowego dzieląc sekcję o długości 10 m oraz szerokości 4 m wirtualną siatką pomiarową o wymiarach pola 25 cm x 25 cm. Każde pole siatki pomiarowej posiada powierzchnię 0,0625 m².

Inwentaryzacja uszkodzeń przebiega w dwóch etapach:

1. Rejestracja obrazu 3D nawierzchni pasa ruchu
2. Identyfikacja uszkodzeń:
 - a. automatyczna identyfikacja spękań, ubytków, wybojów i połamanych płyt;
 - b. półautomatyczna identyfikacja łat i mikropęknięć.

Różnica pomiędzy wytycznymi SOSN-B i DSN, oprócz samej procedury i sposobu identyfikacji uszkodzeń, polega również na różnicy w rodzaju identyfikowanych uszkodzeń przedstawionej w tabeli 7.

Tabela 7. Uszkodzenia identyfikowane w systemach SOSN-B i DSN

Lp.	Typ uszkodzenia	SOSN-B	DSN
1	Pęknięcie pojedyncze podłużne/ukośne	TAK	TAK
2	Pęknięcie pojedyncze poprzeczne	TAK	TAK
3	Połamana płyta	TAK	TAK
4	Pęknięcie przy krawędzi	TAK	TAK
5	Uszkodzone zbrojenie	TAK	-
6	Wadliwe uszczelnienie	TAK	-
7	Uszkodzenie narożnika	TAK	-
8	Wykruszenie szczeliny	TAK	TAK
9	Uszkodzenie powierzchni	TAK	TAK
10	Łata	TAK	TAK

2.4.2 Systemy stosowane w USA

Stany Zjednoczone uważa się za pierwszy na świecie kraj, który wybudował autostradę o nawierzchni z betonu cementowego. Odcinek ten nazwano Long Island Motor Parkway i był zlokalizowany w stanie Nowy Jork. Początkowy plan zakładał realizację autostrady o długości ok. 110 km pomiędzy Nowym Jorkiem a Riverhead w hrabstwie Suffolk. Ostatecznie zbudowano odcinek o długości 72 km drogi od Queens w Nowym Jorku do jeziora Ronkonkoma. Budowa rozpoczęła się w czerwcu 1908 roku, a pierwszy odcinek o długości ok. 16 km został oficjalnie otwarty w październiku 1908 roku. W związku z tak istotnym osiągnięciem, poniżej przedstawiono podejście poszczególnych agencji stanowych do problematyki związanej z oceną stanu technicznego nawierzchni drogowych [62].

W USA ocena stanu technicznego nawierzchni z betonu cementowego (JPCP) może obejmować różne aspekty, takie jak właściwości przeciwpoślizgowe, pęknięcia, ubytki, uskoki, wytrzymałość na ściskanie i wiele innych. W zależności od konkretnego zastosowania i rodzaju oceny, mogą być stosowane różne wytyczne i metody pomiarowe.

W Stanach Zjednoczonych ocena stanu technicznego powierzchni nawierzchni z betonu cementowego jest przeprowadzana zgodnie z wytycznymi, standardami i normami opracowanymi przez różne instytucje i organizacje branżowe. Oto kilka ważnych wytycznych stosowanych w USA:

1. **ASTM International:** ASTM to międzynarodowa organizacja zajmująca się opracowywaniem standardów dla wielu branż, w tym budownictwa. W kontekście oceny stanu technicznego betonowych nawierzchni stosowane są takie standardy jak:

- ASTM D6433 z 2020r.: Standardowa praktyka dotycząca badań wskaźnika stanu nawierzchni dróg i parkingów. Obejmuje określanie stanu technicznego nawierzchni dróg i parkingów za pomocą badań wizualnych z wykorzystaniem metody wskaźnika stanu nawierzchni (PCI) do ilościowego określenia stanu technicznego nawierzchni.
 - ASTM E3303 z 2021r.: Standardowa praktyka generowania wskaźników pęknięć powierzchni nawierzchni na podstawie obrazów cyfrowych.
2. **Federal Highway Administration (FHWA):** Jest to agencja rządowa zajmująca się infrastrukturą drogową w USA. Publikuje wiele raportów i dokumentów dotyczących utrzymania i oceny stanu betonowych nawierzchni dróg.
 3. **State Department of Transportation (DOT):** Każdy stan ma swoje własne wytyczne i standardy dotyczące utrzymania dróg, w tym powierzchni betonowych.

Dane dotyczące stanu technicznego nawierzchni w USA określa się korzystając z metod w pełni zautomatyzowanych, ręcznie (przeoglądając obrazy i wideo na ekranie komputera) lub stosując półautomatyczną kombinację zarówno automatycznego wykrywania, jak i ręcznego przetwarzania końcowego. Aktualne praktyki poszczególnych agencji stanowych w zakresie metod gromadzenia danych o stanie technicznym nawierzchni zestawiono w tabeli 8 na podstawie badań ankietowych przeprowadzonych w 2018 roku przez NCHRP w zakresie nawierzchni z betonu cementowego [88]. Wyniki obejmują typ zbieranych danych oraz to, czy procesy są w pełni zautomatyzowane, półautomatyczne czy ręczne.

Agencje stanowe korzystają z różnych dostawców zautomatyzowanych systemów pomiarowych, które wykorzystują komponenty laserowe do pomiaru pęknięć lub innych typów uszkodzeń w nawierzchni takich jak m.in.:

- Pavemetrics (LCMS – 4M) [63],
- ARRB Systems (iPAVE) [46],
- Pathway Services (System PathRunner 3D) [21],
- Fugro Roadware (ARAN) [25],
- Waylink Systems Corporation (Pave3D i CrackNet) [120].

Tabela 8. Podsumowanie danych zbieranych dla nawierzchni z betonu cementowego w zakresie uszkodzeń powierzchniowych wg. metod ich gromadzenia (automatyczna, półautonomiczna lub ręczna) [89]

Typ uszkodzenia	Metoda gromadzenia danych przez agencje stanowe			Suma odpowiedzi
	Ręczna	Pół-automatyczna	Automatyczna	
Pęknięcie poprzeczne	6	17	16	39
Pęknięcie podłużne	7	13	20	40
Łaty	7	14	8	29
Pęknięcia krawędzi	7	16	7	30
Uszkodzenia powierzchni	8	15	7	30
Pęknięcia siatkowe	2	7	4	13
Połamanie płyty	0	3	1	4
Ubytki	7	3	1	11

Główne przyczyny prowadzenia przez agencje stanowe w dalszym ciągu klasyfikacji stanu technicznego nawierzchni z betonu cementowego na podstawie oceny wizualnej (ręcznej) to:

- prostota i niskie koszty (brak konieczności zakupu drogiego sprzętu lub usług dostawcy/ gromadzenie zebranych danych);
- dodatkowe analizy i konieczność weryfikacji uzyskanych danych;
- dokładność uzyskiwanych danych;
- zmieniające się technologie w zakresie budowy i wykańczania nawierzchni.

Klasyfikacja ta zazwyczaj obejmuje kilka głównych kategorii, które oceniają nawierzchnię pod kątem różnych typów uszkodzeń i ich nasilenia [77].

System oceny wizualnej nawierzchni z betonu cementowego w USA jest zazwyczaj oparty na standardowych protokołach i metodach, które pozwalają na dokładne i obiektywne ocenianie stanu technicznego nawierzchni. Kluczowe elementy tego systemu obejmują:

- szkolenie i certyfikacja inspektorów: inspektorzy są odpowiednio szkoleni i często certyfikowani, aby zapewnić, że ich oceny są dokładne i zgodne z przyjętymi standardami.
- protokoły oceny wizualnej: wykorzystuje się standardowe protokoły, które określają, jakie typy uszkodzeń należy szukać, jak je klasyfikować i dokumentować.

- listy kontrolne i przewodniki: inspektorzy mogą korzystać z list kontrolnych i przewodników, które zawierają szczegółowe opisy różnych typów uszkodzeń, takich jak pęknięcia, wybrzuszenia, ubytki, korozja zbrojenia itp.
- technologie wspomagające: w celu ułatwienia dokładnej oceny, mogą być używane nowoczesne technologie, takie jak drony, systemy GIS (Geographic Information Systems) czy specjalistyczne oprogramowanie do analizy obrazów.
- skalowanie i ocena uszkodzeń: uszkodzenia są zazwyczaj oceniane według skali, która uwzględnia ich wielkość, częstotliwość i wpływ na ogólny stan techniczny nawierzchni.
- raportowanie i dokumentacja: wyniki oceny są dokładnie dokumentowane i raportowane odpowiednim organom lub instytucjom zarządzającym infrastrukturą drogową.
- planowanie napraw i konserwacji: na podstawie ocen, opracowywane są plany naprawy i konserwacji nawierzchni, które są priorytetyzowane w zależności od stopnia i rodzaju uszkodzeń.
- monitorowanie i ocena postępu: regularne monitorowanie stanu technicznego nawierzchni po naprawach jest ważne dla oceny skuteczności przeprowadzonych działań i planowania przyszłych interwencji.

Na podstawie aktualnie widocznej transformacji w agencjach stanowych w zakresie metody przeprowadzania oceny stanu technicznego nawierzchni można wskazać osiągnięcia i wyzwania (tab. 9) jakie zostały określone na podstawie dotychczasowych doświadczeń [89].

Tabela 9. Osiągnięcia i wyzwania w zakresie wprowadzania automatycznej metody oceny stanu technicznego w USA [89]

Osiągnięcia	Wyzwania
<ul style="list-style-type: none"> ▪ bezpieczniejsze, szybsze, wydajniejsze i spójne gromadzenie danych o stanie technicznym nawierzchni w porównaniu z badaniami ręcznymi. ▪ automatyczne wykrywanie pęknięć pozwala agencjom identyfikować rodzaj i wagę pęknięć. 	<ul style="list-style-type: none"> ▪ określanie tolerancji jakości danych, które są rozsądne w odniesieniu do możliwości sprzętu i wymagań w zakresie zarządzania nawierzchnią. ▪ ilościowe określenie uszkodzeń nawierzchni z betonu cementowego (np. pęknięć, ubytków, łat) jest trudne bez ustandaryzowanej metody. ▪ opracowywanie protokołów i algorytmów wykrywania niebezpieczeństwa dla nowych zbiorów danych i wskaźników wydajności. ▪ utrzymywanie stałych wskaźników zagrożenia z roku na rok w zależności od dostawcy.

2.4.3 Systemy stosowane w Niemczech

Niemcy mają jedną z najbardziej wydajnych infrastruktur transportowych w Europie. Jest to podstawowy warunek wysokiego poziomu mobilności, który z kolei warunkuje wzrost gospodarczy, zatrudnienie i udział jednostek w życiu społecznym. Dodatkowo są pierwszym krajem w Europie, który wybudował odcinek autostrady o nawierzchni z betonu cementowego o długości ok. 19,5 km. Jest to odcinek autostrady AVUS (Automobil-Verkehrs- und Übungsstraße) którego budowa rozpoczęła się w 1913 roku, a jej otwarcie miało miejsce dopiero w 1921 r. ze względu na wybuch I wojny światowej, który wstrzymał prace budowlane. AVUS była początkowo zaprojektowana jako tor wyścigowy i droga testowa dla samochodów, ale z czasem stała się częścią niemieckiej sieci autostrad [6].

W zakresie oceny stanu technicznego nawierzchni drogowych w Niemczech, proces ten odbywa się głównie przy wykorzystaniu procedur ZEB (Zustandserfassung und -bewertung, czyli Rejestracja i Ocena Stanu), która jest kluczowym elementem zarządzania utrzymaniem infrastruktury drogowej. Procedura ta dostarcza informacji niezbędnych do podejmowania decyzji technicznych i finansowych w zakresie utrzymania dróg.

Od roku 2001 stosowane są odpowiednie wytyczne ZTV ZEB-StB [19] do rejestracji stanu technicznego i oceny nawierzchni dróg federalnych. W ustalonych odstępach 4-letnich rejestruje się autostrady federalne lub drogi federalne na przemian z poruszającego się pojazdu pomiarowego. W ZEB dla dwujezdniowych dróg federalnych rejestrowany jest tylko wolny pas każdej jezdni. Daje to szacunkową długość ok. 100 000 km dla długości sieci ok. 52 000 km dróg federalnych. Ze względu na tak duży zakres pomiarowy konieczne było rozłożenie badań na kilka lat. Proces Zustandserfassung und -bewertung (ZEB) składa się z kilku kluczowych elementów:

- zbieranie danych: wykorzystuje zaawansowane techniki pomiarowe i wyposażenie, takie jak skanery laserowe, kamery i inne sensory, do zbierania danych o stanie nawierzchni drogi
- analiza danych: zebrane informacje są następnie analizowane pod kątem różnych rodzajów uszkodzeń i zużycia nawierzchni, takich jak pęknięcia, wyboje, deformacje i nierówności
- ocena stanu technicznego: na podstawie analizy danych, stan drogi jest oceniany, co pozwala na określenie priorytetów w zakresie utrzymania i remontów
- planowanie utrzymania i remontów: wyniki oceny są wykorzystywane do planowania niezbędnych działań utrzymaniowych i remontowych, aby zapewnić bezpieczeństwo i wydajność sieci drogowej
- raportowanie i decyzje: informacje i wyniki oceny są raportowane do odpowiednich organów zarządzających drogami, które wykorzystują te dane do podejmowania decyzji dotyczących zarządzania drogami i inwestycji w infrastrukturę drogową.

Gromadzone dane są wykorzystywane do obliczenia zmiennych opisujących stan techniczny nawierzchni. Używa się skali od 1 (bardzo dobry) do 5 (bardzo słaby) do charakteryzowania stanu ocenianej nawierzchni. Oceny składają się z komponentów użyteczności i spójności (powierzchni), zgodnie z zdefiniowanymi wagami. Komponent użyteczności wskazuje poziom bezpieczeństwa i komfortu dla użytkowników drogi, natomiast komponent spójności (powierzchni) wskazuje głównie na wyniki prac utrzymaniowych. Dokument ten skierowany jest do zainteresowanych stron z administracji budowy dróg, biur inżynierskich, firm budowlanych oraz instytucji badawczych i dydaktycznych [18].

Proces ZEB jest dostosowywany do wymagań w miarę pojawiania się nowych wyników badań i praktyki utrzymaniowej. Z reguły innowacje są najpierw testowane w praktyce, zanim będą mogły zostać uznane za aktualne w przepisach. Dlatego dokument roboczy opisuje również charakterystykę stanu technicznego i jego zmienne, które nie są wykorzystywane w rutynowym procesie ZEB, ale są częściowo częścią struktury pliku wyników ZEB. Cały proces ZEB jest zatem kompleksowym podejściem do monitorowania i utrzymania jakości infrastruktury drogowej, łączącym zaawansowane technologie z analizą danych i strategicznym planowaniem. Jeśli chodzi o proces identyfikacji uszkodzeń powierzchniowych nawierzchni, które stanowią pierwszą wskazówkę co do uszkodzenia drogi, są one regularnie rejestrowane w ramach rejestracji i oceny stanu technicznego (ZEB). Stosowane są szybkie systemy pomiarowe, które posiadają kamery obszarowe lub liniowe skierowane na nawierzchnię drogi, za pomocą których rejestrowane są uszkodzenia nawierzchni. Oprócz pęknięć, dla oceny istotne są np. łaty, a w przypadku konstrukcji betonowych, połamane narożniki i uszkodzenia krawędzi. Zdjęcia z przedniego aparatu można wykorzystać do sprawdzenia wiarygodności.

W Niemczech duży nacisk kładzie się na innowacje i ciągłe doskonalenie procesów zarządzania infrastrukturą drogową. Dzięki temu możliwe jest efektywniejsze zapobieganie uszkodzeniom i szybsze reagowanie na problemy. Dlatego w południowej części centrum badawczego duraBASt (Deutsches Zentrum für Luft- und Raumfahrt, Bundesanstalt für Straßenwesen) zbudowano tor referencyjny o nawierzchni asfaltowej oraz betonowej w celu przetestowania systemów pomiarowych. Sekcja zawiera wszystkie właściwości, które należy zarejestrować w ramach ZEB. Sztuczne pęknięcia o różnych szerokościach są odtwarzane poprzez formowanie prawdziwych pęknięć przy użyciu zimnego tworzywa sztucznego. Elementy takie jak połamane naroża i uszkodzenia krawędzi zostały specjalnie uwzględnione w nawierzchni. Ponadto wzdłuż nawierzchni rozmieszczone są panele testowe, które mają wzór testowy opracowany specjalnie do procesu zatwierdzania systemów pomiarowych. Ponieważ fragmenty nawierzchni referencyjnej znajdują się w obszarze przejścia podziemnego, można symulować wpływ zmian światło-cień podczas procesu pomiarowego i sprawdzać oświetlenie obrazów powierzchniowych [33].

3 Teza, cel i zakres rozprawy

Celem pracy badawczej była weryfikacja możliwości wykorzystania sztucznych sieci neuronowych do prognozowania zmian stanu technicznego nawierzchni betonowej. Szczególną uwagę zwrócono na analizę metody rozpoznawania zachodzących procesów degradacji nawierzchni poprzez określenie typu uszkodzeń, ich zakresu oraz zmian w analizowanym okresie, przy zastosowaniu zmodyfikowanej metody inwentaryzacji uszkodzeń oraz sposobu gromadzenia i weryfikacji danych. Prognozy zmian stanu technicznego nawierzchni wykonano przy założeniu wykorzystania klasycznego modelu tendencji rozwojowej z zastosowaniem jednokierunkowych sztucznych sieci neuronowych. Dla wybranych odcinków autostrady eksploatowanych od grudnia 2011 r. utworzono szeregi czasowe obejmujące wyniki zmodyfikowanej wizualnej metody oceny stanu technicznego.

Reasumując:

- Problemem naukowym podjętym w dysertacji była trwałość nawierzchni betonowych;
- Oryginalne rozwiązanie problemu naukowego polegało na wykonaniu prognozy trwałości nawierzchni betonowych z wykorzystaniem SSN;
- Teza: na podstawie bazy danych zgodnej z obowiązującymi systemami diagnostyki nawierzchni betonowych możliwe jest efektywne prognozowanie zmian ich stanu technicznego.

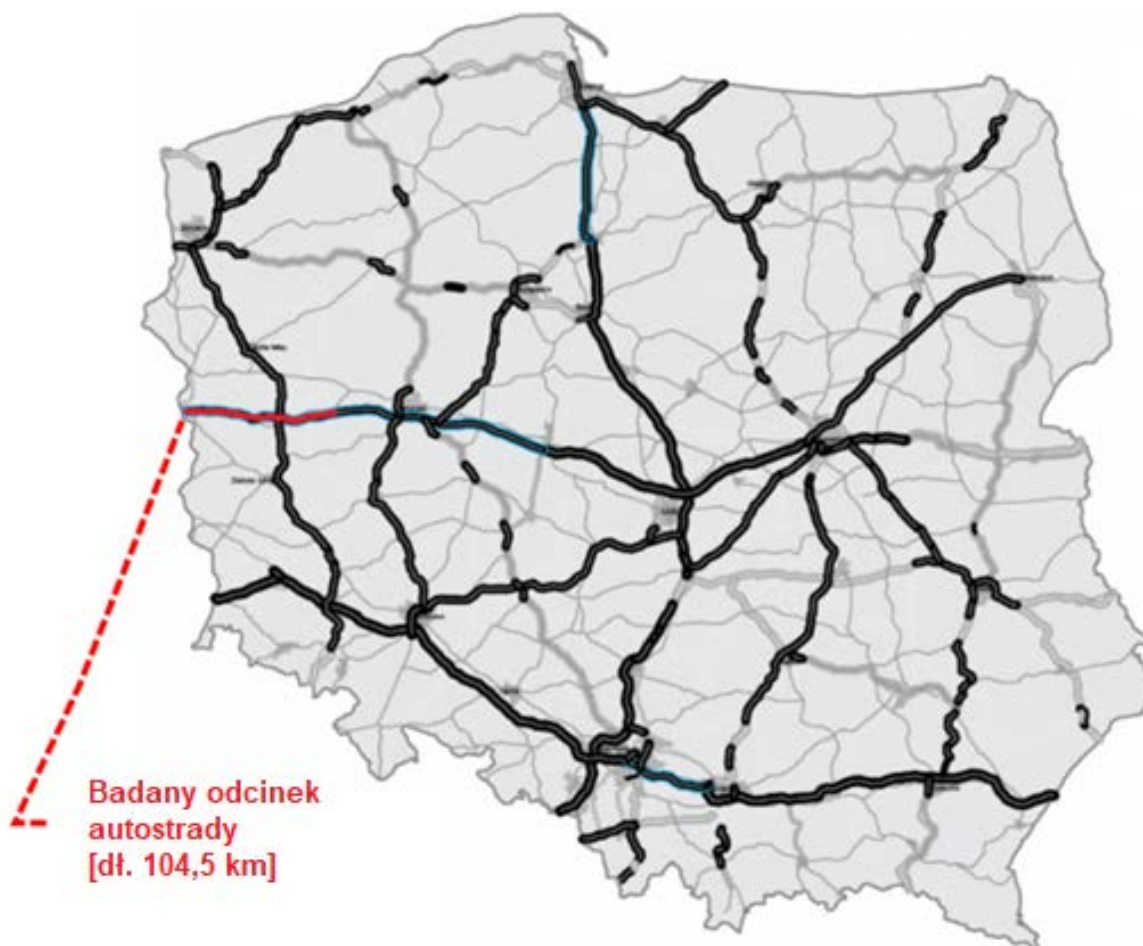
Na zakres rozprawy doktorskiej składają się:

- a) studium literatury krajowej i zagranicznej dotyczącej trwałości i utrzymania nawierzchni betonowych
- b) sformułowanie tezy, celu i zakresu pracy
- c) przeprowadzenie pięciu cykli badań terenowych w ramach zmodyfikowanej metody oceny cech powierzchniowych nawierzchni z betonu cementowego
- d) opracowanie bazy danych zawierającej informacje o obciążeniu ruchem oraz warunkach klimatycznych w zakresie analizowanych odcinków autostrady
- e) opracowanie modeli prognostycznych dla różnych typów uszkodzeń (UP, UN, WS, PT, PK, PL) uwzględniających dostępne zmienne wejściowe (konstrukcja nawierzchni, obciążenie ruchem pojazdów, warunki klimatyczne) przy wykorzystaniu sztucznych sieci neuronowych (SSN)
- f) przeprowadzenie analiz zmiennych wejściowych oraz określenie optymalnej architektury SSN dla poszczególnych typów uszkodzeń.

Na pozostałą część dysertacji składają się cztery rozdziały. Rozdział czwarty zawiera informacje na temat odcinków testowych o nawierzchni betonowej, które zostały poddane badaniom. W rozdziale piątym opisano bazę danych i informacji przyjętych do przewidywania trwałości nawierzchni. W rozdziale szóstym przedstawiono wyniki opracowania modeli degradacji, określono znaczenie i dokonano analizy zmiennych wejściowych. Rozdział siódmy zawiera podsumowanie wyników badań wraz z zaleceniami dotyczącymi przyszłych prac badawczych.

4 Charakterystyka analizowanych odcinków drogi o nawierzchni z betonu cementowego

W ramach przeprowadzonych badań poddano analizie odcinek autostrady A2 od km 3+375 do km 107+900 (łącznie 104,5 km). Odcinek tej drogi stanowi część sieci dróg transeuropejskich (TEN-T) i jest jednym z najważniejszych połączeń pomiędzy Europą Zachodnią a Środkowowschodnią. Lokalizacja badanych odcinków testowych została przedstawiona na rys. 10.

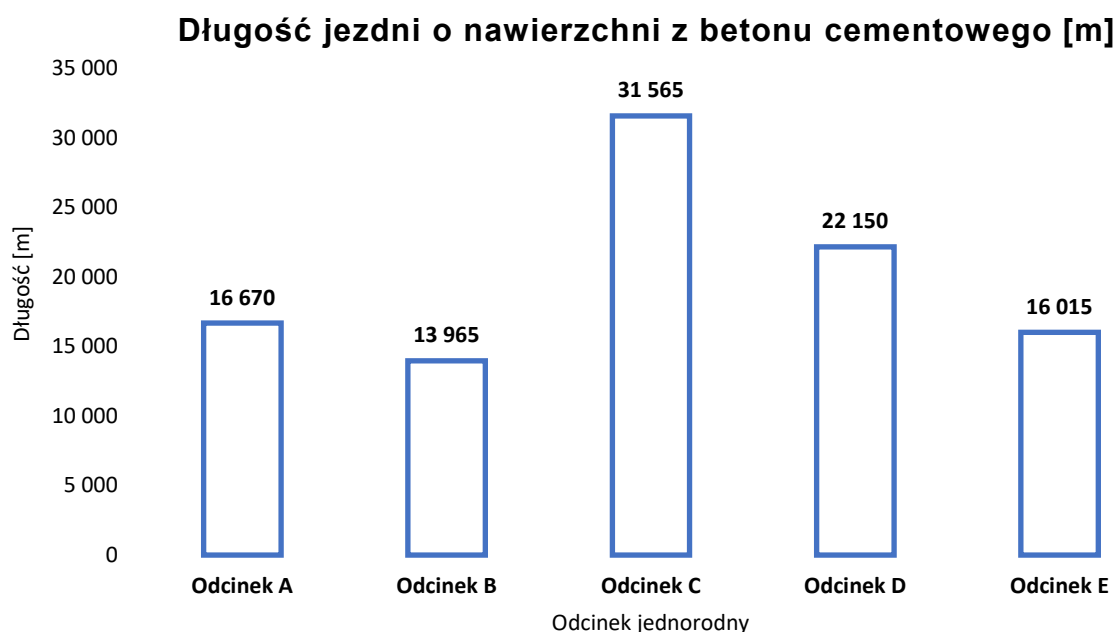


Rysunek 10. Lokalizacja badanych odcinków testowych (linia czerwona) o sumarycznej długości jezdni o nawierzchni z betonu cementowego ok. 202 km.


4.1 Podział na odcinki jednorodne

W ramach prowadzonych badań uzasadnione było wyodrębnienie jednorodnych odcinków nawierzchni z betonu cementowego jako fragmentów drogi o jednolitej konstrukcji nawierzchni, wykonanej z takiego samego materiału i o takich samych parametrach technicznych w tym grubości warstw na całej swojej długości i szerokości. Jest to ważne, ponieważ jednorodne odcinki drogi pozwoliły na zagregowanie danych ze względu na ich zmienność pod względem typu i ilości uszkodzeń powierzchniowych, ruchu pojazdów, warunków klimatycznych. Parametry odcinków jednorodnych przedstawiono na rysunkach 11-14. Wyodrębnione odcinki


mają różną długość tj. Odcinek A od km 3+375 do km 20+685, Odcinek B od km 20+685 do km 35+345, Odcinek C od km 35+345 do km 68+485, Odcinek E od km 68+485 do km 91+415, Odcinek F od km 91+415 do km 107+900.



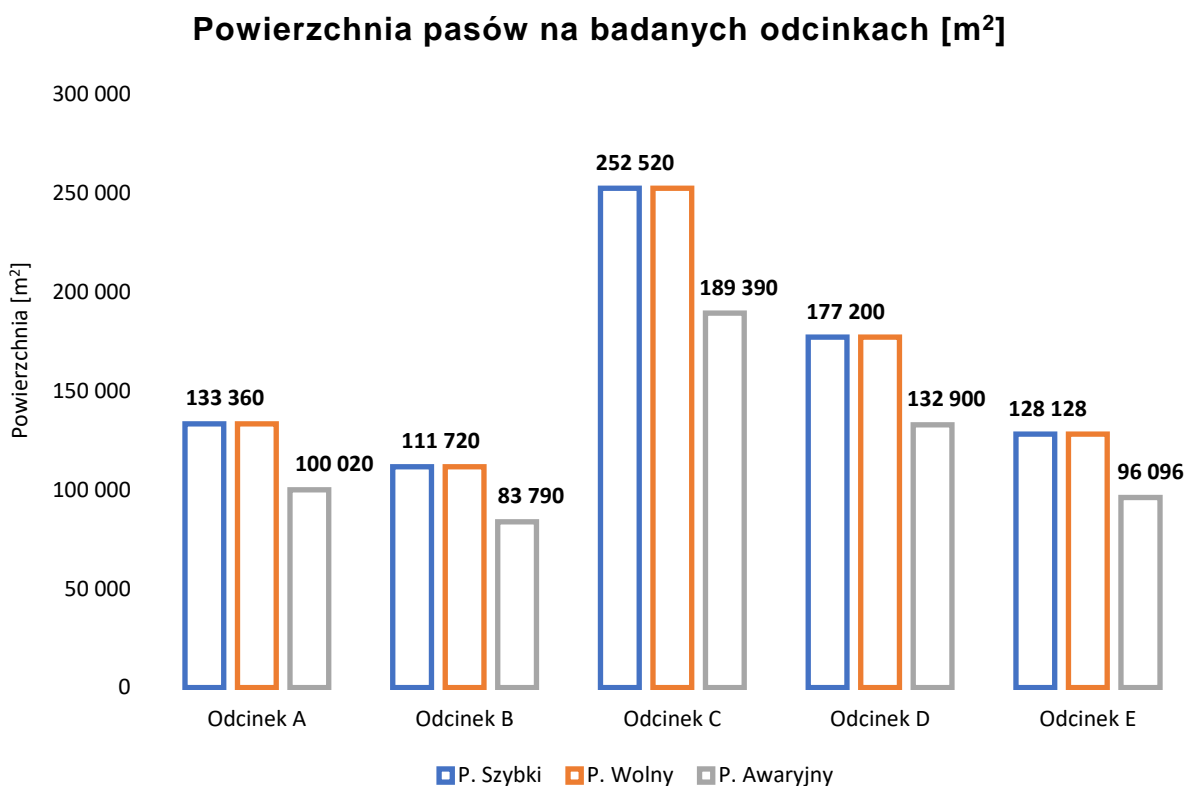
Rysunek 11. Zestawienie długości jezdni z podziałem na odcinki jednorodne A-E



Rysunek 12 Zestawienie powierzchni jezdni z podziałem na odcinki jednorodne (A-E)



Rysunek 13. Zestawienie liczby płyt betonowych z podziałem na odcinki jednorodne (A-E)



Rysunek 14. Zestawienie powierzchni pasów ruchu z podziałem na odcinki jednorodne (A-E)

4.2 Wykonanie nawierzchni

4.2.1 Założenia projektowe

W poniższych podrozdziałach zestawiono główne dane konstrukcyjne z projektu konstrukcji nawierzchni z betonu cementowego autostrady A2 na odcinku Świecko – Nowy Tomyśl.

Projektowane grubości poszczególnych warstw konstrukcji nawierzchni, wykonanych z określonych materiałów z zastosowaniem określonej technologii, musiały zapewnić spełnienie warunki nośności oraz warunki odporności konstrukcji na powstawanie wysadzin. Warunek nośności określono jako trwałość zmęczeniową spełniającą wymaganie prognozy ruchu oraz nie mniejszą niż 40 mln osi 115 kN w całym zakładanym okresie eksploatacji nawierzchni. Warunek odporności na powstawanie wysadzin określono jako zabezpieczenie podłoża gruntowego warstwą mrozoochronną lub jego wzmocnieniem przed szkodliwymi skutkami przemarzania. W rejonie usytuowania analizowanych odcinków głębokość przemarzania gruntu wynosi 80 cm.

4.2.2 Analiza ruchu na etapie projektowania

Wyznaczenie liczby osi obliczeniowych 115 kN przeprowadzono zgodnie z procedurą opisana w „Katalogu Typowych Konstrukcji Nawierzchni Sztywnych” IBDiM Warszawa 2001 [53]. Okres obliczeniowy dla nawierzchni betonowej przyjęto równy 30 lat (od roku 2012 do roku 2042).

Zganie z zaleceniami [53] liczbę osi obliczeniowych wyznaczono na podstawie liczby pojazdów ciężarowych na dobę na pas obliczeniowy w piętnastym roku po oddaniu drogi do eksploatacji (1).

$$L = (N_1 \cdot r_1 + N_2 \cdot r_2 + N_3 \cdot r_3) \cdot f_1 \quad (1)$$

gdzie:

L – liczba osi obliczeniowych na dobę na pas obliczeniowy w piętnastym roku po oddaniu drogi do eksploatacji

$N_{1,2,3}$ – średni dobowy ruch samochodów ciężarowych bez przyczep (N_1), z przyczepami (N_2) i autobusów (N_3) w piętnastym roku po oddaniu drogi do eksploatacji

$r_{1,2,3}$ – współczynniki przeliczeniowe samochodów ciężarowych z i bez przyczep oraz autobusów na osie obliczeniowe

f_1 – współczynnik obliczeniowego pasa ruchu

Średni dobowy ruch pojazdów w punktach pomiarowych w 2005 roku przyjęto według ostatniego Generalnego Pomiaru Ruchu dla „korytarza” A2 od granicy Państwa do

Węzła Modła. Procentowy udział poszczególnych pojazdów w grupie pojazdów ciężkich przedstawia się następująco:

- samochody ciężarowe bez przyczep – 12,5 %
- samochody ciężarowe z przyczepami – 85,4 %
- autobusy – 2,1 %

Do dalszych obliczeń liczby osi obliczeniowych 115 kN założono następujący udział procentowy pojazdów ciężkich:

- samochody ciężarowe bez przyczep – 12,3 %
- samochody ciężarowe z przyczepami – 86,0 % (w tym 80% pojazdów 5-osiowych)
- autobusy – 1,7 %

W tabeli 10 przedstawiono wynikowe liczby osi obliczeniowych 115 kN dla poszczególnych odcinków.


Tabela 10. Struktura ruchu oraz współczynniki przyjęte do obliczenia liczby osi obliczeniowych

Lp.	Odcinek	Liczba osi obliczeniowych 115 kN
1	A	68 050 872
2	B	40 240 694
3	C	40 589 814
4	D	53 580 759
5	E	52 239 403

4.2.3 Przekrój poprzeczny jezdni

Projektowana szerokość płyt w przekroju poprzecznym jezdni dla dwóch pasów ruchu przedstawiona jest na rysunku 15. Długość płyt betonowych założono równą 5,0 m.

Rysunek 15 przedstawia jednocześnie zaprojektowane rozłożenie dybli o średnicy 25 mm i długości 50 cm. W kierunku podłużnym założono 3 kotwy na długość płyty o średnicy 20 mm i długości 80 cm w rozstawie 1,70 m od siebie oraz 0,8 m od krawędzi płyty.



Rysunek 15. Geometria płyt betonowych wraz z rozmieszczeniem dybli (od lewej: pas szybki – 3,75 m, pas wolny – 3,75 m, pas awaryjny 3 m)

Do wymiarowania grubości płyty przyjęto geometrię płyty najbardziej narażonej na oddziaływanie ruchu ciężkiego (tj. występowanie największej liczby obciążeń powtarzalnych od osi pojazdów) znajdującej się na pasie ruchu wolnego, zgodnie z rysunkiem 15. W obliczeniach przyjęto następujące wymiary płyty betonowej (szerokość x długość): 4,0 m x 5,0 m.

4.2.4 Metoda obliczeń trwałości

W celu oszacowania trwałości zmęczeniowej nawierzchni betonowej wyznaczono naprężenia w płycie pochodzące od ruchu pojazdów oraz od temperatury. Podczas obliczeń trwałości nawierzchni zakładano najbardziej niekorzystny wariant występowania naprężeń w płycie.

Zastosowano następującą metodykę obliczeń:

- założono odpowiednią geometrię płyty betonowej,
- założono parametry materiałowe dla poszczególnych warstw,
- obliczono naprężenia wywołane zmianami temperatury,
- obliczono naprężenia od ruchu pojazdów ciężkich,
- uwzględniono wpływ współczynnika przenoszenia obciążeń na zmianę naprężeń w płycie,
- obliczono stopień szkody zmęczeniowej dla trwałości zmęczeniowej dla najbardziej niekorzystnego oddziaływania obciążenia od ruchu (N_1) oraz od najbardziej niekorzystnego kumulatywnego oddziaływania obciążenia od ruchu przy wysokich temperaturach (N_2),
- obliczono trwałość zmęczeniową nawierzchni betonowej (N),
- uwzględniono współczynnik bezpieczeństwa obliczając całkowitą trwałość zmęczeniową konstrukcji nawierzchni (N_{115}),

Do obliczeń przyjęte zostały parametry materiałowe, których wartości zestawiono w tabeli 11.

Tabela 11. Parametry materiałowe przyjęte do obliczeń

Lp	Warstwa	Grubość warstwy h cm	Moduł sprężystości E N/mm ²	Współczynnik Poissona ν	Ciężar właściwy kN/m ³	Wytrzymałość na rozciąganie przy zginaniu f_{cf} N/mm ²
1	Beton cementowy	27 / 28 / 29	35 000	0,2	23,6	5,5
2	Chudy beton	20	1 800	0,2	-	
3	Warstwa mrozochronna	-	$E_2 \geq 120$	0,3	-	

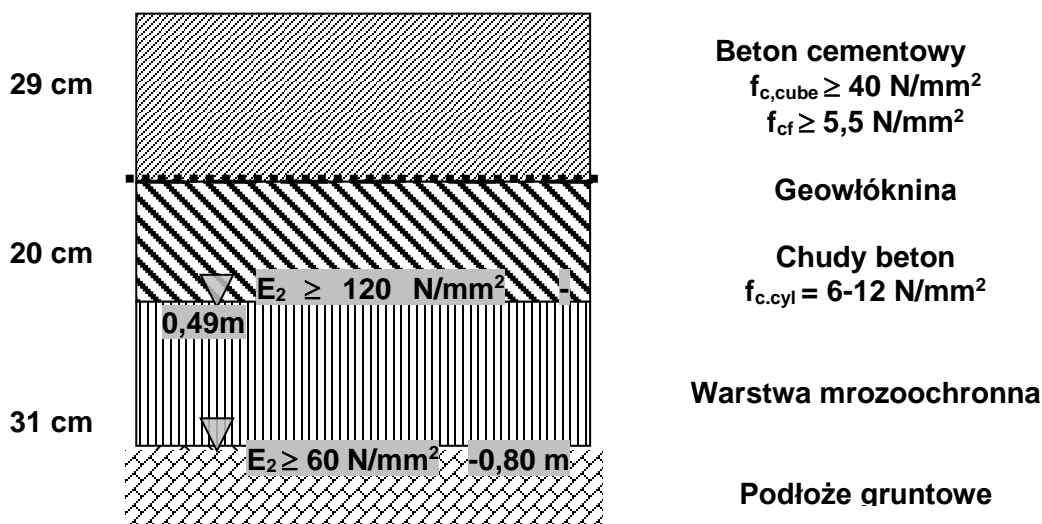
4.2.5 Projektowanie konstrukcji nawierzchni

Wyniki obliczeń trwałości nawierzchni betonowej przy założonym współczynniku bezpieczeństwa γ równym 1,3 oraz okresie oddziaływania wysokiej temperatury równym 25% całkowitego okresu eksploatacji, przedstawiono w tabeli 12.


Tabela 12. Projektowane grubości płyty betonowej oraz podbudowy z chudego betonu na poszczególnych odcinkach oraz trwałość zmęczeniowa nawierzchni wg obliczeń

Odcinek	Projektowana grubość płyty betonowej [cm]	Projektowana grubość chudego betonu [cm]	Prognozowana liczba osi obliczeniowych, mln osi 115 kN	Trwałość zmęczeniowa nawierzchni, mln osi 115 kN
A	29	20	68,1	78,1
B	27	20	40,2	49,2
C	27	20	40,6	49,2
D	28	20	53,6	62,1
E	28	20	52,2	62,1


Projektowana konstrukcja nawierzchni na poszczególnych odcinkach przedstawiona została na rysunkach 16-18.



Rysunek 16. Projektowana konstrukcja nawierzchni betonowej dla odcinka A



Rysunek 17. Projektowana konstrukcja nawierzchni betonowej dla odcinka B i C.



Rysunek 18. Projektowana konstrukcja nawierzchni betonowej dla odcinka D i E

4.2.6 Skład mieszanki betonowej

Skład mieszanki mineralnej stosowanej do betonu cementowego stosowanego na nawierzchnie drogowe ma istotny wpływ na takie parametry jak wytrzymałość na ściskanie oraz rozciąganie, charakterystykę porów powietrznych, mrozoodporność oraz moduł sprężystości betonu. Zastosowanie nieodpowiedniego kruszywa wpływa negatywnie na trwałość nawierzchni a w szczególności na jej mrozoodporność, która przyczynia się do skrócenia okresu jej trwałości oraz szybszej degradacji w postaci uszkodzeń warstwy powierzchniowej w formie odprysków lub łuszczenia [93].

Na analizowanych odcinkach nawierzchni z betonu cementowego zastosowano taką samą mieszankę mineralną z podziałem na dolną warstwę betonu (DWB) i górną warstwę betonu (GWB) według tabeli 12 – 14 (źródło: zatwierdzenia materiałowe na dolną i górną warstwę nawierzchni betonowej).

Tabela 12. Cechy fizycznochemiczne kruszywa – reaktywność alkaiczna

Lp.	Kruszywo	Norma badawcza	Wynik	Wymagania
1	Kruszywo drobne 0/2	PN-92/B-06714/46	0,34%	≤ 0,5%
2	Kruszywo grube 2/8 amfibolit		0,29%	
3	Kruszywo grube 5/8 amfibolit		0,28%	

Tabela 13. Skład mieszanki betonowej w 1m³ na dolną warstwę betonu (DWB)

Lp.	Skład mieszanki	Zawartość [%]	Suma składników	
1	Cement CEM I 42.5 N-NA	15,1	kg	375
2	Woda	5,8	dm ³	143
3	Kruszywo drobne 0/2	19,5	kg	483
4	Kruszywo grube 2/8 amfibolit	9,8	kg	242
5	Kruszywo grube 8/16 amfibolit	20,5	kg	509
6	Grys amfibolitowy 16/22	29,3	kg	726

Tabela 14. Skład mieszanki betonowej w 1m³ na górną warstwę betonu (GWB)

Lp.	Skład mieszanki	Zawartość [%]	Suma składników	
1	Cement CEM I 42.5 N-NA	17,6	kg	420
2	Woda	6,7	dm ³	160
3	Kruszywo drobne 0/2	19,6	kg	467
4	Kruszywo grube 2/8 amfibolit	11,8	kg	282
5	Kruszywo grube 5/8 amfibolit	44,3	kg	1057

Do produkcji mieszanki betonowej (rys.19) wykorzystano kruszywo łamane ze skały amfibolitycznej eksploatowane z jednej z największych w Polsce złóż tego typu surowca zlokalizowanego na Dolnym Śląsku z kamieniołomu „Piława Górna”.

Skała amfibolityczna charakteryzuje się obecnością minerałów z grupy amfiboli, głównie hornblendy oraz często plagioklazów [129]. Posiada ona zwykle ziarnistą teksturę, która może być różnorodna w zależności od warunków, w jakich skała uległa metamorfizmowi [9].

Skąła ta zazwyczaj ma ciemny kolor, od ciemnoszarego do czarnego, który jest wynikiem obecności ciemnych minerałów hornblendy [72]. Amfibolit jest twardą i wytrzymałą skałą, odporną na warunki atmosferyczne, co czyni ją bardzo użyteczną w budownictwie drogowym.



Rysunek 19. Wytwórnia mieszanki betonowej zlokalizowana na Odcinku D

W odniesieniu do przedstawionego składu mieszanki betonowej otrzymano pozytywne wyniki w odniesieniu do stawianych wymagań dla nawierzchni drogowych z betonu cementowego (Tabela 12).

Tabela 12. Cechy mieszanki betonowej oraz betonu (źródło: zatwierdzenia materiałowe na dolną i górną warstwę nawierzchni betonowej).

Lp.	Badana cecha	J.m.	Norma badawcza	DWB [Wynik]	GWB [Wynik]
1	Konsystencja mieszanki mineralnej	-	PN-EN 12350-4	1,27-1,35	1,28-1,38
2	Zawartość powietrza w mieszance betonowej	%	PN-EN 12350-7	5	6,5
3	Odporność na powierzchniowe łuszczenie w obecności NaCl	kg/m ²	PKN-CEN/TS 12390-8	0,1	0,2
4	Wytrzymałość betonu na ściskanie	N/mm ²	PN-EN 12390-3	46,7	52,7
5	Wytrzymałość betonu na zginanie	N/mm ²	PN-EN 12390-5	6,0	6,3
6	Wytrzymałość betonu na rozciąganie	N/mm ²	PN-EN 12390-6	3,3	3,8
7	Gęstość mieszanki betonowej	kg/dm ³	PN-EN 12350-6	2 467	2 387

4.2.7 Technologia wykonania

Nawierzchnię wykonano z betonu cementowego wg PN-EN 206-1 z klasą betonu co najmniej C30/37, jednak z minimalną wytrzymałością na ściskanie na kostkach po 28 dniach $f_{c,cube} \geq 40 \text{ N/mm}^2$ oznaczoną wg PN-EN 12390-3 oraz z minimalną wytrzymałością na zginanie po 28 dniach $f_{ct} \geq 5,5 \text{ N/mm}^2$ oznaczoną wg PN-EN 12390-5. Jezdnię z betonu cementowego wbudowano w dwóch warstwach, warstwie górnej (GWB) i dolnej (DWB).

Teksturowanie powierzchni górnej warstwy wykonano przez częściowe odkrycie kruszywa przy zastosowaniu tzw. technologii „Waschbeton” (z języka niemieckiego) pozwalającej na usunięcie wierzchniej warstewki zaczynu z użyciem środków chemicznych. Górna warstwa betonu spełnia wymagania klasy ekspozycji XF4 tj. odporności na zamrażanie / rozmrażanie oraz odporności na środki odladzające wg PN-EN 206-1 oraz wymagania klasy ekspozycji XM2 ze względu na silny wpływ ścierania wg krajowego załącznika PN-B-06265 do normy PN-EN 206-1. Do warstwy górnej zastosowano kruszywa łamane o wskaźniku polerowalności $PSV \geq 53$, o uziarnieniu do 8 mm. Minimalna zawartość cementu w górnej warstwie betonu wynosi 420 kg/m^3 . Grubość górnej warstwy wynosi co najmniej 5 cm. Dolna warstwa betonu spełnia wymagania klasy ekspozycji XF4.

Płyty betonowe w przekroju poprzecznym wykonane zostały zgodnie z rysunkiem 15. Szczeliny poprzeczne skurczowe wykonano w odległości co 5,0 m. W szczelinach skurczowych wbudowano dyble o średnicy 25 mm i długości równej 50 cm w rozstawie jak na rys. 15. Dyble pokryte są polimerową powłoką antykorozyjną o grubości 0,3 mm. Natomiast w szczelinach podłużnych wbudowano kotwy o średnicy 20 mm i długości 80 cm (środek kotwy, około 20 cm, pokryty powłoką antykorozyjną) w ilości 3 sztuki na płytę w rozstawie 1,70 m od siebie i 0,80 m od krawędzi płyty. Dyble układano równolegle do powierzchni w odległości od powierzchni równej $h/2$, gdzie h jest grubością płyty betonowej. Układarka powinna umożliwiać automatyczne rozkładanie dybli w zaprojektowanej pozycji - połowie grubości warstwy płyty betonowej, równolegle do powierzchni i ustawieniu poziomym. Do wypełnienia szczelin zastosowano masy zalewowe na gorąco.

Pod płytą betonową, na warstwie chudego betonu umieszczono geowłókninę jako warstwę poślizgową oraz zapobiegającą przenoszeniu spękań z podbudowy wykonanej z chudego betonu.

Geowłóknina spełnia następujące wymagania:


- masa od 450 do 550 g/m^2
- grubość pod naciskiem 20 $\text{kN/m}^2 \geq 2,5 \text{ mm}$
- wytrzymałość na rozciąganie $\geq 10 \text{ kN/m}$
- wskaźnik wodoprzepuszczalności w kierunku pionowym $k_{V20.5\%} \geq 1 \cdot 10^{-4} \text{ m/s}$ i w kierunku poziomym $k_{H20.5\%} \geq 5 \cdot 10^{-4} \text{ m/s}$
- odporna na alkalia $\geq 96\% \text{ PP/PE}$

Mieszanka z chudego betonu wykonana została w wytwórniach stacjonarnych zgodnie z zasadami normy PN-S-96013. Wymagana wytrzymałość na ściskanie po 28 dniach znajdowała się w przedziale od 6,0 do 12,0 N/mm^2 . Warstwa podbudowy z

chudego betonu rozkładana była na szerokość o 40 cm większą z każdej strony od warstwy betonu nawierzchniowego. Zagęszczenie mieszanki prowadzono do osiągnięcia wymaganej wartości wskaźnika zagęszczenia $\geq 0,98$ ocenionej na podstawie normalnej próby Proctora wg PN-B-04481. W ramach zabezpieczenia powierzchni przed nadmiernym odparowaniem wody, bezpośrednio po ułożeniu prowadzono skrapianie wodą lub inną odpowiednią metodą przez co najmniej 3 dni. Warstwa mrozochronna została wykonana z materiału, który jest niewysadzinowy i wodoprzepuszczalny ($k > 5,6$ m/dobę). Warstwa spełnia wymaganie nośności w zakresie wtórnego modułu odkształcenia, co najmniej $E_2 = 120$ N/mm² na górze warstwy, czyli bezpośrednio pod warstwą z chudego betonu. Warstwa mrozochronna była wykonywana w 2 wariantach, poprzez rozłożenie i wyprofilowanie mieszanki kruszyw 0/31,5 mm (żużel pomiedziowy KGHM 0/31,5 mm (40%) plus piasek z wykopu (60%) w dwóch warstwach o zbliżonej grubości. W pierwszym etapie rozłożona została dolna część warstwy mrozochronnej za pomocą spycharki i równiarki. Dolna część wyprofilowana została za pomocą równiarki i wstępnie zagęszczona. W drugim etapie rozłożona została górna część warstwy mrozochronnej oraz wyprofilowana za pomocą równiarki z automatycznym sterowaniem do rzędnych i spadków zgodnych z projektem (z zachowaniem dopuszczalnych odchyłek). Całość została zagęszczona za pomocą walców aż do uzyskania wymaganego zagęszczenia. Wykonanie warstwy nawierzchniowej z betonu cementowego na analizowanych odcinkach składało się z następujących procesów technologicznych:

- ułożenia warstwy poślizgowej z geowłókniny,
- produkcji mieszanki betonowej w węźle betoniarskim,
- wbudowania, zagęszczenia i wykończenia mieszanki betonowej przy użyciu mechanicznej układarki,
- wbudowania dybli przez układarkę i kotew przy użyciu ręcznych wibratorów,
- aplikacji środka opóźniającego wiązanie i usunięcia wierzchniej zaprawy,
- aplikacji środka pielęgnacyjnego,
- wykonania szczelin i ich wypełnienia.

Ustawienia układarki do wbudowania mieszanki betonowej zostały wykonane metodą „na linkę” (rys. 20). Szpilki zostały wbite po lewej i prawej stronie podbudowy z chudego betonu w odstępach podłużnych co 5 m. Ustawienie szpilek zostało wykonane metodą geodezyjną z dokładnością ± 1 cm. Po ustawieniu geodezyjnym wysokościowym szpilek z dokładnością do ± 1 mm została przymocowana i naciągnięta linka.



Rysunek 20. Ustawienie układarki przy wykorzystaniu linek i szpilek

Przed rozłożeniem geowłókniny, nieregularne, pojedyncze zanieczyszczenia i luźne ziarna kruszywa zostały wyczyszczone z powierzchni podbudowy z chudego betonu. Geowłóknina została ułożona z 20 cm (± 5 cm) naddatkiem. W pojedynczym punkcie nie było więcej niż trzy warstwy (zakład w kierunku podłużnym i poprzecznym).

W celu zabezpieczenia geowłókniny przed przemieszczeniem się podczas transportu i wbudowania betonu, została ona przymocowana do podbudowy z chudego betonu. Mocowanie odbyło się za pomocą gwoździ.

Mieszanka betonowa była wbudowywana przez zestaw do układania ślizgowego (rys. 21). Maszyna ta zapewnia równe i jednorodne wbudowanie mieszanki betonowej na pełnej szerokości nawierzchni betonowej. Zestaw ten zawiera maszynę, która rozprowadza, zagęszcza i wykańcza beton w ciągłym procesie: pierwsza układarka do niższej warstwy betonu (DWB) i urządzenie do umieszczania dybli, druga układarka do górnej warstwy (GWB) i przygotowania nawierzchni, platforma robocza do rozprowadzania środka opóźniającego wiązanie i środka pielęgnacyjnego do górnej warstwy betonu.



Rysunek 21. Zestaw do układania ślizgowego mieszanki betonowej

Zestaw do układania ślizgowego zagęszcza beton za pomocą wglębnych wibratorów i formuje płytę betonową pomiędzy deskowaniem ślizgowym. Górna warstwa betonu jest umieszczana w zbiorniku celem przetransportowania za pomocą taśmociągu (rys. 22) do układarki górnej warstwy betonu. W celu niedopuszczania do wymieszania się różnych mieszanek nawierzchni betonowej wglębne wibratory umieszczone na drugiej układarce są odpowiednio ustawione co do rozmieszczenia, częstotliwości i amplitudy.




Rysunek 22. Taśmociąg transportujący beton do układarki górnej warstwy betonu

Poziom ułożenia dybli i kotew (rys. 23) był kontrolowany automatycznie z prowadnicy linki za pomocą sensora. Ustawienie układarki było kontrolowane automatycznie z prowadnicy linki przez przynajmniej jeden sensor przymocowany do układarki. Ostateczna regulacja położenia górnej powierzchni warstwy betonowej nawierzchni była wykonywana za pomocą podłużnego oscylującego pływaka poruszającego się w poprzek płyty. Koniec układanej działki został odpowiednio przedłużony tak, aby w miejscu ostatniej spiny po odcięciu wykończenia, ostatnia płyta posiadała wymaganą długość, grubość i równość. Odcięcie zostało wykonane prostopadle do osi na całej szerokości jezdni, po uzyskaniu odpowiedniej wytrzymałości stwardniałego betonu, umożliwiającej na wjazd piły do cięcia. Odcięty koniec układanego odcinka został usunięty, a w przeciętej płycie nawierzchni zostały nawiercone otwory na dyble. Przed rozpoczęciem układania nowego odcinka, w nawierconych otworach zostały zamontowane dyble.

Zestaw do układania ślizgowego zapewnia automatyczne umieszczanie dybli (rys. 24) w dolnej części warstwy betonu na projektowane położenie, równoległe do nawierzchni i w poziomym wyrównaniu na $\frac{1}{2}$ głębokości płyty

betonowej z podłużną tolerancją ± 50 mm, odległość pomiędzy dyblami z tolerancją ± 50 mm , w innych kierunkach ± 20 mm.



Rysunek 23. Proces wbudowywania dybli w mieszankę betonową



Rysunek 24. Automatyczny proces umieszczania dybli w mieszance betonowej

Kotwy były umieszczone za pomocą ręcznych wibratorów (rys. 25) w wyrównaniu do podłużnych szczelin w odległościach zgodnych z projektem na 2/3 grubości płyty, mierzone od góry nawierzchni. Pręty kotew były ułożone w rozstawie 3 sztuk na płytę przy długości płyty 5 m, odległość pomiędzy kotwami wynosiła 1,70 m od siebie i 0,80 m od krawędzi płyty.



Rysunek 25. Ręczne umieszczanie kotew w mieszance betonowej

W celu zapewnienia odpowiedniej trwałości cech powierzchniowych nawierzchni betonowej, bardzo ważny element wykonania robót nawierzchniowych stanowi zabieg pielęgnacji, prowadzony w odpowiednio długim okresie, jak również zabezpieczenie powierzchni dostosowane do aktualnych warunków wbudowania mieszanki (rys. 26). Dodatkowo w celu przedłużenia pielęgnacji wbudowanej mieszanki betonowej, nawierzchnia była spryskiwana z platformy roboczej środkiem opóźniającym wiązanie i środkiem pielęgnacyjnym. Aplikacja środków została wykonana przez automatyczny spryskiwacz z ochronną osłoną zabezpieczającą przed wiatrem. Boki płyty zostały zabezpieczone środkiem pielęgnacyjnym przez spryskiwanie z platformy roboczej. Wymagany czas wiązania betonu poniżej powierzchni był sprawdzany ręcznie przy pomocy ręcznej szczotki. Kiedy beton był wystarczająco twardy aby wykluczyć wykruszanie się nawierzchni, na planowanej długości nawierzchni można było rozpocząć szczotkowanie. Szczotkowanie było wykonane za pomocą mechanicznych stalowych szczotek w podłużnych pasach do osiągnięcia właściwej głębokości makrotekstury (rys. 27).



Rysunek 26. Pielęgnacja górnej warstwy nawierzchni betonowej



Rysunek 27. Nadawanie powierzchni jezdni z betonu cementowego odpowiedniej tekstury

Pierwsze cięcie szczelin skurczowych było wykonane tak szybko jak tylko beton związał na tyle mocno, aby mogła wjechać maszyna z piłą i zanim pojawią się przypadkowe spękania w płycie. Drugie cięcie zostało wykonane po osiągnięciu przez warstwę betonu twardości pozwalającej na uzyskanie równych szczelin.

Podłużne szczeliny były wykonane w tym samym czasie, po wykonaniu poprzecznych szczelin w nawierzchni. Pierwsze cięcie szczelin poprzecznych (rys. 28) wykonano na głębokość $\frac{1}{4}$ grubości warstwy nawierzchniowej z betonu cementowego i o szerokości 3 mm. Pierwsze cięcie szczelin podłużnych

wykonano na 1/3 grubości płyty i o szerokości 3 mm. Szczeliny poprzeczne zostały wykonane w rozstawie co 5 m. Drugie cięcie szczelin podłużnych wykonano o szerokości 8mm i głębokości 3 cm z 3x3mm fazowaniem.

Wypełnianie dolnej szczeliny polegało na uszczelnieniu jej przez wciśnięcie sznura uszczelniającego (kordu) o średnicy większej o około 25% od szerokości szczeliny. Boczne ścianki były zagruntowane środkiem zwiększającym przyczepność masy zalewowej. Gruntowanie szczeliny było przeprowadzone poprzez wprowadzenie preparatu gruntującego do wnętrza szczeliny pod ciśnieniem za pomocą ręcznego spryskiwacza. Przystąpienie do wypełniania szczeliny następowało po odparowaniu rozpuszczalnika z gruntownika.



Rysunek 28. Proces cięcia szczelin skurczowych w nawierzchni betonowej

Wypełnienie szczeliny masą zalewową wykonano z użyciem sprzętu mechanicznego (rys. 29). Zalewę wprowadzano do szczeliny pod ciśnieniem w celu uzyskania menisku wklęsłego 0 do -5 mm.



Rysunek 29. Proces mechanicznego wypełniania szczelin w nawierzchni z betonu cementowego


5 Modyfikacja wizualnej metody oceny stanu technicznego nawierzchni betonowych

W diagnostyce nawierzchni drogowych sukcesem, jeżeli chodzi o wdrożenie nowych urządzeń lub rozwiązań, jest ich pozytywna weryfikacja na eksploatowanej drodze [102]. Powtarzalne i wiarygodne dane o stanie technicznym nawierzchni odgrywają ważną rolę w opracowywaniu wskaźników stanu, modeli wydajności, zrozumieniu, w jaki sposób i dlaczego nawierzchnie sprawdzają się lepiej niż inne, a także w znalezieniu opłacalnych rozwiązań potrzeb w zakresie utrzymania nawierzchni. Dobre i wiarygodne dane o stanie nawierzchni również odgrywają ważną rolę w określaniu jej parametrów użytkowych [13].

Jedną z głównych przyczyn przystąpienia do modyfikacji aktualnie stosowanej metody automatycznej oceny uszkodzeń powierzchniowych wg. DSN za pomocą pojazdu wyposażonego w system LCMS była wykonana w 2015 r. próba identyfikacji defektów nawierzchni przez wykonawcę, który jako jeden z nielicznych podmiotów w Polsce był w posiadaniu w tamtym okresie tego typu sprzętu. W jej wyniku stwierdzono nieskuteczność tej metody w zakresie analizowania uszkodzeń nawierzchni z betonu cementowego z zastosowaniem tekstury z odkrytym kruszywem. Główne wady automatycznej oceny cech powierzchniowych dotyczyły analizy uszkodzeń w zakresie zdjęć, których obszar obejmował powierzchnię o długości 10 m i szerokości 4 m, co przy płytach o rozmiarach 4x5 m i 3x5 m zaprojektowanych i wykonanych na analizowanych odcinkach uniemożliwiało uzyskanie pełnego obrazu pojedynczej płyty.


Należy zwrócić szczególną uwagę na to, że w przypadku nawierzchni z betonu cementowego proces identyfikacji uszkodzeń jest bardzo trudny ze względu na różne typy tekstury górnej powierzchni, która wykonywana jest przy zastosowaniu różnych narzędzi (rys. 30). Proces ten ma istotny wpływ na zwiększenie wartości współczynnika tarcia na styku opon pojazdów i nawierzchni, poprawę bezpieczeństwa na drodze, zapewnienie komfortu jazdy, również na skuteczność odprowadzenia wód opadowych (przeciwdziałanie zjawisku akwaplaningu) oraz zredukowanie emitowanego hałasu drogowego [73].

Dodatkowo specyfika nawierzchni betonowej, która została wykonana w technologii płyt dyblowanych i kotwionych, poprzez występowanie dylatacji poprzecznych i podłużnych wpływało to wielokrotnie na zaliczanie ich do uszkodzeń jako spękania podłużne lub poprzeczne. Kolejnym aspektem, z którym system miał duży problem, była tekstura powierzchni jezdni z betonu cementowego wykonana w technologii odkrytego kruszywa, co było oznaczane w wielu obszarach powierzchni jako ubytki uziarnienia. Natomiast najistotniejszą wadą oceny stanu powierzchni były liczne braki w identyfikacji istotnych uszkodzeń nawierzchni betonowej (rys. 31), przez co proaktywny proces utrzymaniowy w zakresie prowadzonych prac naprawczych był istotnie utrudniony lub niemożliwy.




Rysunek 30. Technologia wykańczania nawierzchni betonowej za pomocą a) szczotki stalowej b) tkaniny jutowej [76] c) odkryte kruszywo, d) szlifowanie i rowkowanie

W dalszej części opisana jest realizacja badań polegających na modyfikacji metody oceny identyfikacji cech powierzchniowych nawierzchni z betonu cementowego na 5 odcinkach autostrady, które były prowadzone sześć lat z rzędu. Projekt identyfikacji uszkodzeń nawierzchni betonowej o łącznej długości 606 km pasów ruchu oraz pasów awaryjnych wykonano w okresie od roku 2016 do roku 2021, który rozszerza zakres identyfikacji uszkodzeń w zakresie dotychczas stosowanych wytycznych SOSN-B, jak i wytycznych Diagnostyki Stanu Nawierzchni (DSN) obowiązujących od roku 2015.



Rysunek 31. Przykładowy obszar badawczy uzyskany z pojazdu pomiarowego wyposażonego w urządzenie LCMS realizowany wg. DSN

Prowadzona w ramach zmodyfikowanej oceny cech powierzchniowych nawierzchni z betonu cementowego diagnoza w odróżnieniu od wytycznych DSN umożliwia analizę każdej pojedynczej płyty betonowej jako niezależnego obiektu (rys. 32) oraz identyfikacji wszystkich możliwych uszkodzeń występujących na jej powierzchni tj. zarówno uszkodzeń jak i dokonanych napraw co ma istotne znaczenie dla prowadzenia skutecznego procesu utrzymaniowego a ostatecznie na okres cyklu życia nawierzchni (LCA/LCM).




Zdjęcie prezentuje fragmenty 3 płyt
 Zdjęcie prezentuje pełny obszar płyty
 Rysunek 32. Porównanie wizualizacji obszaru z pojazdu pomiarowego wyposażonego w urządzenie LCMS oraz obszaru w ramach zmodyfikowanej metody oceny cech powierzchniowych

5.1 Realizacja prac

Projekt ze względu na swoją złożoność został podzielony na 4 etapy, co zagwarantowało możliwość skutecznej kontroli nad przebiegiem realizacji oraz pozwoliło na wykonywanie pewnych prac równolegle. Było to niezbędne, aby skrócić czas realizacji badań. Na rysunku 33 przedstawiono schematycznie przebieg realizacji projektu tj.:

- opracowanie dedykowanej mapy geodezyjnej nawierzchni betonowej (1);
- pomiary terenowe – rejestracja powierzchni jezdni (2);
- kalibracja zdjęć powierzchniowych oraz identyfikacja uszkodzeń (3);
- identyfikacja i weryfikacja uszkodzeń płyt betonowych w terenie (4).

Wykonanie zdjęć obejmowało akwizycję obrazu powierzchni jezdni oraz zdjęć korytarza drogi, co zostało zrealizowane poprzez wykorzystanie odpowiedniego pojazdu pomiarowego.



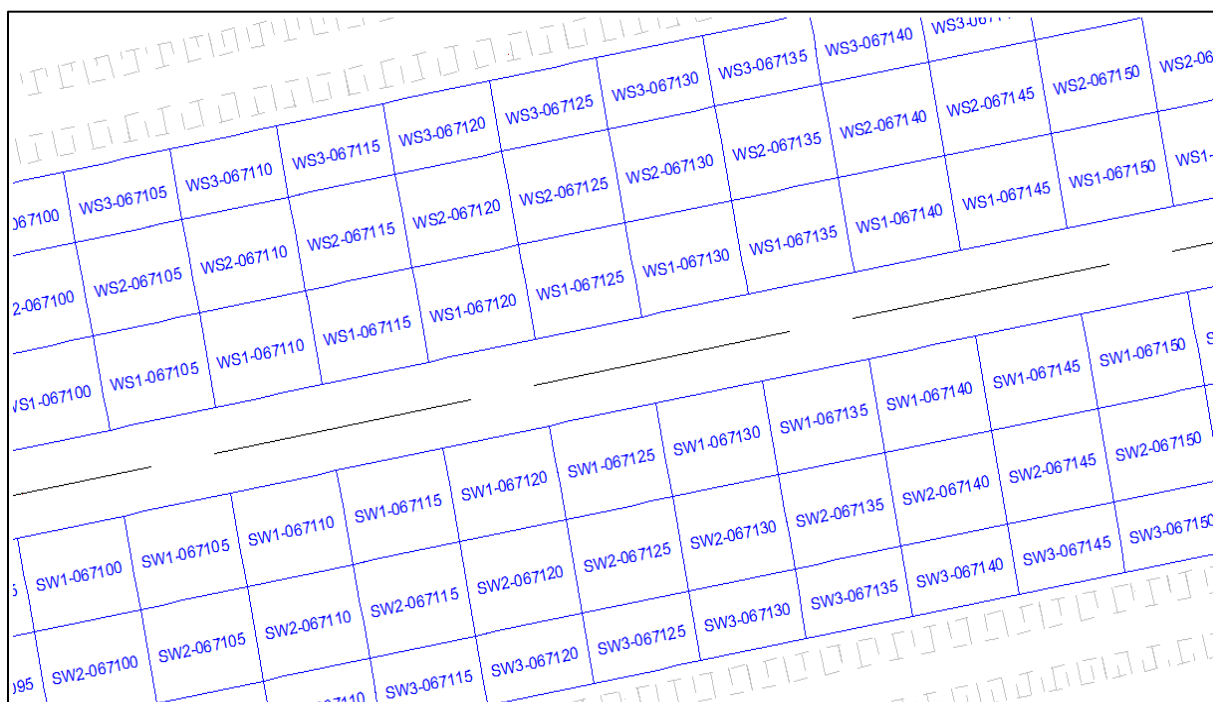
Rysunek 33. Etapy realizacji projektu modernizacji oceny wizualnej

Diagnoza nawierzchni z betonu cementowego wg. zmodyfikowanej metody jest opracowywana corocznie na koniec maja danego roku. Ocenie podlega nawierzchnia obejmująca 120 438 szt. płyt betonowych.

Po przejściu materiału zebranego przez pojazd pomiarowy, zdjęcia podlegały przetwarzaniu, które składało się m.in. z wyrównania oświetlenia zdjęć oraz ich kalibracji. Proces identyfikacji uszkodzeń był ściśle powiązany z wewnętrzną kontrolą identyfikacji uszkodzeń, która zapewniła spójność identyfikacji oraz oznaczenie uszkodzeń, wymagających uwagi dla nawierzchni z betonu cementowego. Podczas analizy wyników identyfikacji, każde uszkodzenie zostało ocenione wg. podziału uszkodzeń określonych w SOSN-B.

Podstawą każdego systemu wspomagającego utrzymanie infrastruktury drogowej są informacje ewidencyjne o zarządzanych zasobach. Szczególną cechą tej grupy informacji jest fakt, że charakteryzują się one długim okresem aktualności, a wiele z nich nie ulega zmianie przez cały cykl życia obiektu. Dodatkowo, wychodząc z założenia, że nowoczesna diagnostyka nawierzchni powinna opierać się na uporządkowanych i wiarygodnych pomiarach, opracowano dedykowaną mapę geodezyjną nawierzchni wraz z systemem znakowania każdej analizowanej płyty, tak

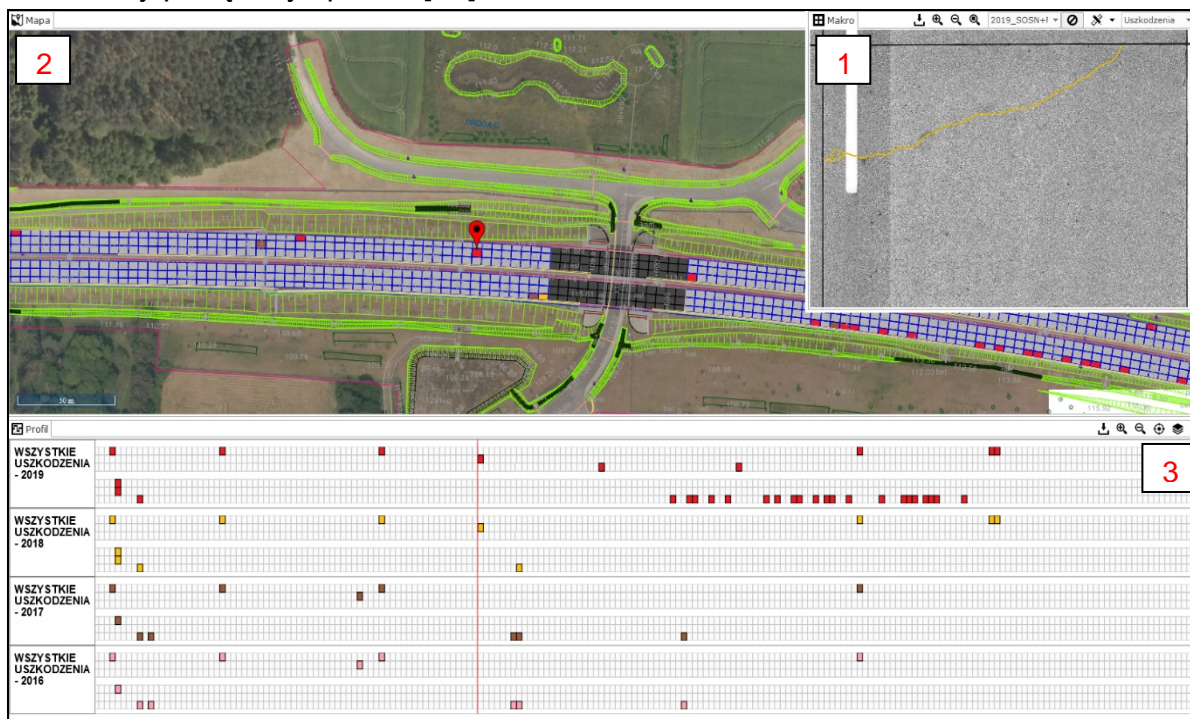
aby wyeliminować powstające błędy wynikające z odczytów GPS i licznika przebiegu zainstalowanych na pojazdach pomiarowych (w zakresie do 10 lub 20 metrów) między różnymi kampaniami, które są dopuszczalne w odniesieniu do większości procedur utrzymaniowych. W odniesieniu do nawierzchni z betonu cementowego wymagane jest przypisanie danego uszkodzenia do konkretnej płyty. Identyfikacja wszystkich płyt betonowych została wykonana poprzez przypisanie im współrzędnych x, y a następnie nadano im indywidualny numer (rys. 34) przez co uzyskana została wymagana powtarzalność w odniesieniu do każdej płyty, a ich lokalizacja w terenie przez służby utrzymaniowe jest łatwa i szybka poprzez zastosowanie odpowiedniego urządzenia.



Rysunek 34. Przykład zewidencjonowania każdej płyty betonowej (120 438 szt.) oraz nadania jej uniwersalnego numeru

Pozwoliło to na uzyskanie seryjnych wyników na poziomie pojedynczej płyty. Tego typu podejście jest niezbędne, aby zapewnić uzyskanie zsynchronizowanych danych, które będą służyć do dalszej oceny stanu technicznego nawierzchni. Umożliwia ono również prowadzenie szczegółowej analizy cyklu życia na poziomie pojedynczej płyty a nie na kilkunastometrowych odcinkach diagnostycznych, co ma kluczowe znaczenie w przypadku nawierzchni z betonu cementowego wykonanych w technologii płyt dyblowanych i kotwionych. Dodatkowo zastosowana metoda identyfikacji, powoduje brak konieczności ingerencji w urządzenia zamontowane na drodze w celu ich oznaczania. Wyniki inwentaryzacji uszkodzeń cech powierzchniowych nawierzchni zostały zaimportowane do odpowiednio zaprojektowanej platformy gromadzącej dane do dalszych ich analiz (rys. 35). Przedstawiona zawartość okien na rysunku 35 jest zsynchronizowana ze sobą tj. wybrana lokalizacja w jednym oknie powoduje natychmiastową aktualizację

pozostałych okien. W związku z tym wszystkie wizualizacje danych pomiarowych poszczególnych kampanii (historycznych oraz aktualnych) można łączyć i analizować w dowolny pożądanym sposób [94].



Rysunek 35. Przykładowy widok okna systemu do przetwarzania danych uzyskanych ze zmodyfikowanej metody oceny powierzchni jezdni z betonu cementowego: 1) zdjęcie makro pojedynczej płyty betonowej w odniesieniu do konkretnej kampanii pomiarowej, 2) mapa geodezyjna z oznakowaniem i lokalizacją w terenie wszystkich pojedynczych płyt betonowych, 3) profil tematyczny ze zdefiniowanymi danymi.

Skuteczność przedstawionego rozwiązania została potwierdzona na odcinku drogi o nawierzchni z betonu cementowego (płyty dyblowane i kotwione) o długości około 202 km (w przeliczeniu na rzędy płyt to około 606 km), składającej się ze 120 438 sztuk płyt o wymiarach (szerokość x długość) 4x5 m i 3x5 m.

5.2 Wykonanie pomiarów

Badania powierzchni jezdni zostały wykonane za pomocą systemu pomiarowego SPDE (System for Pavement Distress Evaluation) produkcji firmy Greenwood (rys. 36). Zawiera on w sobie kilka podsystemów pomiarowych, działających w oparciu o wspólne oprogramowanie. System SPDE może być wykorzystany do badania cech nawierzchni takich jak profil podłużny i poprzeczny, teoretyczna głębokość filmu wodnego w koleinie, pochylenia podłużne i poprzeczne jezdni, tekstura nawierzchni. SPDE spełnia wymagania stawiane urządzeniom wykonującym pomiary równości podłużnej i poprzecznej określone przez Międzynarodową Organizację Normalizacyjną (ISO) w normie PN-EN 13036-6 „Pomiary poprzecznych i podłużnych profili w zakresie długości fali równości i mega tekstury [73].



Rysunek 36. System pomiarowy SPDE produkcji firmy Greenwood

SPDE umożliwia rejestrację cyfrowego obrazu powierzchni jezdni i występujących na niej uszkodzeń na szerokości do 3,9 m z rozdzielczością 1 mm x 1 mm. Zaprojektowany został z myślą o prowadzeniu badań na sieci drogowej niezależnie od panujących warunków ruchu. Dzięki użyciu technologii oświetlenia LED pozostaje również niewrażliwy na zmieniające się warunki oświetleniowe (rys. 37).




Rysunek 37. Oświetlenie LED gwarantuje wysoką jakość zdjęć powierzchni jezdni (źródło IBDiM)

Błyski światła LED mają wysoką intensywność w widmie światła nagrywanego, które kilkukrotnie przewyższa intensywność światła dziennego. Dodatkowo umieszczona z przodu pojazdu kamera umożliwia fotorejestrację pasa drogowego. Zastosowane zaawansowane technologie pomiarowe (GPS, Odometer) pozwalają na precyzyjną lokalizację uzyskiwanych danych pomiarowych.

5.3 Przetwarzanie zdjęć

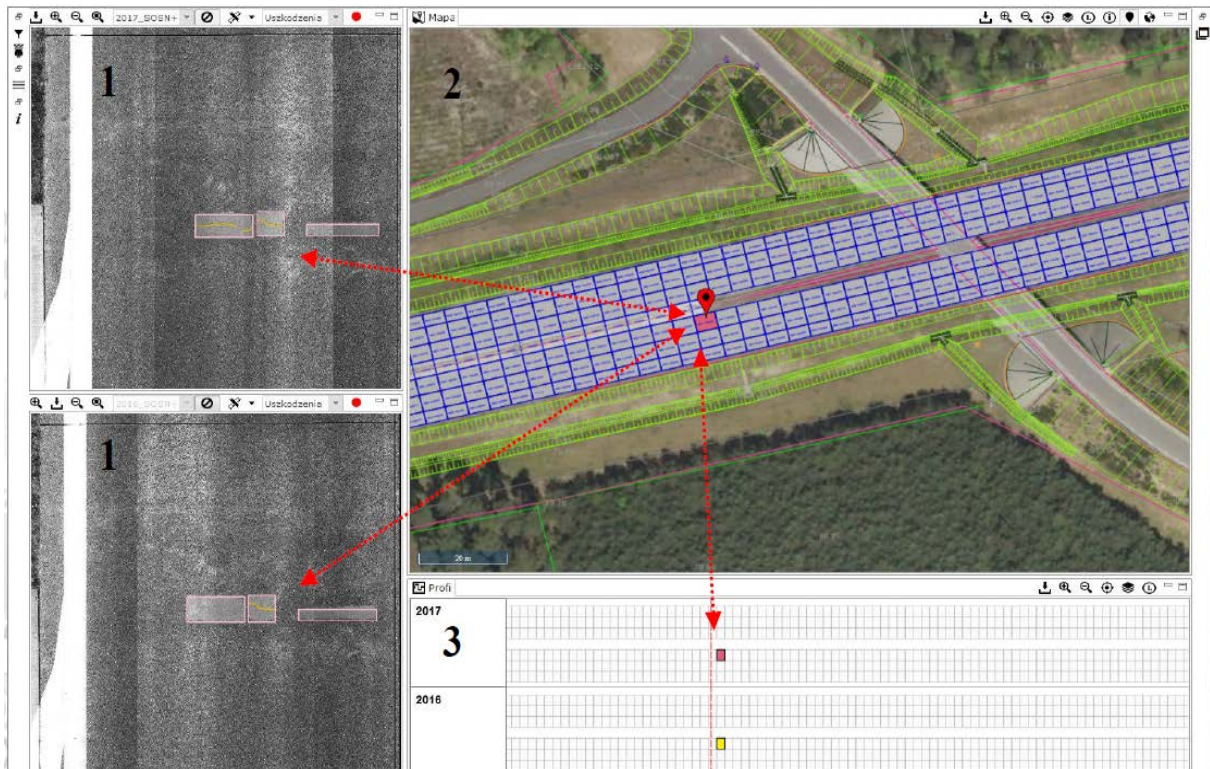
Ponieważ wymiary płyt na zasadniczych pasach ruchu były zbyt szerokie w stosunku do możliwości urządzenia pomiarowego i nie mogły one zostać uchwycone w jednym przejeździe pojazdu pomiarowego, zdjęcia wykonane przez pojazd SPDE zostały poddane dodatkowemu przetworzeniu i kalibracji, dzięki czemu możliwe było wykonywanie na nich pomiarów długości i określenie powierzchni zidentyfikowanych uszkodzeń. Krok ten był niezbędny do przeprowadzenia precyzyjnej identyfikacji uszkodzeń nawierzchni z betonu cementowego. Kalibrację zdjęć wykonano przy zastosowaniu przekształceń afinicznych tzn. przekształceń geometrycznych przestrzeni euklidesowych. Dla precyzyjnej analizy zidentyfikowanych uszkodzeń zdjęcia makro przetworzono w taki sposób aby pojedyncze zdjęcie przedstawiało pojedynczą płytę o pionowych prostych krawędziach podłużnych, na których zakodowano geometrię każdego uszkodzenia. Zdjęcia posiadają margines od 15 do 35 cm (rys. 38).



Rysunek 38. Przykład zdjęcia powierzchni płyty betonowej po kalibracji i doświetlaniu z zaznaczonym naprawionym uszkodzeniem narożnika (oznaczenie uszkodzenia UNn).


W przedstawionym przykładzie płyta w rzeczywistości ma rozmiar 4 m szerokości i 5 m długości, rozmiar zdjęcia w pikselach to 4072x5258.

W nazwie pliku ze zdjęciem oraz na samym zdjęciu (rys. 38) znajduje się sygnatura płyty, zaś same pliki zostały zapisane w uporządkowanych katalogach odpowiadających kolejnym odcinkom oraz pasom nawierzchni tak, żeby odnalezienie zdjęcia dowolnej płyty było szybkie i łatwe w celu zaimportowania ich do dedykowanego oprogramowania przedstawionego na rysunku 39.



Rysunek 39. Widok okna do analizy danych z przetworzonych zdjęć powierzchni jezdni.

Podczas przetwarzania, zdjęcia podlegały doświetlaniu w miejscach nierównego oświetlenia (rys. 40). Zabiegi te wykonano w celu polepszenia jakości zdjęć oraz ułatwienia interpretacji zdjęć w procesie identyfikacji, a tym samym skutecznego odnajdywania uszkodzeń na płytach.



Rysunek 40. Przykład zdjęcia powierzchni płyty betonowej przed doświetleniem (po lewej) i po doświetleniu (po prawej)

5.4 Identyfikacja uszkodzeń

Pod pojęciem uszkodzenia w niniejszej pracy określane są efekty powodujące pogorszenie parametrów technicznych, a w rezultacie stanu technicznego nawierzchni z betonu cementowego. Identyfikacja uszkodzeń została przeprowadzona na podstawie zdjęć nawierzchni oraz zdjęć z kamery frontowej, która w pewnym stopniu umożliwia ocenę wymiarów w kierunku prostopadłym do płyty (np. ocena głębokości). Dodatkowo, poprzez zastąpienie subiektywnej oceny obserwatora, obiektywną oceną geometrii i obmiaru uszkodzeń (szerokości, długości, powierzchni) z parametrami wyświetlanymi na ekranie urządzenia (warto zauważyć, że takie podejście umożliwia studiowanie przypadków na dużych populacjach), czyni ocenę stanu technicznego nawierzchni wiarygodną, pozbawioną wad subiektywności charakterystycznej dla oceny wizualnej. Tego typu podejście umożliwia również analizę zmian stanu nawierzchni pomiędzy kampaniami i po naprawach w celach analitycznych i kontrolnych.

Dla każdej uszkodzonej płyty zostały zidentyfikowane i sklasyfikowane występujące na niej defekty. Uszkodzenia zidentyfikowane zostały zgodnie z katalogiem (tab. 13), który jest zmodyfikowany w stosunku do wymagań SOSN-B oraz DSN. Dla uszkodzeń liniowych i powierzchniowych została określona długość i szerokość uszkodzenia. Dodatkowo, zgodnie z wytycznymi SOSN-B zidentyfikowane zostały naprawione lub zabezpieczone (uszczelnione) uszkodzenia typu PL, PT, UN, UP i WS.

Przy identyfikacji wymienionych parametrów wykorzystywano zdjęcia powierzchni jezdni oraz zdjęcia frontowe, co pozwoliło na oszacowanie głębokości uszkodzeń. To jest niezbędne do określenia potencjalnej szkodliwości danych defektów nawierzchni. Należy pamiętać, iż nawierzchnia identyfikowanego odcinka została wykonana w technologii waschbeton z odsłoniętym kruszywem w górnej warstwie betonu (powierzchnia z odkrytym kruszywem o głębokości makrotekstury do 1,5 mm), co przy aktualnie stosowanych metodach może mieć wpływ na skuteczną identyfikację potencjalnych uszkodzeń powierzchniowych. Zakwalifikowanie potencjalnych uszkodzeń powierzchniowych jest wykonywane na podstawie obserwacji materiału zdjęciowego, bez wykorzystania dodatkowej aparatury pomiarowej. W wyniku przeprowadzonej identyfikacji uszkodzeń, zaobserwowano liczne uszkodzenia, których wprost nie można było przypisać do katalogu typowych uszkodzeń stosowanego do identyfikacji nawierzchni z betonu cementowego zgodnie z SOSN-B lub DSN. Dlatego w zestawieniu uszkodzeń wyodrębniono dodatkowo uszkodzenie pn. „Wykruszenie krawędzi” oznaczone symbolem WK oraz jego odpowiednik WKn (naprawione wykruszenie krawędzi).

Tabela 13. Parametry identyfikowanych uszkodzeń

Lp.	Uszkodzenie	Symbol	Wymiar	
			Powierzchnia	Długość
1	Pęknięcie pojedyncze podłużne/ukośne	PL	-	[m]
1a	<u>Uszczelnione</u> pęknięcie pojedyncze podłużne/ukośne	PLn	-	[m]
2	Pęknięcie pojedyncze poprzeczne	PT	-	[m]
2a	<u>Uszczelnione</u> pęknięcie pojedyncze poprzeczne	PTn	-	[m]
3	Pęknięcie przy krawędzi	PK	-	[m]
4	Uszkodzenie narożnika	UN	[m ²]	-
4a	<u>Naprawione</u> uszkodzenie narożnika	UNn	[m ²]	-
5	Wykruszenie szczeliny	WS	[m ²]	-
5a	<u>Naprawione</u> wykruszenie szczeliny	WSn	[m ²]	-
6	Wykruszenie krawędzi	WK	[m ²]	-
6a	<u>Naprawione</u> Wykruszenie krawędzi	WKn	[m ²]	-
7	Uszkodzenia powierzchni (pęknięcia powierzchniowe, złuszczenia, ubytki)	UP	[m ²]	-
7a	<u>Naprawione</u> uszkodzenia powierzchni	UPn	[m ²]	-

6 Prognozowanie trwałości nawierzchni betonowej z wykorzystaniem sztucznych sieci neuronowych (SSN)

6.1 Sztuczne sieci neuronowe

Sztuczne sieci neuronowe (ang. Artificial Neural Networks, ANN) to rodzaj algorytmów i modeli matematycznych inspirowanych biologicznymi sieciami neuronów w mózgu. Sztuczne sieci neuronowe (SSN) powstały dzięki poznaniu zasad działania systemów nerwowych istot żywych i wykorzystaniu tej wiedzy w poszukiwaniach nowych rozwiązań technologicznych. Początek prac nad sieciami neuronowymi jest datowany na przełom lat 50. i 60. ubiegłego wieku, gdy podjęto próby stworzenia sztucznych systemów przetwarzania informacji wykorzystujących wzorce biologiczne. Brak większych sukcesów oraz przekonanie o ograniczonym zakresie praktycznych zastosowań [78] spowodowały zahamowanie tempa badań nad sieciami neuronowymi od początku lat 70. do połowy 80. Rozwój technik komputerowych w latach 80. oraz opracowanie rozwiązań teoretycznych dotyczących sieci wielowarstwowych zapoczątkowały istotny, trwający nieustannie do dziś, rozwój technologii neuronowych. Podstawy teoretyczne zastosowań sieci neuronowych jako narzędzi przetwarzania informacji oraz jako narzędzi niesymbolicznej reprezentacji wiedzy przedstawiają liczne specjalistyczne monografie [20, 45, 48, 65]. W naszym kraju w obrębie tego obszaru badań znane są m.in. prace [8, 66, 67, 68, 82, 90]. W sztucznych sieciach neuronowych, zamiast neuronów biologicznych, wykorzystuje się sztuczne neurony, które są połączone ze sobą w warstwy. Każda warstwa składa się z jednego lub wielu neuronów, a połączenia między nimi mają różne wagi. Wagi te są modyfikowane w trakcie procesu uczenia, aby sieć neuronowa mogła nauczyć się rozpoznawać wzorce lub dokonywać predykcji na podstawie danych wejściowych. Sztuczne sieci neuronowe znalazły zastosowanie w wielu dziedzinach (rys. 41), w tym w rozpoznawaniu obrazów i dźwięków, przetwarzaniu języka naturalnego, analizie finansowej, medycznej i przemysłowej, a także w sterowaniu robotami i autonomicznymi pojazdami.



Rysunek 41. Przykład zastosowania sieci neuronowych [55]

Początek zastosowania sztucznych sieci neuronowych w zagadnieniach zarządzania przedsiębiorstwami budowlanymi datowany jest na wczesne lata dziewięćdziesiąte ubiegłego wieku [55]. Sztuczne sieci neuronowe można zastosować do rozwiązań nieliniowych problemów inżynierskich, takich jak przewidywanie i szacowanie, rozpoznawanie wzorców i optymalizacja [1, 10]. Obecnie coraz częściej stosuje się sztuczną inteligencję do optymalizacji zagadnień inżynierskich, a zwłaszcza takich, które charakteryzują się losowością i dużą zmiennością w czasie. Sieci neuronowe posiadają wiele właściwości, dzięki którym mogą stanowić nieodzowny instrument do analizy i prognozowania szeregów czasowych. Ich atrakcyjność wynika przede wszystkim z zdolności aproksymacji dowolnych nieliniowości oraz dostrajania przyjętej struktury na podstawie danych z badań terenowych. Co istotne, proces budowy modelu neuronowego polega na eksploracji dostępnych zbiorów danych i prowadzi do całkowicie automatycznego oszacowania na tej podstawie modelu opisującego stwierdzone prawidłowości i współzależności. Stosowanie modeli neuronowych nie wymaga w związku z tym znajomości postaci funkcji opisującej istniejącą prawidłowość. W efekcie modele neuronowe mogą znaleźć zastosowanie wszędzie tam, gdzie nie jest znane dokładne prawo opisujące kształtowanie się badanych zależności [100]. Sieci SSN są cennymi narzędziami obliczeniowymi, które są coraz częściej wykorzystywane do rozwiązywania złożonych problemów wymagających dużej ilości zasobów jako alternatywa dla stosowania bardziej tradycyjnych technik. SSN wykorzystywane były jako narzędzia analizy strukturalnej nawierzchni do szybkiego i dokładnego przewidywania profili ugięcia nawierzchni poddanych typowym obciążeniom autostradowym. Wykorzystanie SSN w ramach wstecznej propagacji w programie komputerowym do wstecznego obliczania modułów sprężystości warstw nawierzchni

spowodowało osiągnięcie 42-krotnego wzrostu szybkości przetwarzania [74]. Zespół projektu badawczego pracujący nad rozwojem nowego, opartego na mechanizmie narzędzia AASHTO Pavement Design (NCHRP 1-37A) uznał SSN za nietradycyjne, ale posiadające bardzo potężne techniki obliczeniowe, wykorzystując modele SSN do przygotowania pakietu do analizy nawierzchni betonowych z 2002 r. Design Guide.

Podstawowym elementem składowym sztucznej sieci neuronowej jest element przetwarzający (*neuron*). Jest on uproszczonym modelem rzeczywistych komórek nerwowych wchodzących w skład układu nerwowego, odpowiedzialnego za przetwarzanie i analizę informacji w organizmie ludzkim. Rzeczywistą komórkę nerwową traktować można jako biologiczny system przetwarzania informacji. Informacje wprowadzone za pośrednictwem wejść (*dendrytów*) są przetwarzane wewnątrz komórki. Przetworzony sygnał przesyłany jest za pośrednictwem *aksonu* do następnych komórek.

W zależności od zastosowanej metody agregacji danych wejściowych wyróżnia się dwa podstawowe rodzaje neuronów:

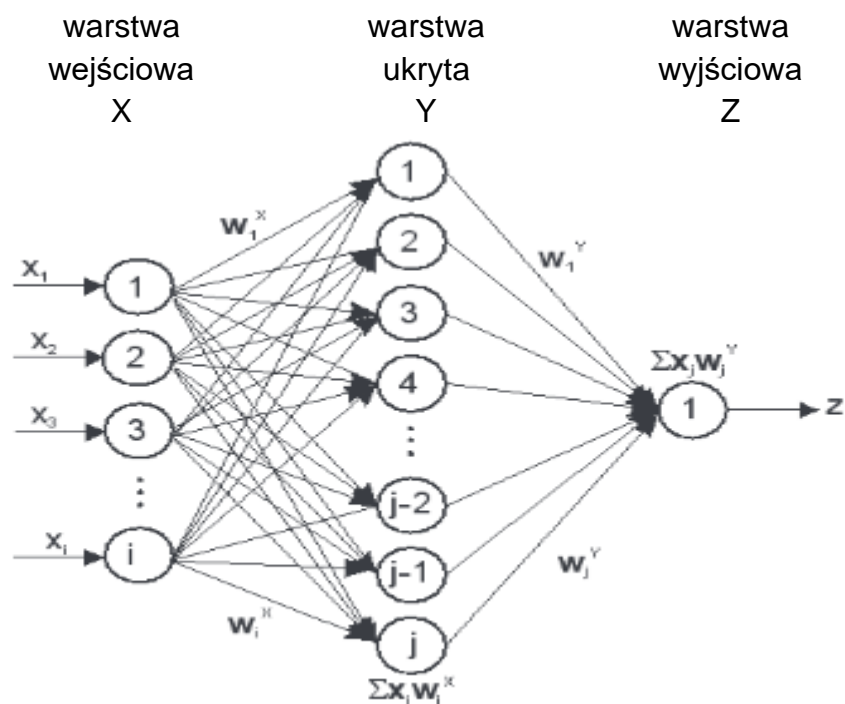
- neuron liniowy – zagregowana wartość wejściowa jest sumą ważonych wejść (liniową kombinacją wartości wejściowych),
- neuron radialny – zagregowana wartość wejściowa jest odległością pomiędzy wektorem wejściowym i wektorem wag.

Zagregowana wartość wejściowa neuronu staje się parametrem funkcji aktywacji danego neuronu. Dostępne w programie Statistica Automatyczne Sieci Neuronowe rodzaje funkcji aktywacji to:

- liniowa,
- logistyczna (określana często w literaturze jako sigmoidalna),
- hiperboliczna (występująca pod nazwą tangensoidalna)
- wykładnicza,
- softmax,
- sinus,
- Gaussowska.

Każda sieć neuronowa może składać się z wielu neuronów pogrupowanych w różną liczbę warstw. W modelach informatycznych ich liczba zależna jest od rodzaju użytej sieci neuronowej, liczby danych wejściowych oraz poziomu skomplikowania procesu podlegającego opisowi. Zasada działania sztucznego neuronu polega na przekazie sygnału wejściowego przez węzły o odpowiednich wagach, blok sumacyjny oraz blok aktywacji, co w efekcie prowadzi do jego modyfikacji w sygnał wyjściowy. Sztuczne sieci neuronowe wykorzystują matematyczną symulację biologicznych układów nerwowych do przetwarzania uzyskanych informacji i uzyskiwania prognozowanych wyników po odpowiednim przeszkoleniu sieci w zakresie rozpoznawania wzorców. Sieć neuronowa składa się z wielu warstw równoległych elementów przetwarzających, czyli neuronów. Pomiędzy warstwą wejściową i wyjściową może istnieć jedna lub więcej ukrytych warstw. Neurony w warstwach ukrytych są połączone z neuronami sąsiedniej warstwy za pomocą współczynników wagowych,

które można regulować podczas procesu uczenia modelu. Sieci są zorganizowane według metod szkoleniowych dla określonych aplikacji. Rysunek 42 ilustruje typową trójwarstwową sieć neuronową składającą się z x_i neuronów na warstwie wejściowej, Y_j neuronów w warstwie ukrytej oraz jednego neuronu w warstwie wyjściowej oraz łączące współczynniki wagowe (w_{ij}) między warstwami neuronów. „Trening” modelu SSN to procedura, dzięki której SSN wielokrotnie przetwarza zestaw danych testowych (par danych wejście-wyjście), zmieniając wartości swoich wag zgodnie z zadaniem algorytmem w celu poprawy jego wydajności [108].



Rysunek 42. Typowa trzy warstwowa sztuczna sieć neuronowa [108].

Generowana przez sieć po wprowadzeniu wartości wejściowych i wartości wyjściowych Y jest uzależniona od wartości wag np. w_1 oraz w_2 , co można zapisać:

$$Y = f(x_1, w_2) \quad (2)$$

Podstawowym miernikiem określającym jakość sieci jest błąd definiowany jako:

$$E = (D - Y)^2 = (D - f(w_1, w_2))^2 \quad (3)$$

Wartość tak zdefiniowanego błędu jest uzależniona od wartości wag. Procedura uczenia ma na celu taki dobór wartości wag, który zapewni minimalizację funkcji błędu. SSN podlegają procesowi uczenia, który dopasowuje wagi wejść poszczególnych połączeń oraz parametry zadeklarowanych funkcji aktywacji każdego neuronu.

Istnieje wiele algorytmów uczenia. Poniżej przedstawiono przykładowe metody (Haykin, 1999):

- wstecznej propagacji błędów (back propagation),
- zmiennej metryki,
- Levenberga-Marquardta,
- gradientów sprzężonych (conjugate gradient).

Propagacja wsteczna jest najpopularniejszym algorytmem uczenia modeli SSN [70]. Jest to metoda uczenia nadzorowanego, w której błąd wyjściowy jest przesyłany wstecz przez sieć, zmieniając wagi połączeń, aby zminimalizować błąd między wyjściem sieciowym a wyjściem docelowym.

Podczas procesu uczenia sztucznej sieci neuronowej, istnieje możliwość tak zwanego „przeuczenia” sieci. Aby zapobiec „przeuczeniu” należy zastosować odpowiedni algorytm (Bishop, 1995), na przykład wczesnego zatrzymania (early stopping). Z procesem uczenia związane jest próbkowanie zbioru danych, czyli pobieranie losowe próbek. Poniżej przedstawiono niektóre z metod próbkowania danych (Haykin, 1999):

- losowe próbkowanie (metoda Monte Carlo),
- sprawdzian krzyżowy,
- metoda bootstrap.

Procedura uczenia ma charakter iteracyjny. Jej celem jest wyznaczenie takiego wektora wag, dla którego wartość błędu będzie najmniejsza. W przypadku neuronu wyposażonego tylko w dwie wagi można wyznaczyć powierzchnię błędu pokazującą wartość błędu dla każdej kombinacji wag.

Podstawowe problemy związane z procedurą uczenia to:

- właściwy dobór wartości współczynnika uczenia,
- unikanie zatrzymania algorytmu uczenia w minimum lokalnym funkcji błędu.

Znanych jest wiele typów i rodzajów sieci neuronowych, różniących się między sobą strukturą i działaniem, natomiast głównie stosowane w programie Statistica wykorzystanym do dalszych analiz to m.in. perceptrony wielowarstwowe: jest to bardzo popularny i uniwersalny typ sieci jednokierunkowej, kojarzony ze skrótem MLP (ang. Multilayer Perceptron) i wykorzystywany do rozwiązywania różnych problemów, w tym technicznych [97]. MLP składa się z co najmniej trzech warstw: warstwy wejściowej, jednej lub wielu warstw ukrytych oraz warstwy wyjściowej. Każda warstwa składa się z jednostek zwanych neuronami lub węzłami, które przetwarzają informacje za pomocą odpowiednich wag i funkcji aktywacji.

Główne cechy MLP to:

1. Wielowarstwowa struktura: MLP składa się z co najmniej jednej warstwy ukrytej, co pozwala na modelowanie bardziej złożonych zależności między danymi wejściowymi a danymi wyjściowymi.
2. Neurony z funkcją aktywacji: Każdy neuron w MLP ma funkcję aktywacji, która wprowadza nieliniowość do sieci. Popularne funkcje aktywacji w MLP to sigmoidalna funkcja logistyczna, funkcja tangensa hiperbolicznego (tanh) lub funkcja ReLU (Rectified Linear Unit).

3. **Uczenie nadzorowane:** MLP jest uczony za pomocą algorytmów uczenia nadzorowanego, takich jak wsteczna propagacja błędu (backpropagation). Polega to na prezentowaniu sieci danych wejściowych i porównywaniu jej wyjścia z oczekiwanymi wyjściami, a następnie dostosowywaniu wag i biasów w celu minimalizacji błędu.
4. **Zastosowania:** MLP jest wykorzystywany w wielu dziedzinach, takich jak rozpoznawanie obrazów, rozpoznawanie mowy, analiza danych, prognozowanie, systemy rekomendacyjne i wiele innych.
 - Sieć o radialnych funkcjach bazowych (RBF) posiada trzy warstwy:
 - warstwę wejściową (neurony liniowe),
 - warstwę ukrytą (neurony radialne),
 - warstwę wyjściową (neuron liniowy).

Uczenie sieci o radialnych funkcjach bazowych składa się z trzech etapów [80]:

- określenie centrów radialnych – dobór centrów funkcji bazowych poprzez określenie wartości wag t_1, \dots, t_n dla każdego neuronu radialnego – są to punkty, dla których wartość wyjściowa neuronu będzie maksymalna,
- określenie odchyleń radialnych – dobór szerokości funkcji aktywacji – parametr określający kształt funkcji aktywacji przechowywany jest jako wartość progowa neuronu radialnego,
- określenie wartości wag neuronu warstwy wyjściowej.

Określenie centrów radialnych funkcji bazowych (punktów, nad którymi zakotwiczone zostaną funkcje bazowe) następuje za pomocą metody K-średnich – elementy zbioru uczącego dzielone są na grupy elementów podobnych (liczba wyróżnionych grup jest równa liczbie neuronów w warstwie ukrytej; do grupowania obiektów stosowana jest metoda taksonomiczna znana pod nazwą metody K-średnich. W charakterze wag neuronów radialnych stosowane są środki ciężkości każdej wyróżnionej grupy.

Określanie kształtu (szerokości) funkcji aktywacji odbywa się za pomocą metody K najbliźszych sąsiadów – w charakterze odchyleń przyjmuje się odchylenie standardowe z odległości pomiędzy wektorem wag rozpatrywanego neuronu a wektorami wag k najbliźszych neuronów radialnych. Liczba uwzględnionych neuronów sąsiedzkich wyspecyfikowana jest w polu edycyjnym. Informacja o szerokości funkcji aktywacji przechowywana jest w postaci wartości progowej neuronu. Uczenie warstwy wyjściowej odbywa się metodą pseudoinwersji.


6.2 Budowanie bazy danych do nauki

Konieczność utrzymania nawierzchni z betonu cementowego zależy od jej trwałości i zachowania w fazie eksploatacji. Mają na nie wpływ takie czynniki, jak projekt konstrukcji, budowa, ruch pojazdów, warunki klimatyczne (np. temperatura, trudne warunki pogodowe). Te czynniki, pojedynczo, jak i łącznie powodują i przyspieszają degradację (propagację uszkodzeń) nawierzchni [14]. Przyczynami uszkodzeń nawierzchni mogą być czynniki zewnętrzne, takie jak obciążenie

ruchem, oddziaływania środowiskowe itp. a także czynniki wewnętrzne, jak na przykład procesy reologiczne zachodzące w materiałach zastosowanych w konstrukcji. Pozyskiwanie wiedzy to złożony proces wydobywania danych i formowania ich w sposób przydatny dla analiz prognostycznych i stanowi prawdziwe wyzwanie ze względu m.in. na ich objętość, złożoność oraz dostępność. Na szczęście, wraz ze wzrostem ilości danych następuje szybki rozwój technologii komputerowych oraz dedykowanym do tego celu różnych programów.

W ramach prowadzonych badań wykorzystywano dane gromadzone m.in. w:

- Systemie ewidencji płyt betonowych na odcinkach (rys.43 poz. 1, 2, 3 i 4)
- Systemie ważenia pojazdów i stacji pomiaru ruchu (rys.43 poz. 5);
- Systemie meteorologicznym (rys.43 poz. 6)



Rysunek 43. Zestawienie systemów, z jakich pozyskane zostały dane w ramach prowadzonej analizy prognostycznej

Kolejnym krokiem było zidentyfikowanie i ocena źródła danych, które mogłyby potencjalnie zostać wykorzystane do opracowania modeli degradacji, pod kątem zawartości i dokładności.

W szczególności oceniono następujące rodzaje danych:

- szeregi czasowe parametrów cech powierzchniowych
- charakterystyka cech konstrukcyjnych
- ruch drogowy
- zmienne klimatyczne.

6.3 Warunki obciążenia ruchem

Analizowane odcinki drogi (A-E) o nawierzchni z betonu cementowego są częścią Transeuropejskiej Sieci w Europie Środkowej i stanowią kluczowe ogniwo w sektorze autostrad między Warszawą a Berlinem. Zgromadzenie danych historycznych o ruchu miało na celu oszacowanie rocznego natężenia ruchu na każdym z analizowanych odcinków. Stan techniczny nawierzchni zależy od jej trwałości i wieku, z kolei na trwałość nawierzchni wpływają warunki klimatyczne, jej konstrukcja i właściwości materiałów, z których została wykonana, a przede wszystkim obciążenie ruchem drogowym.

Rozpoznanie charakterystyki ruchu pojazdów ciężkich i analizę obciążenia nawierzchni badanych odcinków drogowych przeprowadzono na podstawie danych z systemu pomiaru ruchu drogowego. Urządzenia przeznaczone do ważenia pojazdów w ruchu gromadzą dane z dokładnością i tolerancją określoną dla klasy B(10) Specyfikacji COST 323: „Weight in Motion of Road Vehicles” Final Report Appendix 1 – European WIM Specification Version 3.0 [„Ważenie pojazdów w ruchu” Raport Końcowy, Załącznik 1 – Europejska Specyfikacja WIM (Ważenie pojazdów w ruchu)] z sierpnia 1999 r. Dane w bazie są przechowywane w rozbiu na pasy ruchu, z podziałem na kategorie pojazdów na każdym pasie.

Zbieranie danych o ruchu na analizowanych odcinkach autostrady nie były tak proste, jak zbieranie pozostałych danych opisanych w pozostałych rozdziałach. Istniało wiele wyzwań, aby przeanalizować i zestawić ogromną ilość danych.

Pozyskane dane pochodzą z Systemu Pomiaru Ruchu Drogowego (tab. 14, 15) tj.:

- jedna stacja ważenia pojazdów w ruchu składająca się na System ważenia pojazdów w ruchu,
- trzy stacje pomiaru ruchu drogowego składające się na System Pomiaru Ruchu.

Tabela 14. Parametry techniczne stacji pomiaru ruchu AVC 100

Lp.	Pomiar	Dokładność
1	Dokładność pomiaru prędkości	±3%
2	Błąd zliczania ogólnej liczby pojazdów	±1%
3	Zakres zliczania ogólnej liczby pojazdów	do 1 000 000 pojazdów za pojazdem
4	Kategorie klasyfikacji pojazdów	EUR-6 (Tab. 15)

Tabela 15. Klasyfikacja EUR-6


Kategoria pojazdu	Rodzaj pojazdu	Dokładność pomiaru
1	motocykle	±10%
2	samochody osobowe i dostawcze	±3%
3	samochody osobowe z przyczepami	±10%
4	pojedyncze samochody ciężarowe	±3%
5	samochody ciężarowe z przyczepami i naczepami	±3%
6	autobusy	±5%

System pomiaru ruchu przeznaczony jest do zliczania w sposób ciągły liczby pojazdów w podziale na ustalone kategorie. Pomiary ruchu odbywają się na obu jezdniach (tab. 16).


Tabela 16. Lokalizacja stacji pomiaru ruchu

Lp.	Nazwa obiektu	Lokalizacja
1	Stacja pomiaru ruchu i ważenia	Odcinek A
2	Stacja pomiaru ruchu	Odcinek B i C
3	Stacja pomiaru ruchu	Odcinek D i E


Dane w bazie są przechowywane w rozbiciu na pasy drogi, z podziałem na kategorie pojazdów na każdym pasie. Ogólnie zaobserwowano, że ruch na wszystkich odcinkach stopniowo wzrastał, co przedstawiono na kolejnych wykresach. Niedawny wpływ pandemii SARS-CoV-2 na ruch drogowy jest wyraźnie widoczny od pierwszego kwartału 2020 r. Z początkiem kwietnia 2020 r., ruch pojazdów lekkich znacznie się zmniejszył, natomiast w okresie letnim powrócił do pierwotnego poziomu. Należy zaznaczyć, że największy ruch pojazdów ciężkich, który ma istotny wpływ na trwałość nawierzchni z betonu cementowego był obserwowany na odcinku A, co jest również skorelowane z konstrukcją nawierzchni i jej grubością tj. 29 cm, w stosunku do pozostałych odcinków (tj. B i C grubość równa 27 cm oraz D i E równa 28 cm). Ruch rzeczywisty pojazdów lekkich i ciężkich na odcinkach jednorodnych (A-E) przedstawiono na rysunkach 44 - 48.




Rysunek 44. Średni dobowy ruch pojazdów w okresie 2016 - 2021 na odcinku A w okresach miesięcznych




Rysunek 45. Średni dobowy ruch pojazdów w okresie 2016 - 2021 na odcinku B w okresach miesięcznych



Rysunek 46. Średni dobowy ruch pojazdów w okresie 2016 - 2021 na odcinku C w okresach miesięcznych



Rysunek 47. Średni dobowy ruch pojazdów w okresie 2016 - 2021 na odcinku D w okresach miesięcznych



Rysunek 48. Średni dobowy ruch pojazdów w okresie 2016 - 2021 na odcinku E w okresach miesięcznych

Obciążenia przekazywane na nawierzchnię przez koła pojazdów są zmienne, dlatego do projektowania i analiz konstrukcji nawierzchni obciążenia te są przeliczane na liczbę obciążeń wyrażonych liczbą równoważnych osi standardowych za pomocą współczynników równoważności obciążenia. Warto zaznaczyć, że zagadnienie obciążenia dróg przez pojazdy ciężkie i ich oddziaływanie na nawierzchnie od wielu lat jest aktualne i często poruszane w publikacjach naukowych [71, 101]. Badania te od wielu lat są prowadzone, a ich wyniki zostały opublikowane w licznych pracach naukowych. Na Politechnice Wrocławskiej opracowano Katalog Typowych Konstrukcji Nawierzchni Sztywnych [58] i w roku 2014 podano w nim współczynniki przeliczeniowe odpowiednie dla nawierzchni sztywnych. W wymiarowaniu konstrukcji nawierzchni drogowych brane jest pod uwagę sumaryczne prognozowane natężenie ruchu pojazdów ciężkich, a okres, na jaki wykonywana jest prognoza natężenia ruchu pojazdów, jest uzależniony od zakładanego okresu eksploatacji nawierzchni i wynosi 30 lat dla nawierzchni sztywnych.

W ramach przeprowadzonych w 2012 r. prac nad aktualizacją Katalogu Typowych Konstrukcji Nawierzchni Sztywnych z roku 2001 stwierdzono, że w strukturze rodzajowej pojazdów ciężkich w okresie ostatnich kilku lat zaszły istotne zmiany. Przede wszystkim zauważalne jest systematyczne zmniejszanie się liczby samochodów ciężarowych dwuosiowych oraz zdecydowany przyrost liczby pojazdów członowych pięciosiowych. Ma to wpływ m.in. na to, że wykorzystane współczynniki przeliczeniowe wykorzystane do celów projektowych analizowanych odcinków były nieodpowiednie i należało je uaktualnić. Stwierdzono również

występowanie większych oddziaływań pojazdów poszczególnych grup na nawierzchnie drogowe w stosunku do przyjmowanych poprzednio. Ustalono strukturę rodzajową pojazdów ciężkich na drogach krajowych w Polsce. Ze względu na zaobserwowane różnice w charakterystyce obciążeniowej pojazdów różnych grup i różny ich udział w strumieniu ruchu w zależności od charakteru ruchu i kategorii drogi (na analizowanych odcinkach dominują w strumieniu ruchu pojazdy ciężkie wykorzystywane w transporcie dalekobieżnym). Dlatego do dalszych analiz zastosowano nowe współczynniki przeliczeniowe sylwetek (tab. 17) pojazdów na osie obliczeniowe zgodnie z KTKNS z 2014 r. stanowiący załącznik do zarządzenia Nr 30 Generalnego Dyrektora Dróg Krajowych i Autostrad z dnia 16.06.2014 r.

Zgodnie z Katalogiem typowych konstrukcji nawierzchni sztywnych z 2014 r. ruch projektowy określa się na podstawie wzoru:

$$N_{115} = f_1 \cdot f_2 \cdot f_3 \cdot (N_C \cdot r_C^{115} + N_{C+P} \cdot r_{C+P}^{115} + N_A \cdot r_A^{115}) \quad (4)$$

gdzie:

- N_{115}** – ruch projektowy, sumaryczna liczba osi standardowych 115 kN w całym okresie projektowym nawierzchni przypadająca na pas obliczeniowy,
- N_A** – ruch rzeczywisty, sumaryczna liczba autobusów (A) w całym okresie projektowym, w przekroju drogi,
- N_C** – ruch rzeczywisty, sumaryczna liczba samochodów ciężarowych bez przyczep (C) w całym okresie projektowym, w przekroju drogi,
- N_{C+P}** – ruch rzeczywisty, sumaryczna liczba samochodów ciężarowych z przyczepami oraz ciągników siodłowych z naczepami (C+P) w całym okresie projektowym, w przekroju drogi,
- r_A^{115}** – współczynnik przeliczeniowy liczby autobusów (A) na liczbę osi standardowych 115 kN,
- r_C^{115}** – współczynnik przeliczeniowy liczby samochodów ciężarowych bez przyczep (C) na liczbę osi standardowych 115 kN,
- r_{C+P}^{115}** – współczynnik przeliczeniowy liczby samochodów ciężarowych z przyczepami oraz ciągników siodłowych z naczepami (C+P) na liczbę osi standardowych 115 kN,
- f_1** - współczynnik obliczeniowego pasa ruchu,
- f_2** - współczynnik szerokości pasa ruchu,
- f_3** - współczynnik pochylecia niwelety.


Tablica 17. Współczynniki przeliczeniowe pojazdów ciężkich na osie standardowe 115 kN [56, 58].

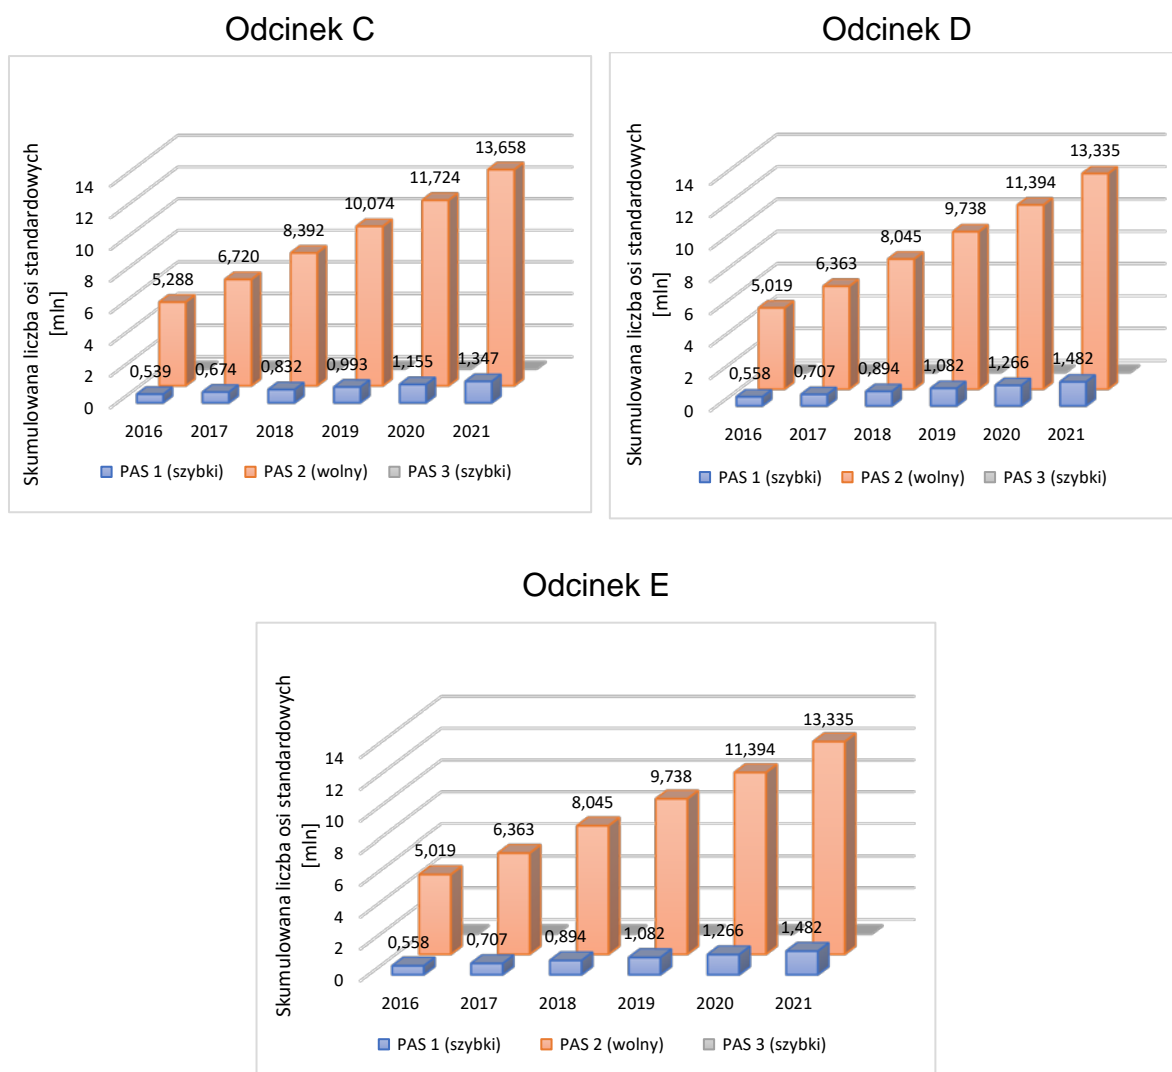
Lp.	Rodzaje pojazdów	Katalog 2001	Katalog 2014
1	Samochody ciężarowe bez przyczep	0,01	0,130
2	Samochody ciężarowe z przyczepami oraz ciągniki siodłowe z naczepami	0,483 ¹⁾ 1,229 ²⁾	1,483
3	Autobusy	0,141	0,199

1) Samochody 4-osiowe

2) Samochody 5-osiowe

Do obliczenia skumulowanej liczby osi standardowych od roku 2011 do roku 2021 na analizowanych odcinkach wykorzystano dane pozyskane ze stacji pomiaru ruchu drogowego oraz rodzajową strukturę ruchu z generalnego pomiaru ruchu uzyskanego w latach 2010, 2015, 2020/2021 [27, 28, 29].





Rysunek 49. Skumulowana liczba osi standardowych na analizowanych odcinkach (A-E) w latach 2016 – 2021

W ramach przeprowadzonych obliczeń w zakresie wyznaczenia obciążenia nawierzchni przez rzeczywistą skumulowaną liczbę osi standardowych (rys. 49), najbardziej obciążonym ruchem ciężkim od roku 2011 do 2021 roku był odcinek A (21, 2 mln osi standardowych) a najmniej - odcinek B (14,4 mln osi standardowych).

6.4 Zmienne klimatyczne na odcinkach objętych analizą

Opublikowany w 2021 roku 6. Raport I Grupy Roboczej Międzyrządowego Panelu Ekspertów ds. Zmiany Klimatu (IPCC WGI) potwierdza, że klimat Ziemi zmienia się od połowy XIX wieku w tempie niespotykanym nigdy wcześniej, a postępujące ocieplenie stanowi zagrożenie dla dobrostanu planety, jej ekosystemów i życia człowieka. Wpływ współczesnego ocieplenia jest powszechny – najbliższe 2-3 dekady będą miały krytyczne znaczenie dla przyszłości Ziemi. Z tego względu konieczne są wielokierunkowe działania, w tym niezbędne, systematyczne

monitorowanie systemu klimatycznego, podejmowanie aktywności spowalniających lub nawet eliminujących przyczyny współczesnej zmiany klimatu, jak również prognozowanie przyszłej ewolucji systemu klimatycznego i opracowywanie strategii dostosowania się, czyli podejmowanie działań adaptacyjnych [61]. Zmiany klimatu mogą mieć znaczący wpływ na zmiany w stanie technicznym infrastruktury, jak i na proces jej degradacji [35, 75, 117]. Krajowe organy regulacyjne w związku z zachodzącymi zmianami klimatycznymi będą zmuszone do uwzględnienia tych czynników w analizach związanych z zarządzaniem nawierzchniami drogowymi [128].


Nawierzchnie drogowe z betonu cementowego wykonane są na wielu odcinkach dróg szybkiego ruchu (autostrad i dróg ekspresowych) zlokalizowanych w różnych częściach obszaru Polski, gdzie warunki atmosferyczne wykazują znaczne zróżnicowanie. Klimat w Polsce charakteryzuje się znacznymi wahaniami temperatury, czego efektem są różniące się od siebie pory roku. Do najchłodniejszych miesięcy należy styczeń, natomiast do najcieplejszych należy zaliczyć miesiące letnie tj. lipiec oraz sierpień.

Wpływ na pracę nawierzchni mają następujące czynniki klimatyczne [30]:

- typ klimatu,
- temperatura powietrza i temperatura nawierzchni,
- liczba przejść temperatury powietrza i temperatury nawierzchni przez 0°C ,
- ilość opadów atmosferycznych i wilgotność konstrukcji nawierzchni i podłoża gruntowego,
- głębokość przemarzania gruntu,
- nasłonecznienie (teren wilgotny zalesiony, teren otwarty suchy).

6.4.1 Warunki temperaturowe

Płyty betonowe zastosowane w warstwie nawierzchniowej jezdni drogowych muszą być odporne na obciążenia statyczne i dynamiczne od poruszających się po niej pojazdów oraz obciążenia termiczne będące wynikiem zmian warunków atmosferycznych – podlegające oddziaływaniom o charakterze cyklicznym (zmiany dobowe i roczne). Można wyróżnić dwie przyczyny powstawania naprężeń w płycie betonowej indukowanych termicznie: spowodowane różnicą temperatury w górnej i dolnej części płyty, powodujące jej zginanie oraz wywołane zmianą średniej temperatury płyty, mające wpływ jedynie na zmianę wymiarów płyty w planie (rys. 50) [95].



Rysunek 50. Schemat deformacji swobodnej płyty betonowej w wyniku oddziaływania termicznego: a) gradient dodatni (ΔT^+); b) gradient ujemny (ΔT^-) [95].

Naprężenia wywołane zmianami temperatury mogą osiągać znaczne wartości i zależą w głównej mierze od: wymiarów geometrycznych płyt, ciężaru własnego płyt, wartości gradientu termicznego oraz wartości sił pochodzących od więzów podłoża. Należy przy tym zauważyć, że temperatura średnia ma wpływ jedynie na zmianę wymiarów płyty w planie, zaś zmiana temperatury na jej powierzchni oraz spodzie powoduje jej deformację przestrzenną [69]. Przy znacznych wahaniach dobowych temperatury powietrza może dochodzić do nakładania się niekorzystnych warunków, a w konsekwencji do nieodwracalnego wypaczania i deformacji płyt i powstawania pęknięć o dużej szkodliwości (rys. 51).



Rysunek 51. Spękanie płyty betonowej o dużej szkodliwości powstałe tuż po etapie wykonania nawierzchni w wyniku nieodpowiedniej pielęgnacji w czasie występowania wysokiej temperatury otoczenia.

Zasadniczy wpływ na zjawiska termiczne zachodzące w betonie nawierzchniowym ma warstwa powietrza zalegająca tuż nad powierzchnią płyty [69]. Dlatego poprzez wykorzystanie danych ze stacji meteorologicznych tzn. wartości temperatury powietrza rejestrowanych w odstępach 1 h w miesiącach letnich można ustalić rzeczywisty gradient temperatury (różnica temperatury pomiędzy dolną i górną częścią płyty).


Wartości temperatury zostały uzyskane na podstawie danych z drogowych stacji meteorologicznych (rys. 52), które zakresem monitorowania obejmują następujące parametry:

- temperatura powietrza;
- temperatura na powierzchni jezdni – t_1
- temperatura nawierzchni (na głębokości 6 cm) – t_2
- temperatura nawierzchni (na głębokości 30 cm) – t_3
- wilgotność względna powietrza;
- temperatura punktu rosy;
- temperatura zamarzania;
- trend zmian temperatury powietrza;
- trend zmian temperatury nawierzchni;
- stan nawierzchni (sucha, wilgotna, mokra itd.);
- prędkość i kierunek wiatru;
- rodzaj opadu (mżawka, deszcz, śnieg itd.).




Rysunek 52. Przykładowa drogowa stacja meteorologiczna zlokalizowana na jednym z analizowanych odcinków


Należy zaznaczyć, że administracje drogowe na całym świecie poddają opracowane kryteria zmęczeniowe nawierzchni drogowych ciągłej rewizji (w okresach kilku-kilkunastoletnich), w wyniku zmieniających się warunków lokalnych. Słuszność takiego postępowania została potwierdzona na podstawie analizy temperatur powietrza w ekstremalnych miesiącach letnich w okresie od 2016 do 2021, dla których przedstawiono zmiany temperatur oraz gradientów temperatury. W ramach niniejszej pracy badawczej stwierdzono m.in., że dla jednego z analizowanych odcinków zmiana temperatur wynosiła ok. 9°C pomiędzy dolną i górną powierzchnią płyty betonowej (gradient +) w roku 2017 wyniósł $27,8^{\circ}\text{C}$ (tj. $0,99^{\circ}\text{C}$ na 1 cm grubości płyty) co zostało przedstawione na rysunkach 53-56.




Rysunek 53. Zestawienie porównawcze dobowej temperatury powietrza dla Odcinka D i E w ekstremalnych miesiącach letnich dla wartości zarejestrowanych w okresie jej eksploatacji (2016 – 2021)



Rysunek 54. Przykładowa dobowo zmiana temperatury (2017 rok) płyty betonowej w różnych miejscach o grubości 28 cm (docinek D i E) w miesiącach letnich



Rysunek 55. Zestawienie porównawcze dobowej temperatury powietrza dla Odcinka D i E w miesiącach zimowych dla wartości zarejestrowanych w okresie jej eksploatacji (2016 – 2021).



Rysunek 56. Przykładowa zmiana dobowej temperatury (2019 rok) płyty betonowej w różnych miejscach o grubości 28 cm (docinek D i E) w miesiącach zimowych

W tabeli 18 przedstawiono główne dane uzyskane z badań warunków termicznych na analizowanych odcinkach (A-E) natomiast kompletne zestawienie danych temperaturowych na wszystkich analizowanych odcinkach w latach 2016 - 2021 zestawiono w Załączniku 2 w celu wykorzystania ich w dalszej części pracy badawczej w ramach adaptacji sztucznych sieci neuronowych tj:

- Maksymalny gradient +;
- Maksymalny gradient -;
- Maksymalna temperatura powietrza (okres letni);
- Minimalna temperatura powietrza (okres zimowy).

Tabela 18. Zestawienie danych w zakresie max. gradientu (+) oraz max. gradientu (-) na analizowanych odcinkach (A-E) w okresie 2016 - 2021

Odcinek	Parametr	Wyniki prowadzonych obserwacji [°C]					
		2016	2017	2018	2019	2020	2021
Odcinek A	Max. Gradient +	24,4	25,5	22,9	26,4	20,4	25,3
	Max. Gradient -	11,7	7,8	9,1	5,7	3,1	7,4
Odcinek B i C	Max. Gradient +	25,1	24,8	19,5	23,2	22,8	23,9
	Max. Gradient -	10,0	7,9	8,4	6,1	7,0	6,8
Odcinek D i E	Max. Gradient +	24,6	27,8	19,6	24,0	24,1	24,1
	Max. Gradient -	12,0	8,5	11,5	7,5	15,6	8,0

6.4.2 Warunki hydrologiczne


Warunki hydrologiczne w powiązaniu z liczbą dni z temperaturą poniżej 0°C mają znaczący wpływ na trwałość nawierzchni drogowych z betonu cementowego. Główne czynniki jakie wpływają na degradację nawierzchni z betonu cementowego w zależności od wyżej wymienionych warunków to m.in.:

- zawilgocenie gruntu, które może prowadzić do zmniejszenia nośności dolnych warstw konstrukcji nawierzchni. Ponadto, nadmierna wilgotność gruntu może prowadzić do powstawania pęknięć i deformacji nawierzchni.
- nadmiar wody z opadów deszczu, który może prowadzić do zwiększenia ilości wody w dolnych warstwach konstrukcji, może wpłynąć na zmniejszenie nośności całej konstrukcji nawierzchni lub nierównomierne osiadanie płyt (złe przenoszenie obciążeń) poprzez penetrację wody i erozję podbudowy. Do takiego zjawiska może dochodzić w sytuacji tzw. „pompowania” hydrodynamicznego przez nieszczelne szczeliny, które są najsłabszym elementem betonowych nawierzchni dyblowanych i kotwionych [107].
- namywanie zanieczyszczeń przez wody opadowe, które w przypadku przedostania się przez nieszczelną szczelinę dylatacyjną, może prowadzić do wzmożonego zjawiska akumulacji materiału mineralnego, dotyczy najczęściej


skrajnego pasa nawierzchni, zgodnie ze spadkiem nawierzchni. W wyniku tego materiał mineralny zgromadzony wewnątrz szczeliny dylatacyjnej, uniemożliwia odpowiednią pracę płyty betonowej w warunkach zmiennej temperatury nawierzchni betonowej (dzień/noc, lato/zima), podczas których dochodzi do odkształcenia się płyty betonowej i zmiany jej wymiarów w planie w wyniku termicznej rozszerzalności betonu oraz samej płyty betonowej, czego wynikiem jest wystąpienie spękań, nazywanych spękaniem „motylkowymi” [32, 116].

- cykliczne zamrażanie i rozmrażanie w połączeniu ze stosowaniem środków odladzających może powodować poważne uszkodzenia nawierzchni z betonu cementowego. Woda, która przedostaje się do porów betonu, może tam zamarać, co powoduje rozszerzanie się porów a następnie powstawanie uszkodzeń powierzchniowych w wyniku niedostatecznej mrozoodporności kruszywa, a w przypadku częstego stosowania środków odladzających może dochodzić do złuszczeń na powierzchni betonu.

W ramach badanych odcinków jednorodnych zostały przeanalizowane dane ze stacji meteorologicznych w zakresie ilości opadów oraz ilości dni poniżej 0°C, które przedstawiono na rys. 57-58 w celu wykorzystania ich do dalszych analiz prognostycznych.



Rysunek 57. Zestawienie ilości opadów w analizowanym okresie (2016 – 2021) na badanych odcinkach.



Rysunek 58. Zestawienie liczby dni z temperaturą poniżej 0°C w analizowanym okresie (2016 – 2021) na badanych odcinkach


W przedstawionych powyżej punktach wykazano, że wpływ warunków hydrologicznych jest istotny i w niektórych przypadkach może być groźny dla trwałości konstrukcji nawierzchni z betonu cementowego. W związku z tym, aby wydłużyć trwałość nawierzchni, konieczne jest uwzględnienie warunków hydrologicznych w czasie projektowania, budowy i jej eksploatacji. W przypadku regionów o dużych opadach, należy zapewnić odpowiedni stan techniczny m.in. szczelin dylatacyjnych zabezpieczających przed wnikaniem wody z zanieczyszczeniami w dolne warstwy konstrukcyjne. Ponadto, wykonywanie cyklicznych prac utrzymaniowych polegających na bieżących naprawach uszkodzeń powierzchniowych oraz uszczelnianiu spękań nawierzchni z betonu cementowego minimalizuje wpływ warunków hydrologicznych na trwałość nawierzchni.

6.5 Dane ze zmodyfikowanej wizualnej metody oceny stanu technicznego nawierzchni betonowych


Pełną identyfikację uszkodzeń w ramach zmodyfikowanej metody oceny powierzchni jezdni z betonu cementowego przeprowadzono dla wyznaczonych wszystkich pięciu odcinków jednorodnych (A-E) o łącznej liczbie płyt równej 120 438 szt. w pięcioletnim okresie badawczym (2016-2021).

Wyniki w zakresie ilości zidentyfikowanych uszkodzeń oraz ich podział na typy oraz odcinki zostały zaprezentowane na rysunkach nr 59-72, co umożliwia analizę zmian stanu nawierzchni pomiędzy kampaniami i po naprawach w celach analitycznych i kontrolnych.


Odcinek A




Odcinek B




Odcinek C



Odcinek D




Odcinek E




Rysunek 59. Zestawienie liczbowe zidentyfikowanych uszkodzeń powierzchni (UP) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



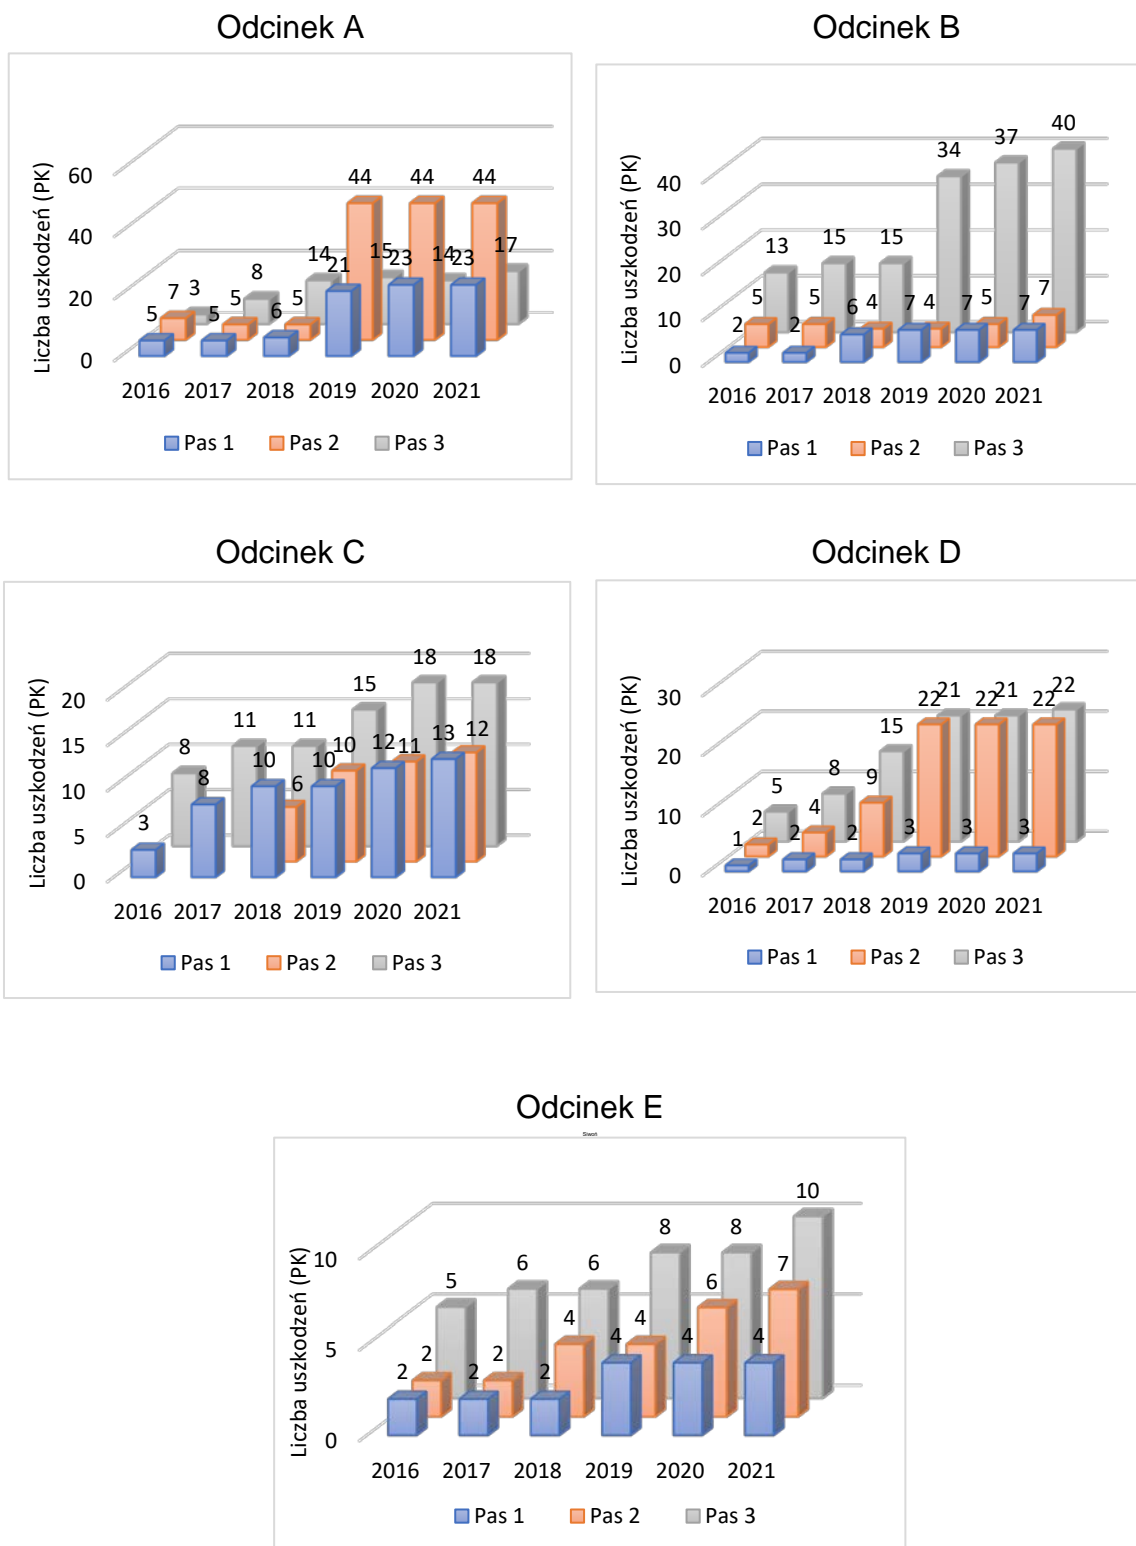
Odcinek D



Odcinek E




Rysunek 60. Zestawienie liczbowe zidentyfikowanych uszkodzeń naroży (UN) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 61. Zestawienie liczbowe zidentyfikowanych pęknięć krawędzi (PK) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



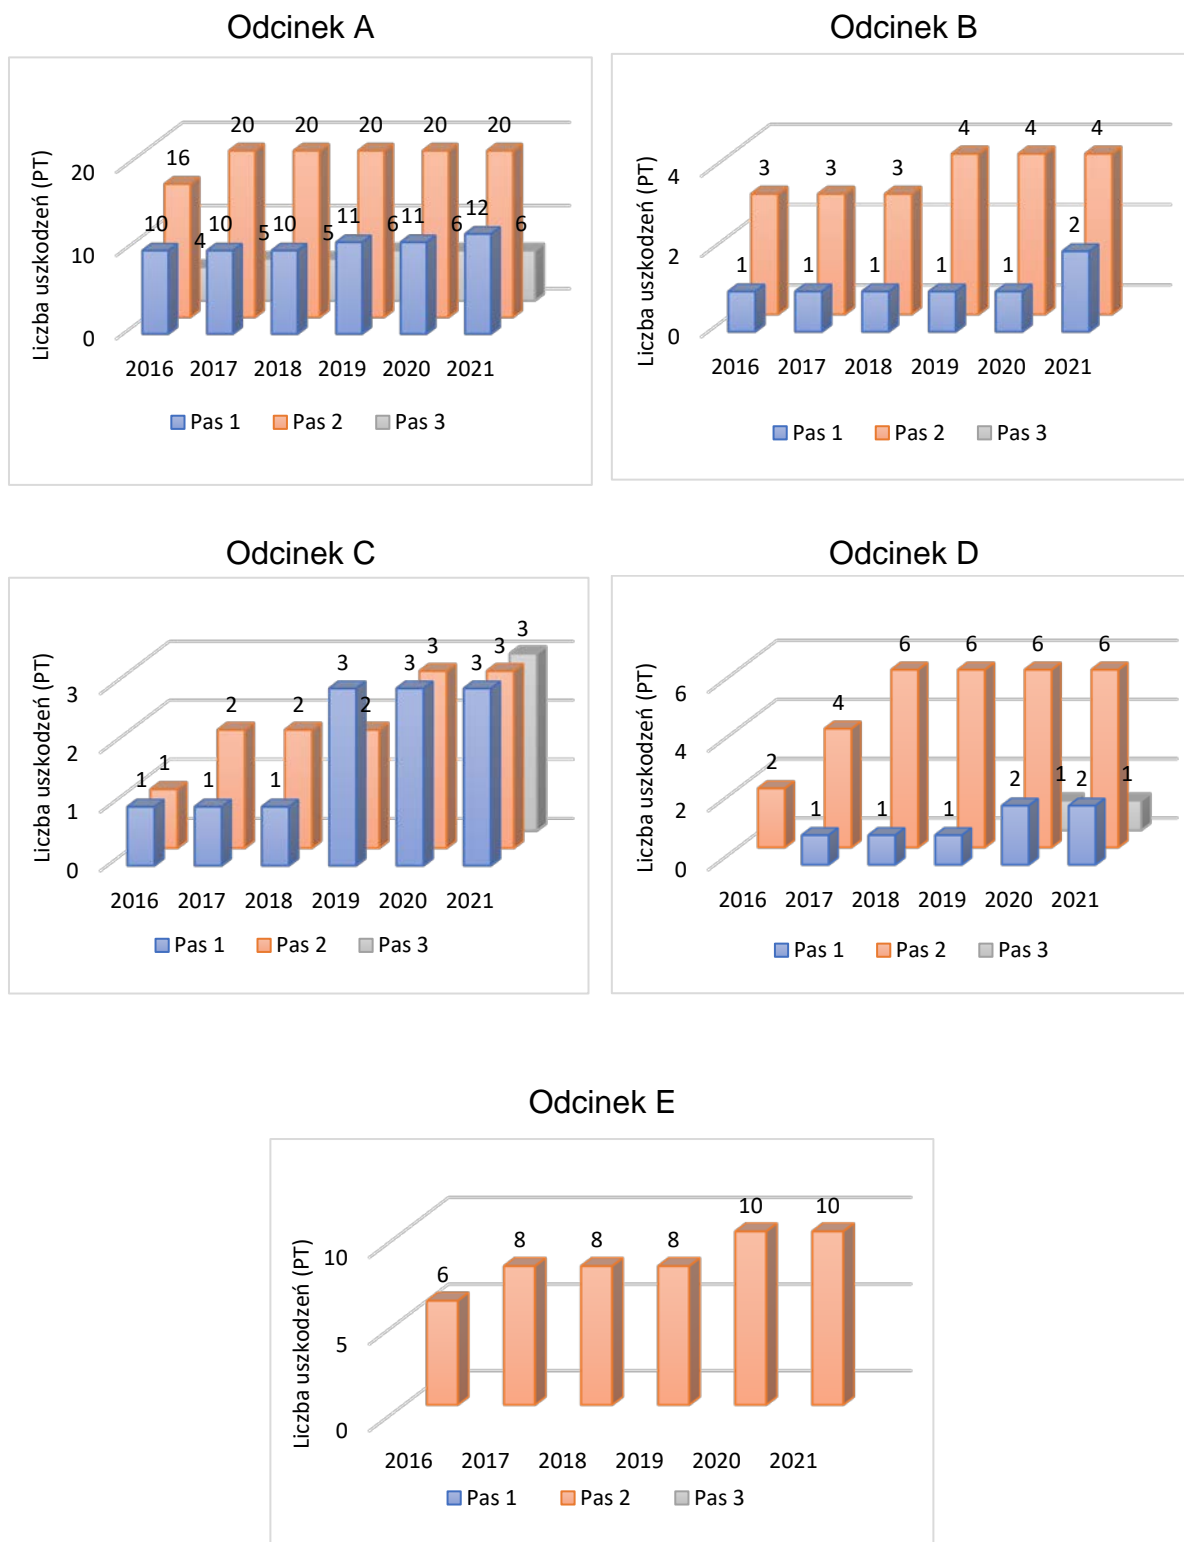
Odcinek D



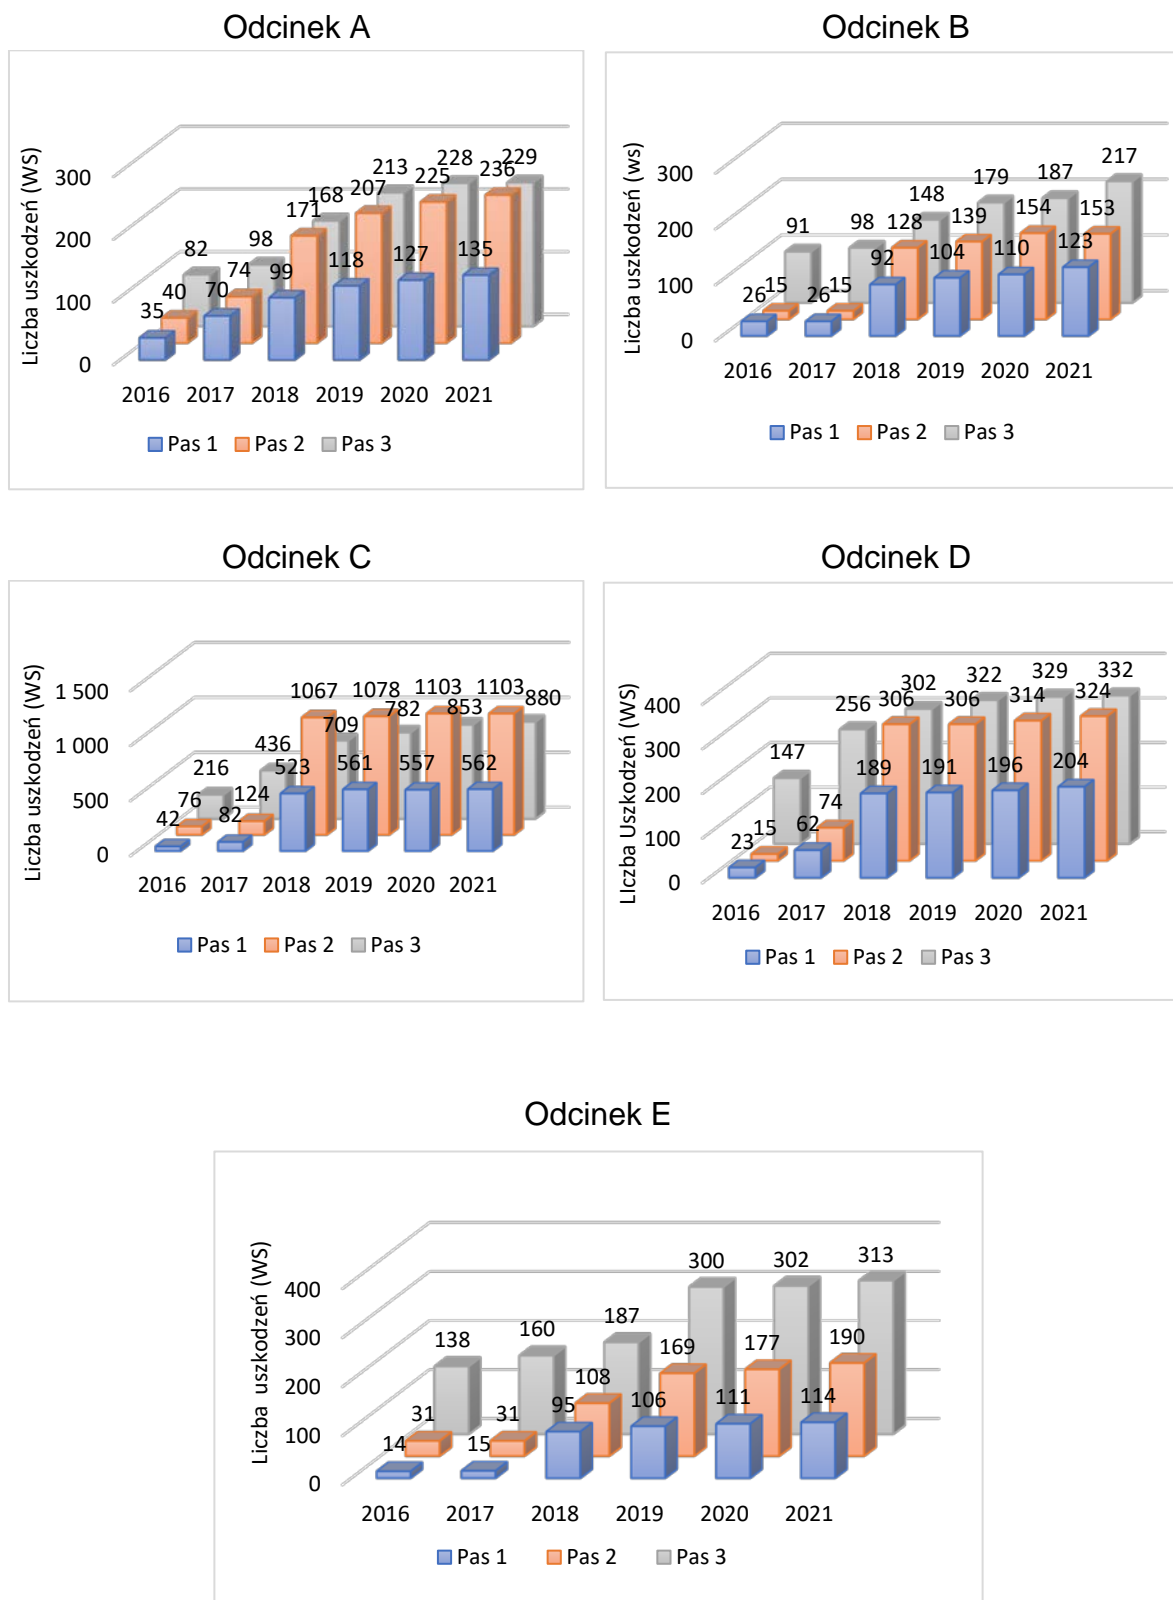
Odcinek E



Rysunek 62. Zestawienie liczbowe zidentyfikowanych pęknięć podłużnych (PL) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 63. Zestawienie liczbowe zidentyfikowanych pęknięć poprzecznych (PT) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 64. Zestawienie liczbowe zidentyfikowanych wykruszeń szczelin (WS) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



Odcinek D




Odcinek E




Rysunek 65. Zestawienie liczbowe zidentyfikowanych wykruszeń krawędzi (WK) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



Odcinek D




Odcinek E




Rysunek 66. Zestawienie powierzchni zidentyfikowanych uszkodzeń powierzchni (UP) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



Odcinek D




Odcinek E




Rysunek 67. Zestawienie powierzchni zidentyfikowanych uszkodzeń naroży (UN) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



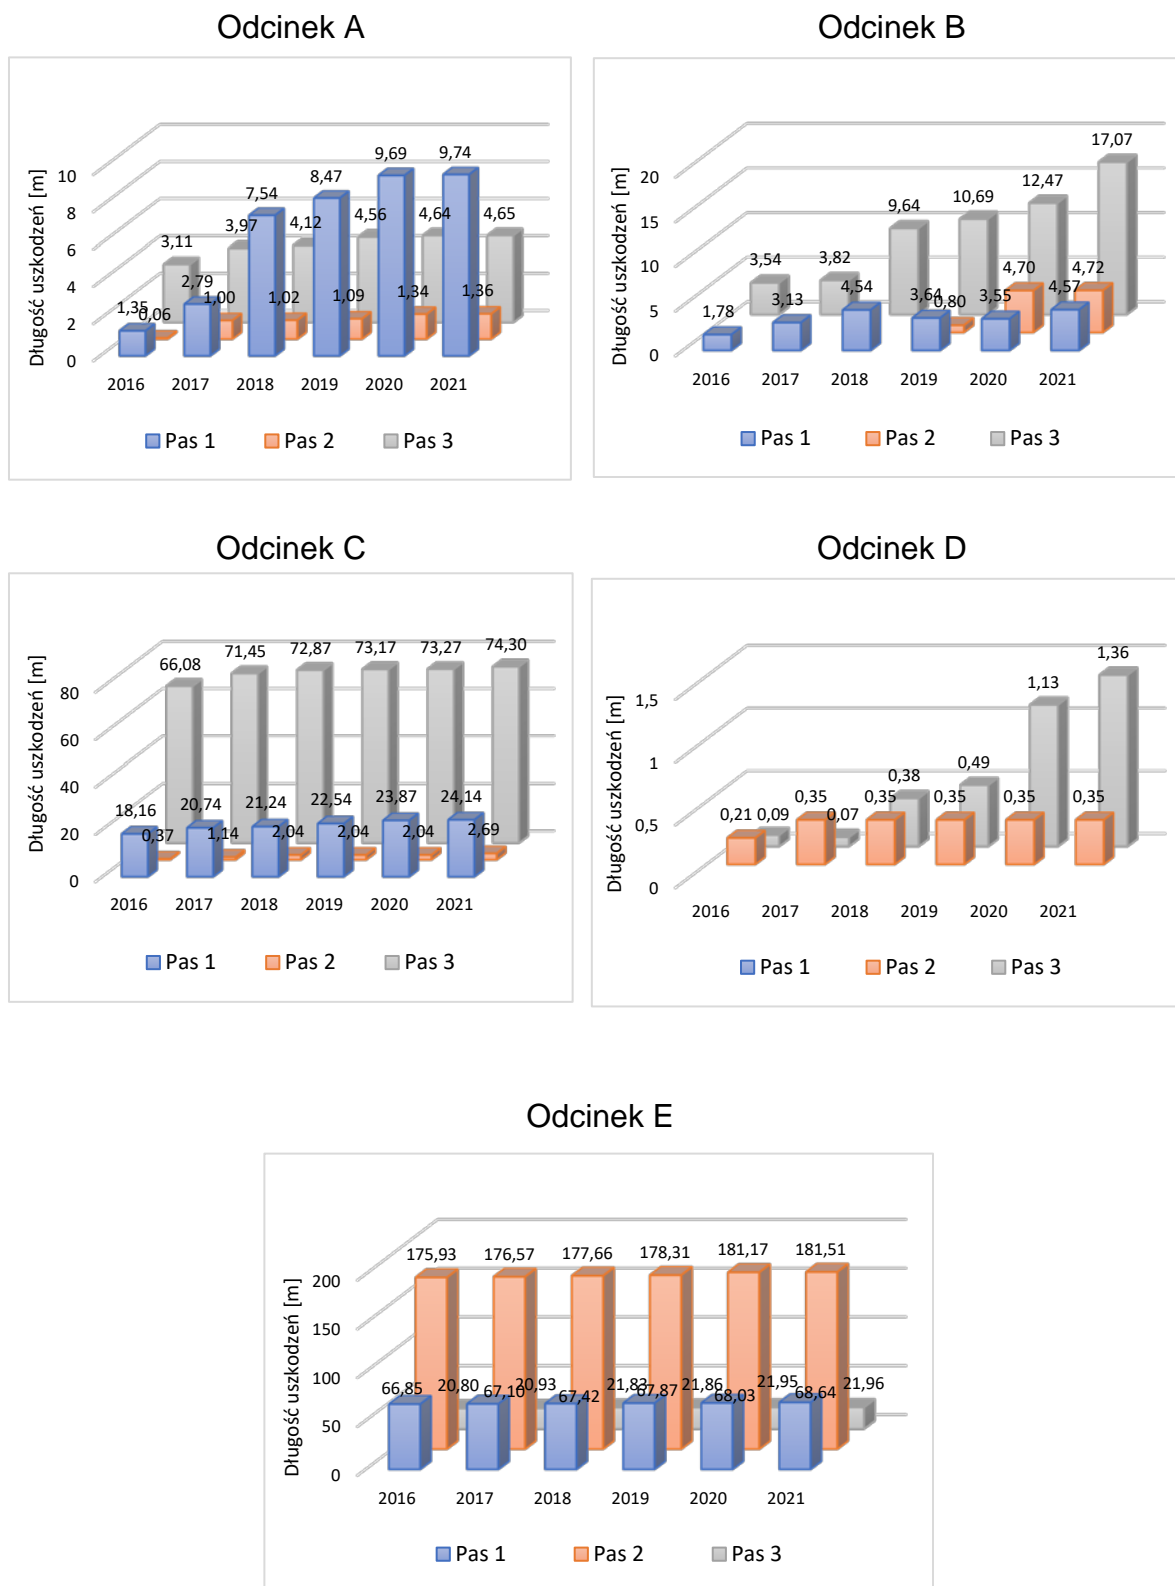
Odcinek D



Odcinek E




Rysunek 68. Zestawienie powierzchni zidentyfikowanych pęknięć krawędzi (PK) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 69. Zestawienie powierzchni zidentyfikowanych pęknięć podłużnych (PL) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



Odcinek D




Odcinek E




Rysunek 70. Zestawienie powierzchni zidentyfikowanych pęknięć poprzecznych (PT) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



Odcinek D




Odcinek E




Rysunek 71. Zestawienie powierzchni zidentyfikowanych wykruszeń szczelin (WS) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)


Odcinek A




Odcinek B




Odcinek C



Odcinek D



Odcinek E



Rysunek 72. Zestawienie powierzchni zidentyfikowanych wykruszeń krawędzi (WK) na analizowanych odcinkach jednorodnych (A-E) z podziałem na pasy (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

Ważnym aspektem w ramach zmodyfikowanej oceny cech powierzchniowych nawierzchni z betonu cementowego i badań terenowych, jakie zostały przeprowadzone w okresie 2016 – 2021, jest możliwa bardzo szczegółowa analiza zmian parametrów uszkodzeń w zakresie ich liczby, powierzchni oraz długości pomiędzy poszczególnymi kampaniami pomiarowymi oraz odcinkami (tab. 19-20).

Tabela 19. Zestawienie liczby zinwentaryzowanych typów uszkodzeń wraz z ich przyrostem w okresie 2016 – 2021 (5 lat) z podziałem na odcinki (A-E)

Odcinek	Parametry uszkodzeń	UP	UN	WS	WK	PK	PL	PT	SUMA
A	Liczba uszkodzeń	1 314	77	600	304	84	34	38	2 451
	Przyrost [%]	20%	44%	74%	43%	82%	32%	21%	
B	Liczba uszkodzeń	1 789	66	493	1 381	54	49	6	3 838
	Przyrost [%]	37%	24%	73%	38%	63%	69%	33%	
C	Liczba uszkodzeń	1 576	180	2 545	592	43	90	9	5 035
	Przyrost [%]	26%	17%	87%	41%	74%	14%	78%	
D	Liczba uszkodzeń	1 354	72	860	432	47	7	9	2 781
	Przyrost [%]	30%	51%	78%	49%	83%	71%	78%	
E	Liczba uszkodzeń	1 332	80	617	363	21	89	10	2 512
	Przyrost [%]	29%	26%	70%	34%	57%	17%	40%	
	SUMA	7 365	475	5 115	3 072	249	269	72	16 617

W ramach przeprowadzonych badań terenowych wg. zmodyfikowanej oceny cech powierzchniowych w okresie 2016 - 2021 ocenie podlegało corocznie 120 438 płyt betonowych na 5 odcinkach jednorodnych (A-E). Łącznie zinwentaryzowano 16 617 szt. uszkodzeń (w tym uszkodzeń naprawionych), z czego najliczniejszą grupę oraz największy średni przyrost stanowią wykruszenia szczelin (WS). Sytuacja ta może wynikać z faktu, iż w latach 2016 – 2019 prowadzone były prace związane z kompleksową wymianą uszczelnień szczelin dylatacyjnych i w ramach procesu usuwania (wrywania starej masy zalewowej) mogło dochodzić do ich mechanicznych uszkodzeń.


Tabela 20. Zestawienie powierzchni oraz długości zinwentaryzowanych typów uszkodzeń wraz z ich przyrostem w okresie 2016 – 2021 (5 lat) z podziałem na odcinki (A-E)

Odcinek	Parametry uszkodzeń	UP [m ²]	UN [m ²]	WS [m ²]	WK [m ²]	PK [m]	PL [m]	PT [m]
A	Ilość	69	2	3	6	48	16	38
	Przyrost [%]	33%	79%	78%	72%	89%	71%	40%
B	Ilość	52	1	3	72	23	26	12
	Przyrost [%]	49%	59%	89%	28%	60%	80%	43%
C	Ilość	151	1	17	8	30	101	12
	Przyrost [%]	17%	40%	92%	13%	88%	16%	49%
D	Ilość	189	1	6	12	25	2	29
	Przyrost [%]	40%	67%	86%	46%	89%	82%	87%
E	Ilość	168	1	7	4	16	272	18
	Przyrost [%]	31%	77%	87%	50%	77%	3%	11%
SUMA		629	7	36	102	143	417	110
		774				670		

Łączna powierzchnia zidentyfikowanych uszkodzeń na analizowanych odcinkach (A-E) do roku 2021 to 774 m² co stanowi 0,04% całkowitej powierzchni jezdni na badanych odcinkach. Natomiast łączna długość zlokalizowanych uszkodzeń to 670 mb. na odcinku drogi o długości 101 km (licząc poszczególne pasy ruchu 606 km). Powyższe informacje oznaczają, że zgodnie z aktualnie stosowanymi kryteriami ocen wg. DSN analizowaną nawierzchnię (po 10 latach eksploatacji) można zaliczyć do wielkości pożądanej (Wp), co oznacza że jest to ocena która określa stan nawierzchni nowych, odnowionych oraz eksploatowanych, które nie wymagają planowania zabiegów remontowych.

W ramach wyżej przeprowadzonej identyfikacji uszkodzeń nawierzchni z betonu cementowego i wyodrębnieniu dodatkowego uszkodzenia pt. „Wykruszenie krawędzi” (rys. 73) oznaczony symbolem WK oraz WKn (uszkodzenie naprawione), które występują wyłącznie na pasie 1 (szybkim) i pasie 3 (awaryjnym) oraz ze względu na ich genezę powstania, która to jest związana z mechanicznymi uszkodzeniami płyt w ramach prowadzonych innych prac utrzymaniowych m.in. w procesie koszenia poboczy oraz pasa dzielącego, ten typ uszkodzenia nie został uwzględniony w dalszej analizie w zakresie prognozowania jego zmian.


Dodatkowo kluczowymi danymi, jakie są gromadzone w ramach zmodyfikowanej oceny cech powierzchniowych nawierzchni z betonu cementowego w ramach badanych odcinków (A-E) są informacje o uszkodzeniach, które są naprawione (rys.74).



Rysunek 73. Przykładowe zinventaryzowane wykruszenia krawędzi a) pas nr 1 (szybki), b) pas nr 3 (awaryjny) wg. zmodyfikowanej metody oceny cech powierzchniowych


a) Uszkodzenie Powierzchniowe (UP)

b) Naprawione uszkodzenie powierzchniowe (UPn)




Rysunek 74. Przykład zidentyfikowanego a) uszkodzenia powierzchniowego (UP) (kampania pomiarowa w roku 2017), b) uszkodzenia powierzchniowego naprawionego (UPn) (kampania pomiarowa w roku 2018)

Dane te są istotne ze względu na prowadzenie i monitorowanie skutecznego procesu utrzymania, a co za tym idzie możliwość jego modyfikowania. Informacja ta jest niezbędna do rzetelnej oceny stanu technicznego nawierzchni. Przykładowe zestawienie tego rodzaju danych zamieszczono na rysunkach 75-76 dla uszkodzenia powierzchniowego (UP/UPn). Pozostałe informacje prezentujące podział poszczególnych typów uszkodzeń z wyodrębnieniem uszkodzeń naprawionych zestawiono w załączniku 1.



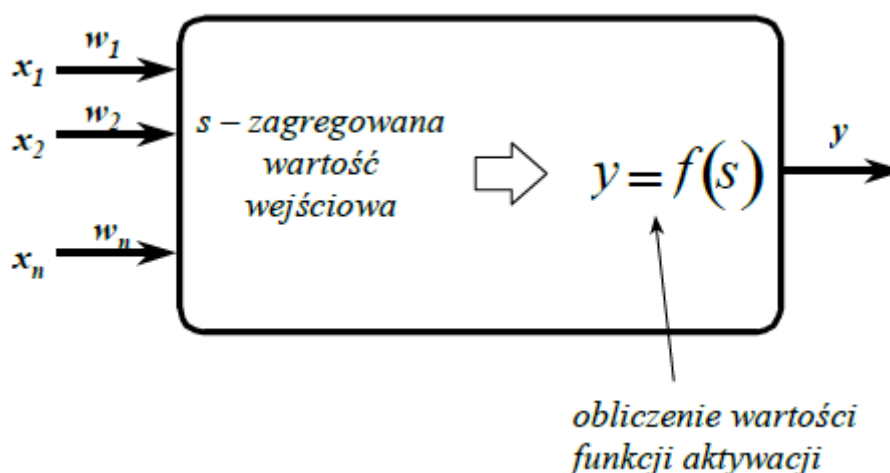
Rysunek 75. Zestawienie procentowe uszkodzeń powierzchni (UP) do naprawionych uszkodzeń powierzchni (UPn) z podziałem na odcinki jednorodne (A-E)



Rysunek 76. Zestawienie powierzchni uszkodzeń powierzchni (UP) do naprawionych uszkodzeń powierzchni (UPn) z podziałem na odcinki jednorodne (A-E)

6.6 Proces uczenia sieci neuronowych w programie STATISTICA

Schemat działania modelu neuronu dostępnego w programie Statistica Automatyczne Sieci Neuronowe przedstawia rysunek 77.




Rysunek 77. Schemat działania modelu neuronu dostępnego w programie Statistica Automatyczne Sieci Neuronowe

Neuron posiada określoną liczbę wejść, na które wprowadzane są wartości wejściowe x_1, x_2, \dots, x_n . Z każdym wejściem powiązana jest waga w_1, w_2, \dots, w_n . Wewnątrz neuronu realizowane są dwie podstawowe operacje:

- wyznaczenie zagregowanej wartości wejściowej (operacja ta realizowana jest przez funkcję agregującą zwaną funkcją potencjału postsynaptycznego lub funkcją PSP),
- wyznaczenie wartości wyjściowej neuronu (za wyznaczenie tej wartości odpowiedzialna jest funkcja aktywacji zwana również funkcją przejścia).

Uczenie neuronu realizowane jest poprzez odpowiednią modyfikację jego parametrów (wag). Sposób realizacji uczenia jest uzależniony od celu procedury uczącej. Celem procedury uczącej jest utworzenie modelu opisującego zależność pomiędzy zmiennymi wejściowymi i zmienną wyjściową (rys. 78).



Rysunek 78. Przykład zależności pomiędzy zmiennymi wejściowymi x_1 oraz x_2 a zmienną wyjściową Y . Budowany model składa się z jednego neuronu.

Proces uczenia polega na:


- obliczaniu gradientu funkcji błędów w punkcie odpowiadającym aktualnym wartościom wag (gradient wskazuje kierunek najszybszego wzrostu wartości funkcji) - gradient funkcji E w punkcie \mathbf{w} oznaczany jest jako $\mathbf{E}(\mathbf{w})$,
- wyznaczeniu wektora przeciwnego do gradientu (a więc wektor równy $-\mathbf{E}(\mathbf{w})$) - wskazuje on na kierunek najszybszego spadku wartości funkcji,
- przemnożeniu wektora przeciwnego do gradientu przez współczynnik uczenia (znacznie mniejszą od jedności wartość dodatnią) - w ten sposób obliczana jest poprawka, o którą modyfikowane są wartości wag.

Każdy sygnał wejściowy przedstawiony jako x_i jest przemnażany przez wagę w_i połączenia między sygnałem wejściowym a blokiem sumacyjnym. Wszystkie sygnały wejściowe przemnożone przez odpowiadające im wagi są sumowane w bloku sumacyjnym. Następnie sygnał jest przekształcany przez funkcję aktywacyjną w tak zwany blok aktywacji w finalny sygnał wyjściowy. Funkcje aktywacyjne mogą przybierać postać różnych funkcji matematycznych, od najprostszej funkcji liniowej aż po na przykład sigmoidalną bipolarną [113]. Działanie sztucznego neuronu może być opisane [7] za pomocą wzoru:

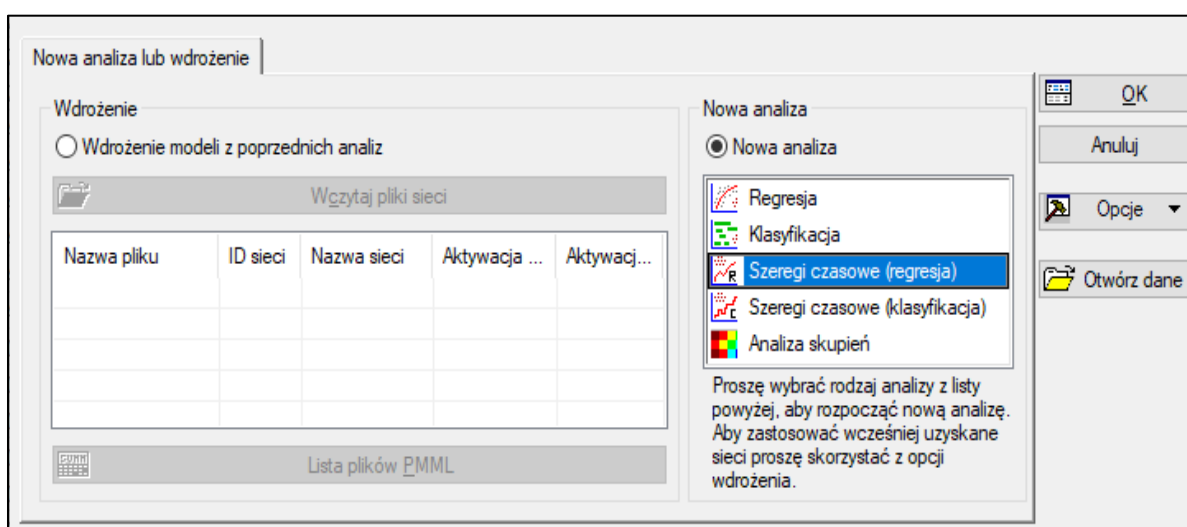
$$Y = F\left(\sum_{i=1}^n w_i x_i\right) \quad (5)$$

gdzie: F jest funkcją aktywacji, x_i jest sygnałem wejściowym, w_i jest wagą sygnału wejściowego, i jest liczbą zmiennych wejściowych, $i = 1, \dots, n$, a y jest sygnałem wyjściowym

STATISTICA Sieci Neuronowe umożliwia modelowanie i prognozowanie szeregów czasowych. W typowych zastosowaniach analizowane są jednowymiarowe szeregi czasowe, w których rozpatrywana wartość szeregu jest uzależniona od wyszczególnionej liczby przeszłych wartości tego samego szeregu (rys. 79, 80).



Rysunek 79. Schemat prognozowania szeregu czasowego



Rysunek 80. Okno wyboru modelu analizy

Procedura prowadząca do utworzenia sieci perceptronowej (MLP) rozpoczyna się w podobny sposób jak w przypadku tworzenia sieci liniowej. Należy pamiętać, aby w oknie Projektant sieci użytkownika w panelu Typ sieci wskazać wartość Perceptron wielowarstwowy. Po dokonaniu tej czynności na karcie Neurony należy określić strukturę sieci. Działanie sieci tego typu polega na:

- wprowadzeniu danych wejściowych,
- wyznaczeniu wartości wyjściowych neuronów ukrytych,
- wyznaczeniu wartości wyjściowej neuronu wyjściowego (lub neuronów wyjściowych).

Rezultat działania sieci uzależniony jest od:

- wartości wag neuronów ukrytych i wyjściowych,
- struktury sieci.

Uczenie jednokierunkowych sieci wielowarstwowych przebiega w trybie z nauczycielem, co oznacza, że w skład zbioru uczącego wchodzi wartości wprowadzane na wejściu sieci i odpowiadające im wartości wyjściowe. Celem uczenia jest wyznaczenie takich wartości wag, dla których wartości wyjściowe sieci będą identyczne (lub bardzo zbliżone) z rzeczywistymi wartościami wyjściowymi.

Uczenie doprowadzić ma do minimalizacji błędu sieci będącego zagregowaną miarą różnic pomiędzy rzeczywistymi wartościami wyjściowymi i wartościami obliczonymi za pomocą sieci. Najczęściej stosowaną formułą służącą do obliczania błędu jest suma kwadratów różnic pomiędzy wspomnianymi wartościami, czyli:

$$E = \sum_{i=1}^n (d_i - y_i)^2 \quad (6)$$

gdzie: d_i jest rzeczywistą wartością wyjściową, y_i jest odpowiadającą jej wartością wyznaczoną przez sieć, zaś N jest liczebnością zbioru uczącego.

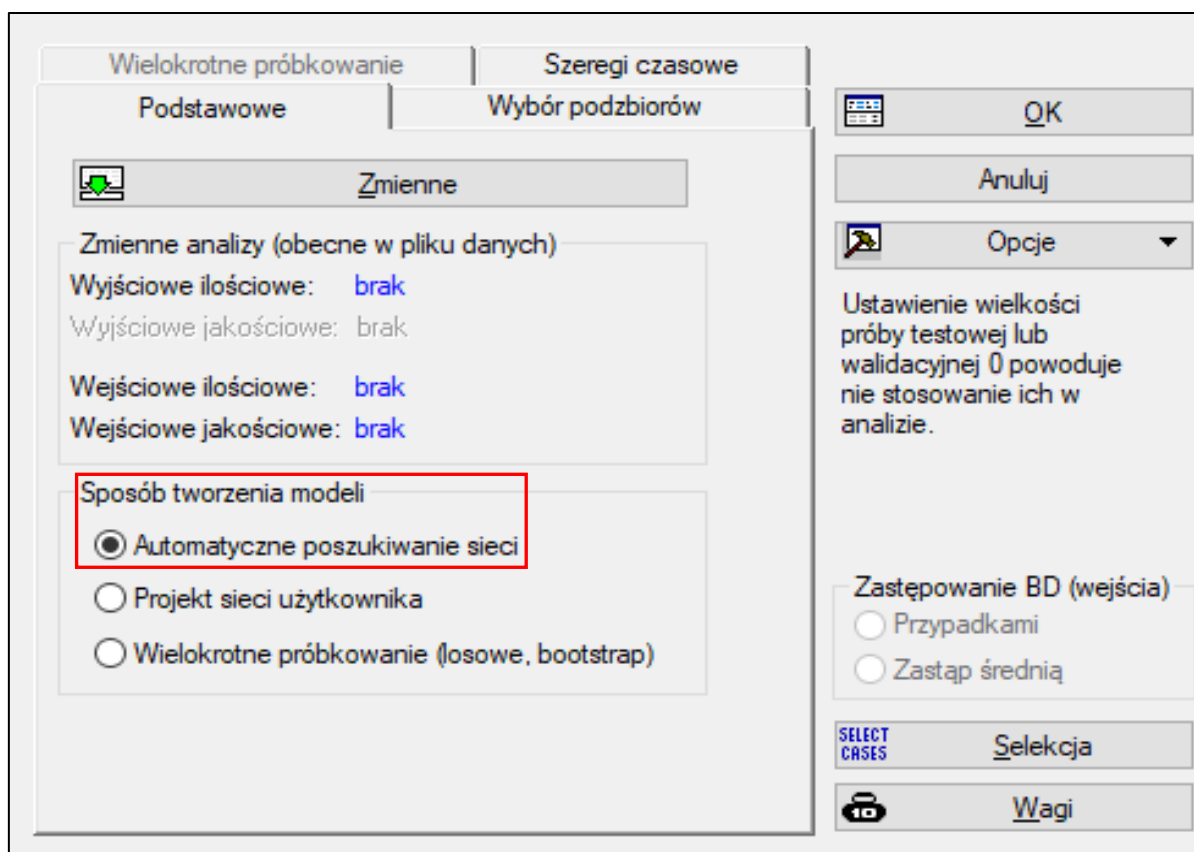
Rodzaj stosowanej w trakcie uczenia funkcji błędu określony jest przez konstruktora modelu. W trakcie budowy neuronowego modelu regresyjnego należy podjąć wiele decyzji, dotyczących między innymi:

- rodzaju i struktury sieci,
- sposobu jej uczenia,
- doboru zmiennych wejściowych.

W programie dostępne są trzy tryby wykonywania analizy:

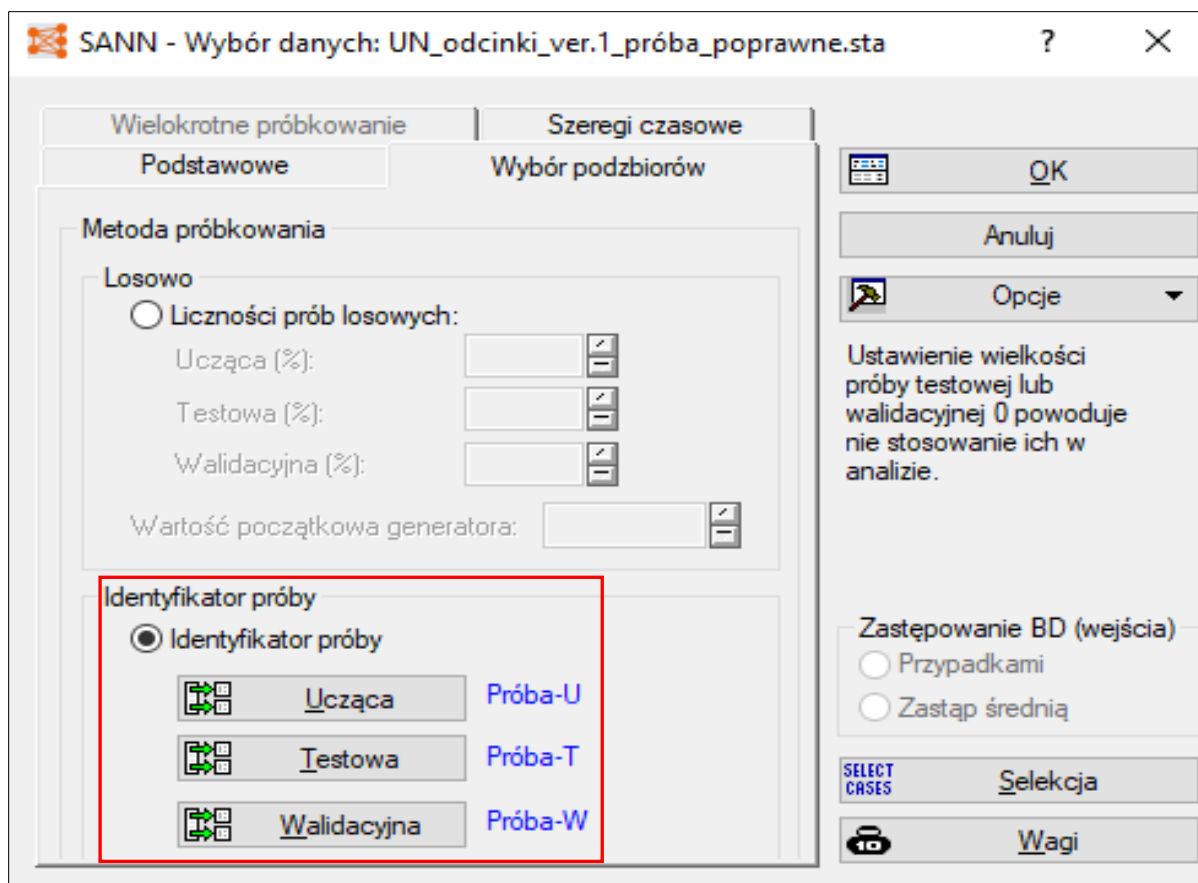
- automatyczne poszukiwanie sieci, umożliwiające automatyczne przetestowanie wielu układów hiperparametrów (ustawień) metody i wybór najlepszych. Układy hiperparametrów określane są w sposób losowy.
- projekt sieci użytkownika, umożliwiające określenie ustawień analizy ręcznie przez użytkownika.
- wielokrotne próbkowanie (losowe, bootstrap), pozwalający na budowę wielu modeli po każdorazowym wylosowaniu przypadków uczących. Zbudowane modele traktowane powinny być następnie jako zespół głosujących ekspertów.

W wielu przypadkach nie istnieją przesłanki merytoryczne pozwalające na wskazanie właściwych rozwiązań i niezbędne jest wówczas zastosowanie drogi eksperymentalnej. Jej stosowanie polega na doborze właściwych parametrów modelu w oparciu o wyniki uzyskane w trakcie kolejnych eksperymentów, wykorzystujących różne modele. Podstawową wadą eksperymentalnego podejścia do procesu budowy modelu neuronowego są duże wymagania czasowe. Jeśli kolejne eksperymenty miałyby być realizowane, to niezbędne do tego nakłady czasowe mogłyby być bardzo duże. W programie Statistica dużym ułatwieniem jest dostęp do modułu pt. Automatyczne poszukiwanie sieci. Jego uruchomienie jest możliwe z poziomu okna SANN Wybór Danych poprzez wybranie opcji Automatyczne poszukiwanie sieci. Jego uruchomienie jest możliwe z poziomu okna przedstawionego na rysunku 81.



Rysunek 81. Okno wyboru sposobu tworzenia SSN

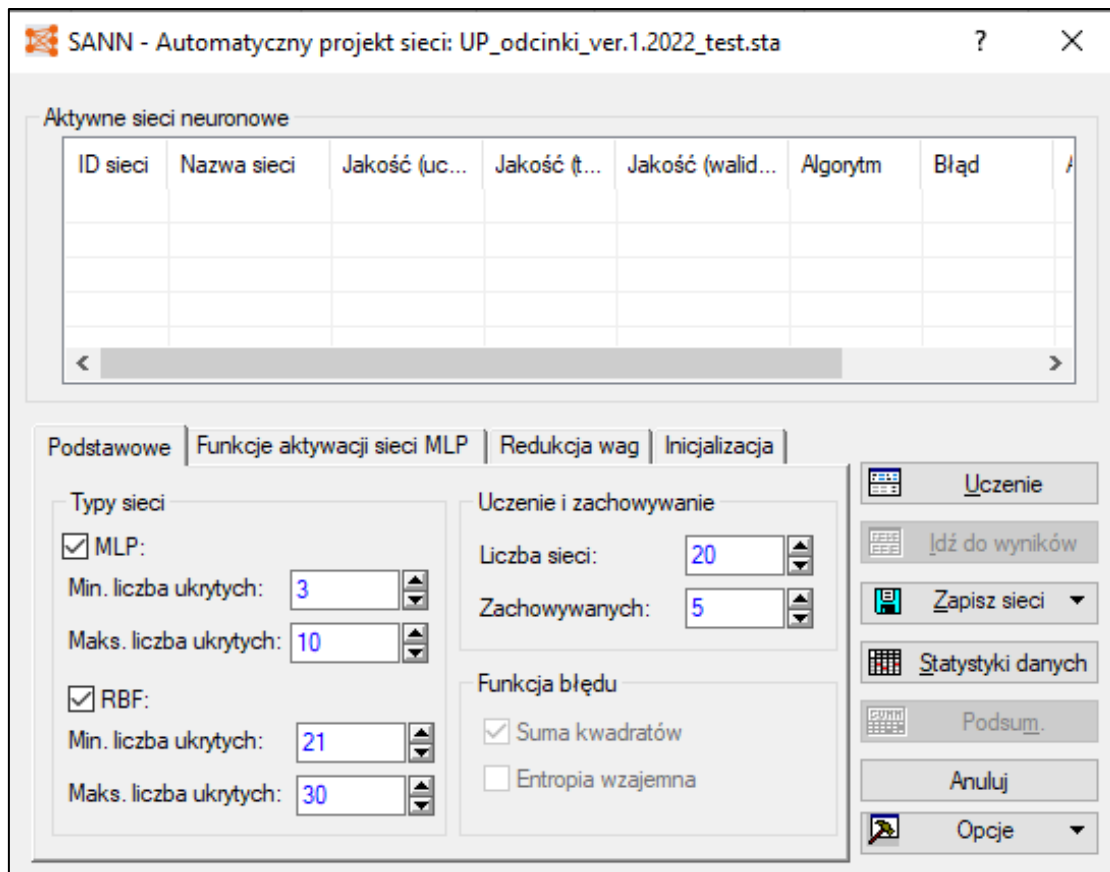
Chcąc usprawnić proces uczenia modelu neuronowego, a jednocześnie zwiększyć wiarygodność uzyskiwanych statystyk służących jego ocenie wypracowano alternatywne metody konstrukcji zbiorów (rys. 82). Pociągnęło to za sobą konieczność dokonania zmian w stosowanych procedurach uczenia i oceny modeli. Zbiór uczący wykorzystywany jest bezpośrednio do modyfikacji wag sieci, przypadki walidacyjne pozwalały na bieżące monitorowanie procesu uczenia, zaś zbiór testowy służył do ponownej oceny jakości modelu przeprowadzanej po zakończeniu procesu uczenia. Losowy sposób podziału dostępnych przypadków na zbiór uczący, walidacyjny i testowy ma swoje wady w sytuacji, gdy dostępny zbiór danych składa się ze stosunkowo małej liczby przypadków, niewielka liczba przypadków wpływa negatywnie na rezultaty uczenia (zwiększa się możliwość przeuczenia sieci) oraz utrudnia wiarygodną ocenę jakości modelu.



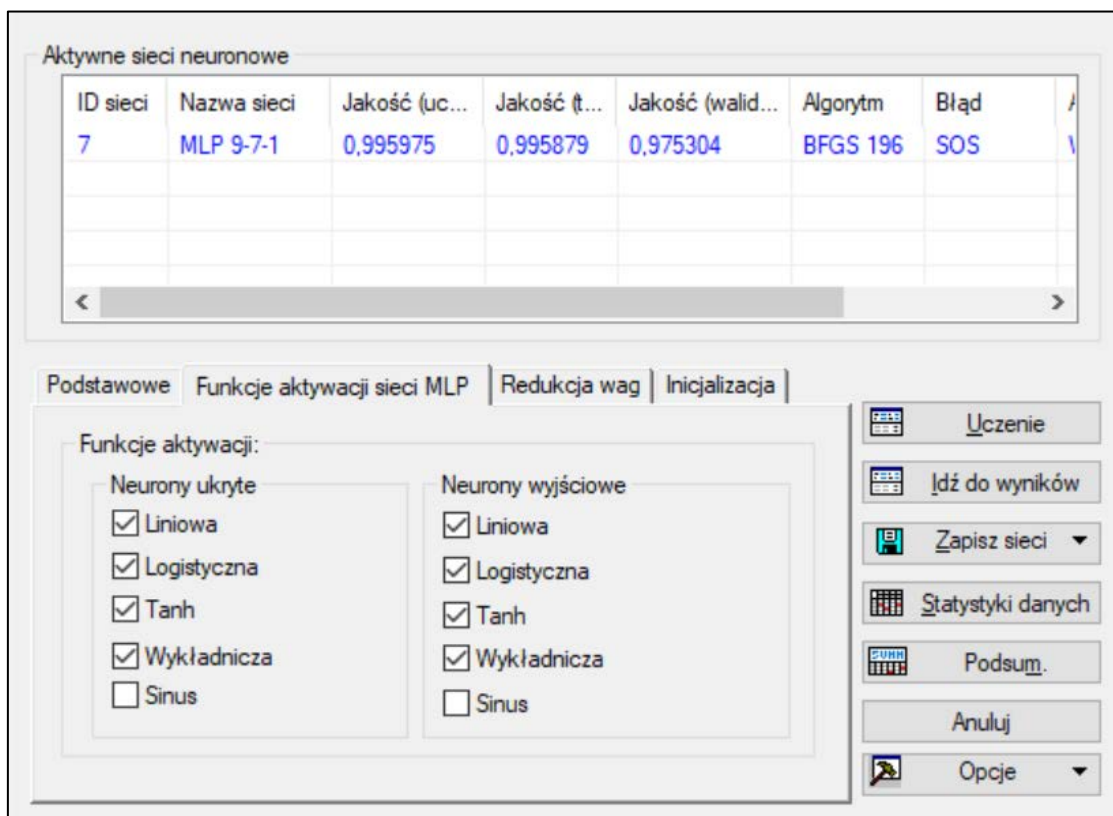
Rysunek 82. Proces doboru zbioru uczącego, testowego oraz walidacji

Na karcie Podstawowe (rys. 83) znajdują się parametry pozwalające na określenie zakresu poszukiwań. W tym miejscu można określić liczbę testowanych modeli (opcja Liczba sieci) oraz określić, jaka liczba najlepszych sieci ma zostać zachowana (Zachowywanych). Zwiększanie wartości w polu Liczba sieci zwiększa szanse na skonstruowanie dobrego modelu, ale wydłuża również czas obliczeń. W obszarze Typy sieci możemy określić typy sieci uwzględnianych w trakcie przeprowadzanych eksperymentów oraz zdefiniować minimalną i maksymalną liczbę neuronów ukrytych w rozpatrywanych typach sieci neuronowych.

Na karcie Funkcje aktywacji sieci MLP (rys. 84) określamy dostępne funkcje aktywacji dla neuronów warstwy ukrytej i wyjściowej.



Rysunek 83. Okno do określenia parametrów poszukiwanej sieci



Rysunek 84. Okno Funkcja aktywacji sieci MLP

Celem uczenia jest zawsze minimalizacja wartości błędu modelu neuronowego przeprowadzona poprzez modyfikację wartości parametrów (wag) sieci. Program SANN pozwala użytkownikowi na wybór algorytmu stosowanego do modyfikacji parametrów sieci.

Na liście dostępnych metod znajdują się metody:

- Najszybszego spadku (metoda wstecznej propagacji błędów),
- BFGS (metoda zmiennej metryki, Quasi-Newton)
- Gradientów sprzężonych,

Uwagi dotyczące uczenia metodą najszybszego spadku (wstecznej propagacji błędów) są następujące:

- konieczna do zrealizowania liczba epok jest uzależniona od złożoności zadania i od wielkości zbioru uczącego; wartość ta musi zostać dobrana indywidualnie dla każdego zadania; stosując tę metodę uczenia w większości przypadków należy zrealizować większą liczbę epok uczenia niż w przypadku zastosowania innych metod (ale czas realizacji jednej epoki jest krótszy niż w przypadku zastosowania innych algorytmów uczenia),
- w wersji algorytmu wstecznej propagacji błędów zaimplementowanej w SANN modyfikacja wag następuje po prezentacji każdego elementu zbioru uczącego (a nie w sposób skumulowany po zakończeniu prezentacji wszystkich elementów składających się na zbiór uczący), wartość współczynnika uczenia musi zostać dobrana indywidualnie dla rozwiązywanego problemu. Zbyt duża wartość powoduje, że proces uczenia nie jest zbieżny, zaś wartość zbyt mała powoduje bardzo powolne zmniejszanie się wartości błędu. Zaleca się zmniejszanie wartości współczynnika uczenia w trakcie działania algorytmu – w początkowej fazie działania stosuje się wartość stosunkowo dużą, zaś w trakcie działania metody jest ona zmniejszana (aby osiągnąć taki efekt należy zdefiniować w okienku dialogowym wartość początkową i końcową, w trakcie uczenia wartość współczynnika jest zmniejszana w sposób liniowy),
- współczynnik momentum określa wpływ zmian wartości współczynników wagowych dokonanych w kroku poprzednim algorytmu na zmiany w kroku bieżącym. Zastosowanie członu momentum powoduje przyspieszenie procesu uczenia oraz zmniejsza prawdopodobieństwo zatrzymania algorytmu w minimum lokalnym funkcji błędu. Wartość współczynnika momentum kształtuje się w przedziale od 0 do 1, ale musi być dobrana w zależności od specyfiki rozwiązywanego problemu.

Algorytm Broydena-Fletcher-Goldfarba-Shanno (BFGS) to iteracyjna metoda optymalizacji stosowana do znajdowania minimum (lub maksimum) funkcji wielu zmiennych. Nazwa algorytmu pochodzi od nazwisk jego twórców tj. Charlesa G. Broydena, Rogera D. Fletchera, Donalda Goldfarba i Davida G. Shanno. Algorytm BFGS jest często stosowany w dziedzinie optymalizacji nieliniowej, gdzie celem jest znalezienie najlepszego zestawu wartości zmiennych, które minimalizują (lub maksymalizują) określoną funkcję celu. Może być używany w różnych dziedzinach, takich jak nauki przyrodnicze, inżynieria, ekonomia i wiele innych.

Głównym zadaniem algorytmu BFGS jest obliczenie kierunku poszukiwania minimum funkcji oraz długości kroku, który prowadzi do poprawy wartości funkcji celu. Algorytm utrzymuje przybliżenie hesjanu, który jest estymacją drugiej pochodnej funkcji celu. Na podstawie tego przybliżenia obliczany jest kierunek poszukiwania minimum.

Algorytm BFGS jest często preferowany ze względu na swoją efektywność i zdolność do radzenia sobie z szerokim zakresem problemów optymalizacyjnych. Jest to metoda quasi-Newtonowska, która łączy zalety metody gradientowej (np. prostota implementacji) z przybliżeniem drugiej pochodnej funkcji celu, co pozwala na szybsze zbieganie do rozwiązania.

Algorytm BFGS posiada kilka głównych zalet tj.:

- efektywność - jest znany z wysokiej wydajności i szybkiego zbiegania do rozwiązania. Dzięki przybliżeniu drugiej pochodnej funkcji celu, algorytm może efektywnie ustalić kierunek poszukiwania minimum, co prowadzi do szybkiego zbliżania się do optymalnego punktu.
- globalna zbieżność - jest algorytmem globalnie zbieżnym, co oznacza, że ma zdolność do znalezienia globalnego minimum funkcji celu (o ile istnieje) zamiast utknięcia w lokalnym minimum. Ta cecha czyni go bardziej niezawodnym w porównaniu do niektórych innych metod optymalizacji.
- skalowalność - jest stosunkowo skalowalnym algorytmem, co oznacza, że może być używany w przypadku funkcji celu z wieloma zmiennymi. Jest to szczególnie ważne w przypadku problemów optymalizacyjnych, które mają wiele parametrów do optymalizacji.
- niezawodność - jest dobrze zbadanym i ugruntowanym algorytmem, który został szeroko stosowany i testowany w różnych dziedzinach. Jego niezawodność i stabilność sprawiają, że jest popularnym wyborem dla wielu problemów optymalizacyjnych.

Istnieje wiele dowodów na to, że BFGS jest obecnie najlepszą formułą aktualizacji do wykorzystania w nieograniczonej minimalizacji [16].

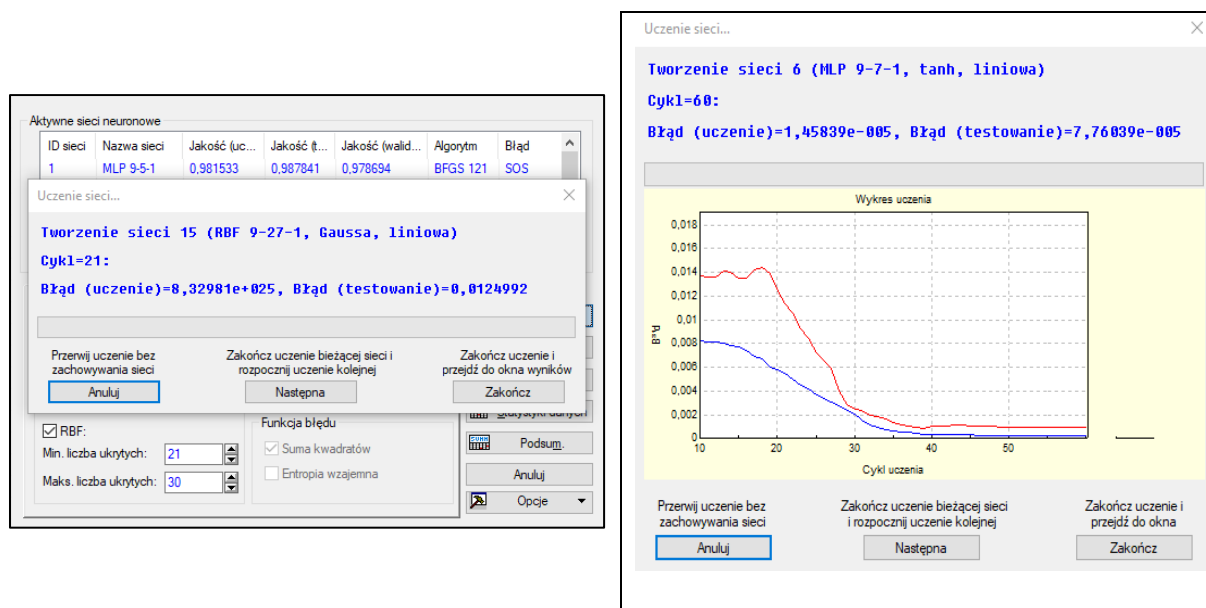
Metoda gradientów sprzężonych jest dostępna po wybraniu na liście wyboru pozycji *Gradienty sprzężone*. Jedynym parametrem, którego wartość musi zostać ustalona przez użytkownika jest liczba epok uczenia. Jest to metoda szczególnie zalecana do uczenia dużych sieci (w których liczba wag jest większa od stu). Modyfikacja wag jest przeprowadzana jednokrotnie w jednej epoce uczenia, po prezentacji wszystkich elementów zbioru uczącego. Idea metody jest następująca: w realizowanym kroku algorytmu wyznacza się kierunek poszukiwań minimum funkcji błędu. Następnie wyznacza się wartość najmniejszą minimalizowanej funkcji położoną na wyznaczonym kierunku poszukiwań. Po przejściu do wyznaczonego punktu wyznacza się nowy kierunek poszukiwań, który jest sprzężony z poprzednim. Kolejnym krokiem jest wyznaczenie minimum funkcji błędu w nowym kierunku poszukiwań.

Dwie główne zalety metody gradientu sprzężonego to:

- osiągnięta w kolejnym kroku algorytmu wartość funkcji błędu nigdy nie jest większa od wartości błędu w kroku poprzednim,

- metoda gradientu sprzężonego nie posiada parametrów, których wartość musiałaby być ustalona przez użytkownika, a które wpływałyby istotnie na szybkość działania i osiągnięty efekt końcowy.

Uczenie sieci ma charakter wieloetapowy. W trakcie każdego kroku wyznaczane są kolejne przybliżenia optymalnych wartości parametrów. Realizowane kroki nazywane są epokami uczenia. Epoka obejmuje jednorazową prezentację wszystkich przypadków uczących i przeprowadzoną na tej podstawie modyfikację parametrów sieci (wag i progów). Postęp uczenia prezentowany jest zwykle za pomocą wykresu błędu uczenia (rys. 85).



Rysunek 85. Okna prezentujące proces uczenia sieci neuronowych

W ramach wyboru najlepszego modelu należy kierować się następującymi kryteriami (uporządkowanymi w hierarchii od zazwyczaj najistotniejszych do najmniej istotnych):

- jakość (błąd) modelu na zbiorze TESTOWYM
- różnica jakości (błędu) modelu pomiędzy zbiorem UCZĄCYM a zbiorem TESTOWYM
- wielkość sieci (im mniej neuronów w warstwie wyjściowej tym lepiej)
- rodzaj funkcji aktywacji w warstwie wyjściowej – im prostsza tym lepsza (preferowana liniowa)
- rodzaj funkcji aktywacji w warstwie ukrytej – im prostsza tym lepsza.

Do oceny zbudowanych modeli i ich wyboru wykorzystywane są informacje dostępne w programie STATISTICA (tab.21).

Tabela 21. Podstawowe informacje o sieciach neuronowych zbudowanych w programie STATISTICA

Lp.	Informacja	Opis
1.	Nazwa sieci	rodzaj zbudowanej sieci oraz jej topologia
2.	Jakość (uczenia)	współczynnik korelacji liniowej pomiędzy zmienną wyjściową a prognozą sieci dla zbioru uczącego
3.	Jakość (testowania)	współczynnik korelacji liniowej pomiędzy zmienną wyjściową a prognozą sieci dla zbioru testowego
4.	Jakość (walidacji)	współczynnik korelacji liniowej pomiędzy zmienną wyjściową a prognozą sieci dla zbioru walidacyjnego
5.	Błąd (uczenia)	wartość błędu średniokwadratowego (podzielona przez dwa) dla zbioru uczącego
6.	Błąd (testowania)	wartość błędu średniokwadratowego (podzielona przez dwa) dla zbioru testowego
7.	Błąd (walidacji)	wartość błędu średniokwadratowego (podzielona przez dwa) dla zbioru walidacyjnego
8.	Algorytm uczenia	rodzaj algorytmu uczenia oraz liczba epok uczenia
9.	Aktywacja (wyjściowe)	rodzaj funkcji aktywacji użyty w neuronach warstwy wyjściowej

W programie Statistica stosowane są funkcje błędu w postaci sumy kwadratów (SOS) oraz entropii. Wykorzystywane są różne funkcje aktywacji w warstwie ukrytej i wyjściowej:

- Tanh,
- Wykładnicza,
- Liniowa,
- Logistyczna,
- Sinus.

Generalna zasada mówi, że jeżeli dwie sieci działają porównywalnie to wybieramy sieć prostszą.

Z licznych analiz modeli eksploatacyjnych (np. HDM-4) [83] wynika, że degradacja nawierzchni zależy zasadniczo od:

- natężenia ruchu,
- wieku nawierzchni (liczonego od daty budowy lub od ostatniego zabiegu remontowego),
- warunków klimatycznych.

Zmienne te umożliwiają określenie początku i przebiegu procesu degradacji. Mogą również wskazywać na różne powiązania między poszczególnymi typami uszkodzeń. Szczegóły w zakresie inwentaryzacji uszkodzeń nawierzchni z betonu cementowego pochodzą z sześciu cykli pomiarów terenowych według zmodyfikowanej metody

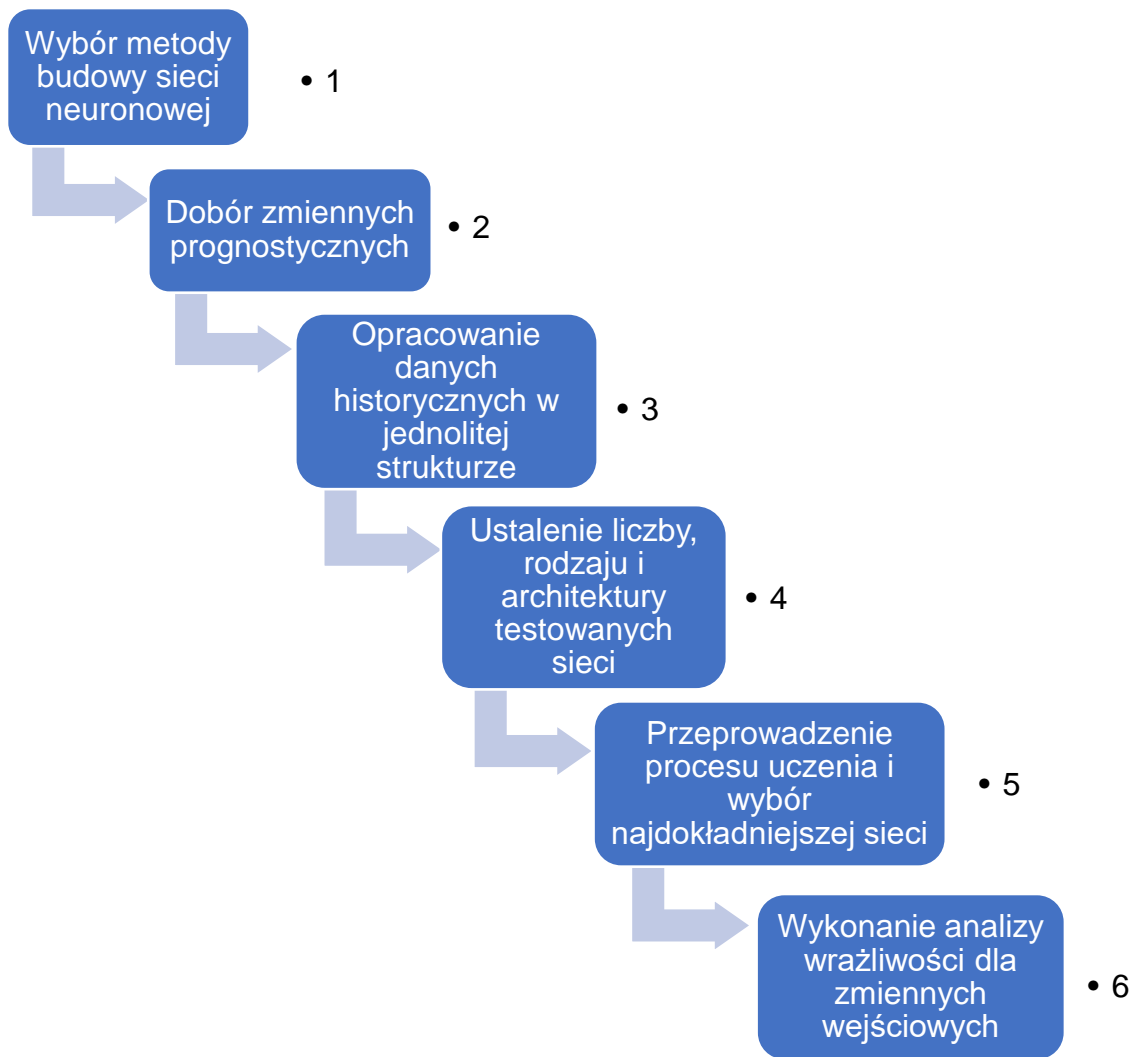
inwentaryzacji uszkodzeń płyt betonowych oraz danych o ruchu i wytypowanych parametrów meteorologicznych wg. tab.22.

Tabela 22. Źródło oraz charakterystyka danych do opracowania SSN

Lp.	Typ danych	Źródło	Charakterystyka danych
1.	Natężenie ruchu	Stacje pomiaru ruchu (pkt. 6.3)	<ul style="list-style-type: none"> ▪ osie standardowe (ruch rzeczywisty) ▪ pas ruchu ▪ kierunek ▪ odcinek jednorodny
2.	Warunki klimatyczne	Stacje meteorologiczne (pkt. 6.4)	<ul style="list-style-type: none"> ▪ gradient + (różnica temperatury) ▪ gradient – (różnica temperatury) ▪ liczba dni o temperaturze poniżej 0°C ▪ ilość opadów; ▪ odcinki jednorodne;
3.	Inwentaryzacja uszkodzeń nawierzchni	Zmodyfikowana metoda oceny cech powierzchniowych nawierzchni z betonu cementowego (pkt. 6.5)	<ul style="list-style-type: none"> ▪ typ uszkodzenia – PT/PTn, PL/PLn, PK, UN/UNn, UP/UPn, WS/WSn; ▪ pas ruchu; ▪ kierunek; ▪ odcinek jednorodny;

Zasadniczym czynnikiem powodzenia rozwiązań technicznych związanych z wykorzystaniem sieci neuronowych jest odpowiednio liczna i wiarygodna baza danych wyrażająca istotę rozpatrywanych problemów. W tym badaniu opracowano indywidualne ujednoczone modele SSN w celu prognozowania wartości zmian w obszarze uszkodzeń powierzchniowych nawierzchni, w odniesieniu do powierzchni analizowanych odcinków jednorodnych dla nawierzchni z betonu cementowego. Sześć różnych typów architektury SSN zostało użytych dla każdego typu uszkodzenia, aby otrzymać najlepszą architekturę modelu SSN. Szczegóły dotyczące doboru różnych parametrów wejściowych do tworzenia modeli, wyboru bazy danych do uczenia, testowania i walidacji modeli SSN zostały omówione w dalszej części dysertacji.

Przyjęty w pracy badawczej algorytm działania w celu opracowania szeregów czasowych i prognozy uszkodzeń składa się z kilkunastu etapów, jednak kluczowych można wyróżnić sześć (rys. 86).



Rysunek 86. Algorytm działania w zakresie opracowania SSN dla wybranego typu uszkodzenia nawierzchni z betonu cementowego

Założenia przyjętej architektury sieci neuronowych w ramach budowy modeli degradacji nawierzchni z betonu cementowego można scharakteryzować w następujący sposób:

- wybór metody budowy sieci neuronowej – wykorzystano automatyczne poszukiwanie sieci neuronowej; parametr jaki został przyjęty do prognozowania to ilość uszkodzonych płyt (w %) a parametrem weryfikacyjnym była informacja o ilości powierzchni uszkodzonej nawierzchni (w %);
- dobór zmiennych prognostycznych charakteryzujących prognozowane zagadnienie – dla każdego typu uszkodzenia przyjęto wszystkie wskaźniki (zmienne) dostępne w ramach analizowanych danych (tab.22);
- opracowanie danych historycznych i utworzenie cząstkowych szeregów czasowych – dla każdego typu uszkodzenia dane zostały zagregowane do parametrów wg. tab. 23;

- ustalenie liczby, rodzaju i architektury testowanych sieci neuronowych – do opracowania sztucznej sieci neuronowej wykorzystano program Statistica . Do badań wybrano dwa typy sztucznych sieci neuronowych tj. sieci o radialnych funkcjach bazowych (RBF) oraz perceptrony wielowarstwowe (jednokierunkowe sieci wielowarstwowe, sieci MLP). Zbiór danych uczących (U), testowania (T) oraz walidacji (W) został podzielony chronologicznie (2016 – 2019 – zbiór U, 2020 – zbiór T, 2021 – zbiór W);
- przeprowadzenie procesu uczenia i wybór najdokładniejszej sieci jako modelu prognostycznego - procedura polegała na porównaniu modelu zawierającego wszystkie dostępne zmienne na wejściu z modelami uproszczonymi (pojedynczymi zmiennymi na wejściu) a następnie kombinacją zmiennych o najlepszych jakościowo parametrach w zbiorze testowym;
- wykonanie analizy wrażliwości dla zmiennych wejściowych i ewentualna modyfikacja modelu semantycznego - korygowanie modelu SSN polegało na eliminacji zmiennych wejściowych, które pogarszają dokładność działania sieci neuronowej. Weryfikacja procesu polegała na ocenie modelu na podstawie wcześniej opisanych kryteriów m.in. jakości (błędu w zbiorze testowym) w stosunku do modelu zawierającego wszystkie zmienne wejściowe.

Tabela 23. Zestawienie zmiennych objaśniających (dane na wejściu) oraz zmiennych objaśnianych (dane na wyjściu).

Lp.	Zmienne objaśniające		Zmienne objaśniane
	Zbiór danych	Podział	
1	Odcinek	A, B, C, D, E	Typ uszkodzenia - [%] uszkodzonych płyt / [%] uszkodzonej powierzchni w 5, 6, 7, 8, 9 i 10 roku eksploatacji nawierzchni dla wszystkich analizowanych odcinków jednorodnych (od A do E)
2	Grubość płyt [cm]	27, 28, 29	
3	Rok eksploatacji	5, 6, 7, 8, 9, 10	
4	Pas	awaryjny, wolny, szybki	
5	Obciążenie ruchem	awaryjny, wolny, szybki	
6	Gradient max. (+)	odcinek	
7	Gradient max. (-)	odcinek	
8	Opady [mm]	odcinek	
9	Ilość dni pon. 0°C	odcinek	

Decyzja w zakresie wyboru celu (informacji) prognozy tj. ilości uszkodzonych płyt [%] oraz ilości uszkodzonej powierzchni [%] wynikała m.in. z:

- możliwości szybkiej oceny i porównania stanu poszczególnych analizowanych odcinków;
- możliwej szybkiej oceny efektywności działań prewencyjnych, mniejsze wartości wskazują na mniejszy zakres uszkodzeń, które wymagają mniej skomplikowanych napraw, podczas gdy większe wartości wymagają bardziej zaawansowanych działań;
- charakterystyki analizowanych odcinków, które różnią się między sobą m.in. długością, powierzchnią nawierzchni oraz liczbą płyt betonowych. Ze względu na to przyjęcie jednostki prognozy jako procent (%), umożliwia w spójny sposób wyrazić stosunek liczby uszkodzonych płyt do ogólnej liczby płyt w nawierzchni na danym odcinku;
- przyjęcie jednostki procentowej jest to wygodny sposób przedstawiania danych dotyczących uszkodzeń lub innych zjawisk wizualizujących relacje w skali 0-100%.

Wybór budowy SSN nie jest procesem decyzyjnym. W większości przypadków polega on na metodzie prób i błędów w połączeniu z typem uszkodzeń, dla których prowadzona jest analiza w celu określenia odpowiedniej architektury dla konkretnego przypadku. W niniejszej analizie wiele zmiennych wejściowych i wyjściowych jest utrzymywanych na stałym poziomie, a w poszczególnych warstwach ukrytych i neuronach dokonuje się zmian. Szczegóły dotyczące sześciu różnych rodzajów architektury modeli SSN zastosowanych dla konkretnego typu uszkodzenia przedstawiono w kolejnym rozdziale.

W przeprowadzonej analizie podział na zbiory: uczący, testowy oraz walidacji był rozpatrywany z podziałem na okresy pozyskanych badań terenowych w ramach następującego zestawienia:

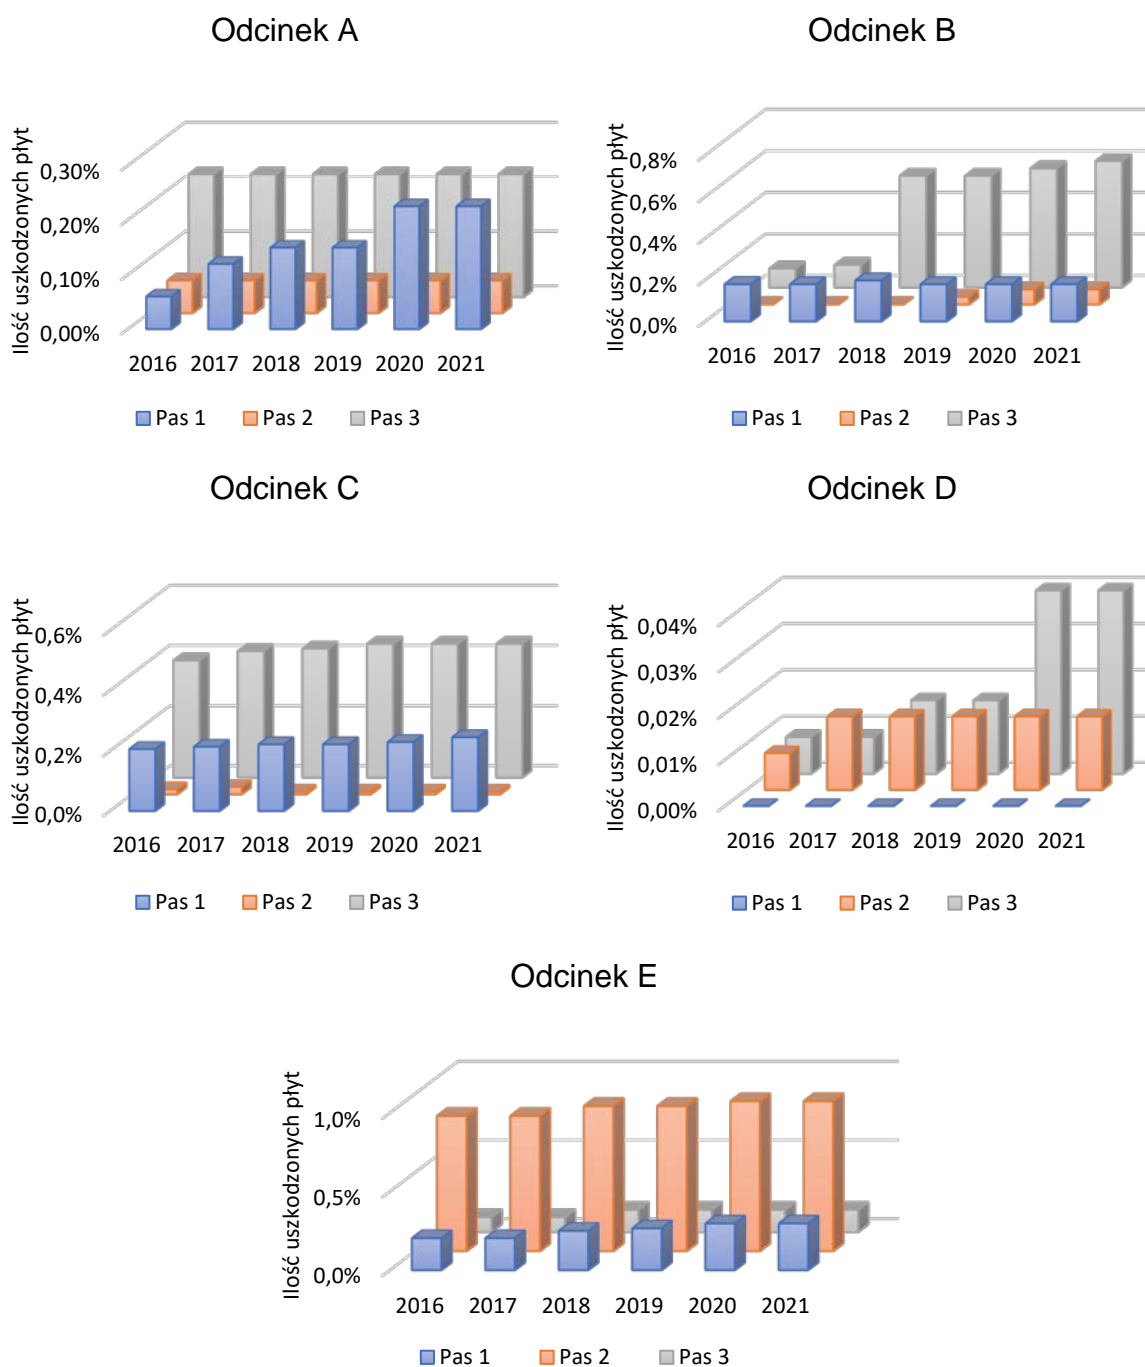
- zbiór uczący: okres 2016 – 2019 (4 letni okres badawczy),
- zbiór testowy: rok 2020,
- zbiór walidacji: rok 2021.

Do badań wybrano dwa dostępne w programie STATISTICA typy sztucznych sieci neuronowych: sieci o radialnych funkcjach bazowych (RBF) oraz wielowarstwowe preceptrony (MLP). Kryterium wyboru modelu była minimalna wartość błędu średniokwadratowego (MSE) dla danych ze zbioru testowego.

6.7 Wyniki modelowania [% płyt]

6.7.1 Pęknięcia podłużne

Graficzny charakter tego typu uszkodzenia zinwentaryzowanego w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim przedstawiono na rys. 87.



Rysunek 87. Zestawienie procentowe płyt ze zinwentaryzowanym uszkodzeniem podłużnym/ukośnym (PL) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1- pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach opisanego i przedstawionego wcześniej algorytmu budowy modelu neuronowego (rys.86) zdecydowano, że analizowanym parametrem na wyjściu będzie procent uszkodzonych płyt zgodnie z przedstawionym w poprzednim podrozdziale objaśnieniem, dla którego przystąpiono do opracowania sztucznej sieci neuronowej służącej do prognozowania pęknięcia podłużnego (PL). Parametrami wejściowymi budowanej sieci było osiem parametrów opisujących indywidualny charakter badanych odcinków nawierzchni z betonu cementowego: osie standardowe, pas jezdni, wiek, grubość, ilość opadów, liczba dni z temperaturą mniejszą niż 0°C, maksymalny gradient (+) oraz maksymalny gradient (-). Naukę sieci przeprowadzono z wykorzystaniem algorytmu Broydena-Fletcher-Goldfarba-Shanno (BFGS). Bazę danych stanowiły zgromadzone informacje z przeprowadzonych badań terenowych w ramach zmodyfikowanej wizualnej metody oceny stanu technicznego nawierzchni z betonu cementowego, analizy danych ruchowych ze stacji zliczania ruchu oraz ich przeliczenia na osie standardowe oraz danych ze stacji meteorologicznych rozlokowanych w obrębie analizowanych odcinków jednorodnych.

W rozwiązaniu problemu przeprowadzono poniższe czynności:

1. W pierwszej kolejności dla tego typu uszkodzenia na wejściu przyjęto wszystkie zmienne (poz. 1 z tab. 24) dostępne w ramach analizowanych danych oraz wyznaczono jakość tak uzyskanych sieci m.in. jakość testowania na poziomie 0,978.
2. Kolejno przeprowadzono powyższą procedurę dla każdego pojedynczego parametru (poz. od 2 do 9 z tab. 24) w celu wyznaczenia dla nich poszczególnych modeli, w wyniku czego uzyskano osiem pojedynczych sieci o jakości parametru testowania od 0,477 do 0,804;
3. Następnie dla zmiennej objaśniającej o najlepszych parametrach tj. pas przeprowadzono kolejną analizę dodając pojedynczo pozostałe zmienne w celu określenia jakości w taki sposób opracowanych sieci (poz. od 10 do 16 z tab. 24).
4. W wyniku przeprowadzonych analiz w ramach pkt. 3 można stwierdzić, że sieć neuronowa ze zmiennymi objaśniającymi (na wejściu) typu pas oraz wiek nawierzchni (analiza nr. 11 z tab. 24) uzyskała najlepszą jakość testowania na poziomie 0,993. W wyniku uzyskania jedynie przy dwóch zmiennych lepszą jakość sieci neuronowej w stosunku do sieci uwzględniającej wszystkie zmienne (analiza nr. 1 z tab. 24) proces szukania sieci uznano za zakończony.

Tabela 24. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia podłużnego/ukośnego (PL) w ramach analizy wrażliwości dla zmiennych wejściowych


Numer analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie analizy			
	2	3	4	5	6	7	8	9	10	11		Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] płyt	MLP 15-7-1	0,975	0,978	Logistyczna
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,492	0,509	Liniowa
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-7-1	0,666	0,687	Liniowa
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,785	0,804	Wykładnicza
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,477	0,492	Wykładnicza
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,482	0,493	Tanh
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-5-1	0,478	0,494	Wykładnicza
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-4-1	0,492	0,501	Liniowa
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,487	0,477	Tanh
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,984	0,985	Tanh
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-5-1	0,995	0,993	Liniowa
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,977	0,978	Liniowa
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-8-1	0,980	0,977	Tanh
14	Liczba dni z temp.<0°C	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,975	0,973	Tanh
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-8-1	0,983	0,978	Tanh
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-8-1	0,985	0,979	Tanh

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-5-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, pięć w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 25. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy 158 iteracji (epoki).


Tabela 25. Podstawowe informacje o sieci o strukturze MLP 9-5-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-5-1	0,995	0,993	0,980	0,000	0,000	0,000	BFGS 158	Liniowa


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-5-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 88-92.




Rysunek 88. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-5-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 89. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-5-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 90. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-5-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



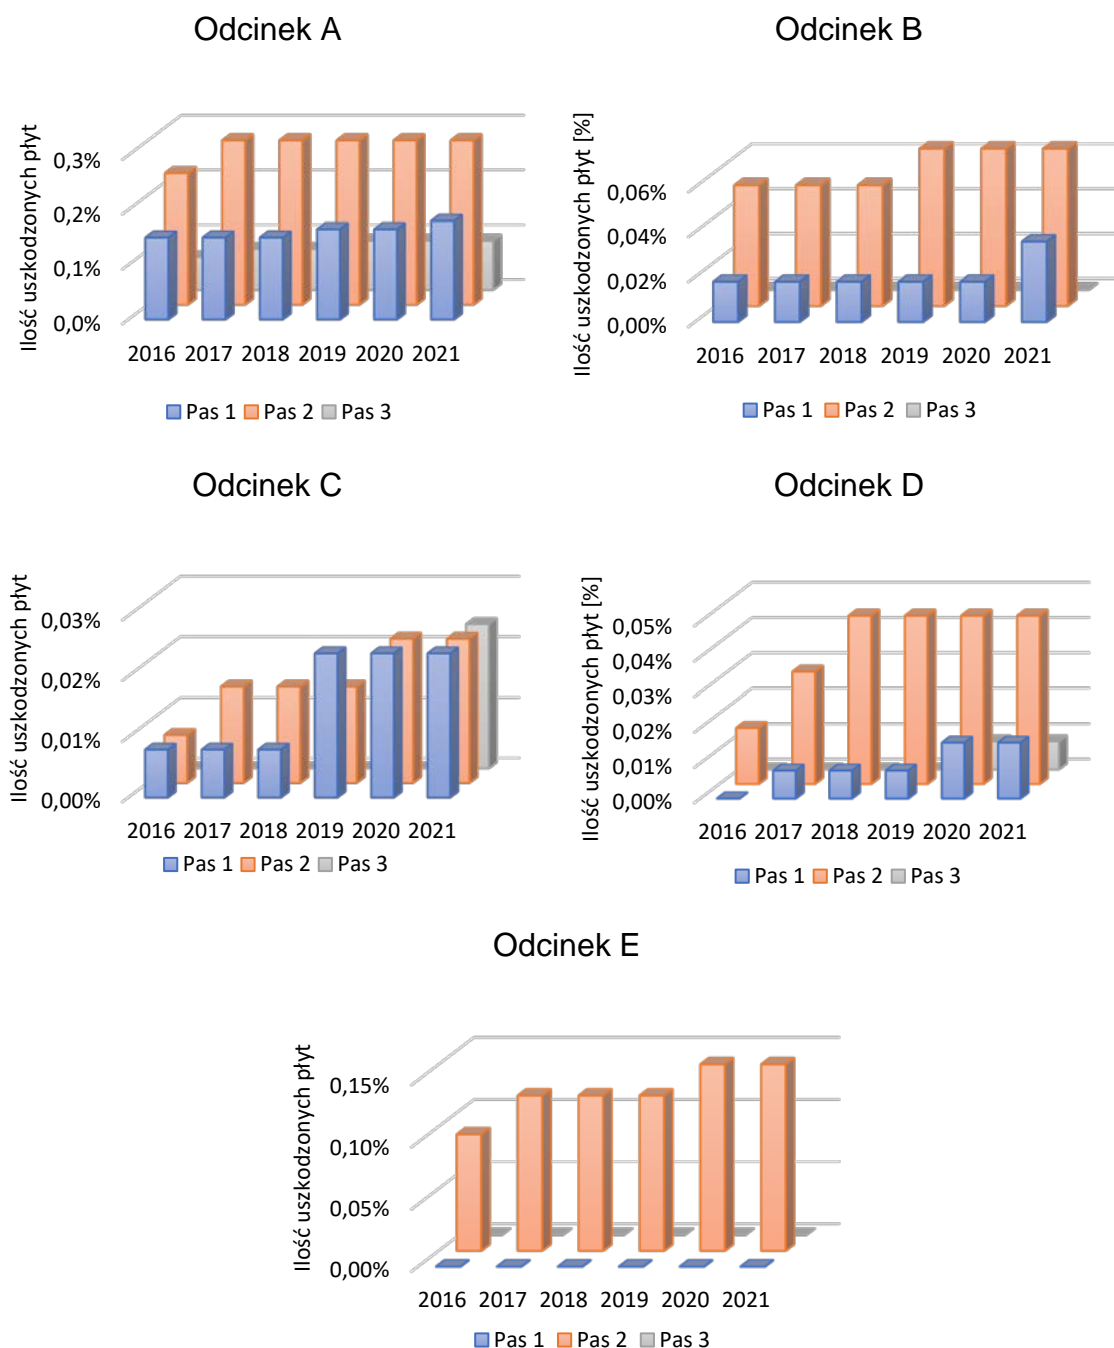
Rysunek 91. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-5-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 92. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-5-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.7.2 Pęknięcia poprzeczne

Graficzny charakter pęknięć poprzecznych zinwentaryzowany w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim przedstawiono na rys. 93.



Rysunek 93. Zestawienie procentowe płyt ze zinwentaryzowanym uszkodzeniem poprzecznym (PT) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

Tabela 26. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia poprzecznego (PT) w ramach analizy wrażliwości dla zmiennych wejściowych

Numer analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11		Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] płyt	MLP 15-11-1	0,992	0,990	Logistyczna
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,601	0,585	Liniowa
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,756	0,759	Tanh
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,760	0,760	Wykładnicza
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,598	0,584	Wykładnicza
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,593	0,583	Wykładnicza
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-5-1	0,601	0,585	Tanh
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,596	0,584	Tanh
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,601	0,580	Tanh
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-10-1	0,995	0,995	Logistyczna
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-10-1	0,999	0,996	Liniowa
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,994	0,989	Tanh
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,996	0,995	Liniowa
14	Liczba dni z temp.<0°C	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-4-1	0,995	0,991	Liniowa
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-5-1	0,994	0,991	Tanh
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-10-1	0,997	0,988	Tanh

W ramach przedstawionego w poprzednim podrozdziale algorytmu (rys. 86) oraz zgodnie z przedstawioną metodologią przeprowadzono całościową analizę (wyniki w tabeli 26) dla uszkodzenia typu pęknięcie poprzeczne, które polegało na:


5. W pierwszej kolejności dla tego typu uszkodzenia na wejściu przyjęto wszystkie zmienne (poz. 1 z tab. 26) dostępne w ramach analizowanych danych oraz określono jakość sieci m.in. jakość testowania na poziomie 0,990;
6. Kolejno przeprowadzono powyższą procedurę dla każdego pojedynczego parametru (poz. od 2 do 9 z tab. 26) w celu wyznaczenia dla nich poszczególnych modeli, w wyniku czego uzyskano osiem pojedynczych sieci o jakości testowania od 0,584 do 0,760;
7. Następnie dla zmiennej objaśniającej o najlepszych parametrach tj. pas przeprowadzono kolejną analizę dodając pojedynczo pozostałe zmienne w celu określenia jakości w taki sposób opracowanych sieci (poz. od 10 do 16 z tab. 26).
8. W wyniku przeprowadzonych analiz w ramach pkt. 3 można stwierdzić, że sieć neuronowa ze zmiennymi objaśniającymi (na wejściu) typu pas oraz wiek nawierzchni (analiza nr. 11 z tab. 26) uzyskała najlepszą jakość testowania na poziomie 0,996. W wyniku uzyskania jedynie przy dwóch zmiennych lepsze parametry jakości sieci neuronowej w stosunku do sieci uwzględniającej wszystkie zmienne (analiza nr. 1 z tab. 26) proces szukania sieci uznano za zakończony.

Najlepszą jakość uzyskała sieć neuronowa o architekturze MLP 9-10-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, dziesięć w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 27. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczane są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy 289 iteracji (epoki).


Tabela 27. Podstawowe informacje o sieci o strukturze MLP 9-10-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-10-1	0,998	0,996	0,991	0,000	0,000	0,000	BFGS 289	Liniowa


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-10-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 94-98.




Rysunek 94. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-10-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek. 95. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-10-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 96. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-10-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 97. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-10-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

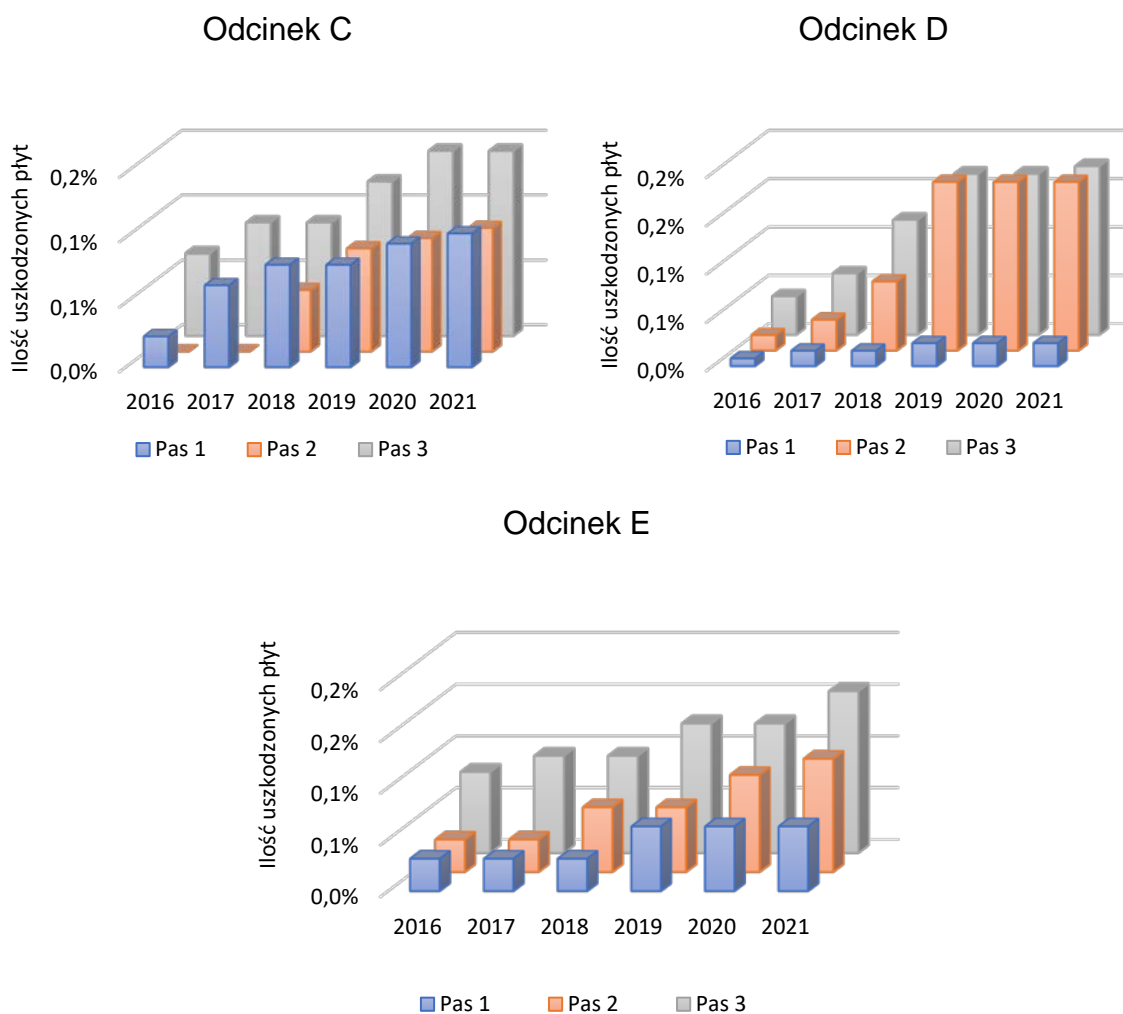


Rysunek 98. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-10-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.7.3 Pęknięcia krawędzi

Graficzny charakter tego typu uszkodzenia zinventaryzowanego w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim przedstawiono na rys. 99.





Rysunek 99. Zestawienie procentowe płyt z zinwentaryzowanym pęknięciem krawędzi (PK) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach opisanego wcześniej algorytmu zdecydowano, że analizowanym parametrem na wyjściu będzie procent uszkodzonych płyt, dla którego przystąpiono do opracowania sztucznej sieci neuronowej służącej do prognozowania pęknięcia krawędzi (PK). Ocenę wyników rozpoczęto od oceny zbudowanych modeli i wyboru najlepszego z nich. Przeprowadzona analiza wrażliwości modelu semantycznego (tab. 29) wykazała, że wszystkie przyjęte w pierwszej analizie zmienne wejściowe nie są istotne. W celu określenia istotnych zmiennych przystąpiono do modyfikacji modelu i wytypowania zmiennych, które mają istotny wpływ na jakość sieci neuronowej oraz zmiennych wyjściowych, które nie poprawiają jakości i zaburzają proces uczenia. W wyniku przeprowadzonych dalszych modyfikacji, można wywnioskować, że sieć neuronowa uzyskuje najlepszą wartość (jakość testowania) podczas analizy nr 10, przy uwzględnieniu na wejściu danych z informacją o pasie oraz wieku nawierzchni.

Tabela 29. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia pęknięcia krawędzi (PK) w ramach analizy wrażliwości dla zmiennych wejściowych


Nr. analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11		Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] płyt	MLP 15-4-1	0,817	0,785	Tanh
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-7-1	0,613	0,602	Liniowa
3	Osie std..	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-5-1	0,469	0,351	Wykładnicza
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-9-1	0,557	0,698	Tanh
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-4-1	0,328	0,372	Tanh
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,426	0,387	Tanh
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,462	0,337	Wykładnicza
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-9-1	0,333	0,374	Tanh
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,419	0,374	Logistyczna
10	Pas	Wiek.	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,918	0,954	Logistyczna
11	Osie std.	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-4-1	0,778	0,799	Tanh
12	Grubość	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-10-1	0,674	0,717	Liniowa
13	Opady	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-5-1	0,726	0,704	Logistyczna
14	Liczba dni z temp.<0°C	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-5-1	0,798	0,808	Logistyczna
15	Max. gra. +	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,649	0,707	Tanh
16	Max. gra. -	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,731	0,700	Tanh

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-6-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, sześć w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 28. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 55 iteracji (epoki).


Tabela 28. Podstawowe informacje o sieci o strukturze MLP 9-6-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-6-1	0,918	0,954	0,917	0,000	0,000	0,000	BFGS 55	Logistyczna


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-6-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 100-104.




Rysunek 100. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 101. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 102. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



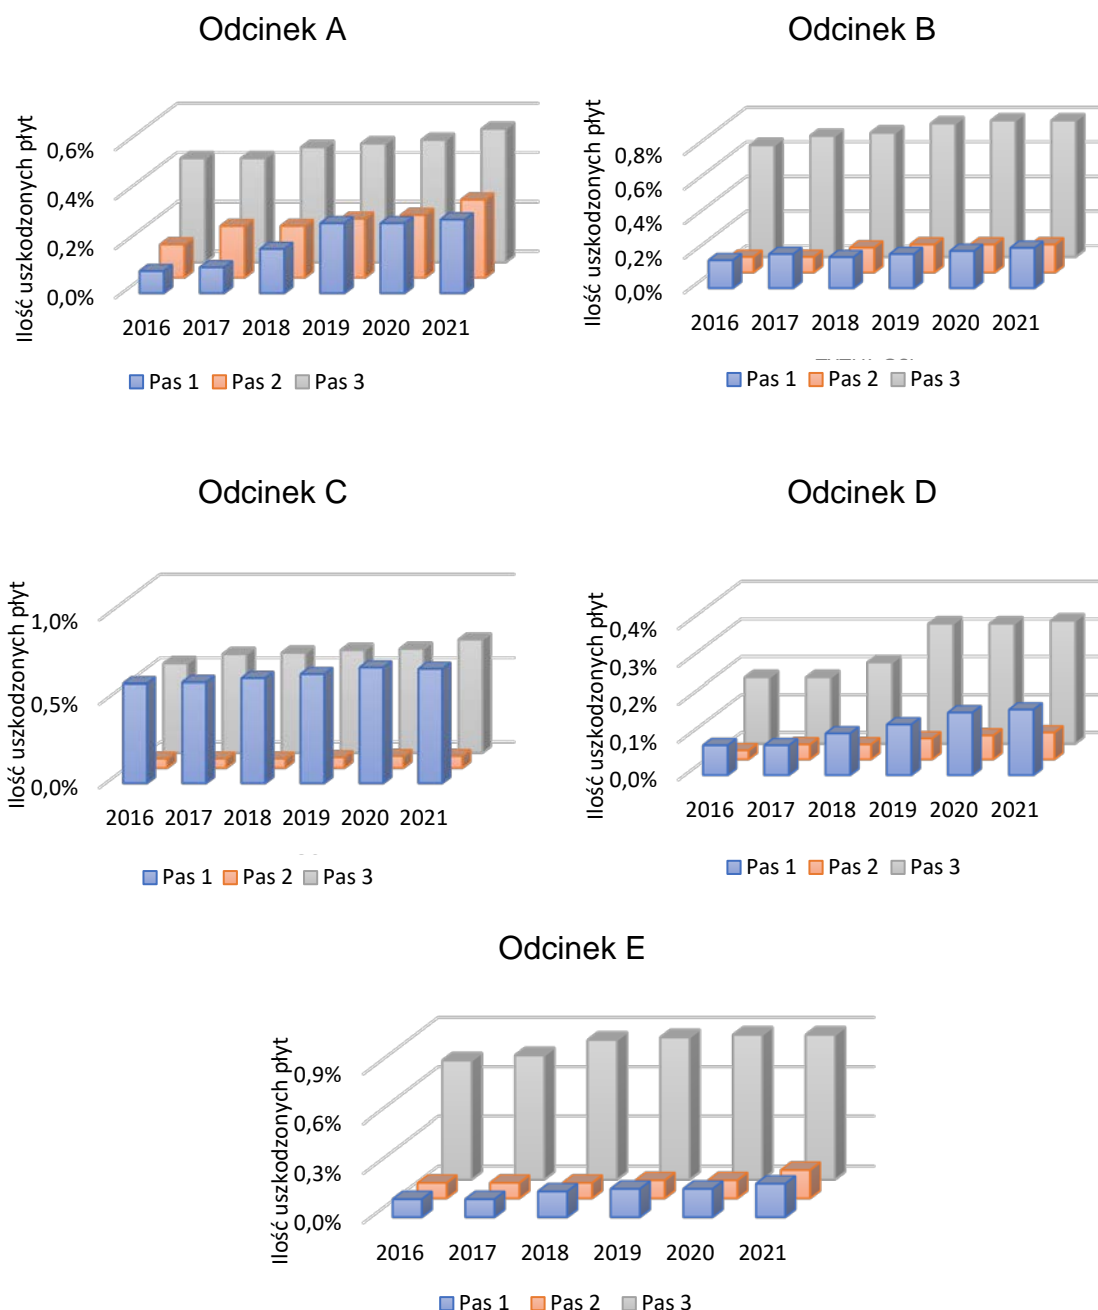
Rysunek 103. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 104. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.7.4 Uszkodzenia naroży

Graficzny charakter tego typu uszkodzenia zinwentaryzowanego w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim przedstawiono na rys 105.



Rysunek 105. Zestawienie procentowe płyt ze zinwentaryzowanym uszkodzeniem naroży (UN) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

Zgodnie z opracowanym algorytmem (rys. 86) przeprowadzono całościową analizę (wyniki w tabeli 31) dla uszkodzenia naroży.

Tabela 31. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia naroży (UN) w ramach analizy wrażliwości dla zmiennych wejściowych

Nr. analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11		Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] płyt	MLP 15-12-1	0,998	0,986	Liniowa
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-5-1	0,351	0,474	Logistyczna
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,721	0,742	Tanh
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-5-1	0,822	0,868	Liniowa
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-4-1	0,343	0,437	Tanh
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-4-1	0,342	0,454	Liniowa
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,336	0,486	Tanh
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-7-1	0,366	0,440	Liniowa
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,345	0,501	Wykładnicza
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,993	0,987	Liniowa
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-3-1	0,975	0,975	Wykładnicza
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,985	0,980	Tanh
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-7-1	0,986	0,981	Liniowa
14	Liczba dni z temp.<0°C	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,986	0,981	Liniowa
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,986	0,976	Tanh
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,990	0,981	Liniowa

Proces analizy polegał na:


1. W pierwszej kolejności dla tego typu uszkodzenia na wejściu przyjęto wszystkie zmienne (poz. 1 z tab. 31) dostępne w ramach analizowanych danych oraz określono jakość sieci m.in. jakość testowania na poziomie 0,986;
2. Kolejno przeprowadzono powyższą procedurę dla każdego pojedynczego parametru (poz. od 2 do 9 z tab. 31) w celu wyznaczenia dla nich poszczególnych modeli, w wyniku czego uzyskano osiem pojedynczych sieci o jakości testowania od 0,440 do 0,822;
3. Następnie dla zmiennej objaśniającej o najlepszych parametrach tj. pas przeprowadzono kolejną analizę dodając pojedynczo pozostałe zmienne w celu określenia jakości w taki sposób opracowanych sieci (poz. od 10 do 16 z tab. 26).
4. W wyniku przeprowadzonych analiz w ramach pkt. 3 można stwierdzić, że sieć neuronowa ze zmiennymi objaśniającymi (na wejściu) typu pas oraz osie standardowe (analiza nr. 10 z tab. 26) uzyskała najlepszą jakość testowania na poziomie 0,987. W wyniku uzyskania jedynie przy dwóch zmiennych lepsze parametry jakości sieci neuronowej w stosunku do sieci uwzględniającej wszystkie zmienne (analiza nr. 1 z tab. 26) proces szukania sieci uznano za zakończony.

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-6-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, sześć w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 30. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 176 iteracji (epoki).


Tabela 30. Podstawowe informacje o sieci o strukturze MLP 9-6-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-6-1	0,993	0,987	0,984	0,000	0,000	0,000	BFGS 176	Liniowa


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-6-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 106-110.




Rysunek 106. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 107. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 108. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 109. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

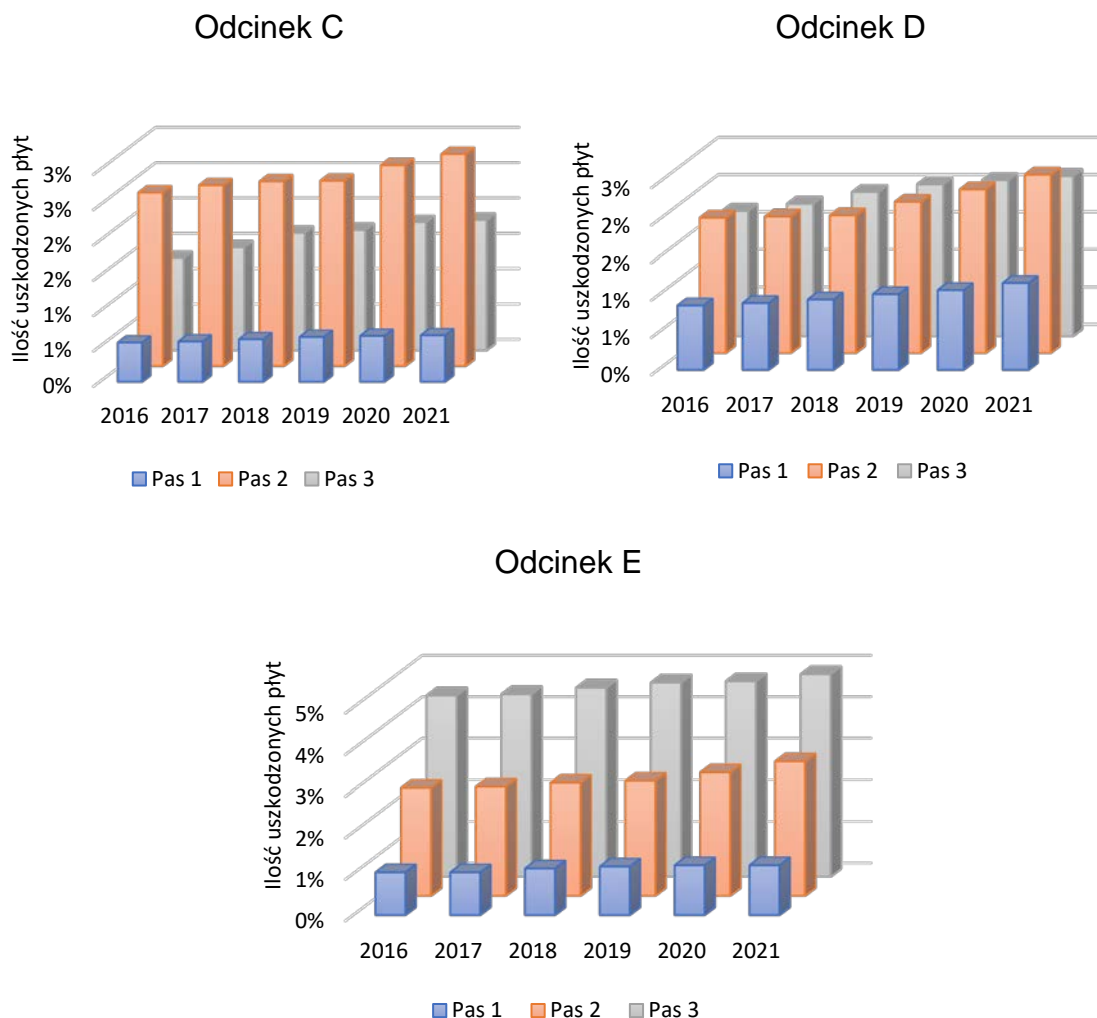


Rysunek 110. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.7.5 Uszkodzenia powierzchni

Graficzny charakter uszkodzeń powierzchniowych zinwentaryzowanych w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim przedstawiono na rys. 111.





Rysunek 111. Zestawienie procentowe płyt z zinwentaryzowanym uszkodzeniem powierzchniowym (UP) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach opisanego wcześniej algorytmu zdecydowano, że analizowanym parametrem na wyjściu będzie procent uszkodzonych płyt, dla którego przystąpiono do opracowania sztucznej sieci neuronowej służącej do prognozowania uszkodzenia powierzchniowego (UP).

Ocenę wyników rozpoczęto od oceny zbudowanych modeli i wyboru najlepszego z nich. Przeprowadzona analiza wrażliwości modelu semantycznego (tab. 33) wykazała, że wszystkie przyjęte w pierwszej analizie zmienne wejściowe nie są istotne. W celu określenia istotnych zmiennych przystąpiono do modyfikacji modelu i wytypowania zmiennych, które mają istotny wpływ na jakość sieci neuronowej oraz zmiennych wyjściowych, które nie poprawiają jakości i zaburzają proces uczenia.

W wyniku przeprowadzonych dalszych modyfikacji, można wywnioskować, że sieć neuronowa uzyskuje najlepszą wartość (jakość testowania) w ramach analizy nr 10 przy uwzględnieniu na wejściu danych z informacją o pasie oraz obciążenia ruchem (osie standardowe).

Tabela 33. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia powierzchniowego (UP) w ramach analizy wrażliwości dla zmiennych wejściowych


Nr. analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11		12	Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] płyt	MLP 15-13-1	0,993	0,984	Logistyczna
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,334	0,527	Logistyczna
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,834	0,871	Tanh
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,885	0,873	Liniowa
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-5-1	0,320	0,502	Liniowa
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,322	0,489	Liniowa
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,311	0,534	Tanh
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-7-1	0,321	0,504	Wykładnicza
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,326	0,491	Logistyczna
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,995	0,996	Logistyczna
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,983	0,986	Tanh
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-5-1	0,982	0,984	Tanh
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,995	0,995	Liniowa
14	Liczba dni z temp.<0°C	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,993	0,995	Logistyczna
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-6-1	0,991	0,995	Logistyczna
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-7-1	0,987	0,991	Tanh

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-6-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, sześć w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 32. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 136 iteracji (epoki).


Tabela 32. Podstawowe informacje o sieci o strukturze MLP 9-6-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-6-1	0,996	0,995	0,993	0,000	0,000	0,000	BFGS 136	Liniowa


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-6-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 112 – 115.




Rysunek 112. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 113. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 114. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



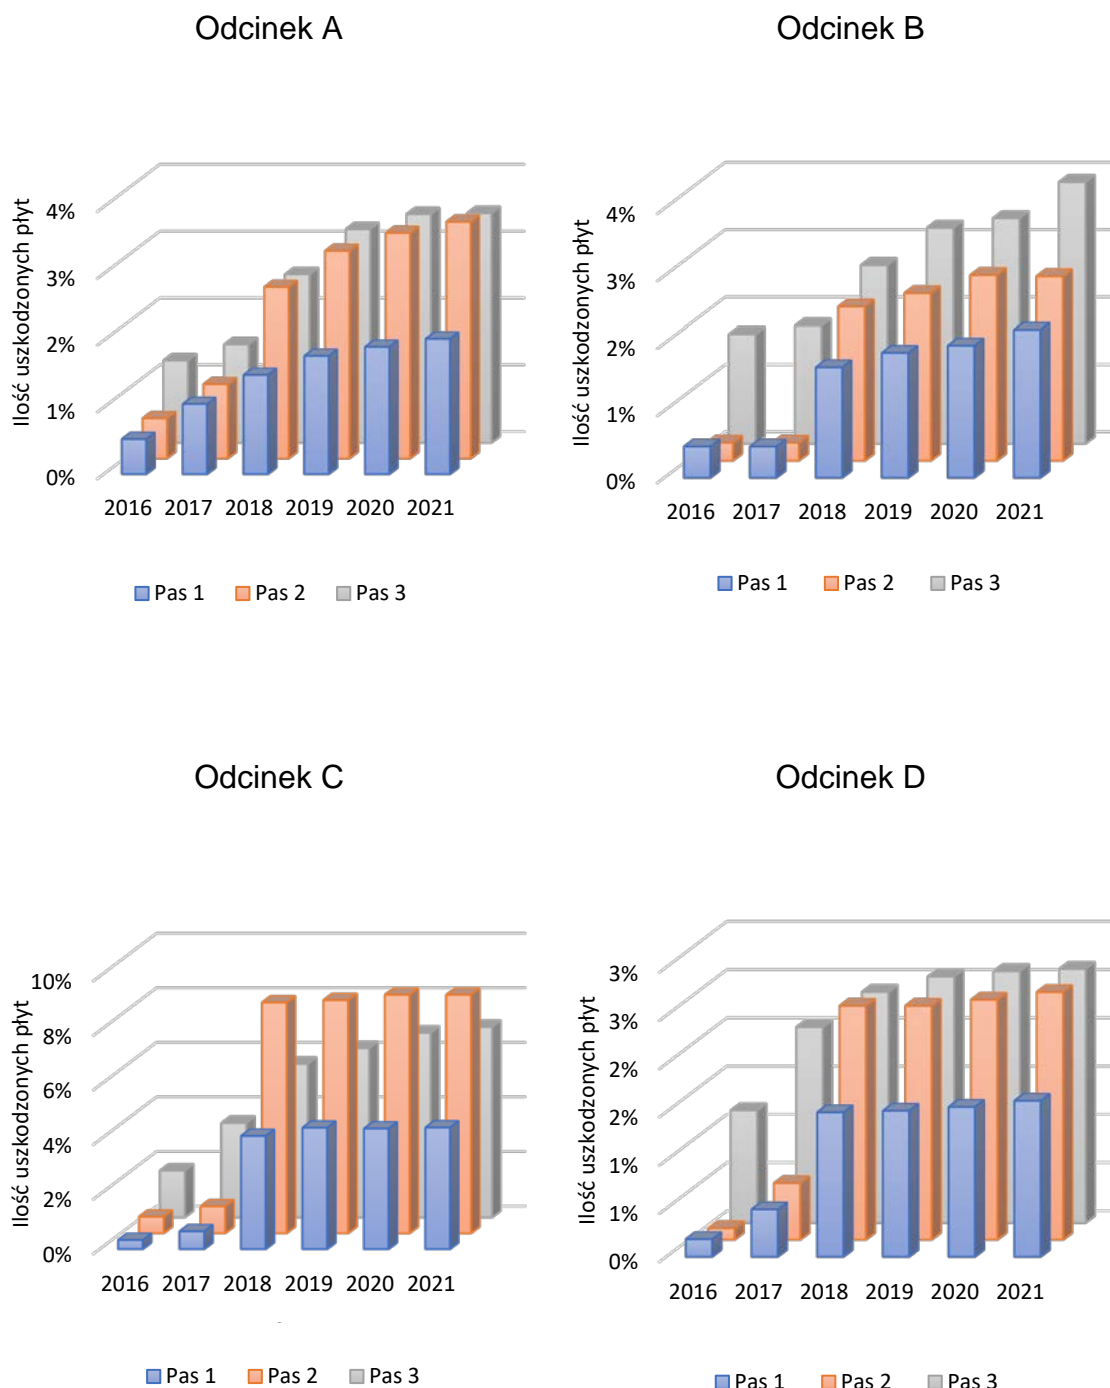
Rysunek 115. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 116. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-6-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.7.6 Wykruszenia szczelin

Graficzny charakter wykruszeń szczelin zinwentaryzowanych w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim przedstawiono na rys. 117.



Odcinek E



Rysunek 117. Zestawienie procentowe płyt ze zinwentaryzowanym uszkodzeniem powierzchniowym (UP) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach opisanego wcześniej algorytmu zdecydowano, że analizowanym parametrem na wyjściu będzie procent uszkodzonych płyt, dla którego przystąpiono do opracowania sztucznej sieci neuronowej służącej do prognozowania wykruszenia szczeliny (WS).

Ocenę wyników rozpoczęto od oceny zbudowanych modeli i wyboru najlepszego z nich. Przeprowadzona analiza wrażliwości modelu semantycznego (tab. 34) wykazała, że wszystkie przyjęte w pierwszej analizie zmienne wejściowe nie są istotne. W celu określenia istotnych zmiennych przystąpiono do modyfikacji modelu i wytypowania zmiennych, które mają istotny wpływ na jakość sieci neuronowej oraz zmiennych wyjściowych, które nie poprawiają jakości i zaburzają proces uczenia.

W wyniku przeprowadzonych dalszych modyfikacji, można wywnioskować, że sieć neuronowa uzyskuje najlepszą wartość (jakość testowania) podczas analizy nr 10 przy uwzględnieniu na wejściu danych z informacją o wieku oraz obciążeniu ruchem (osie standardowe).

Tabela 34. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia typu wykruszenie szczeliny (WS) w ramach analizy wrażliwości dla zmiennych wejściowych


Nr. Analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11		12	13	14	15
1	Osie std.	Wiek	Pas	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] płyt	MLP 15-6-1	0,933	0,773	Tanh
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-9-1	0,735	0,705	Liniowa
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,487	0,734	Tanh
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,577	0,882	Wykładnicza
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-8-1	0,416	0,694	Tanh
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,574	0,671	Liniowa
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-7-1	0,506	0,665	Logistyczna
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-3-1	0,720	0,695	Wykładnicza
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] płyt	MLP 6-6-1	0,626	0,585	Wykładnicza
10	Osie std.	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-7-1	0,997	0,964	Logistyczna
11	Pas	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-3-1	0,873	0,863	Liniowa
12	Grubość	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-3-1	0,684	0,683	Logistyczna
13	Opady	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-8-1	0,810	0,715	Logistyczna
14	Liczba dni z temp.<0°C	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-9-1	0,813	0,712	Liniowa
15	Max. gra. +	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-3-1	0,698	0,698	Tanh
16	Max. gra. -	Wiek	-	-	-	-	-	-	Odcinek	Kierunek	[%] płyt	MLP 9-10-1	0,673	0,642	Liniowa

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-7-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, siedem w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 35. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 144 iteracji (epoki).


Tabela 35. Podstawowe informacje o sieci o strukturze MLP 9-7-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-7-1	0,997	0,964	0,931	0,000	0,000	0,000	BFGS 144	Logistyczna


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-7-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 118 – 122.




Rysunek 118. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 119. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 120. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 121. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

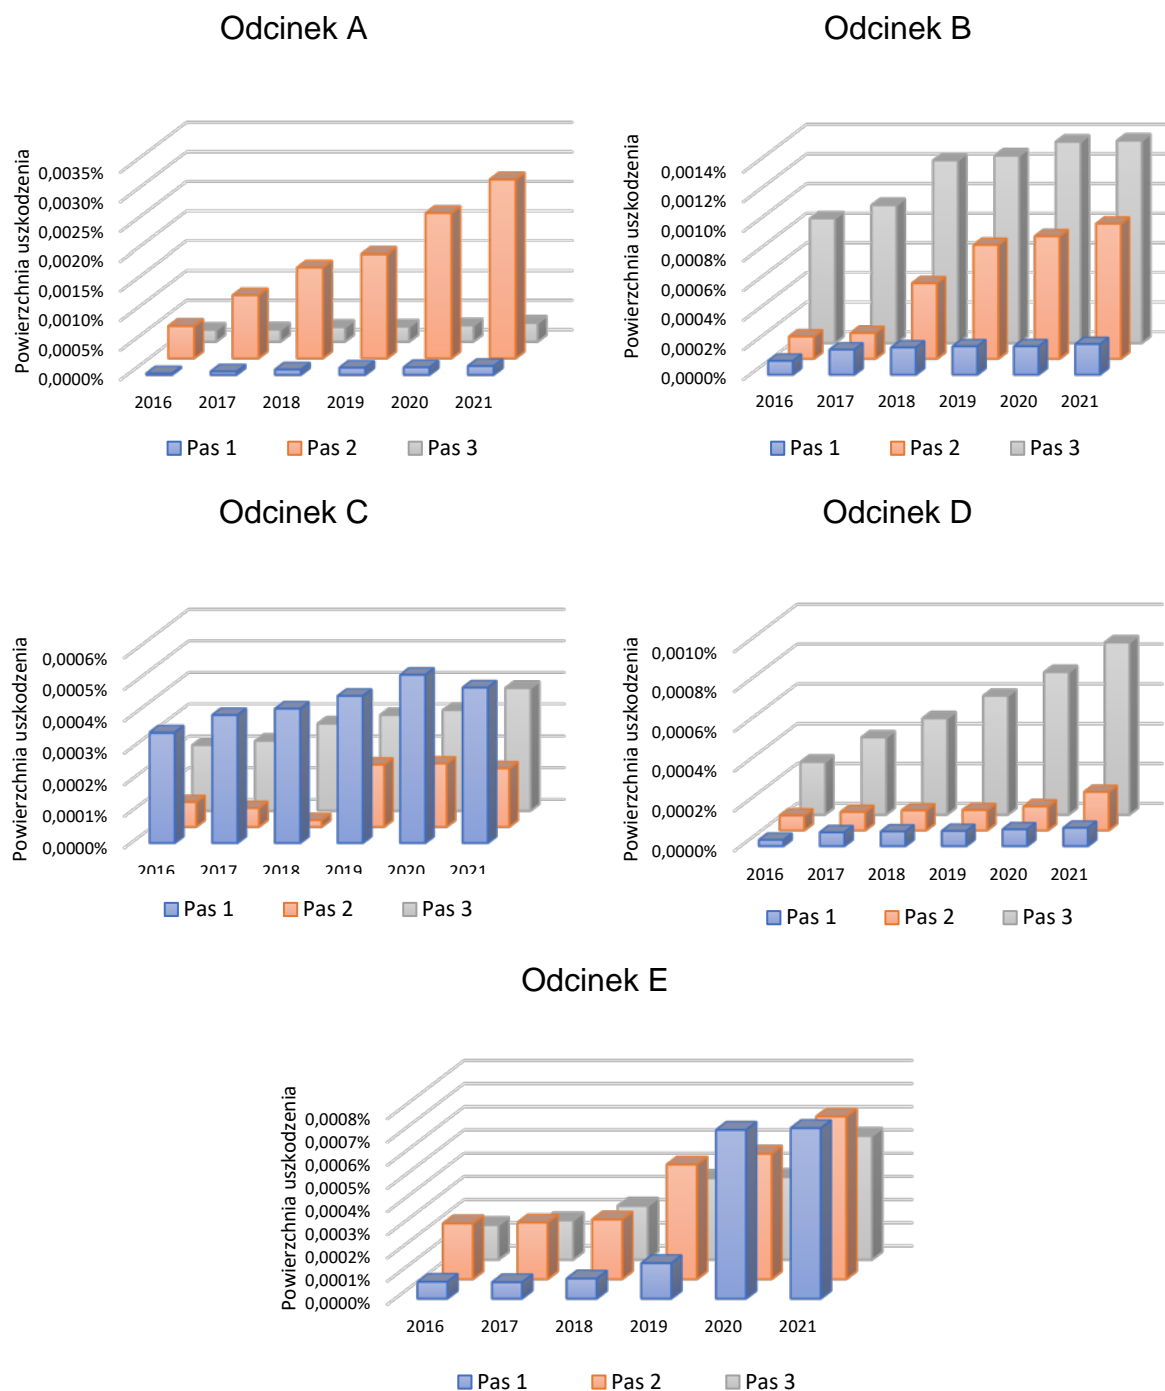


Rysunek 122. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.8 Wyniki modelowania [% powierzchni]

6.8.1 Uszkodzenie naroży

Graficzny charakter uszkodzeń naroży zinwentaryzowanych w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim w odniesieniu do powierzchni nawierzchni przedstawiono na rys. 123.



Rysunek 123. Zestawienie procentowe powierzchni ze zinwentaryzowanym uszkodzeniem naroży (UN) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach poniższego podrozdziału i prowadzonych dodatkowych analiz dla uszkodzeń z informacją o powierzchni tj. UN/UP oraz WS w celu zweryfikowania opracowanej metodologii budowy modeli neuronowych zdecydowano tym razem, że analizowanym parametrem na wyjściu będzie procent uszkodzonej powierzchni płyt, dla którego przystąpiono do opracowania sztucznej sieci neuronowej zgodnie z przyjętym algorytmem (rys. 86) służącym do prognozowania wyżej wskazanych typów uszkodzeń.

Parametrami wejściowymi budowanej sieci jest te same osiem parametrów opisujących indywidualny charakter badanych odcinków nawierzchni z betonu cementowego: osie standardowe, pas jezdni, wiek, grubość, ilość opadów, liczba dni z temperaturą mniejszą niż 0°C, maksymalny gradient (+) oraz maksymalny gradient (-). Naukę sieci przeprowadzono z wykorzystaniem algorytmu Broydena-Fletcher-Goldfarba-Shanno (BFGS). Bazę danych stanowiły zgromadzone informacje z przeprowadzonych badań terenowych w ramach zmodyfikowanej wizualnej metody oceny stanu technicznego nawierzchni z betonu cementowego, analizy danych ruchowych ze stacji zliczania ruchu oraz ich przeliczenia na osie standardowe oraz danych ze stacji meteorologicznych rozlokowanych w obrębie analizowanych odcinków jednorodnych.

W rozwiązaniu problemu przeprowadzono poniższe czynności:

1. W pierwszej kolejności dla tego typu uszkodzenia na wejściu przyjęto wszystkie zmienne (poz. 1 z tab. 36) dostępne w ramach analizowanych danych oraz wyznaczono jakość tak uzyskanych sieci m.in. jakość testowania na poziomie 0,874;
2. Kolejno przeprowadzono powyższą procedurę dla każdego pojedynczego parametru (poz. od 2 do 9 z tab. 36) w celu wyznaczenia dla nich poszczególnych modeli, w wyniku czego uzyskano osiem pojedynczych sieci o jakości parametru testowania od 0,375 do 0,818;
3. Następnie dla zmiennej objaśniającej o najlepszych parametrach tj. pas przeprowadzono kolejną analizę dodając pojedynczo pozostałe zmienne w celu określenia jakości w taki sposób opracowanych sieci (poz. od 10 do 16 z tab. 36).
4. W wyniku przeprowadzonych analiz w ramach pkt. 3 można stwierdzić, że sieć neuronowa ze zmiennymi objaśniającymi (na wejściu) typu pas oraz osie standardowe (analiza nr. 10 z tab. 36) uzyskała najlepszą jakość testowania na poziomie 0,942. W wyniku uzyskania jedynie przy dwóch zmiennych lepszą jakość sieci neuronowej w stosunku do sieci uwzględniającej wszystkie zmienne (analiza nr. 1 z tab. 36) proces szukania sieci uznano za zakończony.

Tabela 36. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia typu uszkodzenie naroży (UN) w ramach analizy wrażliwości dla zmiennych wejściowych


Nr. analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11	12	Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] powierzchni	MLP 15-8-1	0,965	0,874	Tanh
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-7-1	0,448	0,544	Liniowa
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-9-1	0,678	0,785	Tanh
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-8-1	0,765	0,818	Tanh
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-5-1	0,346	0,488	Liniowa
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-5-1	0,357	0,448	Liniowa
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-6-1	0,345	0,458	Liniowa
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-9-1	0,363	0,424	Liniowa
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-9-1	0,442	0,375	Liniowa
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-9-1	0,980	0,942	Wykładnicza
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-8-1	0,976	0,892	Logistyczna
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-10-1	0,848	0,892	Logistyczna
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-5-1	0,784	0,841	Tanh
14	Liczba dni z temp.<0°C	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-7-1	0,871	0,719	Tanh
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-8-1	0,859	0,858	Liniowa
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-5-1	0,914	0,920	Tanh

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-9-1 (perceptron wielowarstwowy mający pięć neuronów w warstwie wejściowej, pięć w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 37. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 292 iteracji (epoki).


Tabela 37. Podstawowe informacje o sieci o strukturze MLP 9-7-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-9-1	0,980	0,942	0,954	0,000	0,000	0,000	BFGS 292	Logistyczna


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-9-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 124 – 128.




Rysunek 124. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-9-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 125. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-9-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 126. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-9-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



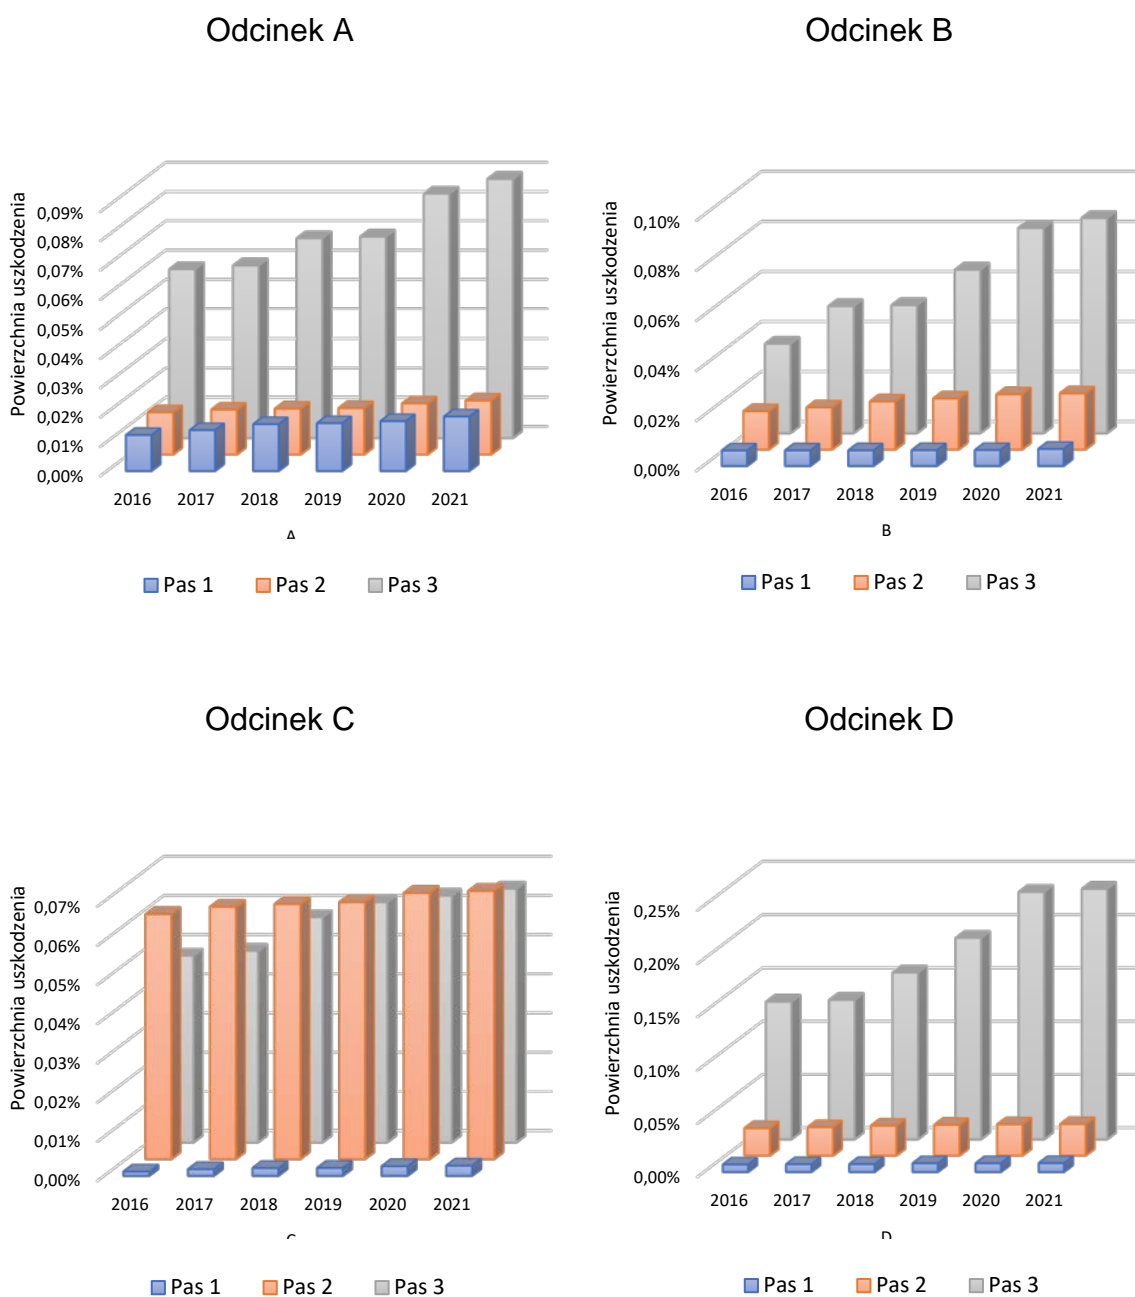
Rysunek 127. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-9-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 128. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-9-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.8.2 Uszkodzenie powierzchni

Graficzny charakter uszkodzeń powierzchni zinwentaryzowanych w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim w odniesieniu do powierzchni zajmowanej przez nawierzchnię przedstawiono na rys. 129.



Odcinek E



Rysunek 129. Zestawienie procentowe powierzchni ze zinwentaryzowanym uszkodzeniem powierzchni (UP) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach przedstawionego i omówionego algorytmu (rys. 86) oraz zgodnie z przedstawioną metodologią przeprowadzono całościową analizę do opracowania sieci neuronowej do prognozowania uszkodzenia powierzchni (wyniki w tabeli 38), której proces polegał na:

1. W pierwszej kolejności dla tego typu uszkodzenia na wejściu przyjęto wszystkie zmienne (poz. 1 z tab. 38) dostępne w ramach analizowanych danych oraz określono jakość sieci m.in. jakość testowania na poziomie 0,948;
2. Kolejno przeprowadzono powyższą procedurę dla każdego pojedynczego parametru (poz. od 2 do 9 z tab. 38) w celu wyznaczenia dla nich poszczególnych modeli, w wyniku czego uzyskano osiem pojedynczych sieci o jakości testowania od 0,154 do 0,804;
3. Następnie dla zmiennej objaśniającej o najlepszych parametrach tj. pas (poz. 4 z tab. 28) przeprowadzono kolejną analizę dodając pojedynczo pozostałe zmienne w celu określenia jakości w taki sposób opracowanych sieci (poz. od 10 do 16 z tab. 38).
4. W wyniku przeprowadzonych analiz w ramach pkt. 3 można stwierdzić, że sieć neuronowa ze zmiennymi objaśniającymi (na wejściu) typu pas oraz osie obliczeniowe (analiza nr. 10 z tab. 38) uzyskała najlepszą jakość testowania na poziomie 0,982. W wyniku uzyskania jedynie przy dwóch zmiennych lepsze parametry jakości sieci neuronowej w stosunku do sieci uwzględniającej wszystkie przyjęte zmienne (analiza nr. 1 z tab. 38) proces wyznaczania sieci neuronowej dla tego typu uszkodzenia uznano za zakończony.

Tabela 38. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia typu uszkodzenie powierzchni (UP) w ramach analizy wrażliwości dla zmiennych wejściowych


Nr. analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	2	3	4	5	6	7	8	9	10	11		Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] powierzchni	MLP 15-9-1	0,995	0,948	Wykładnicza
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-4-1	0,309	0,308	Tanh
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-4-1	0,815	0,570	Wykładnicza
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-4-1	0,812	0,804	Logistyczna
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-6-1	0,260	0,316	Liniowa
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-4-1	0,359	0,154	Liniowa
7	Liczba dni z temp.<0°	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-5-1	0,356	0,303	Liniowa
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-4-1	0,360	0,298	Logistyczna
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-5-1	0,244	0,205	Logistyczna
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-7-1	0,996	0,982	Liniowa
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-8-1	0,984	0,946	Liniowa
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-7-1	0,955	0,937	Wykładnicza
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-8-1	0,804	0,752	Wykładnicza
14	Liczba dni z temp.<0°	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-7-1	0,953	0,929	Liniowa
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-8-1	0,884	0,901	Logistyczna
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-6-1	0,912	0,868	Wykładnicza

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-7-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, siedem w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 39. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 228 iteracji (epoki).


Tabela 39. Podstawowe informacje o sieci o strukturze MLP 9-7-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-7-1	0,996	0,982	0,965	0,000	0,000	0,000	BFGS 228	Liniowa


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-7-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 130 – 134.




Rysunek 130. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 131. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 132. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



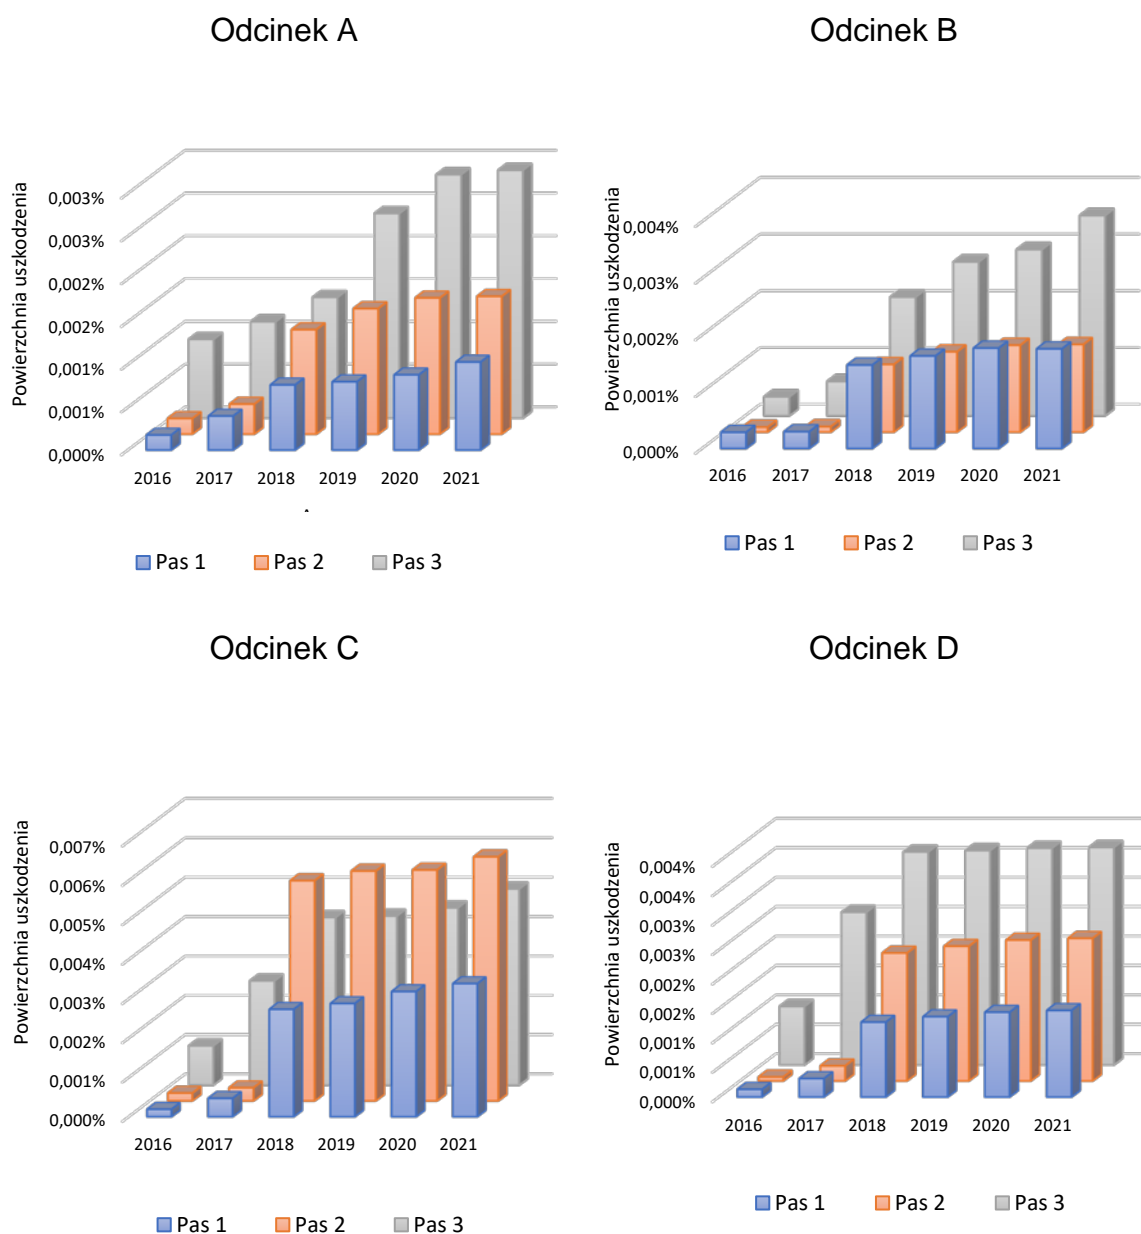
Rysunek 133. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 134. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-7-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.8.3 Wykruszenie szczelin

Graficzny charakter wykruszenia szczelin zinwentaryzowanych w ramach przeprowadzonych badań terenowych na odcinkach jednorodnych (A-E) w okresie sześcioletnim w odniesieniu do powierzchni zajmowanej przez nawierzchnię przedstawiono na rys. 135.



Odcinek E



Rysunek 135. Zestawienie procentowe powierzchni ze zinwentaryzowanym wykruszeniem szczeliny (WS) na analizowanych odcinkach (A-E) w okresie 2016 – 2021, 1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny

W ramach opisanego wcześniej algorytmu i w ramach weryfikacji możliwości zastosowania go do prognozowania szerszego pakietu informacji zdecydowano, że w ramach dodatkowej weryfikacji analizowanym parametrem na wyjściu będzie procent uszkodzonej powierzchni nawierzchni, dla którego przystąpiono do opracowania sztucznej sieci neuronowej służącej do prognozowania wykruszeń szczelin (WS). Ocenę wyników rozpoczęto od oceny zbudowanych modeli i wyboru najlepszego z nich. Przeprowadzona analiza wrażliwości modelu semantycznego (tab. 40) wykazała, że wszystkie przyjęte w pierwszej analizie zmienne wejściowe nie są istotne. W celu określenia istotnych zmiennych przystąpiono do modyfikacji modelu i wytypowania zmiennych, które mają istotny wpływ na jakość sieci neuronowej oraz zmiennych wyjściowych, które nie poprawiają jakości i zaburzają proces uczenia.

W wyniku przeprowadzonych dalszych modyfikacji, można wywnioskować, że sieć neuronowa uzyskuje najlepszą wartość (jakość testowania) podczas analizy nr 11, przy uwzględnieniu na wejściu danych z informacją o wieku i pasie.

Tabela 40. Rodzaje SSN i architektura opracowanych modeli neuronowych dla uszkodzenia typu wykruszenie szczeliny (WS) w ramach analizy wrażliwości dla zmiennych wejściowych


Nr. Analizy	Wejścia ilościowe								Wejścia jakościowe		Wyjścia ilościowe	Podsumowanie			
	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek		Nazwa sieci	Jakość (Uczenia)	Jakość (Testowania)	Aktywacja (wyjściowa)
1	Osie std.	Pas	Wiek	Grubość	Opady	Liczba dni z temp.<0°C	Max. gra. +	Max. gra. -	Odcinek	Kierunek	[%] powierzchni	MLP 15-12-1	0,907	0,834	Logistyczna
2	Wiek	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-7-1	0,686	0,563	Liniowa
3	Osie std.	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-9-1	0,486	0,651	Liniowa
4	Pas	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-3-1	0,532	0,755	Tanh
5	Grubość	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-5-1	0,306	0,495	Wykładnicza
6	Opady	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-5-1	0,476	0,468	Tanh
7	Liczba dni z temp.<0°C	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-7-1	0,437	0,553	Logistyczna
8	Max. gra. +	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-8-1	0,600	0,470	Logistyczna
9	Max. gra. -	-	-	-	-	-	-	-	Odcinek	-	[%] powierzchni	MLP 6-9-1	0,534	0,100	Logistyczna
10	Osie std.	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-5-1	0,958	0,929	Logistyczna
11	Wiek	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-8-1	0,974	0,970	Logistyczna
12	Grubość	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-6-1	0,623	0,947	Liniowa
13	Opady	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-9-1	0,902	0,781	Wykładnicza
14	Liczba dni z temp.<0°C	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-9-1	0,736	0,921	Liniowa
15	Max. gra. +	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-6-1	0,850	0,816	Liniowa
16	Max. gra. -	Pas	-	-	-	-	-	-	Odcinek	Kierunek	[%] powierzchni	MLP 9-9-1	0,771	0,792	Wykładnicza

Szczegółowe informacje o sieci neuronowej o architekturze MLP 9-8-1 (perceptron wielowarstwowy mający dziewięć neuronów w warstwie wejściowej, osiem w warstwie ukrytej i jeden w warstwie wyjściowej) przedstawia tab. 41. Do uczenia sieci został zastosowany algorytm BFGS (w zaimplementowanej w programie wersji algorytmu quasi-Newtona kolejne przybliżenia odwrotności hesjanu wyznaczone są przy pomocy formuły rekurencyjnej zaproponowanej przez Broydena, Fletchera, Goldfarba i Shanno). Sieć uzyskała najmniejszy błąd uczenia przy zrealizowaniu 101 iteracji (epoki).


Tabela 41. Podstawowe informacje o sieci o strukturze MLP 9-8-1

Nazwa sieci	Jakość (uczenia)	Jakość (testowania)	Jakość (walidacji)	Błąd (uczenia)	Błąd (testowania)	Błąd (walidacji)	Algorytm (uczenia)	Aktywacja (wyjściowa)
MLP 9-8-1	0,974	0,970	0,930	0,000	0,000	0,000	BFGS 101	Liniowa


Graficzne zestawienie danych wyuczonej, przetestowanej, zweryfikowanej sieci SSN o strukturze 9-8-1 oraz predykcji dla roku 2022 dla wszystkich odcinków przedstawiono na rys. 136 – 140.




Rysunek 136. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-8-1 dla odcinka A oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)




Rysunek 137. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-8-1 dla odcinka B oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 138. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-8-1 dla odcinka C oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 139. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-8-1 dla odcinka D oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)



Rysunek 140. Wynik uzyskanej sztucznej sieci neuronowej o strukturze 9-8-1 dla odcinka E oraz predykcja wyników dla roku 2022 (1 - pas szybki, 2 - pas wolny, 3 - pas awaryjny)

6.9 Dyskusja

Identyfikacja uszkodzeń oraz ich prognoza w zakresie nawierzchni z betonu cementowego jest jednym z kilku istotnych kierunków badawczych w budownictwie drogowym. Analizy te prowadzone są w szczególności w warunkach terenowych i na nawierzchniach dróg oddanych do eksploatacji.

W ramach niniejszej rozprawy doktorskiej dokonano przeglądu doświadczeń i rozwiązań z dziedziny projektowania, wykonania oraz problematyki związanej z utrzymaniem nawierzchni z betonu cementowego. Kluczową rolę w dysertacji odgrywa opracowana i wdrożona od 2016 roku na wybranych i użytkowanych odcinkach autostrady zmodyfikowana metoda oceny cech powierzchniowych. Poprzez jednoznaczne przypisanie danego typu uszkodzenia do pojedynczej płyty betonowej o unikalnym numerze umożliwiona jest szybka weryfikacja zgromadzonych danych. W odróżnieniu od ocen cech powierzchniowych aktualnie stosowanych, które bazują na ocenie sieciowej, przedstawiona metoda może być doskonałym punktem odniesienia do zastosowania skutecznego procesu utrzymania prewencyjnego już wybudowanych dróg. Dla tak zgromadzonych i usystematyzowanych danych w oparciu o przeprowadzone badania terenowe w okresie 2016 – 2021 na pięciu analizowanych odcinkach autostrady zinwentaryzowano łącznie 16 617 (rozpoczynając od 8 825 szt. w 2016 r.) uszkodzeń wraz z określeniem ich zmian zachodzących w czasie. W celu uzyskania rzeczywistych danych, uwzględniono w identyfikacji również uszkodzenia naprawione, które były wykonywane pomiędzy okresami przeprowadzanych badań terenowych. Zaobserwowano znaczne różnice w ilości i typie występowania uszkodzeń na każdym z badanych odcinków jednorodnych wykonanych w tej samej technologii i z zastosowaniem tych samych materiałów. Podstawą do rozróżnienia analizowanych odcinków na pięć odcinków jednorodnych były wskazane i uwzględnione w pracy różnice w ich obciążeniu ruchem oraz zaobserwowane różnice w warunkach klimatycznych. W związku z powyższym w zakresie wykonanych badań przeprowadzono identyfikację danych o ruchu pojazdów poruszających się na analizowanych odcinkach autostrady oraz przeprowadzono obliczenia skumulowanej liczby osi standardowych dla analizowanego okresu, a zatem wyznaczono do dalszych analiz intensywność oddziaływania ruchu na odcinki jednorodne z podziałem na wyodrębnione pasy. W wyniku tak przeprowadzonych działań uzyskano dane, które są istotne dla etapu związanego z prognozowaniem uszkodzeń nawierzchni. W dysertacji uwzględniono również wpływ warunków klimatycznych, a dane te pozyskano z występujących na badanych odcinkach stacji meteorologicznych. Dzięki temu pozyskano informacje o warunkach termicznych, w szczególności umożliwiających określenie gradientów (+) i gradientów (-) w płytach betonowych. Zgromadzono również informacje o ilości opadów jakie występowały na poszczególnych odcinkach oraz liczbie dni z temperaturą poniżej 0°C, co dodatkowo rozszerzyło zakres informacji możliwych do uwzględnienia w opracowanej prognozie degradacji nawierzchni z betonu cementowego.

Głównym celem pracy było zastosowanie zmodyfikowanej oceny cech powierzchniowych nawierzchni z betonu cementowego oraz pozyskanie wiarygodnych danych o uszkodzeniach oraz możliwości skutecznego zastosowania sztucznych sieci neuronowych (SSN) do prognozowania uszkodzeń nawierzchni z betonu cementowego za pomocą uzyskanych bardzo szczegółowych danych ze zmodyfikowanej metody oceny cech powierzchniowych. Przedstawiono zakres czynności niezbędnych do przeprowadzenia skutecznego procesu prognozowania uszkodzeń nawierzchni z wykorzystaniem wybranego narzędzia analitycznego. Cel ten wypełnia najobszerniejszy, szósty rozdział dysertacji poświęcony szczegółowym zagadnieniom implementacyjnym. W oparciu o narzędzie Statistica i zbudowane w niej modele SSN, przeprowadzono m.in. analizę wrażliwości zmiennych wejściowych w celu doboru danych istotnych na jakość uzyskanych modeli. Przedstawiono zależności pozwalające na określenie danych wejściowych wpływających na prognozowanie poszczególnych typów uszkodzenia nawierzchni. Dokładność wyuczenia, testowania oraz walidacji sieci neuronowych w odniesieniu do indywidualnego typu analizowanego uszkodzenia przeprowadzono za pomocą współczynnika determinacji R^2 . Przyjętym parametrem prognozy była ilość uszkodzonych płyt [%] a parametrem weryfikacyjnym w ramach potwierdzenia stawianej tezy była powierzchnia uszkodzonych płyt [%]. Można zatem stwierdzić, że osiągnięte wyniki pokazują, że zaproponowany algorytm może służyć do długookresowej predykcji uszkodzeń, ponieważ uzyskane błędy prognoz są stosunkowo małe, zarówno dla pierwszego parametru prognozowanego, jak i dla parametru weryfikacyjnego. Postępowanie takie potwierdziło postawioną w pracy tezę mówiącą o rzeczywistej możliwości zastosowania modeli SSN jako skutecznego narzędzia prognozowania uszkodzeń nawierzchni z betonu cementowego, których przewidywanie jest bardzo trudne ze względu na złożoność mechanizmu degradacji nawierzchni, a zwłaszcza wielu czynników oddziałujących na nawierzchnie z betonu cementowego. Zaprezentowane wyniki pokazują, że zastosowanie modelu opartego na sztucznych sieciach neuronowych jest uzasadnione w świetle przygotowanych i zastosowanych do analizy danych.

Obecnie coraz częściej stosuje się sztuczną inteligencję do optymalizacji zagadnień inżynierskich, a zwłaszcza takich, które charakteryzują się losowością i dużą zmiennością w czasie. W ramach przeprowadzonych analiz z zastosowaniem sztucznych sieci neuronowych pokazano, iż ta niekonwencjonalna metoda opisywania zjawisk oraz rozwiązywania problemów może być z powodzeniem stosowana w prognozowaniu uszkodzeń nawierzchni z betonu cementowego. W ramach przeprowadzonych analiz otrzymane sieci MLP zostały zbudowane z jedną warstwą ukrytą. Eksperymenty związane z tworzeniem modeli sieci neuronowych MLP były parametryzowane rodzajem danych na wejściu (tab. 42, 43). W analizach parametr liczba neuronów w warstwie ukrytej przyjmował wartości od 5 do 10, natomiast drugi parametr – liczba epok uczących – przyjmował wartości od 55 do 292. Liczba neuronów w warstwie ukrytej została dobrana automatycznie. Do uczenia sieci MLP wykorzystano algorytm BFGS. Jest to jeden z najbardziej efektywnych algorytmów uczenia sieci neuronowych. Po zakończeniu każdej

analizy przeprowadzone zostały testy, które dostarczały informacji na temat skuteczności sieci.

Tabela 42. Architektura sieci neuronowych oraz dane wejściowe, dla których uzyskano najlepsze parametry w odniesieniu do prognozowania informacji o ilości uszkodzonych płyt [%]

Lp.	Typ uszkodzenia	Dane wejściowe		Architektura sieci	Liczba epok
1	Pęknięcia podłużne (PL)	Wiek nawierzchni	Pas	MLP 9-5-1	134
2	Pęknięcia poprzeczne (PT)	Wiek nawierzchni	Pas	MLP 9-10-1	289
3	Pęknięcia krawędzi (PK)	Wiek nawierzchni	Pas	MLP 9-6-1	55
4	Uszkodzenie naroży (UN)	Osie standardowe	Pas	MLP 9-6-1	176
5	Uszkodzenie powierzchni (UP)	Osie standardowe	Pas	MLP 9-6-1	209
6	Wykruszenie szczelin (WS)	Osie standardowe	Wiek nawierzchni	MLP 9-7-1	144

Tabela 43. Architektura sieci neuronowych oraz dane wejściowe, dla których uzyskano najlepsze parametry w odniesieniu do prognozowania uszkodzonej powierzchni nawierzchni [%]

Lp.	Typ uszkodzenia	Dane wejściowe		Architektura sieci	Liczba epok
1	Uszkodzenie naroży (UN)	Osie standardowe	Pas	MLP 9-9-1	292
2	Uszkodzenie powierzchni (UP)	Osie standardowe	Pas	MLP 9-7-1	228
3	Wykruszenie szczelin (WS)	Pas	Wiek nawierzchni	MLP 9-8-1	101


Podczas analizy uzyskanych rodzajów architektury sieci neuronowych można stwierdzić, że skuteczność sieci w zależności od analizowanego typu uszkodzenia zależy od doboru danych na wejściu w zależności od prognozowanego parametru na wyjściu.

Kluczowymi parametrami w zakresie prognozowania uszkodzeń nawierzchni są:


- wiek nawierzchni,
- obciążenie ruchem (osie standardowe),
- rodzaj pasa ruchu (szybki, wolny, awaryjny).

Do badania dokładności wyuczenia, testowania oraz walidacji sieci neuronowych dla danego typu uszkodzenia nawierzchni z betonu cementowego przyjęto współczynnik determinacji R^2 . Współczynnik ten jest miarą dopasowania, tj. jak dobrze rozważane zmienne niezależne uwzględniają mierzoną zmienną zależną. Im większa wartość R^2 , tym sieć neuronowa posiada lepszą możliwość przewidywania [121]. Wyniki w zakresie uzyskanych dokładności otrzymanych sieci neuronowych dla parametru prognozowanego tj. ilość uszkodzonych płyt oraz ilość uszkodzonej powierzchni płyt na badanych odcinkach jednorodnych przedstawiono na rys. 141 – 142.

W ramach przeprowadzonych ocen dokładności (trafności) wyuczenia, testowania oraz walidacji opracowanych sztucznych sieci neuronowych, można stwierdzić, że średnia wartość przewidywania zawiera się w przedziale od 87% dla uszkodzeń krawędzi (PK) do ponad 90% dla pozostałych typów uszkodzenia. Najlepszą wartość uzyskała sieć neuronowa do prognozowania pęknięć poprzecznych (PT) na poziomie ponad 99% co można uznać za znakomity wynik. Wartości R^2 mieszczą się w przedziale 96%-97% dla uszkodzeń typu UN, PL i UP, co również można uznać za bardzo dobry wynik. Należy również zwrócić uwagę na to, że lepszą wartość dopasowania uzyskano dla prognozowanego parametru związanego z ilością uszkodzonych płyt dla uszkodzeń typu UN, UP, WS niż dla ilości uszkodzonej powierzchni dla tych samych uszkodzeń.



Rysunek 141. Dokładność wyuczenia, testowania oraz walidacji sieci neuronowych w odniesieniu do typu analizowanego uszkodzenia oraz badań terenowych w zakresie ilości uszkodzonych płyt betonowych



Rysunek 142. Dokładność wyuczenia, testowania oraz walidacji sieci neuronowych w odniesieniu do typu analizowanego uszkodzenia oraz badań terenowych w zakresie ilości uszkodzonej powierzchni płyt

7 Wnioski

W wyniku przeprowadzonych badań terenowych i analiz prognostycznych można sformułować następujące wnioski końcowe potwierdzające postawioną w pracy tezę:

- 1) Zmodyfikowana metoda oceny cech powierzchniowych dla nawierzchni z betonu cementowego wykonanych w technologii płyt dyblowanych i kotwionych bardzo dobrze sprawdza się w zakresie lokalizacji i oceny uszkodzeń ze względu na:
 - zastąpienie subiektywnej oceny obserwatora obiektywną oceną geometrii i obmiaru uszkodzeń (szerokości, długości, powierzchni),
 - umożliwienie studiowania przypadków na dużych populacjach,
 - wiarygodność oceny stanu technicznego nawierzchni, pozbawionej wad subiektywności, która zapewnia jej wysoką jakość,
 - jednoznaczne przypisanie danego typu uszkodzenia do pojedynczej płyty betonowej o unikalnym numerze (uzyskano odpowiednią dokładność, precyzję i niezawodność), przez co możliwa jest szybka weryfikacja zgromadzonych danych oraz prowadzenie efektywnego utrzymania prewencyjnego.
- 2) Efektem przeprowadzonych prac jest potwierdzenie skuteczności i bardzo wydajnej metody zastosowania sztucznych sieci neuronowych do przewidywania typów uszkodzeń nawierzchni z betonu cementowego. Składają się na to:
 - indywidualne modele sieci neuronowej dedykowane dla poszczególnych typów uszkodzenia charakterystycznego dla nawierzchni z betonu cementowego
 - określenie istotnych danych wejściowych w zależności od prognozowanego typu uszkodzenia.
- 3) Z przeprowadzonych analiz wynika, że nawet przy braku uwzględnienia niektórych czynników, które wpływają na stan techniczny powierzchni jezdni, jak błędy w wykonawstwie, prowadzone prace utrzymaniowe i inne zdarzenia losowe, uzyskano dużą wartość średnią współczynnika determinacji R^2 dla prognozowanej liczby uszkodzonych płyt na poziomie 94,7% a w zakresie powierzchni uszkodzeń płyt na poziomie 93,3%.
- 4) Osiągnięte wyniki pokazują, że opracowane modele SSN mogą służyć do długookresowej predykcji, ponieważ uzyskane błędy prognoz są stosunkowo małe. Można stwierdzić, że przedstawione modele mogą być skutecznym narzędziem prognozowania uszkodzeń nawierzchni z betonu cementowego, których przewidywanie jest bardzo trudne ze względu na złożoność mechanizmu degradacji nawierzchni, a zwłaszcza czynników oddziałujących na nawierzchnie z betonu cementowego.
- 5) Najlepsze rezultaty w rozwiązywaniu problemów dotyczących oszacowania ilości uszkodzeń nawierzchni z betonu cementowego uzyskano stosując sieci jednokierunkowe warstwowe (MLP), a dominującym algorytmem uczenia jest algorytm BFGS (metoda zmiennej metryki, Quasi-Newton).

- 6) Modele SSN umożliwiają szybkie i wiarygodne prognozowanie uszkodzeń nawierzchni. Stanowią zatem efektywne, możliwe do stosowania w praktyce narzędzia do planowania prewencyjnych prac utrzymaniowych a co za tym idzie prace naprawcze mogą być wykonywane w odpowiednio dobranych odstępach czasu, które gwarantują spełnienie określonych poziomów funkcjonalności nawierzchni ma istotny wpływ na optymalizację kosztów zarządcy drogi. Należy jednak podkreślić, że jednym z warunków sukcesu jest zbudowanie odpowiednich baz danych, właściwe i wiarygodne informacje, od których zależeć będzie następnie jakość generowanych wyników.
- 7) Uzyskane wyniki wskazują, że sztuczne sieci neuronowe mogą być wykorzystywane do optymalizacji strategii prewencyjnego utrzymania nawierzchni oraz do oceny stanu nawierzchni na poziomie projektu i sieci.
- 8) Korzyści ze stosowania sieci neuronowych wielokrotnie przekraczają pracochłonność ich tworzenia. W rzeczywistości najdłuższym etapem procesu ich opracowania jest zgromadzenie i przygotowanie odpowiedniej jakości danych wejściowych, chociaż dzięki zmodyfikowanej metodzie oceny cech powierzchniowych i ten etap można skutecznie zautomatyzować.

Poprzez zmodyfikowanie oceny cech powierzchniowych jezdni z betonu cementowego oraz możliwe opracowanie prognoz powstawania uszkodzeń płyt betonowych za pomocą SSN uzyskano możliwość modyfikacji strategii zarządzania nawierzchniami i odrzucenia reaktywnej eksploatacji oraz przyjęcia utrzymania zapobiegawczego, bardziej aktywnego, w celu zmniejszenia częstotliwości remontów oraz wydłużenia cyklu życia nawierzchni z betonu cementowego.

Wdrożenie przedstawionych procedur poprawia wiarygodność danych oraz umożliwia ich zastosowanie dodatkowo w programach zarządzania nawierzchniami na różnych szczeblach.

Dalsze prace badawcze będą dotyczyły analiz przy zastosowaniu sztucznej inteligencji (AI) i wykorzystaniu utworzonej bazy danych z identyfikacji uszkodzeń na wykonanych zdjęciach płyt w celu opracowania automatycznego algorytmu identyfikacji uszkodzeń.

Literatura

1. Adeli, H., Neural Networks in Civil Engineering: 1989–2000. Computer-Aided Civil and Infrastructure Engineering, 2001, <https://doi.org/10.1111/0885-9507.00219>
2. Alharbi F., Predicting pavement performance utilizing artificial neural network (ANN) models, Iowa State University, 2018
3. Alsugair A. M. Al-Qudrah, A. A., Artificial Neural Network Approach for Pavement Maintenance. Journal of Computing in Civil Engineering, 12(4), 1998, [https://doi.org/10.1061/\(ASCE\)0887-3801\(1998\)12:4\(249\)](https://doi.org/10.1061/(ASCE)0887-3801(1998)12:4(249))
4. American Association of State Highway and Transportation Officials, AASHTO guide for design of pavement structures, (Vol. 1), 1993
5. Anderson, D.A., D.R. Luhr, C.E. Antle. Framework for Development of Performance- Related Specifications for Hot-Mix Asphaltic Concrete. NCHRP Report 332. Washington, DC: Transportation Research Board, 1990
6. AVUS (Automobil- Verkehrs- und Uebungsstraße), eAutobahn, http://www.eautobahn.de/html/avus_automobil-_verkehrs_und_u.html
7. Bartman J., Sztuczne sieci neuronowe, 2012, www.neurosoft.edu.pl/jbartman/NTI1.pdf
8. Bień J., Modelowanie obiektów mostowych w procesie ich eksploatacji, Wrocław 2002
9. Bolewski A., Parachoniak W., Petrografia, Wydawnictwo Geologiczne, 1982
10. Bosurgi, G. Trifir, F., A model based on artificial neural networks and genetic algorithms for pavement maintenance management, International Journal of Pavement Engineering, 2005, <https://doi.org/10.1080/10298430500195432>
11. Chang C., M., Nazarian S.,; Vavrova M., Consequences of Delayed Maintenance of Highway Assets, NCHRP Research report 859, 2017
12. Chang G., Gilliland A., Rada R.G., A. Serigos P., Simpson A., Sareh Kouchaki, S., Successful Practices for Quality Management of Pavement Surface Condition Data Collection and Analysis Phase I: Task 2 –Document of Successful Practices, U.S. Department of Transportation Federal Highway Administration, 2020
13. Chang G., Gilliland A., Gonzalo R. Rada, Pedro A. Serigos, Amy L. Simpson, Kouchaki S., Successful Practices for Quality Management of Pavement Surface Condition Data Collection and Analysis, 2020
14. Concrete Pavement Maintenance Manual, highways england, Version 1.1, June 2021
15. Dacko M., Brodzik R., Numeryczna analiza wpływu obciążeń termicznych na stan przemieszczeń i naprężeń betonowych płyt lotniskowych, Wojskowa Akademia Techniczna, Biuletyn WAT Vol. LVII, Nr 2, 2008
16. Dennis J., Moré J., Quasi-Newton Methods, Motivation and Theory. SIAM Review, 1977
17. Diagnostyka Stanu Nawierzchni i Wybranych Elementów Korpusu Drogi, Wytyczne stosowania, GDDKiA, Warszawa, maj 2019

18. Die Forschungsgesellschaft für Straßen- und Verkehrswesen (FGSV), Systematik der Straßenerhaltung - Arbeitspapiere zur Zustandserfassung und -bewertung der Fahrbahnoberflächen von Straßen, Reihe M: Messtechnische Zustandserfassung von Straßen mit schnell fahrenden Messsystemen, 2019
19. Die Forschungsgesellschaft für Straßen- und Verkehrswesen (FGSV), Zusätzlichen Technischen Vertragsbedingungen und Richtlinien zur Zustandserfassung und -bewertung von Straßen (ZTV ZEB-StB), 2018
20. Domitroviæ J., Dragovan H., Rukavina T., Dimter S., Application of an Artificial Neural Network in Pavement Management System, Tehnièki vjesnik - Technical Gazette, 2018
21. DOT Using Next Level Tech On Wisconsin Roads, <https://www.pathwayservices.com/news/>
22. Eldin N. N., Senouci A. B., A Pavement Condition-Rating Model Using Backpropagation Neural Networks. Microcomputers in Civil Engineering, 10, 1995
23. Falls L., Haas R., McNeil S., Tighe S., Asset management and pavement management: Using common elements to maximize overall benefits. Transportation Research Record: Journal of the Transportation Research Board, 2001
24. Federal Highway Administration, Pavement Preservation Compendium II, September 2006
25. FUGRO Pavement engineering, www.Fugro.com
26. Generalna Dyrekcja Dróg Krajowych i Autostrad, Załącznik do Zarządzenia Nr. 5 System Oceny Stanu Nawierzchni, Aktualizacja związana z wykorzystaniem wyników pomiarów ugięć nawierzchni, Warszawa, 2010
27. Generalny pomiar ruchu w 2010 roku, GDDKiA, 2010
28. Generalny pomiar ruchu w 2015 roku, GDDKiA, 2015
29. Generalny pomiar ruchu w 2020/2021 roku, GDDKiA, 2020/2021
30. Graczyk M., Nośność konstrukcji nawierzchni wielowarstwowych w krajowych warunkach klimatycznych, Studia i Materiały, Zeszyt 63, IBDiM, Warszawa 2010
31. Grzyb M., Łazarowicz M., Zmiana parametrów użytkowych nawierzchni z betonu cementowego w trakcie eksploatacji, Magazyn Autostrady 3/2023
32. Guide for Design and Construction od New Jointed Plain Concrete Pavement (JPCPs), Division of Design, Office of Pavement Design, Pavement Design & Analysis Branch, January 9, 2008
33. Gyergyay, B., Höller, S., Pinkofsky, L., The role of the duraBASt research facility in an innovation ecosystem. An innovation management portfolio analysis, BASt, 2020
34. Highway asset management systems, Transportation Association of Canada (TAC), 1999
35. Highways Agency by Atkins, Economics of Climate Change Adaptation and Risks, Final report, 2013

36. Hoerner T.E, Darter M.I, Khazanovich L, Titus-Glover L., Smith K.L, Improved Prediction Models for PCC Pavement Performance-Related Specifications, Volume I: Final Report, September 2000
37. Hoerner, T.E. Guide to Developing Performance-Related Specifications for PCC Pavements, Volume IV: Appendix G—PaveSpec 2.0 User Guide. FHWA-RD-99-059. Washington, DC: Federal Highway Administration, 1999
38. Hoerner, T.E., M.I. Darter, S.M. Tarr, and P.A. Okamoto. Guide to Developing Performance-Related Specifications for PCC Pavements, Volume II: Appendix B—Field Demonstrations, Washington, DC: Federal Highway Administration, 1999
39. Hoerner, T.E., M.I. Darter. Guide to Developing Performance-Related Specifications for PCC Pavements, Volume I: Practical Guide, Final Report and Appendix A, Washington, DC: Federal Highway Administration, 1999
40. Hoerner, T.E., S.M. Tarr, M.I. Darter, and P.A. Okamoto. Guide to Developing Performance-Related Specifications for PCC Pavements, Volume III: Appendixes C Through F, Washington, DC: Federal Highway Administration, 1999
41. Huang, Y., Birgisson, B., Predictive modeling of pavement performance using artificial neural networks. Construction and Building Materials, 2015
42. Huang, Y., Birgisson, B., Taylor, P. C., Artificial neural networks for predicting pavement performance deterioration. Journal of Transportation Engineering, 2012
43. Huang, Y., Zeng, Z., Long short-term memory recurrent neural networks for predicting pavement performance. Journal of Computing in Civil Engineering, 2019
44. Instrukcja obsługi, System oceny wizualnej nawierzchni, Sowa, DRO-KONSULT, Warszawa, maj 2010
45. Ioannides A. M., Alexander D. R., Hammons I., Davis C. M., Application of Artificial Neural Networks to Concrete Pavement Joint Evaluation, Transportation Research board, 1996
46. iPAVe Continuous functional and structural data at highway speeds, www.arbbsystems.com
47. Irick, P.E., S.B. Seeds, M.G. Myers, E.D. Moody. Development of Performance-Related Specifications for Portland Cement Concrete Pavement Construction, Washington, DC: Federal Highway Administration, 1990
48. Issa A., Samaneh H., Ghanim M., Predicting pavement condition index using artificial neural networks approach, Ain Shams Engineering Journal, 2021
49. Jackiewicz-Rek W., Konopska-Piechurska M., Dudziec P., Concrete Pavement - classification and cause of damage, Dni Betonu 2014
50. Jackiewicz-Rek W., Konopska-Piechurska M., Załęgowski K., Garbacz A., Nawierzchnie betonowe - uszkodzenia i naprawy, <https://www.izolacje.com.pl/artykul/drogi-mosty/174654,nawierzchnie-betonowe-uszkodzenia-i-naprawy>

51. Janowski A., Szpinek S., Brzeziński D., Wykonanie XVII serii badań na Długoterminowych Odcinkach Testowych (DOT) wraz z wykonaniem pomiarów ugięć dynamicznych przy użyciu aparatu FWD na DOT, Etap II Wykonanie serii badań na Długoterminowych Odcinkach Testowych, DRO-KONSULT, Warszawa, kwiecień, 2011
52. Jaskulska K., Perspektywy rozwoju krajowych dróg betonowych, Drogownictwo 10/201
53. Jung Y., Freeman T., Zollinger D., Guidelines for Routine Maintenance of Concrete Pavements, Texas Transportation Institute, April 2008
54. Jung Y., Freeman T., Zollinger D., Guidelines for Routine Maintenance of Concrete Pavements, Texas Transportation Institute, April 2008
55. Juszczak M., Leśniak A., Artificial neural network applications review for cost management in construction projects, Engineering and Environmental Sciences no. 55, 2012
56. Katalog Typowych Konstrukcji Nawierzchni Sztywnych, Generalna Dyrekcja Dróg Publicznych, Warszawa 2001
57. Katalog Typowych Konstrukcji Nawierzchni Sztywnych, Załącznik do zarządzenia nr. 30 Generalnego Dyrektora Dróg Krajowych i Autostrad z dnia 16.06.2014
58. Katalog Typowych Konstrukcji Nawierzchni Sztywnych, Załącznik do zarządzenia nr. 30 Generalnego Dyrektora Dróg Krajowych i Autostrad z dnia 16.06.2014
59. Kljowski P., Analiza kosztów budowy i utrzymania nawierzchni drogowych, SPC, Lublin, listopad 2018
http://kongresdrogowy.pl/files/upload/LUB2018_PKijowski_nawierzchnie.pdf
60. Kirbas U., Gursoy M., Developing the basics of pavement management system in Besiktas district and evaluation of the selected sections. Scientific Research and Essays, 2010
61. Klimat Polski 2021, METEO IMGW-PIB, www.imgw.pl
62. Kroplick H., Velocci Al., Long Island Motor Parkway, 2008
63. Laser Crack Measurement System (LCMS-4M), www.pavemetrics.com
64. Li, Q., Scarpas, T., Predicting the performance of asphalt pavements: A review. Road Materials and Pavement Design, 2011
65. Lin J.D., Yau J.T., Hsiao L.H., Correlation analysis between international roughness index (IRI) and pavement distress by neural network. 82nd Annual Meeting of the Transportation Research Board, Washington, USA, 2003
66. Linek M., Neural model of projecting compressive strength of cement concrete intended for airfield pavements, XV International Conference on Durability of Building Materials and Components, Barcelona, 2020
67. Linek M., Neural model of projecting flexural strength of cement concrete intended for airfield pavements, IOP Conference Series: Materials Science and Engineering, 2019
68. Linek M., Nita P., Neural networks in diagnostics of concrete airfield pavements, Road and Bridges 21, 2022

69. Linek M., Nita P., Odporność termiczna i trwałość betonowych nawierzchni lotniskowych, *Logistyka* 6/2014
70. Lippman R., *An Introduction to Computing with Neural Nets*, IEEE ASSP Management, Vol. 4, 1987
71. Malicki K., Wpływ pojazdów ciężkich na nawierzchnie drogowe - analiza współczynnika agresywności, *Drogownictwo* nr.5, 2007
72. Manecki A., Muszyński M., *Przewodnik po petrografii*, Wydawnictwo AGH, 2008
73. Mechowski T., Sudyka J., Harasim P., *Diagnostyka stanu technicznego dróg*, Budownictwo infrastrukturalne, nr. 500, 2014
74. Meier R.W., Alexander D.R., Freeman R., *Using Artificial Neural Networks as A Forward Approach to Back Calculation*, *Transportation Research Record*, No. 1570, 1997
75. Meyer M., *Climate Change, Extreme Weather Events and the Highway System: Practitioner's Guide and Research Report*, NCHRP Report 750, 2014
76. Michalski W., *Metody nadawania tekstury nawierzchniom betonowym*, Generalna Dyrekcja Dróg Krajowych i Autostrad, „Drogownictwo” 4/2016
77. Miller J., Bellinger W., *Distress Identification Manual for the Long-Term Pavement Performance Program (Fifth Revised Edition)*, May 2014
78. Minsky M.L., Papert S.A., *Perceptrons*, MIT Press, Cambridge, 1969
79. NCHRP Project 14-20A Final Report, Appendix C, *Procedure to Quantify Consequences of Delayed Maintenance of Pavements*, https://onlinepubs.trb.org/onlinepubs/nchrp/nchrp_rpt_859AppendixC.pdf
80. Neruda R., Kudova Petra., *Learning methods for radial basis function networks*, *Future Generation Computer Systems*. Vol. 21, July 2005
81. Norbert J., *Concrete Pavement Design, Construction, and Performance*, Second Edition, 2017
82. Ochmański M., Bzówka J., *Wybrane przykłady zastosowań sztucznych sieci neuronowych w geotechnice*, *Budownictwo i Inżynieria Środowiska*, Gliwice, 2013
83. Odoki J.B., Kerali H.G.R., *Analytical Framework and Model Descriptions*, *Highway Development and Management Series*, Vol. 4, France, 2000
84. Ozer, H., Kisi, O., *Modeling of pavement performance using adaptive neuro-fuzzy inference system*. *Expert Systems with Applications*, 2018
85. Paterson, W., *Road Deterioration and Maintenance Effects: Models for planning and Management*, Baltimore: The John Hopkins University, 1987
86. *Pavement Interactive, Pavement Life-Cycle*, <https://pavementinteractive.org/reference-desk/pavement-management/analysis/pavementlife-cycle/>
87. *Pavement management guide*, (2nd edition). , American Association of State Highway Officials (AASHTO), 2012
88. Pierce, L.M., Weitzel, N.D. *NCHRP Synthesis 531 Automated Pavement Condition Survey*, National Academies of Sciences, Engineering, and Medicine 2019

89. Pierce, L.M., Weitzel, N.D. NCHRP Synthesis 531 Automated Pavement Condition Survey, National Academies of Sciences, Engineering, and Medicine 2019
90. Pożarycki A., Identyfikacja liczby i grubości warstw modelu nowej nawierzchni odcinka próbnego metodami sztucznej inteligencji, Drogi i Mosty nr 2, 2012
91. Praca zbiorowa: System Oceny Stanu Nawierzchni Betonowych SOSN-B. Wytyczne stosowania. Generalna Dyrekcja Dróg Krajowych i Autostrad Biuro Studiów, Warszawa 2007
92. Roesler J.R., Concrete slab analyses with fieldassigned nonuniform support conditions, International Journal of Pavement Engineering, 2016
93. Rogojsz G., Skupski D., The effect of the aggregate type on the properties of pavement concrete, Bulletin of the Military University of Technology, December 2018
94. Rudziński Ł., Słowik M., Concrete pavement management, MATEC Web of Conferences 222, 2018
95. Rudziński Ł., Słowik M., Ocena zmian temperatury w nawierzchniach betonowych, Archiwum Inżynierii Lądowej Nr. 27, 2018
96. Rukavina, T., Ožbolt, M., Pavement Management System - Data Collection, Management of Transport Infrastructure. Transportation Days 2009, Faculty of Civil Engineering of University of Zagreb, Zagreb, 2009
97. Russell S.J., Norvig P. Artificial intelligence: a modern approach, New Jersey: Prentice Hall, 2009
98. Sii H.B., Effect of dowel looseness on response of jointed concrete pavements using three- dimensional finite element analysis, Advanced Materials Research. 2014
99. Sivakumar A., Shahin M. Y., Prediction of pavement condition using logistic regression. Transportation Research Record: Journal of the Transportation Research Board, 2006
100. Siwoń Z., Cieżak W., Cieżak J., Modele neuronowe szeregów czasowych krótkotrwałego zużycia wody w osiedlach mieszkaniowych, XX Jubileuszowa-Krajowa, VIII Międzynarodowa Konferencja Naukowo - Techniczna, Zaopatrzenie w wodę, jakość i ochrona wód, Poland 15-18 June 2008
101. Sławinińska M., Zieliński P., Wpływ natężenia ruchu pojazdów ciężkich na trwałość konstrukcji nawierzchni drogowej, Drogownictwo nr. 3, 2015
102. Sudyka J., Mechowski T., Harasim P.: Nowoczesne metody oceny stanu nawierzchni w utrzymaniu sieci drogowej. IV Międzynarodowa Konferencja „Nowoczesne technologie w budownictwie drogowym”, Poznań 2009
103. Sundin, S., Braban-Ledoux, C., Artificial Intelligence – Based Decision Support Technologies in Pavement Management. Computer-Aided Civil and Infrastructure Engineering, 16, 2001, <https://doi.org/10.1111/0885-9507.00220>
104. Sztukiewicz R., Rydzewski P., Diagnostyka nawierzchni w systemie wspomaganego zarządzania siecią ulic, Instytut Inżynierii Lądowej Politechnika Poznańska, Zeszyty naukowe Politechniki Poznańskiej, 2006

105. Szydło A., Mackiewicz P., Badania i analizy kosztów budowy i utrzymania nawierzchni betonowych i asfaltowych, Raport serii U nr 166/2015, Politechnika Wrocławska, Wydział Budownictwa Lądowego i Wodnego
106. Szydło A., Mackiewicz P., Nawierzchnie betonowe w Polsce - doświadczenia przy projektowaniu i eksploatacji, Drogownictwo 11/2017
107. Szydło A., Nawierzchnie Drogowe z Betonu Cementowego, Polski Cement, Kraków 2004
108. Thube, D. T., Artificial Neural Network (ANN) Based Pavement Deterioration Models for Low Volume Roads in India. International Journal of Pavement Research and Technology, 2011, <http://www.ijprt.org.tw/reader/pdf.php?id=223>
109. Urbański M., Typowe uszkodzenia nawierzchni betonowych, Zeszyty Naukowe Politechniki Częstochowskiej, Częstochowa 2008
110. Van der Gryp A., Bredenhann, S. J., Henderson, M. G., Rohde, G. T., Determining the visual condition index of flexible pavements using artificial neural networks. Fourth International Conference on Managing Pavements, Durban, South Africa, 1998
111. Walker D., Pavement Surface Evaluation and Rating (PASER) Manual, Concrete Roads, Transportation Information Center, University of Wisconsin-Madison, 2002
112. Wang, Y., Li, Z., Predicting pavement performance using random forest regression models. Journal of Computing in Civil Engineering, 2020
113. Waszczyszyn Z., Wprowadzenie do sztucznych sieci neuronowych i ich zastosowań w mechanice konstrukcji. W: „Sztuczne sieci neuronowe, algorytmy genetyczne, zbiory rozmyte”, Studio BEL s.c., Rzeszów, 1999
114. Weed, R.M. Statistical Specification Development. FHWA/NJ-88-017. Trenton, NJ: New Jersey Department of Transportation, 1989
115. Wei B., Guo C., Predicting the Remaining Service Life of Civil Airport Runway considering Reliability and Damage Accumulation, Advances in Materials Science and Engineering Volume 2022, <https://doi.org/10.1155/2022/6494812>
116. William G.W., Effect of temperature variations on premature cracking of dowel jointed concrete pavements, West Virginia University, 2003
117. Willway T., The effects of climate change on highway pavements and how to minimize them: Technical report, TRL Limited 2008
118. Wojtawicki J., Przyczyny powstawania uszkodzeń nawierzchni z betonu cementowego, "Lotnisko", nr 3/2008
119. Wolters, A., Zimmerman K., Research of Current Practices in Pavement Performance Modeling, 2010
120. World Leader in Fully Automated Pavement Survey in Sub-MM 3D, www.waylink.com
121. Yeh I.C., Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks, Cement and Concrete Research, Vol. 28, No. 12, 1998


122. Yeh T., Hong J., Predicting highway pavement performance using multilevel hierarchical Bayesian models. Transportation Research Record: Journal of the Transportation Research Board, 2009
123. Zaniewski, J. P., Mamlouk, M. S., Preventive Maintenance Effectiveness - Preventive Maintenance Treatments. Federal Highway Administration, 1996, <https://www.fhwa.dot.gov/pavement/pubs/013734.pdf>
124. Zhang Y-c., L.-l. Gao., Effect of dowel bar position deviation on joint load-transfer ability of cement concrete pavement, International Journal of Pavement Research and Technology, 2016
125. Zhang, D., Huang, Y., Ni, Z. Predicting asphalt pavement rutting based on an improved support vector regression model. Construction and Building Materials, 2021
126. Zhang, J., Zhou X., Wu W., Pavement performance prediction using a hybrid model based on least squares support vector machines and particle swarm optimization. KSCE Journal of Civil Engineering, 2018
127. Zofka A., Proaktywna strategia zarządzania elementami infrastruktury drogowej, IBDiM, Zeszyt 82, 2019
128. Zofka. A., Proactive pavement asset management with climate change aspects, IOP Conference Series: Materials Science and Engineering, 2018
129. Żaba J., Kozłowski K., Fediuk F., Petrologia skał metamorficznych, Uniwersytet Śląski, 1986

Załącznik nr 1

Zestawienie graficzne uszkodzeń i uszkodzeń naprawionych




Zestawienie ilości uszkodzeń do uszkodzeń naprawionych - uszkodzenia powierzchniowe (UP)




Rysunek Z.1.1 Zestawienie ilości uszkodzeń do uszkodzeń naprawionych – uszkodzenia powierzchniowe (UP)

Zestawienie powierzchni uszkodzeń do uszkodzeń naprawionych - uszkodzenia powierzchniowe (UP)




Rysunek Z.1.2. Zestawienie powierzchni uszkodzeń do uszkodzeń naprawionych – uszkodzenia powierzchniowe (UP)

Zestawienie ilości uszkodzeń do uszkodzeń naprawionych - uszkodzenia naroży (UN)




Rysunek Z.1.3. Zestawienie ilości uszkodzeń do uszkodzeń naprawionych – uszkodzenia naroży (UN)

Zestawienie powierzchni uszkodzeń do uszkodzeń naprawionych - uszkodzenia naroży (UN)




Rysunek Z.1.4. Zestawienie powierzchni uszkodzeń do uszkodzeń naprawionych – uszkodzenia naroży (UN)

Zestawienie ilości uszkodzeń do uszkodzeń naprawionych - wykruszenie szczelin (WS)




Rysunek Z.1.5. Zestawienie ilości uszkodzeń do uszkodzeń naprawionych –
wykruszenie szczelin (WS)

Zestawienie powierzchni uszkodzeń do uszkodzeń naprawionych - wykruszenie szczelin (WS)




Rysunek Z.1.6. Zestawienie powierzchni uszkodzeń do uszkodzeń naprawionych –
wykruszenie szczelin (WS)

Zestawienie ilości uszkodzeń do uszkodzeń naprawionych - pęknięcia podłużne (PL)




Rysunek Z.1.7. Zestawienie ilości uszkodzeń do uszkodzeń naprawionych – pęknięcia podłużne (PL)

Zestawienie długości uszkodzeń do uszkodzeń naprawionych - pęknięcia podłużne (PL)




Rysunek Z.1.8. Zestawienie długości uszkodzeń do uszkodzeń naprawionych – pęknięcia podłużne (PL)

Zestawienie ilości uszkodzeń do uszkodzeń naprawionych - pęknięcie poprzeczne (PT)



Rysunek Z.1.9. Zestawienie ilości uszkodzeń do uszkodzeń naprawionych – pęknięcia poprzeczne (PT)


Zestawienie długości uszkodzeń do uszkodzeń naprawionych - pęknięcia poprzeczne (PT)




Rysunek Z.1.10. Zestawienie długości uszkodzeń do uszkodzeń naprawionych – pęknięcia poprzeczne (PT)

Załącznik nr 2


Zestawienie graficzne danych temperaturowych




Odcinek A




Rysunek Z.2.1.a. Zestawienie temperatur max. w okresie letnim 2016 – 2021




Rysunek Z.2.1.b. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2016




Rysunek Z.2.1.c. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2017




Rysunek Z.2.1.d. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2018



Rysunek Z.2.1.e. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2019




Rysunek Z.2.1.f. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2020




Rysunek Z.2.1.g. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2021

Odcinek A



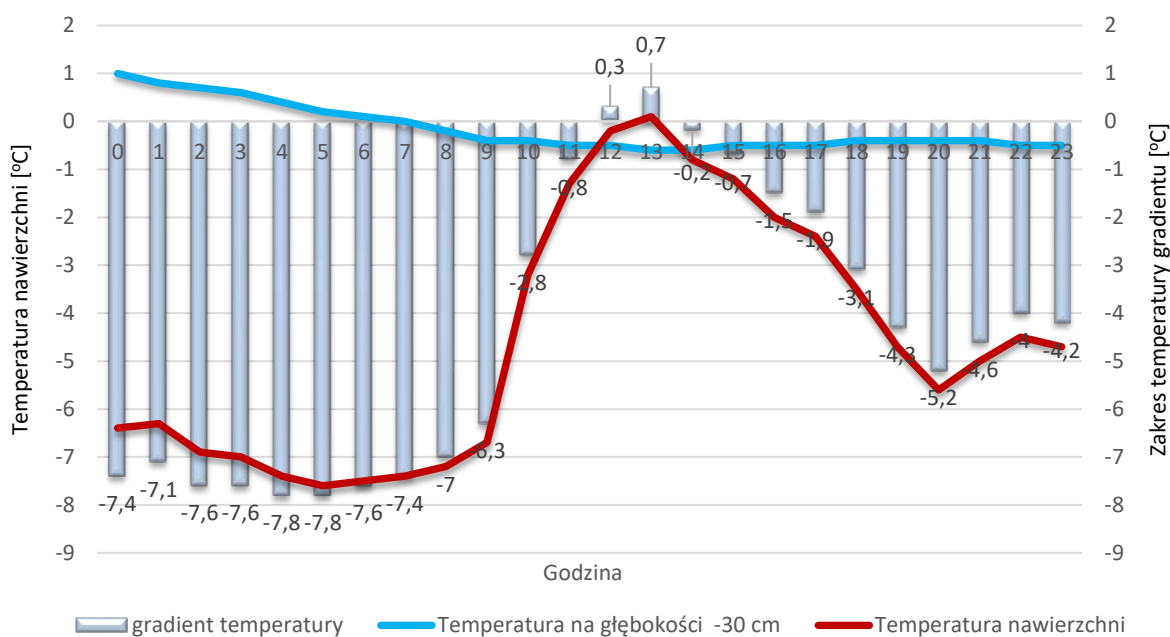
Rysunek Z.2.2.a. Zestawienie temperatur max. w okresie zimowym 2016 – 2021

Max. Gradient temperatury w roku 2016




Rysunek Z.2.2.b. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2016


Max. Gradient temperatury w roku 2017



Rysunek Z.2.2.c. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2017




Rysunek Z.2.2.d. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2018




Rysunek Z.2.2.e. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2019

Max. Gradient temperatury w roku 2020




Rysunek Z.2.2.f. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2020

Max. Gradient temperatury w roku 2021




Rysunek Z.2.2.g. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2021

Odcinek B i C




Rysunek Z.2.3.a. Zestawienie temperatur max. w okresie letnim 2016 – 2021




Rysunek Z.2.3.b. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2016

Max. Gradient temperatury w roku 2017




Rysunek Z.2.3.c. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2017

Max. Gradient temperatury w roku 2018




Rysunek Z.2.3.d. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2018

Max. Gradient temperatury w roku 2019




Rysunek Z.2.3.e. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2019

Max. Gradient temperatury w roku 2020



Rysunek Z.2.3.f. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2020


Max. Gradient temperatury w roku 2021




Rysunek Z.2.3.g. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2021

Odcinek B i C


Min. temperatura powietrza [okres zimowy]




Rysunek Z.2.4.a. Zestawienie temperatur max. w okresie zimowym 2016 – 2021




Rysunek Z.2.4.b. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2016




Rysunek Z.2.4.c. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2017




Rysunek Z.2.4.d. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2018



Rysunek Z.2.4.e. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2019




Rysunek Z.2.4.f. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2020




Rysunek Z.2.4.g. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2021


Odcinek D i E




Rysunek Z.2.5.a. Zestawienie temperatur max. w okresie letnim 2016 – 2021



Rysunek Z.2.5.b. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2016




Rysunek Z.2.5.c. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2017




Rysunek Z.2.5.d. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2018

Max. Gradient temperatury w roku 2019




Rysunek Z.2.5.e. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2019

Max. Gradient temperatury w roku 2020



Rysunek Z.2.5.f. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2020


Max. Gradient temperatury w roku 2021



Rysunek Z.2.5.g. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie letnim w roku 2021


Odcinek D i E

Min. temperatura powietrza [okres zimowy]




Rysunek Z.2.6.a. Zestawienie temperatur max. w okresie zimowym 2016 – 2021

Max. Gradient temperatury w roku 2016




Rysunek Z.2.6.b. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2016

Max. Gradient temperatury w roku 2017




Rysunek Z.2.6.c. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2017

Max. Gradient temperatury w roku 2018




Rysunek Z.2.6.d. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2018


Max. Gradient temperatury w roku 2019



Rysunek Z.2.6.e. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2019



Rysunek Z.2.6.f. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2020



Rysunek Z.2.6.g. Gradient temperatury pomiędzy dolną i górną powierzchnią płyty w okresie zimowym w roku 2021