Politechnika Śląska

RESEARCH UNIVERSITY
EXCELLENCE INITIATIVE
Ministry of Science and Higher Education

Wydział Budownictwa

Rozprawa doktorska

Implementacja algorytmów optymalizacyjnych i technik sztucznej inteligencji w procesie tworzenia cyfrowych bliźniaków obiektów mostowych

mgr inż. Dawid Piotrowski

Promotor: **dr hab. inż. Artur Nowoświat, prof. PŚ.**

Promotor pomocniczy: **dr inż. Piotr Łaziński**

Wydział Budownictwa, Katedra Mechaniki i Mostów

Gliwice, czerwiec 2026

Podziękowania

Realizacja niniejszej rozprawy doktorskiej była możliwa dzięki wsparciu oraz życzliwości wielu osób, którym pragnę złożyć szczere podziękowania.

W pierwszej kolejności chciałbym wyrazić wdzięczność moim promotorom **dr. hab. inż. Arturowi Nowoświatowi, prof. PŚ.** *oraz* **dr. inż. Piotrowi Łazińskiemu** *za opiekę naukową podczas realizacji rozprawy, liczne konsultacje oraz cenne wskazówki przekazywane na kolejnych etapach jej przygotowania. Bardzo dziękuję za poświęcony czas oraz wiedzę i doświadczenie, które pozwoliły mi właściwie ukierunkować prowadzone badania i nadać pracy jej obecny kształt. Wsparcie oraz zaangażowanie promotorów stanowiły niezwykle istotny element realizacji niniejszej rozprawy, za co serdecznie Wam dziękuję.*

Wyjątkowe podziękowania kieruję do **dr. inż. Marcina Jasińskiego**, *którego wkład w realizację pracy był nie do przecenienia. Ogromna pomoc merytoryczna oraz wsparcie, które otrzymałem, są praktycznie niemożliwe do opisania. Wiele rozwiązań przedstawionych w rozprawie powstało dzięki wspólnym dyskusjom, wymianie pomysłów oraz gotowości do dzielenia się wiedzą i doświadczeniem. Twoja pomoc i zaangażowanie miały kluczowe znaczenie dla powstania niniejszej rozprawy.*

Ponadto chciałbym podziękować wszystkim osobom, których zaangażowanie znacznie przyczyniło się do realizacji badań. Dziękuję przedstawicielom firm HBK oraz Peltron za wsparcie techniczne oraz pomoc podczas prac związanych z uruchomieniem systemu pomiarowego. Szczególne wyrazy wdzięczności kieruję także do kolegów z Katedry oraz firmy CadMost, którzy wielokrotnie uczestniczyli w wyjazdach, wspierali prowadzenie badań oraz pomagali w realizacji licznych prac niezbędnych do wykonania niniejszej rozprawy. Bez Waszego zaangażowania, poświęconego czasu i gotowości do pomocy przeprowadzenie wielu etapów badań byłoby znacznie trudniejsze.

Na zakończenie chciałbym podziękować mojej najbliższej rodzinie, w szczególności Mamie oraz Siostrze, za wsparcie i cierpliwość okazywane przez cały okres doktoratu. Wasza obecność i wyrozumiałość miały ogromne znaczenie i pozwoliły mi z pełnym zaangażowaniem ukończyć niniejszą rozprawę.

Streszczenie

Rozwój cyfryzacji oraz systemów monitoringu konstrukcji prowadzi do coraz szerszego wykorzystania cyfrowych bliźniaków w inżynierii lądowej. Ich podstawową ideą jest powiązanie rzeczywistego obiektu z jego wirtualnym odpowiednikiem, umożliwiając bieżącą analizę pracy konstrukcji oraz identyfikację zjawisk zachodzących podczas eksploatacji. Podejście to nabiera szczególnego znaczenia w przypadku obiektów mostowych, które coraz częściej zaliczane są do infrastruktury o znaczeniu strategicznym.

Pomimo dynamicznego rozwoju cyfrowych bliźniaków, w literaturze nadal nie funkcjonuje jedna powszechnie akceptowana definicja tego pojęcia. Dostępne badania koncentrują się na różnych aspektach procesu ich budowy, podkreślając jednak konieczność integracji danych pomiarowych, modeli numerycznych oraz algorytmów wspomagających podejmowanie decyzji. Jednym z kluczowych wyzwań pozostaje natomiast identyfikacja rzeczywistych obciążeń eksploatacyjnych działających na konstrukcję. W niniejszej rozprawie przedstawiono metodykę rozwiązania tego problemu, traktując proces identyfikacji obciążeń jako jeden z podstawowych elementów warstwy informacyjnej cyfrowego bliźniaka.

Badania przeprowadzono na przykładzie mostu łukowego zlokalizowanego w Wolinie, na którym zainstalowano system monitoringu odkształceń. W tym celu wykorzystano czujniki światłowodowe bazujące na technologii siatki Bragga, realizując pomiar w trzech przekrojach zlokalizowanych w $1/4$, $1/2$ oraz $3/4$ rozpiętości przęsła. Szczególną uwagę poświęcono lokalizacji punktów pomiarowych, przeprowadzając teoretyczną analizę statyczną. Wyznaczone linie wpływu poprzecznic wykazały, że możliwa jest identyfikacja pojazdów znajdujących się w bezpośrednim sąsiedztwie analizowanego przekroju, bez zaburzania wyników przez pojazdy stojące w dalszej odległości. Taka cecha konstrukcji pozwoliła na trzykrotny niezależny pomiar masy tego samego pojazdu podczas przejazdu przez obiekt.

W kolejnym etapie przeprowadzono badania pod próbnym obciążeniem, obejmujące schematy statyczne oraz dynamiczne. Pozyskane dane wykorzystano do identyfikacji modelu numerycznego, na podstawie którego wygenerowano zbiór danych treningowych. Posłużył on do uczenia modeli sieci neuronowych, wykorzystywanych w procesie ważenia pojazdów w ruchu. Opracowane rozwiązanie zwalidowano na danych obejmujących różne scenariusze ruchu, uzyskując średnie wartości MAPE dla przejazdów losowych na poziomie 7 – 8 %. Uzyskane wyniki potwierdziły możliwość integracji danych pomiarowych, modeli numerycznych oraz algorytmów uczenia maszynowego w ramach warstwy informacyjnej cyfrowego bliźniaka, umożliwiając tym samym identyfikację rzeczywistych obciążeń eksploatacyjnych.

Abstract

The development of digitalization and structural monitoring systems is leading to the increasingly widespread use of digital twins in civil engineering. Their fundamental concept is to establish a connection between a real object and its virtual counterpart, enabling continuous analysis of structural response and the identification of phenomena occurring during operation. This approach is particularly important in the case of bridge structures, which are increasingly classified as strategic infrastructure.

Despite the dynamic development of digital twins, there is still no single universally accepted definition of this concept in the literature. Available studies focus on different aspects of the digital twin development process, while emphasizing the necessity of integrating measurement data, numerical models, and decision-support algorithms. One of the key challenges remains the identification of actual operational loads acting on the structure. This dissertation presents a methodology for addressing this problem, treating the load identification process as one of the fundamental elements of the information layer of a digital twin.

The research was conducted using the example of an arch bridge located in Wolin, on which a strain monitoring system was installed. For this purpose, fiber optic sensors based on Fiber Bragg Grating technology were used, with measurements performed in three sections located at $1/4$, $1/2$, and $3/4$ of the span length. Particular attention was devoted to the location of measurement points through a theoretical static analysis. The determined influence lines of the crossbeams demonstrated that it is possible to identify vehicles located in the immediate vicinity of the analyzed section without the results being disturbed by vehicles situated farther away. This characteristic of the structure enabled three independent weight measurements of the same vehicle during its passage across the bridge.

In the next stage, load testing was carried out, including both static and dynamic loading schemes. The acquired data were used for the identification of the numerical model, on the basis of which a training dataset was generated. This dataset was used to train neural network models applied in the process of weigh-in-motion. The developed solution was validated using data covering various traffic scenarios, achieving average MAPE values for random vehicle passages at the level of 7 – 8 %. The obtained results confirmed the possibility of integrating measurement data, numerical models, and machine learning algorithms within the information layer of a digital twin, thereby enabling the identification of actual operational loads.

Spis treści

Stosowane oznaczenia 13

Stosowane skróty 18

1 Wprowadzenie 21

1.1 Koncepcja modeli cyfrowych bliźniaków 21

1.2 Cele pracy 24

1.3 Zakres rozprawy 25

2 System monitoringu SHM mostu M-7L w Wolinie 27

2.1 Wstęp 27

2.2 Przegląd literatury 29

2.2.1 Techniki pomiarowe stosowane w SHM 29

2.2.2 Czujniki światłowodowe 31

2.2.3 Analiza rozmieszczenia punktów pomiarowych 33

2.2.4 Metody przetwarzania danych w systemach SHM 34

2.2.5 Podsumowanie 36

2.3 Opis przypadku 37

2.3.1 Charakterystyka badanego obiektu 37

2.3.2 Cel instalowanego monitoringu SHM 39

2.4 Model numeryczny MES 41

2.5 Analiza statyczna 44

2.5.1 Analiza odpowiedzi konstrukcji w formie zakresu zmian sił wewnętrznych . . 44

2.5.2 Analiza położenia obciążenia w przekroju poprzecznym 48

2.6 Dobór systemu 49

2.6.1 Schemat systemu i lokalizacja punktów pomiarowych 49

2.6.2 Pomiar odkształceń wybranych elementów konstrukcyjnych 50

2.6.3 Metody instalacji czujników 52

2.6.4 Pomiar towarzyszący urządzenia dylatacyjnego i łożyska 55

2.6.5 Metody gromadzenia danych . . . 56
2.6.6 Wyznaczenie niepewności standardowej i rozszerzonej pomiarów . . . 58
2.7 Podsumowanie . . . 61

3 Badania pod próbnym obciążeniem 63
3.1 Wstęp . . . 63
3.2 Środki obciążające . . . 65
3.3 Badania statyczne . . . 67
3.4 Badania dynamiczne . . . 73
3.4.1 Przejazdy pojedynczych pojazdów . . . 73
3.4.2 Przejazdy w kolumnach . . . 78
3.5 Podsumowanie . . . 84

4 Identyfikacja modelu numerycznego MES 85
4.1 Wstęp . . . 85
4.2 Przegląd literatury . . . 87
4.2.1 Identyfikacja modeli MES w ujęciu teorii identyfikacji układów . . . 87
4.2.2 Zmienne decyzyjne wykorzystywane w procesach identyfikacji modeli MES . . . 89
4.2.3 Funkcja celu zadania optymalizacyjnego . . . 91
4.2.4 Metody wykorzystywane w procesach identyfikacji modeli MES . . . 92
4.2.5 Modele zastępcze . . . 94
4.2.6 Podsumowanie . . . 95
4.3 Implementacja algorytmu genetycznego w procesie identyfikacji modelu MES . . . 96
4.3.1 Założenia i przyjęte parametry algorytmu genetycznego . . . 96
4.3.2 Funkcja celu . . . 100
4.3.3 Implementacja sieci neuronowej jako modelu zastępczego . . . 107
4.3.4 Integracja modelu zastępczego sieci neuronowej w algorytmie genetycznym . . . 116
4.4 Rezultaty identyfikacji modelu MES . . . 120
4.4.1 Analiza wrażliwości zmiennych decyzyjnych . . . 120
4.4.2 Analiza wrażliwości parametrów algorytmu genetycznego . . . 122
4.4.3 Proces identyfikacji z wykorzystaniem modelu MES . . . 127
4.4.4 Proces identyfikacji z wykorzystaniem modelu zastępczego sieci neuronowej 129
4.5 Podsumowanie . . . 132

5 Predykcja masy całkowitej pojazdów z wykorzystaniem algorytmów uczenia maszynowego 133
5.1 Wstęp . . . 133
5.2 Przegląd literatury . . . 135
5.2.1 Metodologia ważenia pojazdów w ruchu . . . 135
5.2.2 Klasyczne systemy WIM . . . 135
5.2.3 Detekcja masy pojazdów z wykorzystaniem konstrukcji mostu . . . 136
5.2.4 Podsumowanie i określenie luki badawczej . . . 139
5.3 Założenia wdrożonego rozwiązania . . . 140
5.4 Metody przetwarzania zarejestrowanego sygnału . . . 142
5.5 Procedura doboru architektury modeli sieci neuronowych . . . 145
5.6 Predykcja masy całkowitej pojazdów . . . 150
5.6.1 Przejazdy pojedynczych pojazdów . . . 150
5.6.2 Przejazdy w kolumnach . . . 153
5.6.3 Przejazdy losowe . . . 155
5.6.4 Analiza wpływu prędkości i dodatkowego wzbudzenia dynamicznego . . . 159
5.6.5 Podsumowanie wyników . . . 162
5.7 Podsumowanie . . . 163

6 Podsumowanie 165

Bibliografia 169
Artykuły naukowe . . . 169
Standardy techniczne . . . 185

Stosowane oznaczenia

Oznaczenia stosowane w pracy

W pracy przyjęto następującą notację:

- Wartości skalarne oraz nazwy funkcji oznaczane są małą literą w kroju kursywnym,
- Funkcje opisujące modele, metryki oraz funkcje straty, a także wielkości fizyczne oznaczane są wielkimi literami w kroju kursywnym,
- Zbiory oznaczane są wielką literą w kroju kursywnym,
- Wektory oznaczane są małą literą w zapisie pogrubionym,
- Macierze oznaczane są wielką literą w zapisie pogrubionym.

W każdym rozdziale oznaczenia uporządkowano według następującej konwencji: w pierwszej grupie podano skalary i funkcje, następnie wektory, a na końcu macierze. W obrębie każdej z grup zastosowano porządek alfabetyczny.

Rozdział 2

A	Pole powierzchni przekroju [m^2]
a^-	Minimalna wartość odkształceń odpowiadająca dolnej granicy wielkości wejściowej x_i [µm/m]
a^+	Maksymalna wartość odkształceń odpowiadająca górnej granicy wielkości wejściowej x_i [µm/m]
E_{bm}	Moduł sprężystości części monolitycznej płyty pomostowej [GPa]
E_{bp}	Moduł sprężystości części prefabrykowanej płyty pomostowej [GPa]
E_{h}	Moduł sprężystości wieszaków [GPa]
E_{s}	Moduł sprężystości elementów stalowych [GPa]
ε	Wartości odkształceń zwracane przez system pomiarowy [µm/m]
i	Indeks punktu pomiarowego
I_{y}	Moment bezwładności na zginanie względem osi y [m^4]
I_{z}	Moment bezwładności na zginanie względem osi z [m^4]

Oznaczenia stosowane w pracy

k	Współczynnik kalibracyjny czujnika światłowodowego
k_c	Współczynnik rozszerzenia niepewności pomiaru
λ	Zmierzona długość fali Bragga [µm/m]
λ_0	Referencyjna długość fali Bragga czujnika odkształceń [µm/m]
n	Całkowita liczba punktów pomiarowych
m	Całkowita liczba zdefiniowanych źródeł niepewności pomiarowej
S_0, S_1, S_2	Współczynniki kalibracyjne czujników temperatury
T	Zmierzona wartość temperatury [°C]
T_0	Temperatura odniesienia, wyznaczana w chwili zerowych wartości odkształceń [°C]
U	Niepewność rozszerzona pomiarów
$u^2(\hat{x}_i)$	Wariancja (kwadrat niepewności standardowej) odpowiadająca estymacie $\hat{x}_i$
$u_\mathrm{c}(\hat{y})$	Niepewność standardowa oszacowania wyniku $\hat{y}$
$W(\hat{y})$	Względna niepewność rozszerzona [%]
x^-	Dolna granica wielkości wejściowej x_i
x^+	Górna granica wielkości wejściowej x_i
x_i	Wielkości wejściowe przyjmowane podczas wyznaczania niepewności standardowej i rozszerzonej pomiarów
$\hat{x}_i$	Estymata wpływu danej wielkości wejściowej x_i na wartość mezurandu
y_i	Wartości mezurandu (odkształceń) przyjmowane podczas wyznaczania niepewności standardowej i rozszerzonej pomiarów [µm/m]
$\hat{y}$	Estymata wartości mezurandu [µm/m]
z_c	Odległość do środka ciężkości przekroju [m]
Rozdział 3	
a, b	Rozstawy poszczególnych osi pojazdów [m]
w	Szerokość pojazdu [m]

Oznaczenia stosowane w pracy

Rozdział 4

A	Pole powierzchni przekroju [m^2]
α	Parametr pomocniczy przyjmowany na etapie krzyżowania
β	Parametr rozkładu prawdopodobieństwa na etapie krzyżowania
c_s	Liczba schematów próbnego obciążenia statycznego
c_d	Liczba analizowanych przejazdów dynamicznych dla danego pojazdu i pasa ruchu
d	Liczba zmiennych decyzyjnych (wymiar wektora $\mathbf{x}_i$)
$\Delta\varepsilon$	Przyrost odkształceń pomiędzy stanem obciążenia, a wartościami odniesienia w stanie nieobciążonym [µm/m]
$\Delta\varepsilon_{stat}$	Przyrost odkształceń od obciążenia quasi-statycznego przyjmowanego jako wartość odniesienia przy wyznaczaniu współczynnika przewyższenia dynamicznego [µm/m]
$\Delta\varepsilon_{dyn}$	Przyrost odkształceń od przejazdów dynamicznych [µm/m]
δ	Parametr mutacji
δ_L	Granica między częścią kwadratową, a liniową funkcji straty Hubera
$(E_1^{(i)}, \ldots, E_d^{(i)})$	Moduły sprężystości kolejnych elementów konstrukcyjnych
$f(\mathbf{x})$	Zdefiniowana funkcja celu
G_p	Zbiór punktów pomiarowych dla p-tego przypadku obciążenia statycznego, dla których wyznaczana jest wartość funkcji celu
$h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})$	Wartość funkcji hipotezy modelu zastępczego sieci neuronowej dla r--tej próbki
$h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})_j$	j-ta składowa wektora predykcji modelu dla r-tej próbki wejściowej
$h_{\boldsymbol{\theta}}(\mathbf{X})$	Wartość funkcji hipotezy warstwy gęstej modelu zastępczego sieci neuronowej
I	Moment bezwładności na zginanie [m^4]
i	Indeks kandydata w danym pokoleniu algorytmu genetycznego
j	Indeks zmiennej decyzyjnej (składowej wektora $\mathbf{x}_i$)

Oznaczenia stosowane w pracy

k	Indeks punktu pomiarowego (elementu zbioru G_p)
$L(h_{\boldsymbol{\theta}}(\mathbf{X}), \mathbf{Y})$	Funkcja straty Hubera
$l^{(r)}$	Jednostkowa funkcja straty dla każdej próbki $\mathbf{x}^{(r)}$ oraz $\mathbf{y}^{(r)}$
m	Liczba kandydatów w każdym pokoleniu algorytmu genetycznego
n	Czynnik uśredniający dla błędu MAPE, określający całkowitą liczbę punktów pomiarowych dla wszystkich przypadków obciążenia statycznego $n = \sum_{p=1}^{c_\mathrm{s}} n_p$
n_d	Liczba próbek w rozważanym zbiorze danych podczas walidacji modelu zastępczego sieci neuronowej
n_p	Liczba punktów pomiarowych dla p-tego przypadku obciążenia $n_p = \lvert G_p \rvert$
n_r	Liczba próbek w zbiorze treningowym modelu zastępczego sieci neuronowej
η_cr	Parametr redystrybucji przyjmowany na etapie krzyżowania
η_mut	Parametr redystrybucji przyjmowany na etapie mutacji
ϕ	Funkcja aktywacji modelu zastępczego sieci neuronowej
p	Indeks przypadku obciążenia statycznego
p_d	Indeks przejazdu dynamicznego dla danego pojazdu i pasa ruchu
$\mathbf{P} = \{\mathbf{x}_1, \ldots, \mathbf{x}_m\}$	Zbiór wektorów $\mathbf{x}_i$ tworzących populację $\mathbf{P}$ algorytmu genetycznego
Q	Przyjęta miara zgodności predykcji
r	Indeks kolejnej próbki zbioru danych wykorzystywanych w procesie uczenia modelu zastępczego sieci neuronowej
u	Czynnik losowości wprowadzany na etapie krzyżowania oraz mutacji
ρ	Parametr uwzględniający na etapie krzyżowania zdefiniowane granice zmiennych decyzyjnych $\mathbf{x}_\mathrm{min}$ oraz $\mathbf{x}_\mathrm{max}$
μ	Parametr pomocniczy przyjmowany na etapie mutacji
$\mathbf{b}$	Wektor obciążeń poszczególnych neuronów modelu zastępczego sieci neuronowej

Oznaczenia stosowane w pracy

$\boldsymbol{\theta} = \begin{bmatrix} \text{vec}(\mathbf{W}) \\ \text{b} \end{bmatrix}$	Wektor parametrów modelu zastępczego sieci neuronowej, tworzony poprzez wektoryzację macierzy wag **W** oraz dołączenie wektora **b**
$\mathbf{x}_1^{\text{cr}}$, $\mathbf{x}_2^{\text{cr}}$	Wektory zmiennych decyzyjnych dwóch osobników wybranych losowo do operacji krzyżowania
$\mathbf{x}_{\text{min}}$	Wektor dolnych wartości granicznych zmiennych decyzyjnych
$\mathbf{x}_{\text{max}}$	Wektor górnych wartości granicznych zmiennych decyzyjnych
$\mathbf{x}^{\text{mut}}$	Wektor zmiennych decyzyjnych kandydata wybranego podczas mutacji
$\mathbf{x}_{0,p,k}$	Wektor wartości odkształceń zmierzonych podczas badań pod próbnym obciążeniem dla p-tego schematu obciążenia oraz k-tego punktu pomiarowego
$\mathbf{x}_{p,k}$	Wektor wartości odkształceń uzyskanych z modelu MES dla p-tego schematu obciążenia oraz k-tego punktu pomiarowego
$\mathbf{x}^{(r)}$	Wektor zmiennych decyzyjnych dla próbki r zbioru danych wykorzystywanych w procesie uczenia modelu zastępczego sieci neuronowej
$\mathbf{y}_1^{\text{cr}}$, $\mathbf{y}_2^{\text{cr}}$	Wektory rozwiązań potomnych wyznaczonych na etapie krzyżowania
$\mathbf{y}^{\text{mut}}$	Wektor rozwiązania potomnego wyznaczonego na etapie mutacji
$\mathbf{y}^{(r)}$	Wektor wartości odkształceń dla próbki r zbioru danych wykorzystywanych w procesie uczenia modelu zastępczego sieci neuronowej
$\mathbf{y}_j^{(r)}$	Składowa j wektora $\mathbf{y}^{(r)}$
W	Macierz wag modelu zastępczego sieci neuronowej
X	Macierz cech wejściowych modelu zastępczego sieci neuronowej
Y	Macierz cech wyjściowych modelu zastępczego sieci neuronowej

Rozdział 5

α	Współczynnik redukcyjny
c_1	Współczynnik kognitywny
c_2	Współczynnik socjalny
G_j	Najlepsza wartość składowej j rozwiązania znalezionego w całym roju
i	Indeks danej cząstki roju

Oznaczenia stosowane w pracy	
$J(k)$	Finalna wartość błędu RMSE po uwzględnieniu funkcji kary
j	Indeks składowej wektora położenia cząstki $\mathbf{x}_i$
k	Liczba neuronów w danej warstwie modelu sieci neuronowej
m	Liczba zmiennych decyzyjnych w algorytmie PSO
n	Liczba cząstek, wchodzących w skład roju
p_{ij}	Najlepsza wartość składowej j wektora położenia osiągniętego dotychczas przez cząstkę i
r_1, r_2	Wartości losowe, przyjmowane z przedziału $[0, 1]$
t	Indeks iteracji algorytmu PSO
t_{max}	Maksymalna liczba iteracji algorytmu PSO
v_{ij}	Składowa j wektora prędkości $\mathbf{v}_i$ cząstki i
w	Współczynnik inercji
w_{max}	Maksymalna wartość współczynnika inercji
w_{min}	Minimalna wartość współczynnika inercji
x_{ij}	Składowa j wektora położenia $\mathbf{x}_i$ cząstki i
$\mathbf{x}_i = (x_{i1}, \ldots, x_{im})$	Wektor położenia i-tej cząstki w algorytmie PSO
$\mathbf{v}_i = (v_{i1}, \ldots, v_{im})$	Wektor prędkości i-tej cząstki w algorytmie PSO

Stosowane skróty

Skróty stosowane w pracy	
ACC	Współczynnik Zgodności Predykcji (*ang. Accuracy Coefficient*)
API	Interfejs Programowania Aplikacji (*ang. Application Programming Interface*)
BIM	Modelowanie Informacji o Budynku (*ang. Building Information Modelling*)

Skróty stosowane w pracy	
BWIM	Ważenie Pojazdów w Ruchu (*ang. Bridge Weigh-In-Motion*)
CTE	Współczynnik Rozszerzalności Cieplnej Konstrukcji (*ang. Coefficient of Thermal Expansion*)
FBG	Czujniki Światłowodowe Oparte na Technologii Siatki Bragga (*ang. Fiber Bragg Grating*)
GNSS	Systemy Nawigacji Satelitarnej (*ang. Global Navigation Satellite Systems*)
IoT	Internet Rzeczy (*ang. Internet of Things*)
MAE	Średni Błąd Bezwzględny (*ang. Mean Absolute Error*)
MAPE	Średni Bezwzględny Błąd Procentowy (*ang. Mean Absolute Percentage Error*)
MES	Metoda Elementów Skończonych
MPE	Średni Błąd Procentowy (*ang. Mean Percentage Error*)
ME	Średni Błąd (*ang. Mean Error*)
MSE	Średni Błąd Kwadratowy (*ang. Mean Squared Error*)
PCA	Analiza Głównych Składowych (*ang. Principal Component Analysis*)
PSO	Algorytm Optymalizacyjny Roju Cząstek (*ang. Particle Swarm Optimization*)
RMSE	Pierwiastek Średniego Błędu Kwadratowego (*ang. Root Mean Squared Error*)
RSM	Metoda Powierzchni Odpowiedzi (*ang. Response Surface Methodology*)
SBX	Symulowane Krzyżowanie Binarne (*ang. Simulated Binary Crossover*)
SGD	Stochastyczny Spadek Wzdłuż Gradientu (*ang. Stochastic Gradient Descent*)
SHM	Monitoring Strukturalny Konstrukcji (*ang. Structural Health Monitoring*)
SMF	Jednomodowe Włókno Światłowodowe (*ang. Single Mode Fiber*)
TCS	Współczynnik Czułości Temperaturowej Czujnika Odkształceń (*ang. Temperature Cross Sensitivity*)
WIM	Ważenie Pojazdów w Ruchu (*ang. Weigh-In-Motion*)
WPD	Współczynnik Przewyższenia Dynamicznego

1 | Wprowadzenie

1.1 Koncepcja modeli cyfrowych bliźniaków

Rozwój przemysłu wiąże się nierozerwalnie z cyfryzacją i automatyzacją procesów. Tworzenie coraz bardziej zaawansowanych systemów wspomaga podejmowanie decyzji oraz przekłada się na zwiększenie produktywności, minimalizując przy tym ryzyko popełnienia błędów [58]. Jednym z najbardziej zaawansowanych systemów jest koncepcja cyfrowego bliźniaka (*ang. Digital Twin*), rozwijana obecnie w wielu dyscyplinach, między innymi robotyce, energetyce, medycynie czy przemyśle lotniczym. Jednak pomimo wspólnych założeń, mających na celu cyfrowe odwzorowanie rzeczywistego obiektu, dokładny opis cyfrowego bliźniaka często pozostaje odmienny. W literaturze nie funkcjonuje bowiem jedna powszechnie akceptowana definicja, lecz poszczególne badania akcentują odmienne aspekty procesu jego tworzenia. Wang i in. [130] opracowali automatyczny system kontroli danych chodu w cyfrowych bliźniakach egzoszkieletów kończyn dolnych. Autorzy zwrócili przy tym uwagę, że wiele obecnych rozwiązań w obszarze rehabilitacji medycznej nie gwarantuje prawidłowej interakcji informacyjnej pomiędzy pacjentami, a urządzeniami. Również Conde i in. [26] podkreślili istotę informacyjną oraz zarządzania danymi w modelach wirtualnych. Stworzyli oni cyfrowego bliźniaka lotniska, który wykorzystując rzeczywiste informacje o lotach pomagał operatorom naziemnym w planowaniu odlotów i przylotów. Z kolei Prakash i in. [105] w swojej implementacji cyfrowego bliźniaka skupili się na warstwie wizualizacyjnej. Opracowali oni narzędzie, które wykorzystując rozszerzoną i wirtualną rzeczywistość umożliwiało interakcję oraz zdalną współpracę użytkownika z modelem cyfrowym. Dostępne w literaturze badania potwierdzają zatem, że współczesne implementacje cyfrowych bliźniaków mogą koncentrować się na różnych aspektach. Autorzy badań często opisują je w odmienny sposób, skupiając się na zarządzaniu informacją, wspomaganiu procesów decyzyjnych czy interakcji użytkowników z modelami wirtualnymi.

Intensywny rozwój koncepcji cyfrowych bliźniaków zauważalny jest również w inżynierii lądowej, w tym mostowej. Wiele obecnych rozwiązań jest jednak skoncentrowanych na wybranych komponentach, kładąc szczególny nacisk na modelowanie BIM (*ang. Building Information Modelling*). Tymczasem dostępne w literaturze badania przedstawiają ewolucję definicji cyfrowych bliźniaków. Przechodzą one stopniowo z samego modelowania do bardziej praktycznych systemów integrujących dane i gwarantujących synchronizację z rzeczywistym obiektem. Zwracają przy tym szczególną uwagę na możliwość ciągłej aktualizacji modeli cyfrowych oraz znaczenie wymiany informacji pomiędzy rzeczywistym obiek-

tem, a jego wirtualnym odpowiednikiem. Rozszerzają zatem koncepcję cyfrowych bliźniaków do relacji dwukierunkowych, które wymagają dodatkowo analizy i przetwarzania gromadzonych danych. Przykładowe badania przedstawili Gao i in. [39], którzy opracowali architekturę cyfrowego bliźniaka bazującą na Internecie Rzeczy IoT (*ang. Internet of Things*). Autorzy zwrócili przy tym szczególną uwagę na zagadnienie synchronizacji danych pomiędzy rzeczywistym obiektem mostowym, a systemami pomiarowymi i jego cyfrowym odpowiednikiem. Interesujące podejście przedstawili również Ritto i in. [113], którzy opisali model klasyfikacyjny uczenia maszynowego pełniący rolę cyfrowego bliźniaka. Wytrenowany na danych syntetycznych, został następnie wykorzystany w procesie detekcji uszkodzeń. Autorzy podkreślili przy tym, że istotą cyfrowych bliźniaków nie są modele same w sobie, ale dopiero integracja danych pomiarowych, modeli obliczeniowych oraz algorytmów wspomagających podejmowanie decyzji.

W wielu współczesnych definicjach proces tworzenia cyfrowego bliźniaka opiera się przede wszystkim na sprzężeniu modelu wirtualnego z rzeczywistym obiektem oraz jego aktualnym stanem. Kładzie przy tym nacisk głównie na informacje oraz możliwość przeprowadzania w czasie rzeczywistym analiz i symulacji. W przypadku obiektów mostowych podstawowym źródłem informacji może być system monitoringu SHM (*ang. Structural Health Monitoring*), umożliwiający ciągłą rejestrację odpowiedzi konstrukcji na oddziaływania środowiskowe i eksploatacyjne. Jednak proces tworzenia cyfrowego bliźniaka może także wymagać zbierania danych już na etapie budowy, wykorzystując nieniszczące metody pomiarowe [82]. Dane te mogą zostać wykorzystane do identyfikacji modeli numerycznych oraz budowy narzędzi wspomagających ocenę stanu technicznego obiektu. Obecne badania z powodzeniem przedstawiają wdrożenie koncepcji cyfrowych bliźniaków do wielu celów, w tym do detekcji uszkodzeń, wspomagania procesu zarządzania infrastrukturą czy identyfikacji obciążeń. Teng i in. [124] przedstawili koncepcję cyfrowego bliźniaka wykorzystywanego do detekcji uszkodzeń konstrukcji. Autorzy wykorzystali w tym celu splotowe sieci neuronowe oraz dane treningowe wygenerowane za pomocą modeli numerycznych. Zaprezentowane rozwiązanie wdrożyli następnie na rzeczywistej konstrukcji mostowej przy użyciu uczenia transferowego. Z kolei Jiang i in. [60] przedstawili podejście do prognozowania trwałości zmęczeniowej mostów stalowych. Opracowali w tym celu model cyfrowego bliźniaka, integrujący w jednym systemie dane pochodzące z monitoringu oraz modele wieloskalowe i numeryczne.

W niniejszej pracy cyfrowy bliźniak nie jest zatem utożsamiany z pojedynczym modelem, ale pełni bardziej funkcjonalną rolę (Rysunek 1.1). Zapewnia przy tym dwukierunkową relację pomiędzy rzeczywistą konstrukcją, a jej cyfrowym odpowiednikiem. Podstawę tej relacji stanowi system monitoringu, rejestrujący odkształcenia w charakterystycznych elementach konstrukcyjnych. Istotnym etapem procesu tworzenia cyfrowego bliźniaka była natomiast kalibracja systemu pomiarowego, przeprowadzona

podczas badań pod próbnym obciążeniem. Próby statyczne zostały wykorzystane w procesie identyfikacji modelu MES, natomiast dynamiczne umożliwiły późniejszą walidację opracowanego rozwiązania.

Cyfrową reprezentację konstrukcji tworzy natomiast nie tylko model MES, ale również metody przetwarzania danych oraz algorytmy odpowiedzialne za identyfikację obciążeń eksploatacyjnych. Zidentyfikowany model numeryczny został wykorzystany do wygenerowania reprezentatywnego zbioru danych, obejmującego różne scenariusze obciążenia. Na jego podstawie opracowane zostały modele regresyjne, bazujące na metodach uczenia maszynowego, których zadaniem jest szacowanie masy całkowitej pojazdów na podstawie zarejestrowanych odkształceń. Przedstawiony system funkcjonuje w trybie ciągłym, dostarczając na bieżąco informacji o rzeczywistych obciążeniach eksploatacyjnych.

Istotą przedstawionego podejścia jest ciągły przepływ informacji pomiędzy rzeczywistym obiektem mostowym, a jego cyfrowym odpowiednikiem. W przedstawionym rozwiązaniu cyfrowy bliźniak stanowi zatem zintegrowany system, łączący dane pomiarowe, modele numeryczne oraz algorytmy umożliwiające odwzorowanie zachowania konstrukcji i identyfikację działających na nią obciążeń.

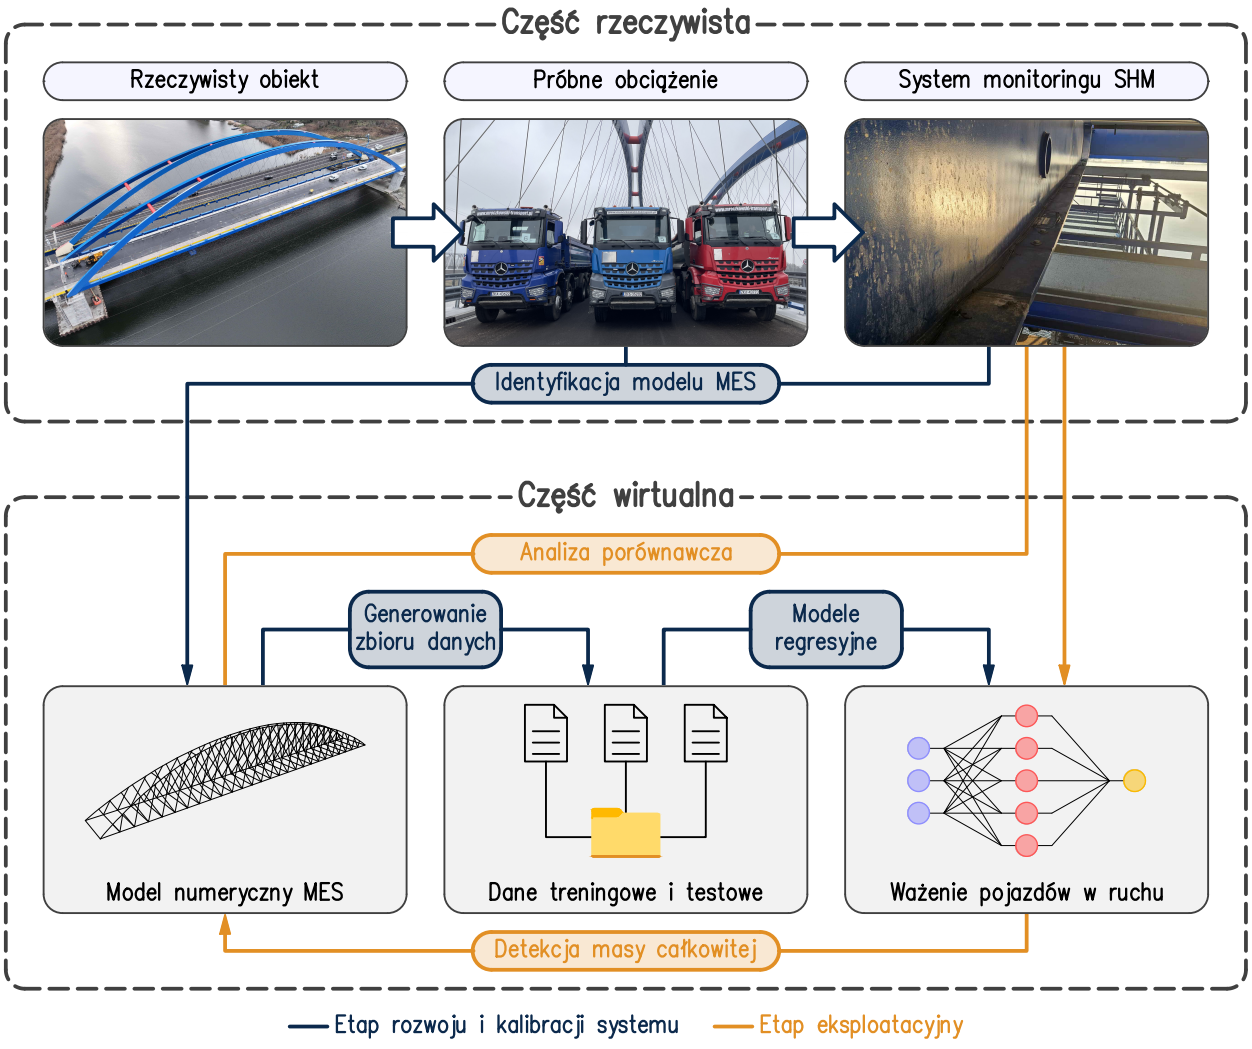

Rysunek 1.1. Koncepcja cyfrowego bliźniaka bazującego na relacji pomiędzy obiektem rzeczywistym i wirtualnym

1.2 Cele pracy

Główny cel pracy stanowi zbadanie możliwości budowy cyfrowego bliźniaka obiektu mostowego, umożliwiającego rekonstrukcję rzeczywistych obciążeń eksploatacyjnych. Przeprowadzony przegląd literatury wykazał, że prowadzone obecnie badania sprowadzają koncepcję cyfrowych bliźniaków do dwukierunkowej relacji pomiędzy obiektem rzeczywistym, a wirtualnym, skupiając się głównie na warstwie informacyjnej. Na podstawie przeprowadzonych analiz sformułowano następującą tezę:

Zastosowanie zwalidowanej metodyki budowy cyfrowego bliźniaka integrującej dane pomiarowe, modele numeryczne i algorytmy uczenia maszynowego umożliwia identyfikację rzeczywistych obciążeń eksploatacyjnych na podstawie danych rejestrowanych przez system monitoringu

Realizacja głównego celu pracy możliwa jest poprzez realizację celów szczegółowych, które opisują kolejne kroki procesu budowy cyfrowego bliźniaka.

Cel szczegółowy nr 1

Zbadanie możliwości wykorzystania odpowiedzi konstrukcji do identyfikacji lokalizacji punktów pomiarowych, zapewniających maksymalną ilość informacji przy jednoczesnej minimalizacji liczby czujników. Na podstawie przeprowadzonych analiz statycznych zostaną określone poziomy wrażliwości poszczególnych elementów konstrukcyjnych na wpływ obciążeń eksploatacyjnych.

Cel szczegółowy nr 2

Przeprowadzenie badań eksperymentalnych, podczas których zostaną zarejestrowane rzeczywiste dane z systemu pomiarowego. W ramach realizacji celu przeanalizowane będą różne scenariusze obciążeń, pozwalające zdefiniować zależności pomiędzy parametrami ruchu, a odpowiedzią konstrukcji.

Cel szczegółowy nr 3

Ocena możliwości wykorzystania zidentyfikowanego modelu MES jako podstawy cyfrowego odwzorowania rzeczywistego obiektu. Przeprowadzona zostanie analiza wykorzystania skalibrowanych parametrów materiałowych do otrzymywania rzeczywistej odpowiedzi konstrukcji w modelu numerycznym.

Cel szczegółowy nr 4

Zbadanie możliwości wykorzystania algorytmów uczenia maszynowego do identyfikacji obciążeń eksploatacyjnych na podstawie danych wygenerowanych z modelu MES cyfrowego bliźniaka. Oceniona będzie reprezentatywność syntetycznego zbioru treningowego oraz skuteczność wdrożonego rozwiązania w warunkach rzeczywistego ruchu.

1.3 Zakres rozprawy

Zakres niniejszej pracy obejmuje przedstawienie koncepcji cyfrowego bliźniaka mostu bazującego na warstwie informacyjnej. Łączy w tym celu dane rejestrowane przez system SHM, modele numeryczne MES oraz algorytmy uczenia maszynowego służące do identyfikacji obciążeń eksploatacyjnych. Przedstawione podejście zweryfikowano na przykładzie mostu łukowego M-7L, zlokalizowanego w Wolinie.

W Rozdziale 2 opisano analizowaną konstrukcję oraz wdrożony system monitoringu. Przedstawiono charakterystykę wykorzystanych urządzeń pomiarowych oraz założenia przyjęte do budowy modelu numerycznego. Opisano również przeprowadzoną analizę statyczną oraz wygenerowane teoretyczne postacie linii wpływu charakterystycznych elementów konstrukcyjnych. Na ich podstawie wyznaczono lokalizację punktów pomiarowych, dzieląc cały obiekt na trzy niezależne bramki pomiarowe.

Rozdział 3 poświęcono badaniom pod próbnym obciążeniem statycznym oraz dynamicznym. Opisano w nim zastosowane środki obciążające, przebieg badań, przyjęte schematy oraz analizę uzyskanych wyników. Zrealizowane badania odniesiono także do przeprowadzonej wcześniej analizy statycznej, weryfikując doświadczalnie teoretyczne postacie linii wpływu poprzecznic, podłużnic oraz wieszaków.

W Rozdziale 4 omówiono proces identyfikacji modelu MES, bazujący na wynikach próbnych obciążeń statycznych. Obejmował on wykorzystanie algorytmu genetycznego oraz modelu zastępczego sieci neuronowej, minimalizując tym samym koszt obliczeniowy procesu optymalizacji. Przedstawione podejście obejmowało kalibrację parametrów materiałowych, dążąc do uzyskania zgodności odkształceń rejestrowanych przez system SHM i wyznaczonych numerycznie w modelu MES. Finalnie uzyskany model posłużył do wygenerowania zbioru danych syntetycznych, wykorzystywanych w dalszych analizach.

Rozdział 5 opisuje sposób wdrożenia i walidację algorytmu ważenia pojazdów w ruchu. W pierwszej kolejności przedstawiono procedurę przetwarzania sygnałów, obejmującą wykorzystanie filtru Butterwortha. Następnie opisano proces doboru architektury modelu sieci neuronowych, wykorzystujący algorytm optymalizacyjny roju cząstek. Końcową część rozdziału stanowi natomiast analiza uzyskanych wyników. Skuteczność opracowanego rozwiązania oceniono dla różnych scenariuszy ruchu, obejmujących pojedyncze pojazdy oraz przejazdy grupowe i losowe. Ponadto opisano analizę wpływu prędkości oraz dodatkowych wzbudzeń dynamicznych na uzyskiwane wyniki predykcji masy całkowitej pojazdów.

Pracę zamyka Rozdział 6, zawierający podsumowanie badań oraz najważniejsze wnioski.

2 | System monitoringu SHM mostu M-7L w Wolinie

Cele rozdziału

W poniższym rozdziale przedstawiony został system monitoringu konstrukcji wdrożony na moście łukowym w Wolinie. Obejmuje on analizę odkształceń elementów stalowych w trzech poprzecznicach, sześciu wieszakach oraz obu ściągach, realizowaną z wykorzystaniem optycznych czujników światłowodowych w technologii siatki Bragga. Lokalizacja czujników została określona na podstawie przeprowadzonej analizy statycznej z wykorzystaniem modelu numerycznego oraz linii wpływu charakterystycznych elementów konstrukcyjnych. W rozdziale przedstawiono również dokładną charakterystykę stosowanych urządzeń pomiarowych, metody ich instalacji oraz gromadzenia danych wraz z określeniem niepewności pomiarowych. Zintegrowany system monitoringu wraz z modelem numerycznym stanowi źródło danych wykorzystywanych w dalszych analizach.

2.1 Wstęp

Systemy monitoringu konstrukcji SHM (*ang. Structural Health Monitoring*) stanowią obecnie istotny obszar badań, łącząc w sobie elementy inżynierii, nauk ścisłych i technologii informatycznych. Ich nadrzędnym celem jest gromadzenie kompleksowych danych na temat stanu zachowania konstrukcji, poprzez zastosowanie różnorodnych algorytmów i metod pomiarowych. Dzięki temu możliwa staje się ciągła lub okresowa ocena stanu technicznego, umożliwiająca wczesną identyfikację ewentualnych zmian lub awarii. Początkowo systemy SHM stosowane były głównie w warunkach laboratoryjnych, jednak obecnie dzięki rozwojowi technologii czujników i metod przetwarzania danych znajdują coraz szersze zastosowanie w rzeczywistych obiektach inżynierskich. Prezentowane w literaturze badania wskazują na szerokie spektrum zastosowań systemów monitorowania konstrukcji, instalowanych w wielu typach obiektów, takich jak budynki wysokościowe, stadiony czy budowle hydrotechniczne. W dobie coraz bardziej ambitnych i zaawansowanych projektów, obejmujących konstrukcje o znacznie większych wysokościach czy rozpiętościach, systemy monitorowania nabierają szczególnego znaczenia.

Skuteczne wdrożenie SHM przedstawili Li i in. [72], opisując przykład 600-metrowego budynku wysokościowego. System zapewniał możliwość monitorowania konstrukcji zarówno na etapie budowy jak i eksploatacji, umożliwiając analizę statycznych i dynamicznych reakcji konstrukcji, a także wzbudzeń

zewnętrznych, uwzględniając oddziaływania wiatru oraz trzęsień ziemi. Cigada i in. [24] zaproponowali i wdrożyli projekt systemu monitoringu stadionu Giuseppe Meazza w Mediolanie. Pomimo że zastosowany układ czujników był stosunkowo ubogi, to dzięki zastosowaniu odpowiednich technik przetwarzania danych autorzy uzyskali istotne informacje o stanie konstrukcji. Pozwoliło to na ocenę poziomu drgań i określenie szczytowych wartości przyspieszeń. Z kolei Li i in. [70] wdrożyli system monitoringu SHM dla dużej konstrukcji hydrotechnicznej, łączący metodę elementów skończonych i analizę danych z wielu czujników. W czasie rzeczywistym monitorowane były wartości naprężeń oraz parametrów dynamicznych konstrukcji. Podobna tendencja rozwoju systemów SHM zauważalna jest również w inżynierii mostowej, przechodząc stopniowo z fazy eksperymentalnej do powszechnej praktyki. Przekłada się to na intensywny rozwój badań oraz adaptację nowych metod pomiarowych i algorytmów analizy danych.

Konstrukcje mostowe, ze względu na złożony charakter pracy oraz długotrwałą eksploatację, stanowią szczególnie istotny obszar zastosowania systemów SHM. Poddawane zmiennym obciążeniom eksploatacyjnym oraz oddziaływaniom środowiskowym są szczególnie podatne na zjawiska zmęczeniowe oraz degradację materiałową. W konsekwencji monitoring tych konstrukcji odgrywa kluczową rolę, skupiając obecne badania w głównej mierze na detekcji uszkodzeń, prognozowaniu trwałości konstrukcji czy analizie zmęczeniowej. Chen i in. [21] przedstawili w swoich badaniach przykład systemu SHM, zainstalowanego na stalowym moście kratownicowym. Autorzy w pierwszej kolejności zbadali widmo obciążenia ruchem oraz charakterystyki modalne mostu, następnie zidentyfikowali model numeryczny, finalnie przedstawiając podejście do analizy uszkodzeń zmęczeniowych konstrukcji. Ietka i in. [56] opisali natomiast system monitoringu mostu Arrábida, będącego przykładem żelbetowej konstrukcji łukowej. Analizując temperaturę mierzoną w płycie pomostowej, możliwe było oszacowanie ruchów urządzenia dylatacyjnego poprzez określenie korelacji między temperaturą, a przemieszczeniami. Na podstawie tych pomiarów autorzy określili także składową dynamiczną od obciążenia ruchem, co pozwalało na oszacowanie wartości zmiennych oddziaływań krótkotrwałych. Zhu i in. [154] przedstawili z kolei system monitoringu zainstalowany na moście wiszącym. Obejmował on analizę parametrów ruchu, warunków środowiskowych, przemieszczeń i odpowiedzi dynamicznej. Dodatkowo, autorzy określili zależność ugięć i odkształceń elementów głównych w zależności od temperatury.

Analiza dotychczasowych wdrożeń systemów SHM wskazuje na rosnące znaczenie ciągłego monitorowania kluczowych parametrów konstrukcji oraz konieczność właściwego doboru metod i technik pomiarowych. Wymaga to, aby już na etapie projektowania SHM uwzględnić specyfikę pracy konstrukcji oraz warunki jej eksploatacji. Pełne zrozumienie zasady działania monitoringu, jego możliwości aplikacyjnych oraz ograniczeń stanowi podstawę do projektowania skutecznego i wydajnego systemu.

2.2 Przegląd literatury

2.2.1 Techniki pomiarowe stosowane w SHM

Stosowane obecnie w inżynierii mostowej systemy monitoringu charakteryzują się złożoną strukturą pomiarową. Integrując w jednym systemie wiele typów czujników, umożliwiają rejestrowanie i analizę określonych parametrów konstrukcyjnych. Obecnie w systemach SHM bardzo powszechnie wykorzystywane są klasyczne czujniki, opierające się na pomiarze odkształceń, przemieszczeń czy parametrów dynamicznych. Dostępne w literaturze badania przedstawiają szerokie spektrum wykorzystania tensometrów, akcelerometrów czy czujników indukcyjnych, często zintegrowanych wspólnie w ramach jednego systemu pomiarowego. Przykładowe badania przedstawili Ghahremani i in. [40], którzy wdrożyli system monitoringu SHM mostu sprężonego. Bazując na odczytach odkształceń z układu przykręconych do konstrukcji tensometrów, autorzy byli w stanie identyfikować dokładny rozkład obciążeń na elementach głównych. Pirrò i in. [104] opisali natomiast wykorzystanie danych pochodzących z akcelerometrów w celu wykrywania i lokalizacji uszkodzeń obiektu łukowego. Do detekcji anomalii autorzy zaimplementowali rzadkie sieci autokoderów, trenowanych przy użyciu zebranych danych dynamicznych.

Grupę urządzeń pomiarowych, szeroko stosowanych w systemach monitorowania konstrukcji mostowych, stanowią także czujniki piezoelektryczne. Wykorzystywane są jako źródło danych między innymi do szacowania sił wewnętrznych czy detekcji uszkodzeń. Przykładowe badania obrazujące ich skuteczne wdrożenie przedstawili w swojej pracy Kaur i in. [63]. Monitorując wartość siły sprężającej, autorzy wykazali, że czujniki te umożliwiają skuteczny monitoring wstępnego naprężenia kabli w mostach sprężonych. Osiągnęli przy tym błąd na poziomie 14 % porównując wyniki pomiarów z klasycznymi tensometrami. Jiang i in. [61] przedstawili natomiast wykorzystanie czujników piezoceramicznych do monitorowania uszkodzeń zmęczeniowych mostowych urządzeń dylatacyjnych. Autorzy zastosowali metodę aktywnego pomiaru fal naprężeń, analizując zmiany propagacji sygnału w obszarze połączeń spawanych. Z kolei Liao i in. [74] opisując swoje badania rozszerzyli tą tematykę o problem trwałości samych czujników piezoelektrycznych. Opracowali nowy typ przetwornika przeznaczonego do pracy w warunkach wysokich odkształceń. Przeprowadzone badania potwierdziły potencjał wykorzystania czujników piezoelektrycznych w systemach SHM realizowanych w wymagających warunkach eksploatacyjnych.

Dostępne w literaturze badania opisują także coraz częstsze wykorzystanie systemów nawigacji satelitarnej GNSS (*ang. Global Navigation Satellite Systems*). Za ich pomocą możliwe jest szacowanie przemieszczenia konstrukcji mostowych, umożliwiając zarówno pomiary statyczne jak i dynamiczne. Metoda GNSS opiera się na precyzyjnym wyznaczeniu zmiany położenia odbiorników umieszczonych na badanym obiekcie i często jest także łączona z innymi, klasycznymi technikami pomiarowymi. Przykła-

dowe badania przedstawili Qu i in. [109], którzy opisali system jednoczesnego monitoringu przemieszczeń i obrotów mostu wantowego. Wykorzystali w tym celu zintegrowane dane z systemów nawigacji satelitarnej oraz akcelerometrów. An i in. [6] łącząc obserwacje GNSS z wielu anten, wdrożyli system monitoringu do szacowania przemieszczeń poziomych i pionowych przęsła mostu wiszącego. Na przykładzie analogicznej konstrukcji Peng i in. [101] identyfikowali przemieszczenia drgań oraz wielorzędowe parametry modalne. Zaproponowane przez autorów podejście opierało się na wykorzystaniu danych pochodzących z systemów GNSS oraz implementacji zaawansowanych metod przetwarzania sygnałów.

Kolejną innowacyjną techniką pomiarową stosowaną w systemach monitoringu obiektów mostowych są metody akustyczne. Rejestrując fale sprężyste, umożliwiają identyfikację zmian właściwości konstrukcji i lokalizację potencjalnych uszkodzeń. Przykładowe badania wykorzystujące metodę emisji akustycznych przedstawili Tonelli i in. [126], którzy wykorzystując dane uzyskane z badań pod próbnym obciążeniem dążyli do wykrywania i klasyfikowania uszkodzeń konstrukcji mostu sprężonego. Autorzy przeprowadzili przy tym analizę parametrów sygnału emisji akustycznej, obejmujących amplitudę, liczbę zdarzeń oraz częstotliwość sygnału. Również Wang i in. [133] przedstawili metodę detekcji uszkodzeń z wykorzystaniem rozproszonego pomiaru akustycznego. Autorzy analizowali przy tym żelbetowe płyty pomostowe, uwzględniając także wpływ prętów stalowych na propagację fal sprężystych.

W ostatnich latach obserwowany jest także znaczący postęp technologii widzenia komputerowego, co przekłada się również na inne dyscypliny naukowe w tym inżynierię lądową. Dostępne w literaturze badania coraz częściej skupiają się na wykorzystaniu tych metod w systemach SHM, obejmując wiele aspektów w tym wykrywanie uszkodzeń, detekcję obciążeń czy pomiar przemieszczeń. Kim i in. [65] przedstawili w swoich badaniach system długoterminowego monitoringu łożysk mostowych. Wykorzystując metody widzenia komputerowego autorzy szacowali wartości przemieszczenia przestrzennego. Z kolei Liu i in. [77] wykorzystując obrazy jako jedyne dane wejściowe oraz hierarchiczną segmentację semantyczną opracowali metodę wykrywania uszkodzeń konstrukcji mostowych. Opracowany model uczył się tylko z potencjalnie uszkodzonych obszarów zdjęć, unikając wpływu nieistotnych fragmentów.

Przedstawione przykłady potwierdzają szerokie spektrum technik pomiarowych stosowanych obecnie w systemach monitoringu. Każde z nich różni się zasadą działania, dokładnością pomiaru oraz zakresem możliwych zastosowań. Stąd też w praktyce inżynierskiej dobór odpowiedniej technologii pomiarowej uzależniony jest od charakteru monitorowanego obiektu, oczekiwanej precyzji pomiarów oraz warunków eksploatacyjnych. Wśród dostępnych rozwiązań szczególne znaczenie zyskują czujniki światłowodowe, które są coraz częściej wykorzystywane w systemach monitoringu obiektów mostowych.

2.2.2 Czujniki światłowodowe

Czujniki światłowodowe stanowią obecnie alternatywę dla tradycyjnych rozwiązań, zapewniając szereg zalet w systemach SHM. Dzięki wysokiej czułości wykrywają niewielkie zmiany mierzonych wielkości. Dodatkowo zapewniają możliwość pomiarów z wysoką rozdzielczością oraz dobrą odporność na korozję i zakłócenia elektromagnetyczne. W zależności od zastosowanej technologii umożliwiają realizację pomiarów w sposób ciągły (rozproszony) oraz punktowy (nierozproszony).

Wykorzystywane w praktyce inżynierskiej systemy rozproszonych czujników światłowodowych oparte są w większości na analizie zjawisk rozpraszania Ramana, Brillouina lub Rayleigha, a opisane w literaturze badania potwierdzają skuteczność ich stosowania w inżynierii lądowej. Yue i in. [143] opracowali w swoich badaniach układ czujników zdolny do monitorowania stanu betonu in situ. System oparty na spektroskopii Ramana został z powodzeniem wykorzystany do wykrywania mechanizmu karbonatyzacji zaczynu z cementu portlandzkiego. Minardo i in. [90] wykorzystali natomiast światłowodowe czujniki odkształceń bazujące na analizie rozpraszania Brillouina do długoterminowego monitorowania tunelu kolejowego. Przyklejone do jego ścian czujniki umożliwiły prowadzenie pomiarów z wysoką rozdzielczością przestrzenną, co pozwoliło na określenie wpływu osuwisk na konstrukcję obiektu. Zhu i in. [156] wykorzystali z kolei czujniki światłowodowe bazujące na zjawisku rozpraszania Rayleigha do pomiaru temperatury, odkształceń i przemieszczeń blach stalowych w warunkach laboratoryjnych.

Rozproszone czujniki światłowodowe są również z powodzeniem wykorzystywane w inżynierii mostowej, obejmując badaniami różne typy obiektów i warunki eksploatacji. Bertulessi i in. [16] przedstawili system monitoringu zainstalowany na żelbetowym moście łukowym, w którym wykorzystane zostały czujniki światłowodowe bazujące na analizie zjawiska rozpraszania Brillouina. Autorzy wykazali skuteczność tego rozwiązania w monitorowaniu złożonych konstrukcji, wymagających szczegółowej i ciągłej kontroli naprężeń. Cheng i in. [22] przedstawili natomiast w swojej pracy monitoring murowanego mostu łukowego, w którym wykorzystali rozproszone czujniki światłowodowe bazujące na zjawisku rozpraszania Rayleigha. Wdrożony system analizował odpowiedź dynamiczną konstrukcji pod wpływem obciążenia wywołanego ruchem kolejowym i był w stanie wykryć anomalie oraz uszkodzenia konstrukcji obiektu. Z kolei Richter i in. [112] wykorzystali w swojej pracy zjawisko rozpraszania Rayleigha do monitorowania sprężonej belki mostowej. Autorzy wyposażyli badany dźwigar w czujniki jeszcze przed betonowaniem, wykazując w trakcie prób obciążeniowych dobrą skuteczność w detekcji anomalii. Niezależnie jednak od przedstawionych zastosowań czujników rozproszonych, w systemach SHM rozwijane i stosowane są także inne technologie światłowodowe, bazujące na pomiarach punktowych.

Jednym z najczęściej stosowanych rozwiązań w grupie czujników nierozproszonych są czujniki świa-

tłowodowe oparte na technologii siatki Bragga FBG (*ang. Fiber Bragg Grating*). Za pomocą znajdującej się w niej siatki odbijają światło o określonej długości fali, umożliwiając pomiar w ściśle zdefiniowanych punktach konstrukcji. Liczne badania naukowe przedstawiają wdrożone systemy SHM, bazujące na czujnikach FBG, wykazując przy tym znaczące zalety tego rozwiązania. Przykładowe badania przedstawili Lu i in. [78] którzy wdrożyli system monitoringu dwóch mostów stalowych. Autorzy zastosowali czujniki FBG w celu pomiarów odkształceń dźwigarów, analizując przy tym różne lokalizacje punktów pomiarowych. Anastasopoulos i in. [7] monitorowali natomiast parametry dynamiczne kładki dla pieszych, za pomocą zainstalowanych na etapie budowy czujników światłowodowych FBG. Wyznaczone parametry modalne posłużyły do identyfikacji modelu numerycznego, za pomocą którego symulowano możliwe scenariusze uszkodzeń. Hu i in. [55] opisali natomiast wykorzystanie czujników FBG do analizy parametrów dynamicznych wieszaków mostu łukowego. Wyznaczona wartość częstotliwości drgań została następnie wykorzystana przez autorów do obliczenia siły naciągu wieszaka linowego.

Zalety czujników FBG oraz ich wysoka dokładność są często przedstawiane w badaniach porównawczych z innymi znanymi technikami pomiarowymi. Pashaie i in. [100] przedstawili przykładowe badania, w których przeprowadzili porównanie pomiaru naprężeń w kompozytach laminowanych. Oprócz czujników FBG autorzy wykorzystali także cyfrową korelację obrazu oraz tensometry, potwierdzając wysoką dokładność czujników bazujących na technologii siatki Bragga. Wang i in. [135] opisali natomiast konstrukcję i konfigurację tensometru FBG. Przeprowadzając symulacje numeryczne i testy laboratoryjne, wykazali dobrą dokładność tych czujników, stwierdzając równocześnie, że mogą one w przyszłości zastąpić tradycyjne techniki pomiarowe. Również Farhat i in. [36] przeprowadzili testy czujników światłowodowych FBG. Porównując pomiary z tradycyjnymi tensometrami, autorzy wskazali na wyższą niezawodność oraz możliwość adaptacji czujników FBG w monitorowaniu stanu konstrukcji.

Równie istotnym zagadnieniem instalacji systemu SHM bazującego na czujnikach FBG jest prawidłowy montaż urządzeń pomiarowych oraz ich zabezpieczenie przed działaniem czynników zewnętrznych. Instalacja czujników najczęściej odbywa się poprzez naklejanie lub zgrzewanie do powierzchni elementu, a w celu zwiększenia trwałości często wykorzystywane są również dodatkowe osłony ochronne. Dostępna literatura przedstawia także rozwiązania umożliwiające instalację czujników FBG w trudno dostępnych miejscach oraz ich wbudowywanie bezpośrednio w elementy konstrukcyjne. Przykładowe badania pokazujące montaż powierzchniowy czujników FBG przedstawili Goossens i in. [44]. Na przykładzie elementów kompozytowych autorzy analizowali wpływ sposobu montażu oraz warunków eksploatacyjnych na jakość uzyskiwanych pomiarów. Yang i in. [141], zaproponowali natomiast metodę hermetyzacji czujników FBG z wykorzystaniem metalowej kapilary ochronnej. Połączenie światłowodu z osłoną

realizowane było za pomocą lutowania ultradźwiękowego. Z kolei Jo i in. [62] zastosowali czujniki FBG wbudowane bezpośrednio w element betonowy. Autorzy instalowali je na elementach zbrojeniowych, monitorując ciepło hydratacji oraz odkształcenia powstające podczas dojrzewania betonu.

Przedstawione przykłady badań pokazują, że wdrożenie technologii światłowodowej w systemach SHM wymaga szeregu działań i decyzji inżynierskich. Jej zastosowanie nie ogranicza się tylko do wyboru odpowiedniego rodzaju czujnika, ale obejmuje również sposób montażu, zabezpieczenia i integracji urządzeń pomiarowych z całym systemem monitoringu. Istotnym etapem projektowania systemu jest także określenie lokalizacji punktów pomiarowych, gwarantujących uzyskanie miarodajnych pomiarów.

2.2.3 Analiza rozmieszczenia punktów pomiarowych

Montaż czujników w systemach SHM powinien zostać poprzedzony dokładną analizą, mającą na celu zdefiniowanie liczby oraz rozmieszczenia urządzeń pomiarowych. Przeprowadzana jest ona zazwyczaj z wykorzystaniem modeli numerycznych, symulując różne scenariusze obciążeń i konfiguracji systemu. Liczne badania koncentrują się przy tym na rodzaju stosowanych czujników oraz ich wydajności i czułości. Poruszają przy tym zagadnienia związane z redukcją zużycia energii, optymalną transmisją danych czy wpływem dodatkowego obciążenia na mierzone wielkości. Zadanie to najczęściej sprowadzane jest do problemu optymalizacyjnego, wykorzystując do jego rozwiązania szeroką gamę algorytmów.

Badania porównawcze różnych technik przedstawili Masciotta i in. [88], wykorzystując przykład wieloprzęsłowego mostu betonowego. Autorzy starali się dobrać lokalizację czujników w taki sposób, aby w pełni scharakteryzować dynamiczne zachowanie konstrukcji. Przetestowali w tym celu osiem algorytmów optymalizacyjnych, dążąc do maksymalizacji ilości pozyskanej informacji przy jednoczesnej redukcji liczby czujników. Zhang i in. [144] opracowali zmodyfikowany algorytm Meta-GA, który wdrożyli do określenia optymalnego rozmieszczenia czujników na przykładzie monitoringu kamiennego mostu łukowego. Autorzy uwzględniali przy tym czułość systemu pod kątem skutecznej detekcji uszkodzeń oraz poziom redundancji informacji pomiarowej. Inne podejście przedstawili Wei i in. [136], którzy opisali adaptacyjną strategię rozmieszczania czujników, bazującą na podejściu bayesowskim. Zaproponowali oni metodę dwuetapową, w której w pierwszym kroku dążyli do minimalizacji niepewności identyfikacji parametrów modalnych mostu, natomiast w drugim skupili się na zwiększeniu czułości projektowanego systemu. Z kolei Fanian i in. [35] przy optymalizacji rozmieszczenia czujników poruszyli także kwestie transmisji danych, uwzględniając ograniczenia energetyczne bezprzewodowych systemów SHM.

Pomimo rozwoju technologii informatycznych, wykorzystanie mechaniki budowli może być jedną z najskuteczniejszych metod, pozwalającą zredukować liczbę czujników i rozmieścić je w sposób najbardziej odpowiadający schematowi pracy konstrukcji. W tym celu mogą zostać wykorzystane linie

wpływu charakterystycznych elementów, umożliwiające identyfikację przekrojów najbardziej wrażliwych na oddziaływania eksploatacyjne. Takie podejście pozwala nie tylko na określenie lokalizacji punktów pomiarowych, ale także na ocenę wpływu obciążenia na każdy z nich, w tym możliwość separacji kolejnych pomiarów. Pomimo tego, że wykorzystanie linii wpływu może znacząco zredukować liczbę instalowanych urządzeń pomiarowych, zagadnienie to jest słabo rozwinięte w systemach SHM, a głównie stosowane jest w diagnostyce czy detekcji uszkodzeń. Ferguson i in. [37] przedstawili przykładowe badania, w których zaproponowali wdrożenie znormalizowanych linii wpływu w diagnostyce obiektów mostowych. Wykazali przy tym zdolność proponowanego podejścia do wykrywania zmian sztywności i uszkodzeń przy ograniczonej liczbie czujników. Z kolei Cai i in. [20] analizowali linie wpływu różnych wielkości fizycznych do detekcji uszkodzeń konstrukcji belkowych. Pomimo dynamicznego rozwoju algorytmów optymalizacyjnych, autorzy wykazali, że wykorzystanie mechaniki budowli może stanowić skuteczne narzędzie w analizie konstrukcji. Podejście to można z powodzeniem zaimplementować na etapie projektowania systemów SHM, co stanowiłoby nowy wkład do obecnie prowadzonych badań.

2.2.4 Metody przetwarzania danych w systemach SHM

Wraz z rozwojem systemów SHM coraz większe znaczenie zyskują metody przetwarzania i analizy danych pomiarowych. Wynika to przede wszystkim z konieczności integracji pomiarów pochodzących z wielu czujników oraz potrzeby ich automatycznej interpretacji. Liczne badania przedstawiają wykorzystanie w tym celu modeli uczenia maszynowego, skupiając się głównie na implementacji sztucznych sieci neuronowych. Przykładowe badania przedstawili Pan i in. [98], którzy wykorzystali sieci splotowe do wykrywania anomalii w danych pomiarowych. Proponowaną metodę zwalidowali dla dwóch rzeczywistych mostów dużej rozpiętości, analizując dane przyspieszeń, odkształceń, przemieszczeń oraz parametrów środowiskowych. Nguyen-Ngoc i in. [94] opisali natomiast wdrożenie głębokich sieci neuronowych oraz algorytmu optymalizacyjnego do oceny stanu mostu kratownicowego. Zaproponowane podejście zwalidowali dla różnych scenariuszy degradacji konstrukcji, wykorzystując zarejestrowane parametry modalne. Również Hoda i in. [53] przeprowadzili badania detekcji uszkodzeń mostu kratownicowego, jednak wykorzystali w tym celu modele uczenia nienadzorowanego. Podczas badań pod próbnym obciążeniem rejestrowali odkształcenia, które następnie poddali analizie głównych składowych.

Istotnym kierunkiem rozwoju systemów monitoringu SHM pozostają również technologie IoT (*ang. Internet of Things*) wykorzystywane do integracji rozbudowanych sieci pomiarowych oraz automatyzacji gromadzenia i przetwarzania danych. Ich skuteczne wdrożenie przedstawili Al-Ali i in. [4], którzy opisali w swoich badaniach przykład systemu monitorowania i ostrzegania o stanie konstrukcji mostów. W zaproponowanym podejściu integrowane były pomiary ugięć, drgań oraz parametrów środowiskowych.

Wang i in. [131] opracowali natomiast bezprzewodowy system SHM, w którym zintegrowali technologię IoT z siecią 5G oraz przetwarzaniem brzegowym (*ang. Edge Computing*). Opisana metoda wykorzystywała również modele sztucznej inteligencji, mające na celu automatyczną detekcję anomalii w danych pomiarowych. Z kolei Hou i in. [54] wykorzystując czujniki bazujące na IoT opracowali bezprzewodowy system monitorowania przemieszczeń. Zaproponowane przez autorów podejście zostało następnie zwalidowane zarówno podczas badań laboratoryjnych jak i na rzeczywistym obiekcie mostowym.

Oprócz metod bazujących na sztucznej inteligencji czy technologiach IoT istotne znaczenie w systemach SHM mają również klasyczne metody analizy sygnałów pomiarowych. W literaturze opisywane są badania wdrażające operacyjną analizę modalną, transformacje w dziedzinie czasu i częstotliwości czy analizy widmowe sygnałów. Mogą być one z powodzeniem wykorzystywane do filtracji szumu pomiarowego, identyfikacji parametrów modalnych czy ekstrakcji cech wykorzystywanych następnie w procesach detekcji uszkodzeń. Przykładowe badania przedstawili Desjardins i in. [31], którzy wdrożyli operacyjną analizę modalną do identyfikacji częstotliwości i postaci drgań własnych mostu wieloprzęsłowego. Zarejestrowane dane wykorzystali następnie w procesach detekcji potencjalnych uszkodzeń. Deng i in. [30] zaproponowali natomiast ocenę jakości danych pomiarowych, bazującą na analizie częstotliwościowej sygnałów. Autorzy wykorzystali w tym celu szybką transformację Fouriera oraz splotowe sieci neuronowe. Identyfikując anomalie w danych dynamicznych mostu podwieszonego, zwracali szczególną uwagę na przypadki, w których sygnały pomimo poprawnego przebiegu w dziedzinie czasu zawierały nieprawidłowości widoczne w analizie widmowej. Z kolei Pan i in. [97] przedstawili podejście bazujące na analizie czasowo-częstotliwościowej do ekstrakcji cech i klasyfikacji stanów uszkodzenia konstrukcji mostu wantowego. Porównali przy tym trzy metody obejmujące transformację falkową, Hilberta-Huanga oraz Teagera-Huanga, oceniając ich skuteczność w analizie danych dynamicznych.

Systemy monitoringu SHM coraz częściej stanowią także podstawę budowy cyfrowych bliźniaków. Liczne badania koncentrują się przy tym na warstwie informacyjnej, traktując ją jako wiodący element cyfrowego modelu. Koncepcja ta obejmuje zatem integrację pomiarów, symulacji numerycznych oraz zaawansowanych algorytmów przetwarzania i analizy danych. Cały system umożliwia następnie predykcję zachowania się konstrukcji oraz detekcję potencjalnych anomalii. Przykładową koncepcję cyfrowego bliźniaka opartą na systemie SHM przedstawili Zhao i in. [149]. Opisane podejście obejmowało integrację danych pomiarowych z modelami uczenia maszynowego, umożliwiając przeprowadzanie symulacji w czasie rzeczywistym. Autorzy zwrócili przy tym szczególną uwagę na możliwość przeprowadzania bieżących analiz, traktując cyfrowego bliźniaka przede wszystkim jako warstwę informacyjną. Takie podejście obejmowało integrację rejestrowanych pomiarów z modelami numerycznymi oraz algorytmami

przetwarzania danych. Połączenie koncepcji cyfrowego bliźniaka z technologią IoT przedstawili natomiast Armijo i in. [9]. Na przykładzie mostu kolejowego autorzy analizowali dynamiczne zachowanie konstrukcji, prowadząc dwuletnie pomiary w ramach systemu SHM. Na podstawie zarejestrowanych danych opracowali zbiór treningowy na potrzeby algorytmów uczenia maszynowego, które następnie wykorzystali w procesach detekcji anomalii. Autorzy przedstawili w swojej pracy koncepcję cyfrowego bliźniaka, na którą składał się cały system pomiarowy wraz z modelami przetwarzania i analizy danych.

2.2.5 Podsumowanie

Systemy monitoringu SHM stanowią intensywnie rozwijany obszar badań, obejmując szerokie spektrum stosowanych technik oraz urządzeń pomiarowych. Dostępne badania coraz częściej koncentrują się na zwiększeniu dokładności pomiarów, integracji wielu czujników czy wykorzystaniu zaawansowanych metod przetwarzania i analizy danych. Szczególnie istotny rozwój obserwowany jest w zakresie technologii światłowodowych, które znajdują coraz szersze zastosowanie w inżynierii mostowej.

Jednocześnie wiele badań podkreśla, że przejście od rozwiązań teoretycznych do praktycznych i skutecznych wdrożeń wciąż pozostaje znaczącym wyzwaniem. Dotyczy to w szczególności złożonych obiektów mostowych, które wymagają zaawansowanych technik pomiarowych, analiz numerycznych oraz metod przetwarzania danych. W swoich badaniach zwrócili na to uwagę Aktan i in. [2], podkreślając trudności związane ze skuteczną implementacją systemów monitoringu. Autorzy wymienili przy tym problemy obejmujące wysokie koszty wdrożenia, rosnące wyzwania związane z technologią i interpretacją danych czy zapewnienie odpowiedniej wydajności systemu. Podobne wnioski przedstawili również Xie i in. [138], skupiając się na mostach dużej rozpiętości. Zwrócili przy tym uwagę na problemy związane z integracją rozbudowanej sieci czujników oraz przetwarzaniem i analizą danych pomiarowych. Autorzy poruszyli również tematykę cyfrowych bliźniaków, które w połączeniu z modelami uczenia maszynowego wskazali jako istotny element nowoczesnych systemów SHM. Podkreślili przy tym szczególne znaczenie warstwy informacyjnej, dzięki której możliwe jest przeprowadzanie dalszych analiz i symulacji.

W praktyce skuteczna implementacja systemów monitoringu SHM zależy od wielu czynników, obejmujących zarówno zastosowane techniki pomiarowe i algorytmy przetwarzania danych, jak również odpowiedni dobór urządzeń pomiarowych. Konieczne jest przy tym uwzględnienie charakteru pracy badanej konstrukcji oraz zdefiniowanie celu instalowanego systemu. Istotnym zagadnieniem pozostaje również lokalizacja czujników, która powinna uwzględniać miejsca newralgiczne, w których spodziewane są największe wartości mierzonych wielkości. Jednak pomimo szerokiego rozwoju technik pomiarowych i metod przetwarzania danych skuteczna implementacja systemów SHM w złożonych konstrukcjach mostowych nadal stanowi istotne wyzwanie badawcze i wdrożeniowe.

2.3 Opis przypadku

2.3.1 Charakterystyka badanego obiektu

Przedstawione w niniejszej pracy badania przeprowadzono na obiekcie mostowym M-7L zlokalizowanym w Wolinie, w ciągu drogi ekspresowej S3. Jest to jednoprzęsłowa konstrukcja łukowa z jazdą dołem i żelbetowym pomostem zespolonym z poprzecznicami. Główny element konstrukcyjny mostu stanowią dwa stalowe łuki o rozpiętości 165 m i wysokości 24,04 m, wykonane w postaci zamkniętych przekrojów skrzynkowych o wymiarach 1,00 m $\times$ 1,80 m. Nachylone do wewnątrz obiektu na odległość 6,975 m, połączone są okrągłymi stężeniami o średnicy zewnętrznej 1,22 m i grubości ścianki 14,20 mm. Całkowita długość mostu wynosi 167,90 m, natomiast szerokość 16,90 m. Do łuków, za pomocą wieszaków linowych ułożonych w układzie siatkowym, podwieszony został pomost w postaci stalowego rusztu. Jego konstrukcja składa się z dwóch podłużnic w rozstawie osiowym 16,15 m, połączonych co 6,00 m poprzecznicami pośrednimi oraz poprzecznicami skrajnymi, zlokalizowanymi w odległości 7,50 m od pierwszej poprzecznicy pośredniej. Podłużnice wykonane są o przekroju prostokątnym zamkniętym o szerokości 0,75 m i wysokości 1,30 m. Przekrój poprzecznic pośrednich stanowi dwuteownik o szerokości 0,45 m i zmiennej wysokości 0,915 – 1,207 m, przechodzący przy połączeniu z podłużnicą w przekrój skrzynkowy o szerokości 0,45 m i zmiennej wysokości 0,880 – 1,160 m. Poprzecznice podporowe mają natomiast zamknięty przekrój prostokątny o szerokości 2,575 m i zmiennej wysokości 0,875 – 1,210 m. Ruszt stalowy połączony jest z żelbetową płytą pomostową, na którą składają się płyty prefabrykowane o grubości 14 cm, zespolone z częścią monolityczną o tej samej grubości. W konstrukcji stalowej zastosowano stal klasy S460N, natomiast płyta pomostowa wykonana została z betonu klasy C50/60 dla elementów prefabrykowanych oraz C40/50 dla części monolitycznej. Metrykę obiektu przedstawiono w Tabeli 2.1.

Tabela 2.1. Metryka obiektu

Metryka obiektu	
Rodzaj konstrukcji:	łukowa z jazdą dołem, pomost żelbetowy zespolony z poprzecznicami
Rozpiętość teoretyczna:	165,00 m
Długość całkowita:	167,90 m
Wysokość łuku:	24,04 m
Szerokość całkowita:	16,90 m
Rozstaw podłużnic:	16,15 m
Rozstawy poprzecznic:	7,50 m + 25 $\times$ 6,00 m + 7,50 m
Materiał ustroju nośnego:	stal konstrukcyjna S460N; beton płyty monolitycznej: C40/50; beton płyt prefabrykowanych: C50/60

Jako podwieszenie wykorzystany został system cięgien linowych REDAELLI FLC44 [ST12]. Są to liny o przekroju zamkniętym, składającym się z rdzenia o konstrukcji spiralnej oraz drutów profilowanych tworzących szczelny oplot zewnętrzny. Średnica nominalna wieszaków wynosi 44 mm, natomiast pole przekroju poprzecznego 1303 mm^2. Na Rysunku 2.1 przedstawiono schemat obiektu w tym przekrój poprzeczny, podłużny, rzut oraz zastosowane przekroje poprzeczne elementów konstrukcyjnych.

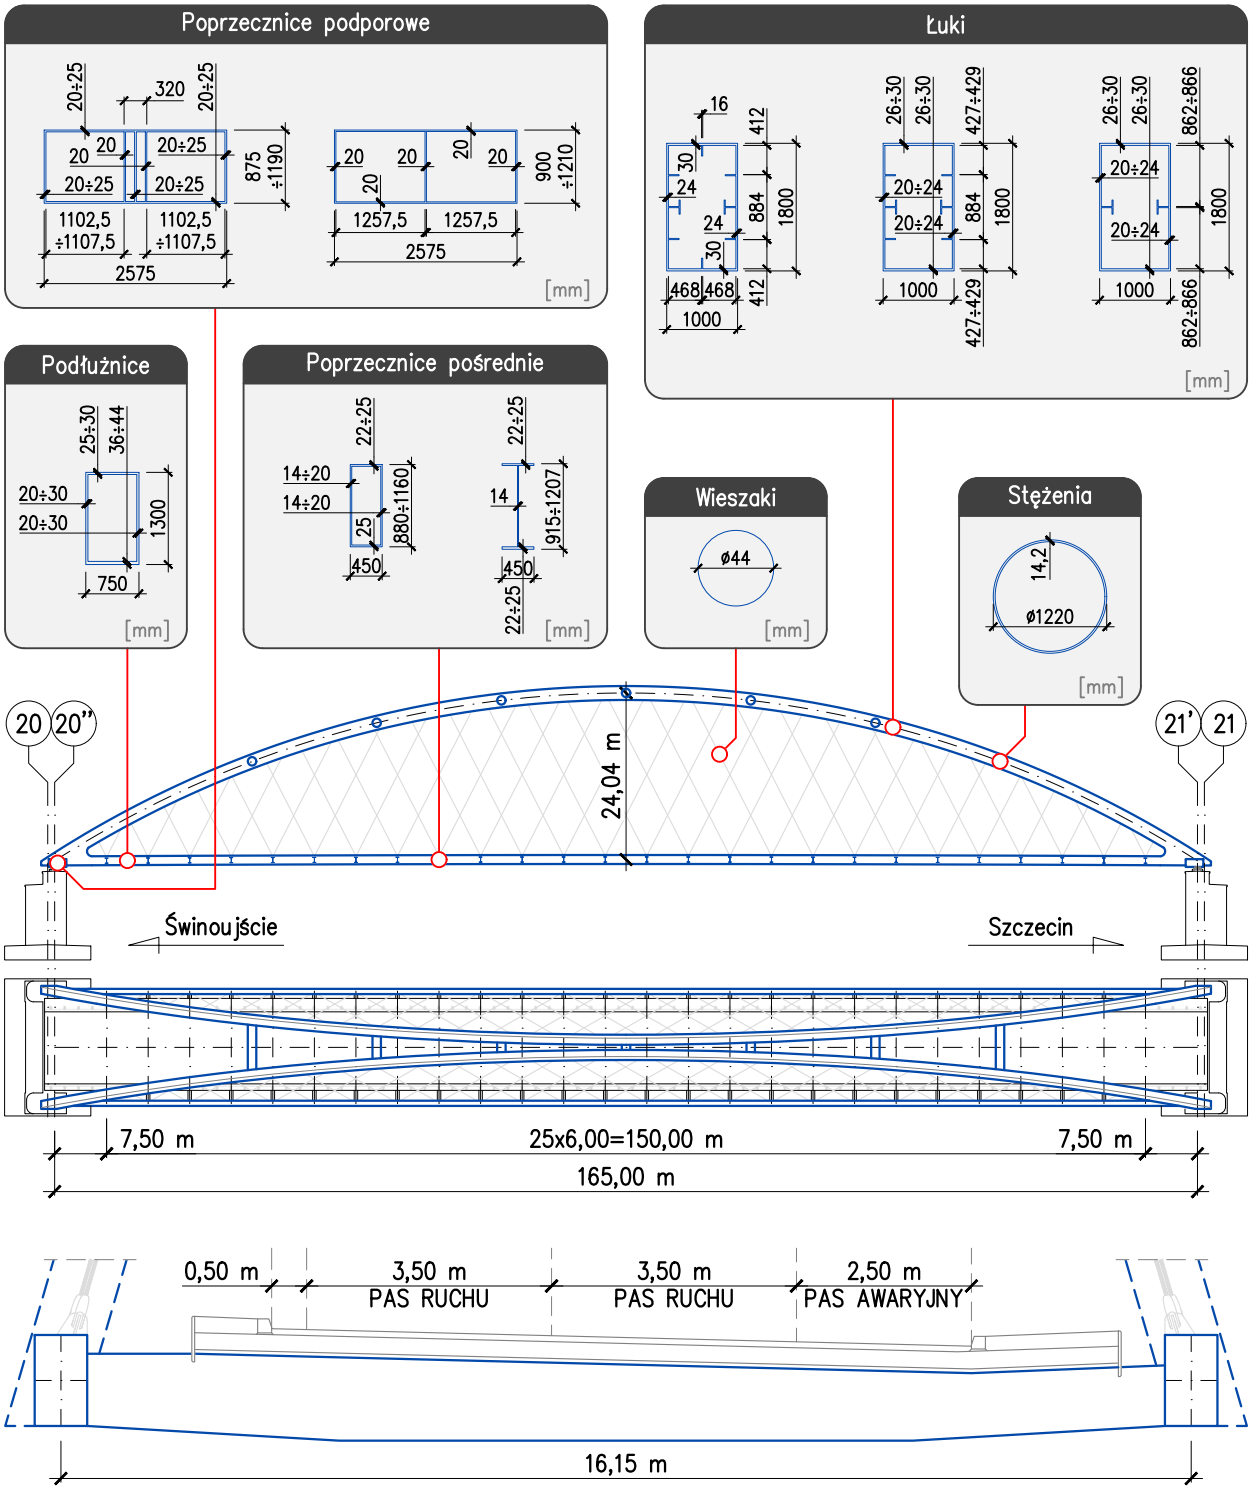

Rysunek 2.1. Schemat mostu M-7L w Wolinie

2.3.2 Cel instalowanego monitoringu SHM

Uwzględniając rozwój sieci drogowej, obiekty mostowe coraz częściej zaliczane są do elementów infrastruktury krytycznej. Ich prawidłowe funkcjonowanie ma bezpośredni wpływ na ciągłość transportu, przepływ towarów oraz bezpieczeństwo komunikacyjne całego regionu. Szczególne znaczenie mają przy tym obiekty zlokalizowane w ciągu głównych szlaków transportowych, które obsługują ruch związany z działalnością przemysłową i transportem ponadnormatywnym. Wyłączenie ich z eksploatacji lub ograniczenie przepustowości może prowadzić do istotnych kosztów społecznych i gospodarczych.

Analizowany obiekt zlokalizowany jest w północno-zachodniej Polsce, w województwie zachodniopomorskim, w Wolinie. Znajduje się on w ciągu drogi ekspresowej S3, która stanowi główny ciąg komunikacyjny pomiędzy portem w Świnoujściu, a siecią dróg prowadzących w głąb kraju. W związku z tym może występować na nim ruch pojazdów ciężkich i ponadnormatywnych, a ograniczenie jego eksploatacji może generować znaczne koszty. Z tego względu uzasadniona jest konieczność wdrożenia systemu, umożliwiającego jego ciągłe monitorowanie oraz analizę oddziaływań eksploatacyjnych generowanych pod rzeczywistym ruchem. Szczególnie zasadne jest to w przypadku obiektów o rozpiętościach przekraczających typowe rozwiązania konstrukcyjne, do których zalicza się analizowany most.

Celem wdrożonego systemu jest monitorowanie pracy wybranych elementów konstrukcyjnych, dzięki czemu możliwa jest ocena zachowania mostu w warunkach rzeczywistej eksploatacji. Zapewnia on możliwość określenia poziomu natężenia ruchu oraz identyfikację masy pojazdów przejeżdżających przez obiekt. Bazuje przy tym na rejestracji odkształceń podstawowych elementów konstrukcyjnych, za pomocą czujników światłowodowych z siatką Bragga. Istotnym założeniem jest także identyfikacja przejazdów ponadgabrytowych, których oddziaływania mogą znacząco wpływać na trwałość konstrukcji i nawierzchni drogowej. Dzięki zainstalowanemu systemowi możliwe staje się ocenienie skutków każdego przejazdu ponadnormatywnego, w tym identyfikacja potencjalnych anomalii. Mogą do nich należeć między innymi nadmierne odkształcenia trwałe lub zmiana charakterystyki odpowiedzi konstrukcji. Wdrożony system wspomaga zatem zarządzanie infrastrukturą, umożliwiając weryfikację zgłoszonych przejazdów ponadnormatywnych oraz ocenę rzeczywistych oddziaływań działających na obiekt.

Istotnym etapem wdrożonego podejścia było przeprowadzenie badań pod próbnym obciążeniem, a pozyskane w ich trakcie dane zostały wykorzystane do identyfikacji modelu numerycznego. Pozwoliło to na wierne odwzorowanie pracy konstrukcji, wykorzystując model MES do generowania syntetycznych danych pomiarowych. Stanowiły one następnie sygnały wejściowe dla algorytmów uczenia maszynowego, których zadaniem była predykcja masy całkowitej pojazdów na podstawie wskazań czujników. Dokładny schemat założeń wdrożonego rozwiązania przedstawiono na Rysunku 2.2.

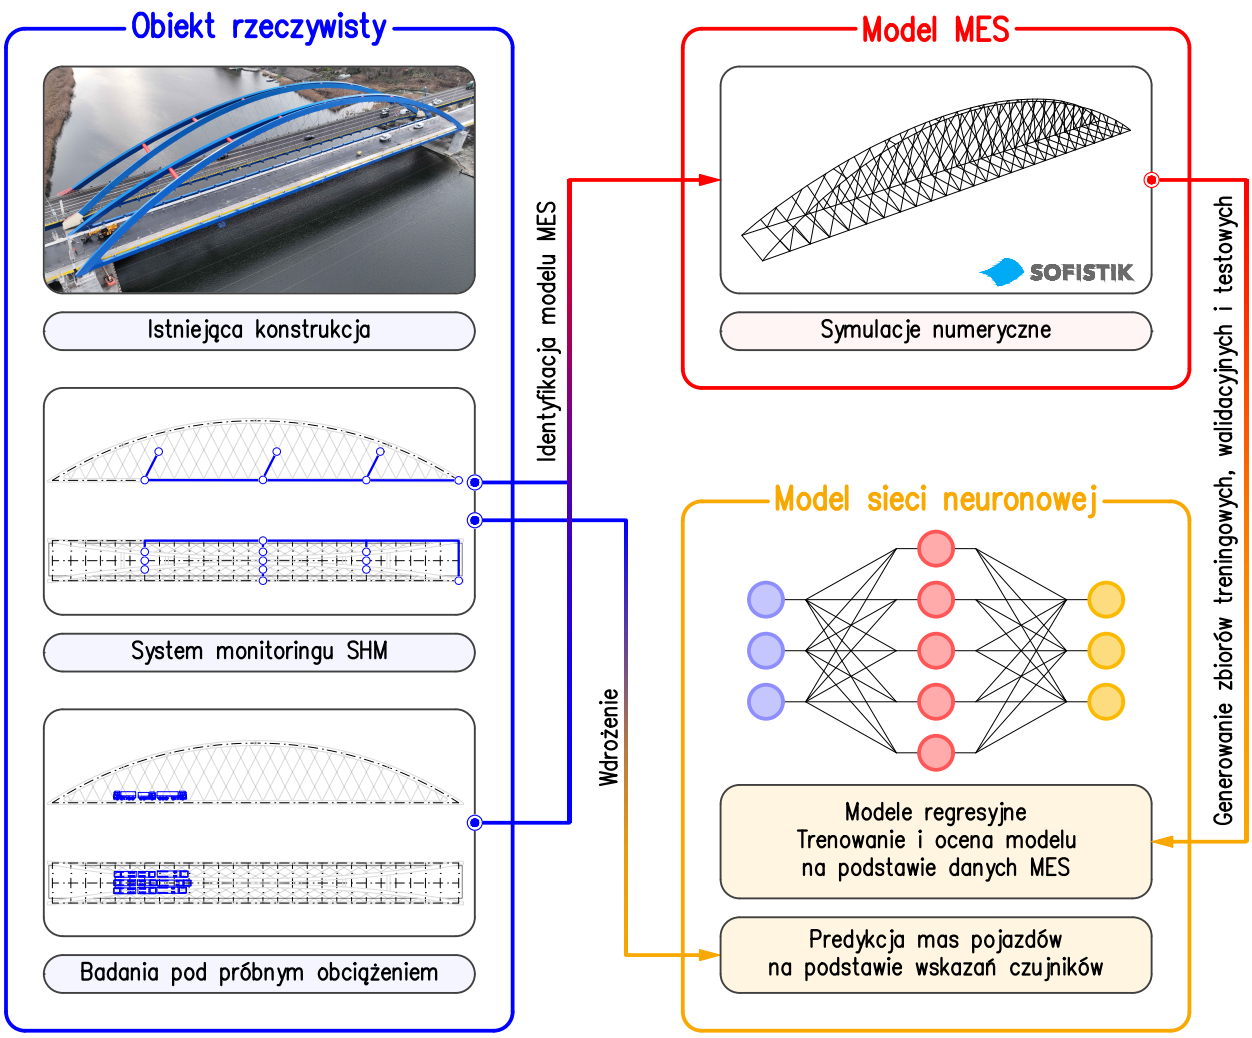

Rysunek 2.2. Założenia wdrożonego systemu monitoringu mostu M-7L

Celem instalacji systemu jest zatem realizacja funkcji ważenia pojazdów w ruchu jako kluczowego źródła danych dla cyfrowego bliźniaka konstrukcji. Jak wskazali Sacks i in. [114], błędnym podejściem jest utożsamianie cyfrowego bliźniaka wyłącznie z rozwinięciem modelowania 3D. Autorzy podkreślają, że istotą cyfrowego bliźniaka jest przede wszystkim ciągła wymiana danych i informacji, obejmująca integrację systemów monitoringu z algorytmami analitycznymi i predykcyjnymi. Zwrócili również uwagę, że wiele współczesnych prac błędnie sprowadza koncepcję cyfrowego bliźniaka wyłącznie do reprezentacji geometrycznej, traktując ją jako synonim modelu 3D.

W przedstawionym podejściu dane pozyskiwane bezpośrednio z konstrukcji są kluczowym elementem cyfrowego bliźniaka. Umożliwiają jej dynamiczne odwzorowanie, identyfikację obciążeń oraz przeprowadzenie analiz MES na wiarygodnym modelu numerycznym. Rolę tę spełnia opracowany system SHM, który w połączeniu z modelem MES i algorytmami predykcyjnymi tworzy cyfrowy odpowiednik analizowanej konstrukcji. Wiarygodność uzyskiwanych informacji wynika bezpośrednio z przeprowadzonych badań eksperymentalnych oraz procesu identyfikacji modelu numerycznego.

2.4 Model numeryczny MES

Obliczenia statyczne ustroju nośnego zostały wykonane w oprogramowaniu *SOFiSTiK*, przyjmując przestrzenny model prętowo-powłokowy klasy $(e^{1+2}; p^3)$. Schemat modelu przedstawiono na Rysunku 2.3, natomiast parametry geometryczne poszczególnych elementów zestawiono w Tabeli 2.2, przyjmując ich wartości zgodnie z dokumentacją powykonawczą. Elementami prętowymi odwzorowany został ruszt stalowy pomostu wraz z łukami, wieszakami oraz stężeniami. Płyta pomostowa stanowiła natomiast niezależny element powłokowy. W modelu nie wprowadzono zatem zespolenia płyty pomostowej z prętami stalowymi, ponieważ rzeczywisty rozkład naprężeń najczęściej nie jest tożsamy z zakładanym odgórnie w modelu MES. Do obliczeń przyjęty został moduł sprężystości prefabrykowanej części płyty pomostowej równy $E_{\text{bp}} = 35$ GPa (beton klasy C40/50) oraz części monolitycznej $E_{\text{bm}} = 37$ GPa (beton klasy C50/60). Dla elementów stalowych przyjęto natomiast moduł stali konstrukcyjnej na poziomie $E_{\text{s}} = 210$ GPa (stal klasy S460N), a wieszaków linowych $E_{\text{h}} = 163$ GPa.

W modelu założone zostało sztywne połączenie wszystkich elementów prętowych. Dodatkowo, świadomie pominięto efekt zespolenia płyty pomostowej z poprzecznicami w elementach prętowych. Założono przy tym, że efektywna sztywność giętna pomostu zostanie określona na etapie identyfikacji modelu numerycznego, poprzez kalibrację parametrów materiałowych. Dzięki niej osiągnięta zostanie zgodność mierzonych odkształceń w wybranych punktach pomiarowych. Na kierunku podłużnym sztywność giętna odpowiadała zatem sumarycznej sztywności podłużnic, łuków oraz płyty pomostowej. Z kolei w kierunku poprzecznym stanowiła sumę sztywności poprzecznic oraz płyty. Tak założone odwzorowanie konstrukcji rzeczywistej, umożliwiło dalszą identyfikację modelu MES, uwzględniając przy tym wyniki badań pod próbnym obciążeniem wraz z towarzyszącymi pomiarami z systemu monitoringu.

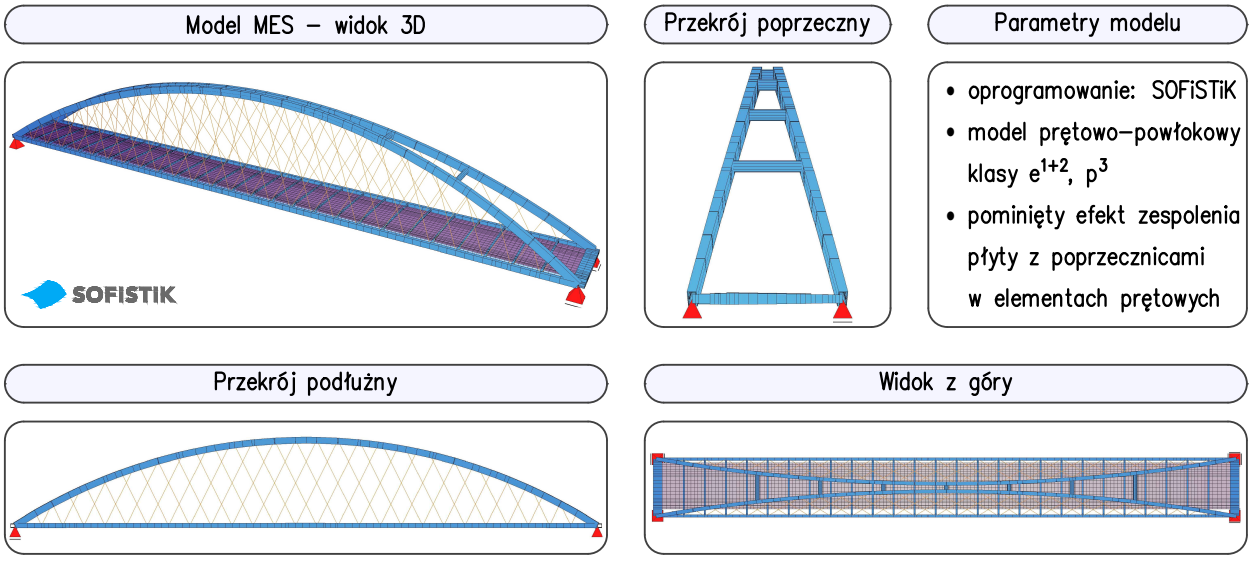

Rysunek 2.3. Model MES

Tabela 2.2. Zadane przekroje podłużnic, łuków i stężeń

Zadane przekroje podłużnic, łuków i stężeń	
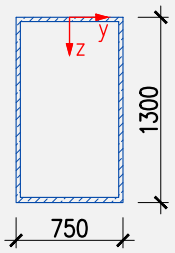	**Podłużnice** Pole powierzchni przekroju: A = 0,0953 – 0,1235 m^2 Moment bezwładności na zginanie I_y = 0,0245 – 0,0292 m^4 Moment bezwładności na zginanie I_z = 0,0087 – 0,0119 m^4 Położenie środka ciężkości z_c = 670,7 – 731,0 mm
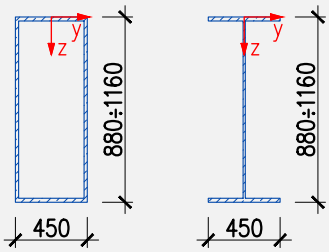	**Poprzecznice pośrednie** Pole powierzchni przekroju: A = 0,0336 – 0,0665 m^2 Moment bezwładności na zginanie I_y = 0,0052 – 0,0119 m^4 Moment bezwładności na zginanie I_z = 0,0004 – 0,0024 m^4 Położenie środka ciężkości z_c = 437,5 – 678,9 mm
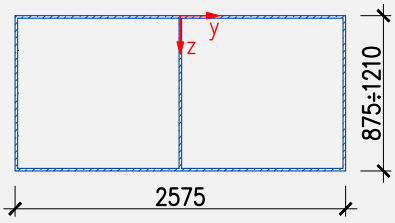	**Poprzecznice podporowe** Pole powierzchni przekroju: A = 0,1549 – 0,1991 m^2 Moment bezwładności na zginanie I_y = 0,0234 – 0,0441 m^4 Moment bezwładności na zginanie I_z = 0,1134 – 0,1528 m^4 Położenie środka ciężkości z_c = 437,5 – 602,5 mm
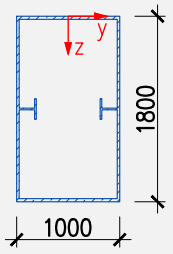	**Łuki** Pole powierzchni przekroju: A = 0,1331 – 0,1547 m^2 Moment bezwładności na zginanie I_y = 0,0587 – 0,0681 m^4 Moment bezwładności na zginanie I_z = 0,0226 – 0,0263 m^4 Położenie środka ciężkości z_c = 900,0 mm
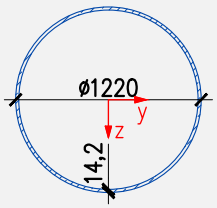	**Stężenia** Pole powierzchni przekroju: A = 0,0538 m^2 Moment bezwładności na zginanie I_y = 0,0098 m^4 Moment bezwładności na zginanie I_z = 0,0098 m^4 Położenie środka ciężkości z_c = 0,0 mm
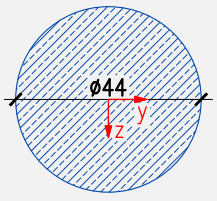	**Wieszaki** Pole powierzchni przekroju: A = 0,001 303 m^2 Moment bezwładności na zginanie I_y = 1,35 . 10^{-7} m^4 Moment bezwładności na zginanie I_z = 1,35 . 10^{-7} m^4 Położenie środka ciężkości z_c = 0,0 mm

Uogólniony schemat rozkładu naprężeń dla elementu zginanego i rozciąganego (podłużnica) oraz zginanego (poprzecznica) przedstawiono na Rysunku 2.4. Z uwagi na przyszły proces identyfikacji modelu, który wiąże się z wieloma iteracjami, jego budowa uwzględniała niezależną sztywność poprzecznicy stalowej i płyty pomostowej. W związku z tym pominięto efekt zespolenia na kierunku poprzecznym poprzez bezpośrednie przypisanie sumy sztywności na poprzecznice. W konsekwencji uzyskane wartości sił wewnętrznych w poprzecznicy są podstawą do określenia odkształceń z wykorzystaniem parametrów geometrycznych elementu stalowego.

Uwzględniając prawo Hooke'a oraz sposób odwzorowania obiektu w modelu MES określono odkształcenia teoretyczne, które posłużyły do identyfikacji modelu poprzez zmianę modułu sprężystości (proces ten opisano dokładnie w Rozdziale 4). Identyfikacja modelu, bazująca na kalibracji parametru modułu, pozwoliła zatem na uzyskanie zgodności odkształceń obliczonych teoretycznie oraz zarejestrowanych przez system pomiarowy. Efektywny moduł sprężystości pełnił w tym przypadku rolę parametru zastępczego, umożliwiającego kompensację rozkładu sztywności oraz niepewności związanych z geometrią, właściwościami materiałowymi oraz wpływem elementów wyposażenia. Tak powstały model został dodatkowo zweryfikowany podczas badań pod próbnym obciążeniem.

Należy podkreślić, że wyznaczony w procesie identyfikacji efektywny moduł sprężystości nie odpowiada rzeczywistym właściwościom materiałowym i nie może być wykorzystywany do wyznaczania wartości naprężeń. Jest on tylko i wyłącznie wartością korygującą ewentualne wpływy zewnętrzne i zapewniającą zgodność rejestrowanych przez SHM odkształceń z wartościami wyznaczonymi w modelu MES. Do ewentualnego obliczenia naprężeń mogą posłużyć siły wewnętrzne zwrócone przez zidentyfikowany model numeryczny oraz rzeczywiste wartości modułów sprężystości.

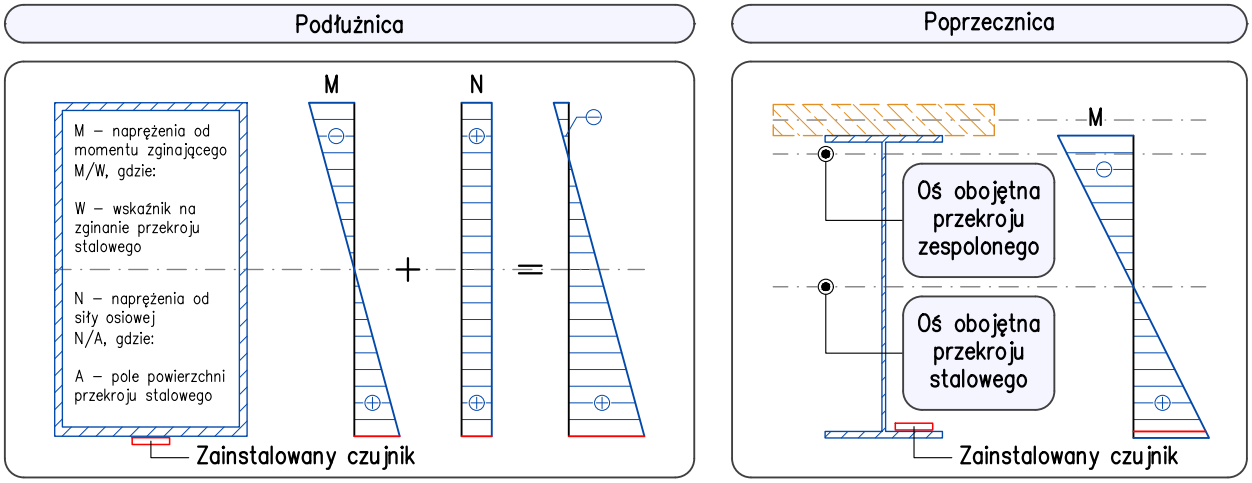

Rysunek 2.4. Uogólniony schemat rozkładu naprężeń dla podłużnicy oraz poprzecznicy

2.5 Analiza statyczna

2.5.1 Analiza odpowiedzi konstrukcji w formie zakresu zmian sił wewnętrznych

Każdy system pomiarowy powinien zostać zaprojektowany w taki sposób, aby gwarantował dokładne i miarodajne pomiary w odniesieniu do zakładanych celów. W związku z tym przed instalacją czujników przeprowadzone zostały symulacje numeryczne, mające na celu określenie lokalizacji punktów pomiarowych. Analizowany obiekt jest konstrukcją łukową o podwieszeniu siatkowym, pozwalającym na znaczną redukcję sił wewnętrznych. Charakterystyczną cechą tego rozwiązania jest również ograniczenie zakresu linii wpływu obciążeń w poprzecznicach, dzięki czemu możliwe jest ograniczenie liczby stosowanych czujników światłowodowych. Wymagało to jednak przeprowadzenia szczegółowej oceny ich lokalizacji, z uwzględnieniem schematu pracy oraz odpowiedzi konstrukcji.

Celem systemu jest trzykrotny, niezależny pomiar masy całkowitej pojazdu na długości obiektu. Do analiz przyjęto trzy bramki pomiarowe, zlokalizowane w przekrojach odpowiadających $1/4$, $1/2$ oraz $3/4$ rozpiętości przęsła. W obiektach łukowych należą one do najbardziej wytężonych, zatem umiejscowienie w nich punktów pomiarowych umożliwia kontrolę globalnej pracy konstrukcji. Dzięki temu rejestrowane pomiary odpowiadają obszarom występowania największych wartości sił wewnętrznych.

Analizę statyczną przeprowadzono z wykorzystaniem siły jednostkowej poruszającej się środkiem jezdni. Na tym etapie istotne było bowiem określenie samego charakteru odpowiedzi, a nie wyznaczenie konkretnych wartości liczbowych. Na podstawie przeprowadzonych symulacji oceniono następnie czy odpowiedź rejestrowana przez jedną bramkę pomiarową może wpływać na mierzoną wartość odkształceń w pozostałych dwóch przekrojach. W tym celu wyznaczono linie wpływu sił wewnętrznych dla poprzecznic (Rysunek 2.5), podłużnic (Rysunek 2.6) oraz wieszaków (Rysunek 2.7).

Każdy z tych elementów charakteryzuje się odmiennym schematem pracy oraz inną odpowiedzią na obciążenie ruchome. W przypadku poprzecznic dominującym efektem są momenty zginające o charakterze lokalnym. W podłużnicach odpowiedź konstrukcji związana jest zarówno z siłami osiowymi, jak i momentami zginającymi, natomiast wieszaki przenoszą wyłącznie siły osiowe. Dodatkowo, jednostronny spadek oraz lokalizacja pasów ruchu nie zapewniają symetrii pomiędzy płaszczyznami lewego oraz prawego łuku. W efekcie odpowiedź konstrukcji po obu stronach przekroju poprzecznego będzie różna. W związku z tym w dalszym etapie wyznaczono linię wpływu poprzecznic od siły jednostkowej poruszającej się w kierunku poprzecznym mostu w przekroju odpowiadającym $1/4$ rozpiętości przęsła (Rysunek 2.8). Przeprowadzone analizy były miarodajne, ponieważ na podstawie sił wewnętrznych oraz wykorzystując prawo Hooke'a możliwe jest dalsze wyznaczenie odkształceń.

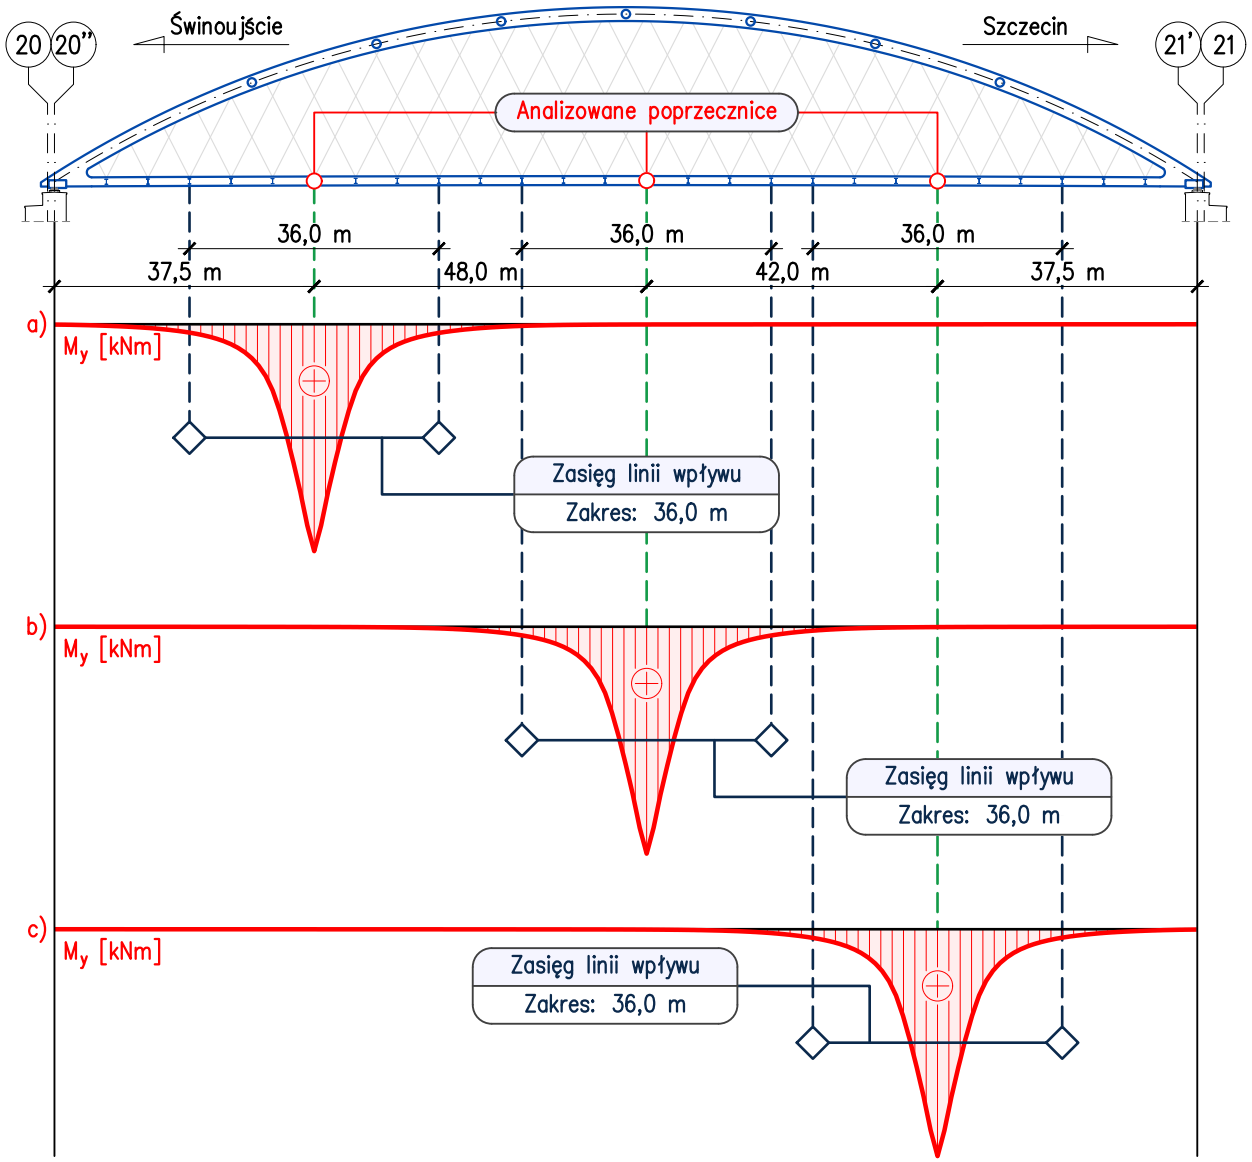

Rysunek 2.5. Linie wpływu momentów zginających poprzecznic

Na podstawie przeprowadzonych analiz widoczny jest wyraźnie ograniczony zasięg linii wpływu poprzecznic. Momenty zginające osiągają wartości ekstremalne w sytuacji, gdy obciążenie znajduje się bezpośrednio nad analizowaną poprzecznicą. Wraz ze wzrostem odległości od punktu przyłożenia siły wpływ obciążenia gwałtownie maleje. Oznacza to, że odpowiedź lokalna poprzecznicy determinowana jest przede wszystkim przez obciążenia znajdujące się w jej bezpośrednim otoczeniu.

Ograniczony zasięg linii wpływu stanowi istotną cechę konstrukcji łukowych, ponieważ pozwala na separację odpowiedzi poszczególnych przekrojów pomiarowych. Dla analizowanego obiektu wynosi on około 36 m, co odpowiada sześciu pasmom pomiędzy kolejnymi poprzecznicami. Jednocześnie już przy odległości około 24 m, odpowiadającej czterem pasmom, wpływ oddalonego obciążenia staje się pomijalnie mały. Dzięki temu możliwe staje się prowadzenie wielokrotnych i niezależnych pomiarów na całej długości obiektu, bez nakładania się odpowiedzi rejestrowanych w kolejnych przekrojach poprzecznych.

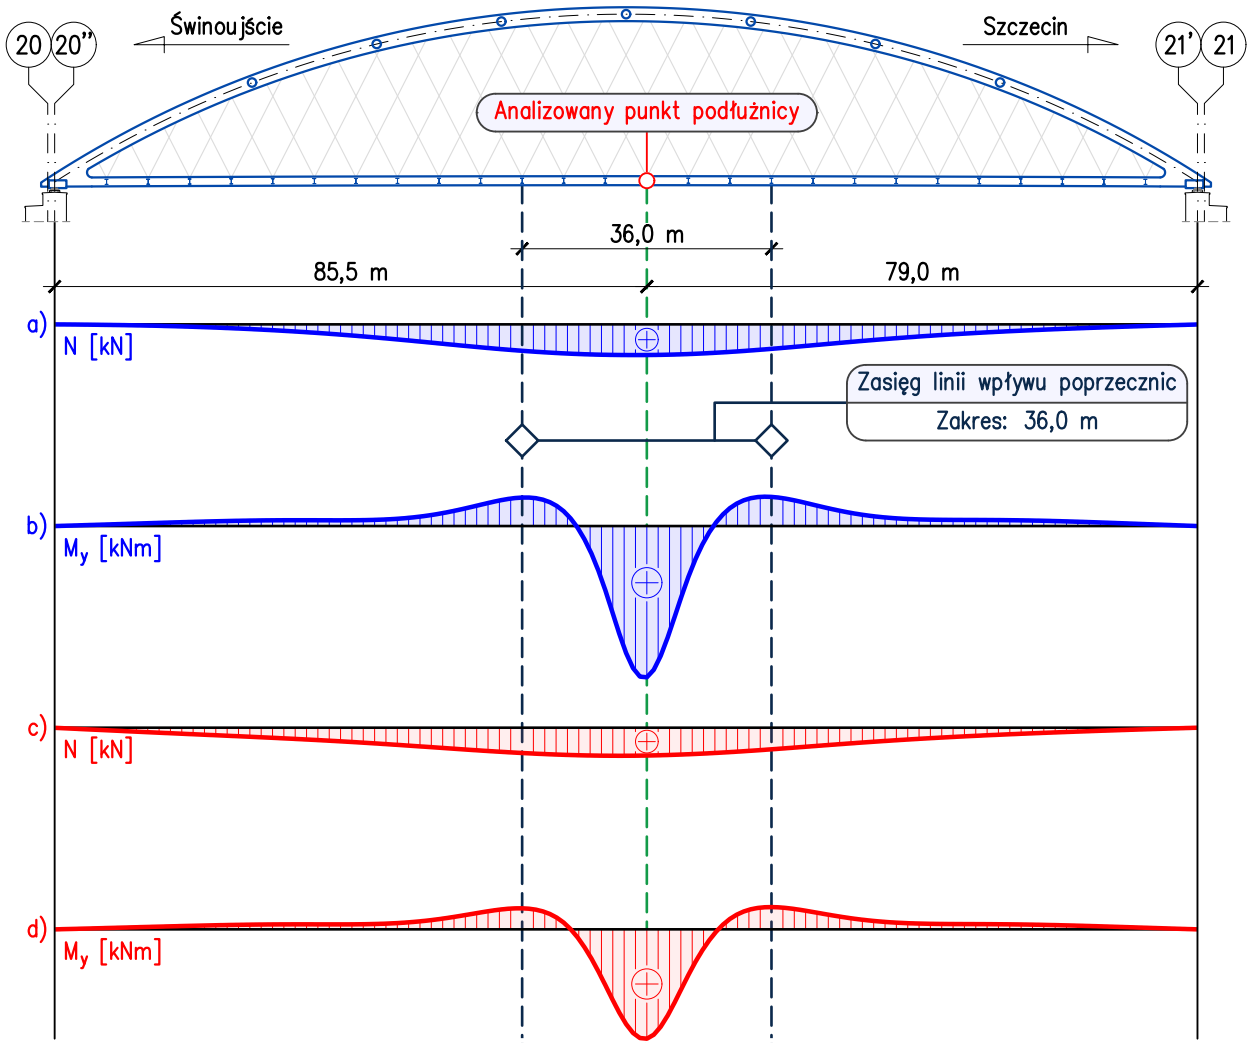

Rysunek 2.6. Linie wpływu sił osiowych i momentów zginających podłużnic

W przeciwieństwie do poprzecznic, podłużnice poddane są nie tylko zginaniu, ale również rozciąganiu. Z tego względu na Rysunku 2.6 przedstawiono linie wpływu momentów zginających oraz sił osiowych. Wyniki uzyskane dla dwóch podłużnic rozróżniono odpowiednio kolorem niebieskim i czerwonym.

Przeprowadzona analiza wykazała odmienny charakter rozkładu poszczególnych sił wewnętrznych. Największe wartości momentów zginających występują w bezpośrednim sąsiedztwie analizowanego przekroju, a ich dominująca część zawiera się w zakresie linii wpływu poprzecznic. Z kolei siły osiowe charakteryzują się szerszym zasięgiem oddziaływania, obejmując praktycznie całą długość przęsła.

Zauważalny jest również wpływ położenia pojazdu na szerokości jezdni. Efekt ten jest szczególnie widoczny w przypadku momentów zginających, dla których jedna z analizowanych podłużnic przejmuje większą część obciążenia. Wynika to z niesymetrycznego położenia toru jazdy względem płaszczyzn łuków, prowadząc do nierównomiernego rozkładu sił wewnętrznych pomiędzy analizowane podłużnice.

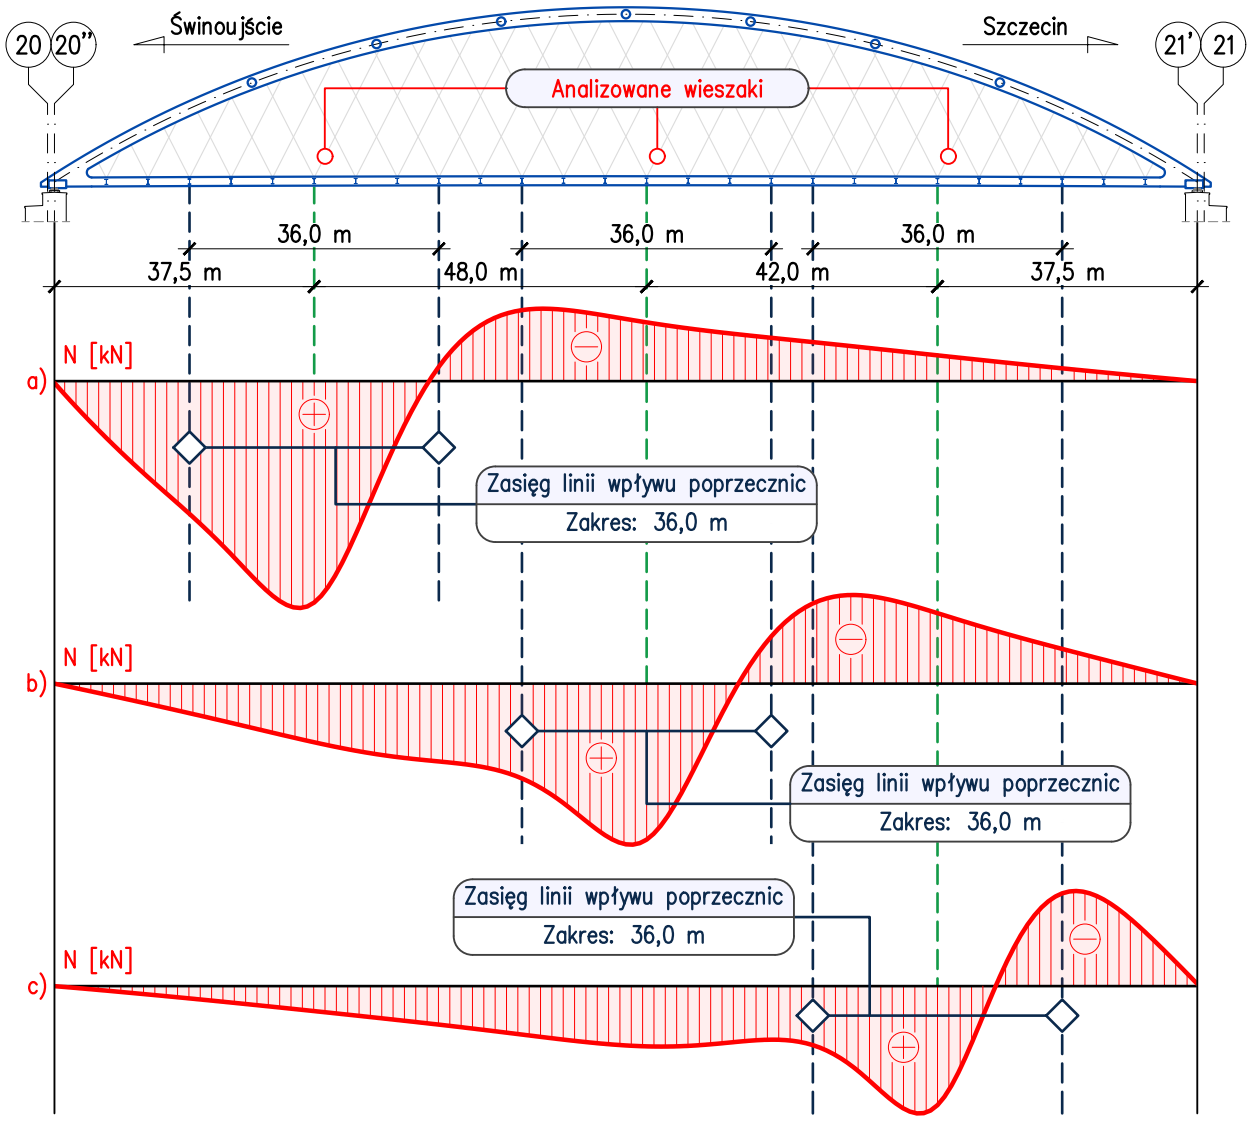

Rysunek 2.7. Linie wpływu sił osiowych wieszaków

W przeciwieństwie do poprzecznic odpowiedź wieszaków ma charakter globalny i związana jest z pracą całego ustroju nośnego. W efekcie pozostają one wrażliwe na obciążenia znajdujące się poza analizowanym przekrojem. W celu porównania, na Rysunku 2.7 zaznaczone zostały zakresy linii wpływu poprzecznic. Zauważalne jest, że poza tymi zakresami wartości sił osiowych w wieszakach pozostają znaczące i mają wpływ na pomiary rejestrowane w danym przekroju. Wieszaki mogą zatem pełnić funkcję pomiarów uzupełniających, umożliwiających globalną ocenę pracy konstrukcji oraz weryfikację odpowiedzi uzyskiwanych z lokalnych pomiarów realizowanych na poprzecznicach.

Na podstawie przeprowadzonych analiz można wnioskować, że poprzecznice są odpowiednimi elementami do przeprowadzania lokalnych pomiarów. Dla podłużnic dominujący zakres linii wpływu momentów pokrywa się z zasięgiem poprzecznic, jednak linie wpływu sił osiowych mają znacznie szerszy zakres oddziaływania. Z kolei pomiary na wieszakach odwzorowują globalną odpowiedź konstrukcji.

2.5.2 Analiza położenia obciążenia w przekroju poprzecznym

Oprócz analiz mających na celu określenie lokalizacji bramek pomiarowych przeprowadzono również symulację lokalnej odpowiedzi poprzecznicy. Jej celem była ocena wpływu położenia pojazdu względem szerokości jezdni na wartości momentów zginających. Wyznaczono zatem linie wpływu dla trzech punktów pomiarowych rozmieszczonych w obrębie jednej poprzecznicy. Wykorzystano w tym celu jednostkową siłę, przemieszczającą się w kierunku poprzecznym na całej szerokości jezdni. Docelowo punkty pomiarowe miały zostać zlokalizowane w przekrojach odpowiadających $1/4$, $1/2$ oraz $3/4$ długości poprzecznicy, jednak z uwagi na obecność elementów jezdnych wózka rewizyjnego, zamontowanych podczas budowy obiektu, skrajne punkty pomiarowe musiały zostać przesunięte.

Przeprowadzone analizy wykazały wyraźną zależność odpowiedzi konstrukcji od położenia obciążenia względem szerokości jezdni (Rysunek 2.8). Dzięki zastosowaniu trzech punktów pomiarowych możliwe staje się nie tylko określenie masy całkowitej pojazdu, ale również identyfikacja jego toru ruchu.

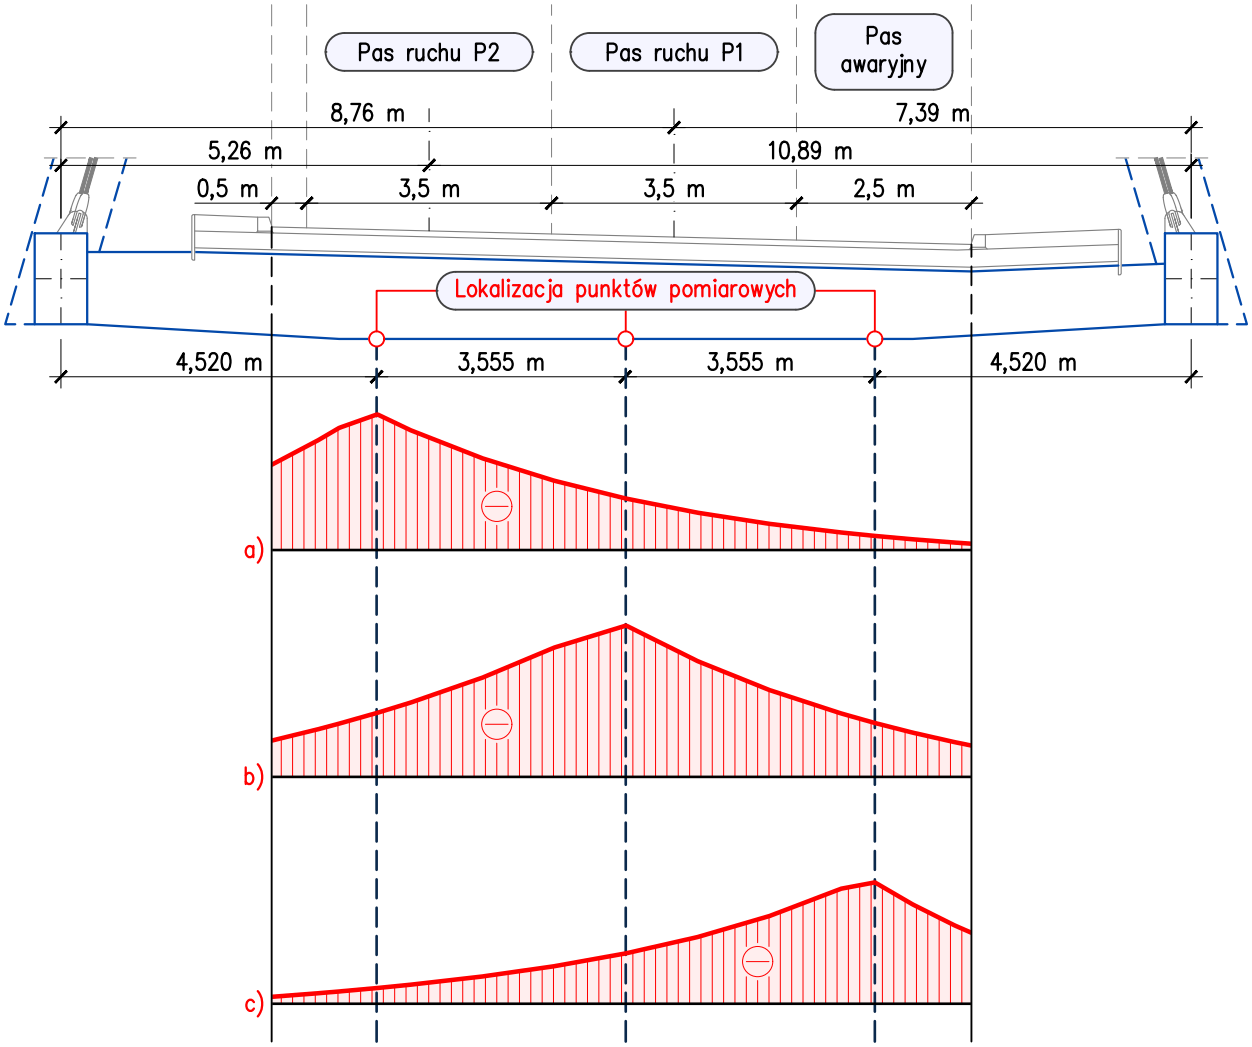

Rysunek 2.8. Linie wpływu momentów zginających poprzecznicy w kierunku poprzecznym

2.6 Dobór systemu

2.6.1 Schemat systemu i lokalizacja punktów pomiarowych

Przeprowadzona analiza wykazała ograniczony zakres linii wpływu poprzecznic, dzięki czemu możliwa jest identyfikacja obciążenia znajdującego się wyłącznie w bezpośrednim sąsiedztwie analizowanego przekroju. Jednocześnie odpowiednia separacja pomiędzy kolejnymi bramkami umożliwia uzyskanie trzykrotnego, niezależnego pomiaru masy pojazdu, bez nakładania się sąsiednich sygnałów.

Na podstawie przeprowadzonych symulacji zostały przyjęte trzy bramki pomiarowe, zlokalizowane w przekrojach odpowiadających $1/4$, $1/2$ oraz $3/4$ rozpiętości przęsła. Łącznie zainstalowanych zostało 17 punktów pomiarowych, zakładając dla każdej bramki pomiarowej trzy czujniki odkształceń na poprzecznicy (oznaczone jako CB) oraz dwa na przeciwległych wieszakach (H). Dodatkowo w środkowej bramce zainstalowano po jednym czujniku na obu ściągach (TB) (Rysunek 2.9 oraz 2.10).

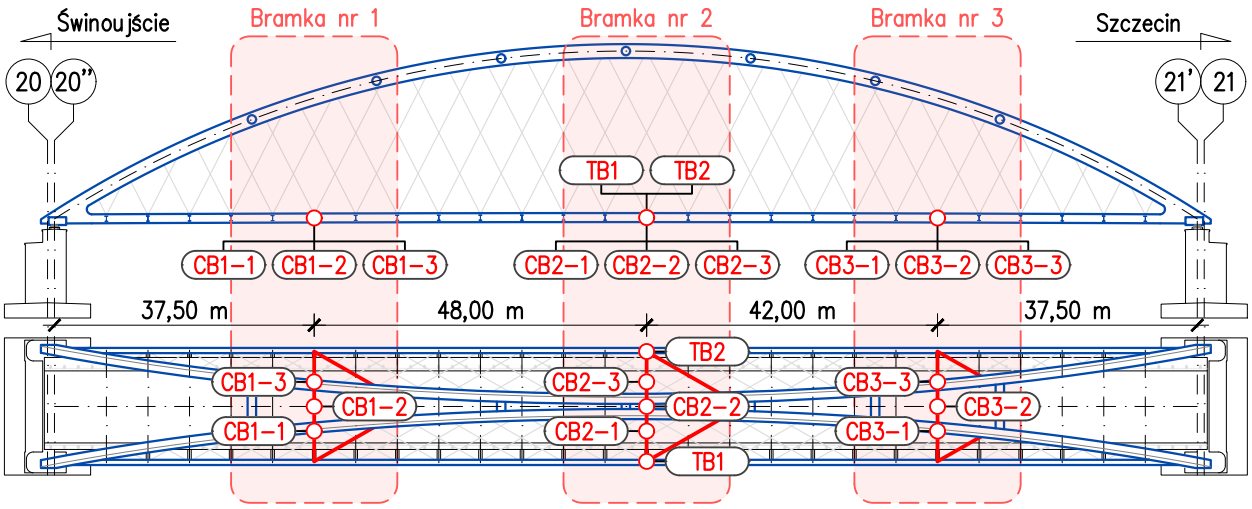

Rysunek 2.9. Rozmieszczenie punktów pomiarowych na podłużnicach (TB) oraz poprzecznicach (CB)

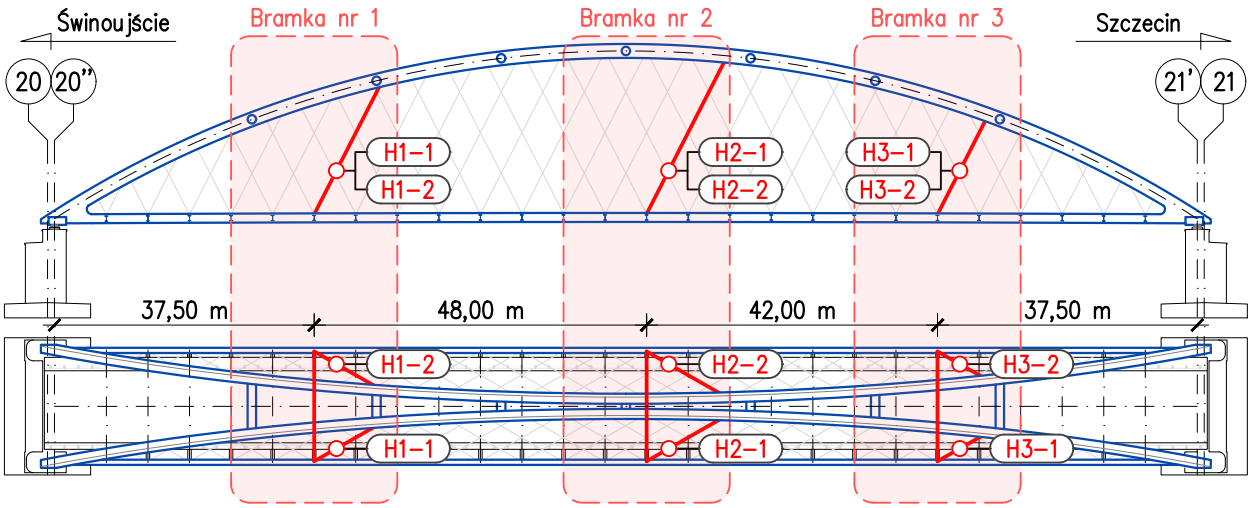

Rysunek 2.10. Rozmieszczenie punktów pomiarowych na wieszakach (H)

2.6.2 Pomiar odkształceń wybranych elementów konstrukcyjnych

Pomiar odkształceń odbywa się w 17 punktach pomiarowych i wykonywany jest za pomocą czujników światłowodowych, bazujących na technologii siatki Bragga. Do podłużnic oraz poprzecznic zainstalowano 11 czujników typu FS62WSS [ST4], natomiast do wieszaków 6 czujników typu FS62RSS [ST3], wykorzystując klasyczne jednomodowe włókno światłowodowe SMF-28 (*ang. Single Mode Fiber*). Producentem urządzeń jest firma *HBK*. Pomiar odkształceń odbywa się w zakresie ±5000 µm/m, przy czułości około 1,2 pm/(µm/m) dla czujników FS62WSS oraz 1,1 pm/(µm/m) dla czujników FS62RSS. Rozdzielczość pomiarów wynosi 0,5 µm/m, natomiast zmiana długości fali odbitej przez siatkę Bragga przeliczana jest na odkształcenie z wykorzystaniem współczynnika kalibracyjnego przyjmującego wartość $k = 0{,}76 \pm 0{,}03$ dla czujników FS62WSS oraz $k = 0{,}7 \pm 0{,}4$ dla FS62RSS. Zainstalowane czujniki charakteryzują się wysoką trwałością i możliwością pracy w zakresie temperatur –20 °C do 80 °C i wilgotności dochodzącej do 100 %. Konstrukcja czujnika instalowanego na wieszakach cechuje się brakiem wrażliwości poprzecznej, natomiast dla czujników poprzecznic i podłużnic wrażliwość ta jest niewielka i wynosi mniej niż 2 %. Dodatkowo charakteryzują się one wysoką odpornością na wstrząsy, co jest istotną cechą w przypadku konstrukcji podatnych na oddziaływania dynamiczne. Zainstalowane czujniki pracują w zakresie długości fal Bragga 1500 – 1600 nm (±0,75), umożliwiając multipleksowanie wielu punktów pomiarowych na jednym torze światłowodowym. Dodatkowo każdy z czujników posiada indywidualną referencyjną długość fali Bragga, co umożliwia jego identyfikację w widmie optycznym interrogatora.

Zmiana długości fali Bragga jest również zależna od warunków środowiskowych, stąd w zastosowanym systemie pomiarowym czujniki odkształceń są rozmieszczane naprzemiennie z czujnikami temperatury. W tym celu zainstalowane zostały czujniki FS63WTS [ST7] dla poprzecznic i podłużnic oraz FS63RTS [ST6] dla wieszaków, również wykorzystujące włókno SMF-28. Charakteryzują się one czułością pomiarów na poziomie 30 pm/°C oraz współczynnikiem kompensacji temperatury 20 (µm/m)/°C. Czujniki te pracują w zakresie temperatur –20 °C do 80 °C, przy rozdzielczości pomiaru wynoszącej 0,02 °C i zakresie długości fal Bragga 1500 – 1600 nm (±0,5). Zastosowanie dodatkowych czujników umożliwia kompensację temperaturową, na którą wpływa wartość współczynnika czułości temperaturowej czujnika odkształceń TCS (*ang. Temperature Cross Sensitivity*) oraz współczynnik rozszerzalności cieplnej konstrukcji CTE (*ang. Coefficient of Thermal Expansion*). Zastosowane czujniki charakteryzują się wartością $TCS = (7{,}6 \pm 1{,}0)$ µm/(m/°C), a wartości odkształceń ε przy zastosowaniu kompensacji wyznaczane są na podstawie Wzoru (2-1). Zastosowane czujniki zestawiono na Rysunku 2.11.

$$\varepsilon = \frac{\lambda - \lambda_0}{k \cdot \lambda_0} \cdot 10^6 - (CTE + TCS) \cdot (T - T_0) \tag{2-1}$$

Pomiar odkształceń jest zależny od zmierzonej długości fali λ oraz referencyjnej długości fali czujnika λ_0, a także zmierzonej temperatury T oraz referencyjnej T_0, wyznaczonej w chwili zerowych wartości odkształceń. Wartość temperatury wyznaczana jest natomiast na podstawie Wzoru 2-2 i zależy od długości fal λ oraz λ_0, a także współczynników kalibracyjnych S_0, S_1 oraz S_2. Określone są one indywidualnie dla każdego czujnika i wynoszą w przybliżeniu $S_0 \approx 30\,°C$, $S_1 \approx 35\,°C/nm$ oraz $S_2 \approx -1\,°C/nm^2$. Dokładne wartości zostały natomiast wyznaczone przez producenta na etapie kalibracji urządzenia.

$$T = (\lambda - \lambda_0)^2 \cdot S_2 + (\lambda - \lambda_0) \cdot S_1 + S_0 \tag{2-2}$$

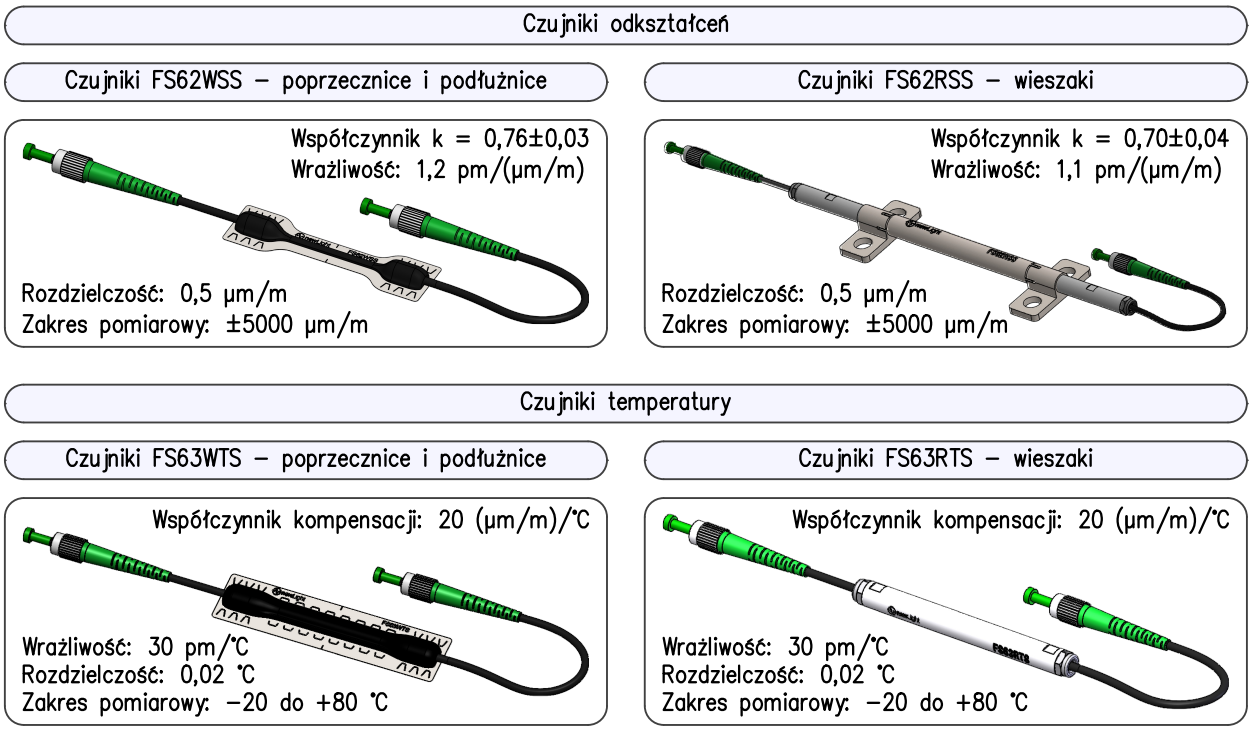

Rysunek 2.11. Zainstalowane czujniki odkształceń oraz temperatury
Grafiki oraz dane czujników pochodzą z kart katalogowych producenta [ST3, ST4, ST6, ST7]

Układ pomiarowy składa się z naprzemiennie ułożonych czujników odkształceń oraz temperatury. Schemat takiej konfiguracji przedstawiono na Rysunku 2.12, obrazując rzeczywistą strukturę toru pomiarowego. Każdy z układów zakończony jest z obu stron złączami typu FC/APC, umożliwiającymi transfer sygnału do kabli zbiorczych oraz rejestratora. Wykorzystanych zostało łącznie sześć układów pomiarowych, instalując na każdej bramce dwa tory światłowodowe. Pierwszy układ obejmował wszystkie trzy punkty zlokalizowane na poprzecznicach i ewentualnie dwa na podłużnicach (w drugiej bramce pomiarowej), natomiast drugi ciąg prowadzony były do dwóch punktów zainstalowanych na wieszakach. Pomiar odkształceń realizowany jest z częstotliwością 100 Hz.

Każdy ciąg pomiarowy składa się z wielu segmentów wzajemnie połączonych ze sobą włókien. Po-

łączenia te, realizowane za pomocą spawów, są następnie zabezpieczone poprzez wykorzystanie osłon typu FS76ARM, wykonanych z materiału polimidowego. Stanowią one cylindryczne osłony o średnicy 8 mm i długości 150 mm, których zadaniem jest zabezpieczenie miejsca spawu światłowodu [ST8].

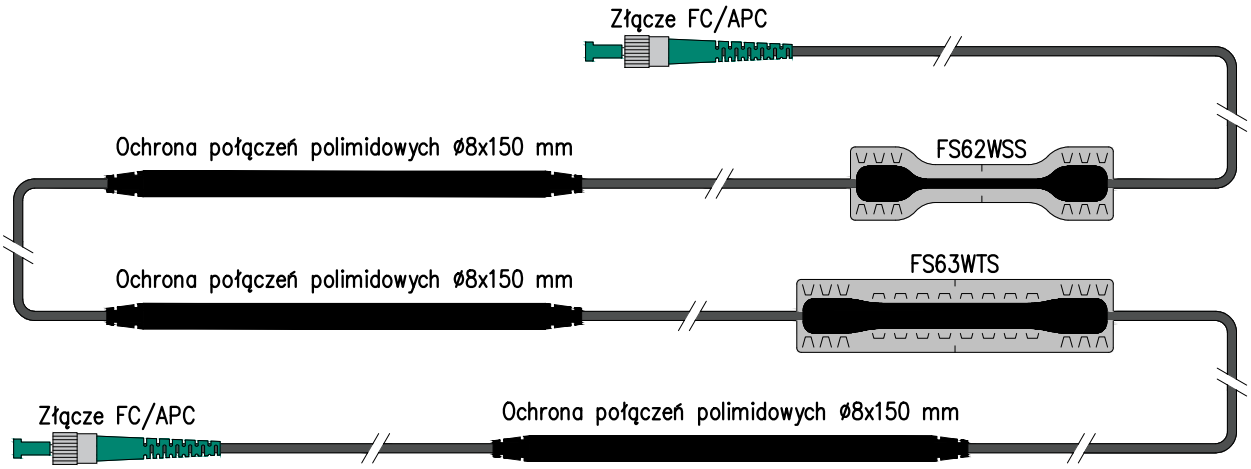

Rysunek 2.12. Ciąg pomiarowy składający się z naprzemiennie ułożonych czujników odkształceń i temperatury
Wykonanie własne na podstawie [ST8]

2.6.3 Metody instalacji czujników

Czujniki światłowodowe zlokalizowane na poprzecznicach i podłużnicach były zgrzewane punktowo do konstrukcji. Na poprzecznicach zostały zainstalowane na górnej powierzchni pasów dolnych, natomiast na ściągach na ich dolnej powierzchni. Montaż czujników poprzedzony był przygotowaniem powierzchni pomiarowej (Rysunek 2.13a), obejmującym jej wyczyszczenie i zeszlifowanie, usuwając powłoki ochronne oraz farbę. Dzięki temu zminimalizowany został wpływ lokalnych niejednorodności, które mogłyby wpłynąć na dokładność pomiarów. Następnie czujniki zostały zgrzane do konstrukcji (Rysunek 2.13b), orientując je zgodnie z kierunkiem głównych odkształceń elementów (Rysunek 2.13c).

Po wykonanej instalacji czujniki oraz przyległe fragmenty kabli światłowodowych zostały zabezpieczone przed oddziaływaniem wilgoci oraz uszkodzeniami mechanicznymi. Ochrona ta została zapewniona za pomocą kitu maskującego o dużej przyczepności AK22 (Rysunek 2.13d) oraz masy szpachlowej ABM75 o grubości 3 mm, wraz z folią aluminiową 0,05 mm (Rysunek 2.13e). W pierwszej kolejności kit AK22 został użyty do pokrycia strefy przejścia pomiędzy czujnikiem, a przewodem światłowodowym. Materiał ten, dzięki swojej plastyczności umożliwił dokładne dopasowanie się do geometrii powierzchni, jednocześnie nie wprowadzając dodatkowych sztywnych połączeń, które mogłyby wpływać na lokalny stan odkształceń. Na czujnik zawierający warstwę uszczelniającą nałożono masę szpachlową ABM75 wraz z folią aluminiową, zapewniając ochronę mechaniczną oraz minimalizując wpływ oddziaływania środowiska zewnętrznego. Po zainstalowaniu i zabezpieczeniu czujników wykonany został pomiar kontrolny, mający na celu weryfikację poprawnego działania układu pomiarowego (Rysunek 2.13f).

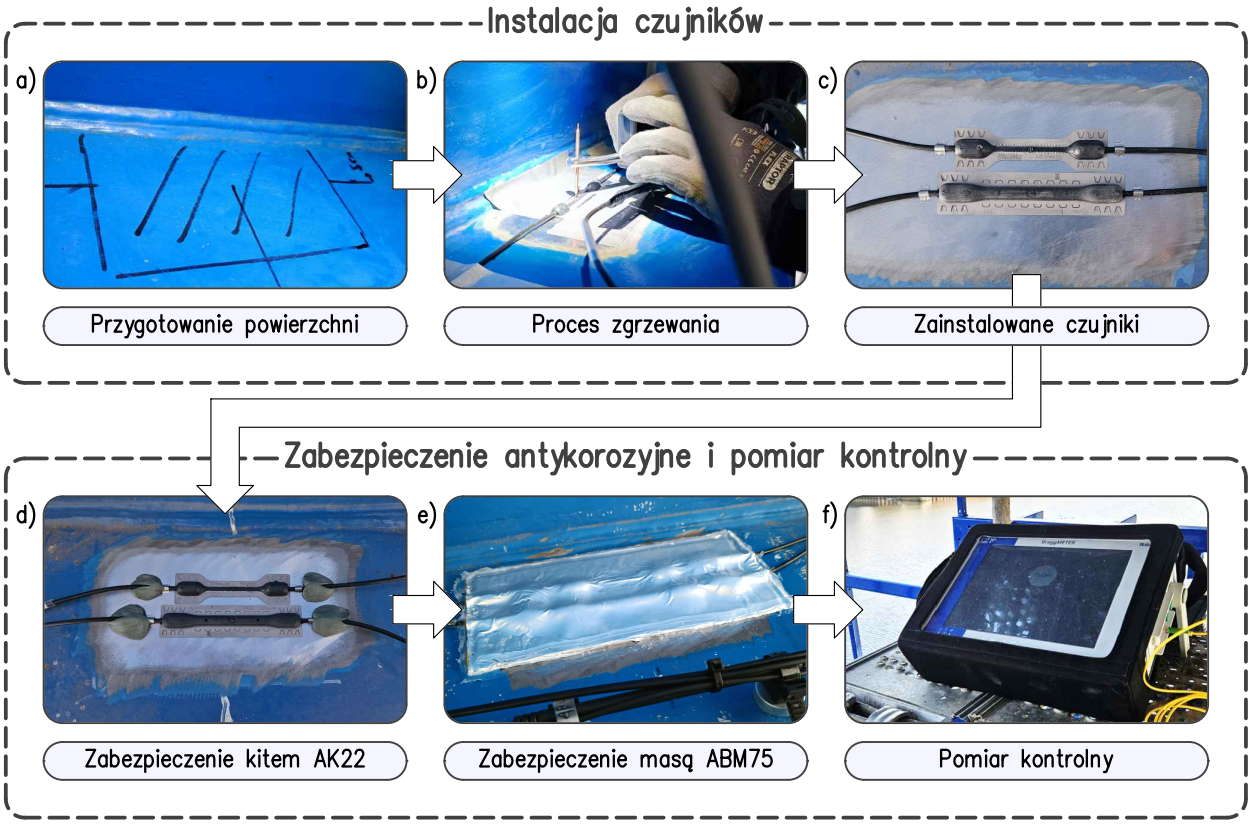

Rysunek 2.13. Proces instalacji czujników światłowodowych na poprzecznicach oraz podłużnicach

Zgrzewanie realizowano sekwencyjnie od środka czujnika do zewnętrznej krawędzi, z punktami oddalonymi od siebie o około 1 mm. Ograniczało to możliwość powstawania naprężeń montażowych oraz lokalnych odkształceń termicznych. W efekcie powstała gęsta baza punktów zgrzewania, zapewniająca równomierne przekazywanie odkształceń na długości całego czujnika (Rysunek 2.14).

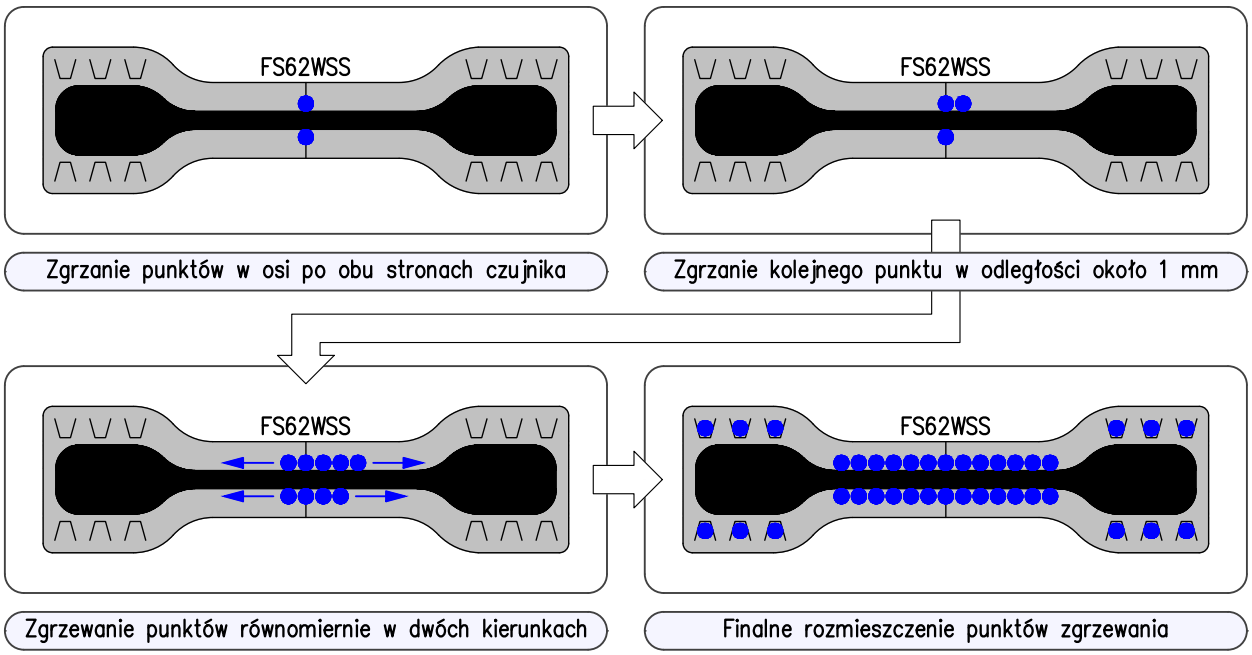

Rysunek 2.14. Schemat zgrzewania czujników, Wykonanie własne na podstawie [ST5]

Wieszaki badanego mostu są częścią systemu lin o pełnym zwoju zamkniętym. Obejmują one liny stalowe o wysokiej wytrzymałości, które uniemożliwiają zastosowanie zgrzewania w celu instalacji czujników. Ze względu na charakterystykę przekroju poprzecznego wieszaka, wykonano dedykowane zaciski (Rysunek 2.15a) do montażu czujników odkształceń (Rysunek 2.15b). Są one zainstalowane wraz z czujnikami temperatury (Rysunek 2.15c), zapewniającymi kompensację temperaturową.



Rysunek 2.15. Zainstalowane czujniki światłowodowe na wieszakach

Układy pomiarowe z każdej bramki zostały przyłączone do zbiorczych kabli, biegnących wzdłuż konstrukcji mostu (Rysunek 2.16a). Kable te posłużyły do przesyłania sygnałów ze wszystkich układów pomiarowych do interrogatora. Połączenia zostały natomiast zrealizowane w skrzynkach zainstalowanych na poprzecznicach każdej z bramek (Rysunek 2.16b), dzięki którym wszystkie łączenia są chronione przed oddziaływaniem czynników zewnętrznych. Zastosowano łącznie cztery kable zbiorcze, rozmieszczone zgodnie ze schematem przedstawionym na Rysunku 2.16. Każdy z nich składał się z czterech lub ośmiu kanałów, wyposażonych w złącza typu FC/APC (Rysunek 2.16c).

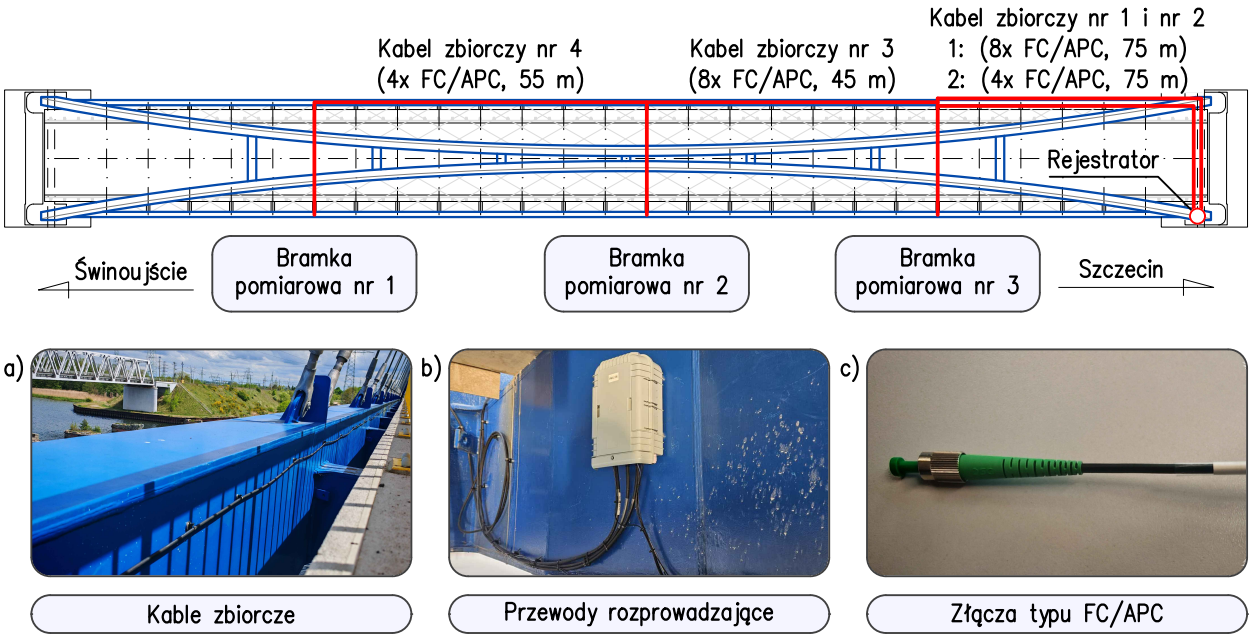

Rysunek 2.16. Przyłączenie ciągów pomiarowych z każdej bramki do kabli zbiorczych

Kable nr 1 i 2 zostały zainstalowane pomiędzy trzecią bramką pomiarową a interrogatorem i odpowiadają za transmisję sygnału ze wszystkich trzech bramek. Obejmują łącznie sześć układów pomiarowych, mają długość 75 m i zawierają osiem oraz cztery kanały. Każdy układ pomiarowy zakończony jest z obu stron złączem FC/APC (Rysunek 2.12), stąd łącznie wykorzystywanych jest dwanaście kanałów.

W skrzynce zlokalizowanej na trzeciej bramce pomiarowej (Rysunek 2.17c) łączone są dwa lokalne układy pomiarowe wraz z kablem zbiorczym nr 3, biegnącym od drugiej bramki pomiarowej. Kabel ten ma długość 50 m, zawiera osiem kanałów i przesyła sygnał z pierwszej oraz drugiej bramki.

Następnie w skrzynce zlokalizowanej na drugiej bramce pomiarowej (Rysunek 2.17b) następuje rozdzielenie sygnału na dwa układy pozostające w tej bramce oraz dwa kolejne prowadzone do pierwszej bramki pomiarowej. Połączenie najbardziej oddalonej od interrogatora bramki nr 1 zapewnia kabel zbiorczy nr 4, mający długość 55 m i zawierający cztery kanały. W skrzynce zlokalizowanej na pierwszej bramce pomiarowej (Rysunek 2.17a) łączy się on z dwoma ostatnimi układami pomiarowymi.

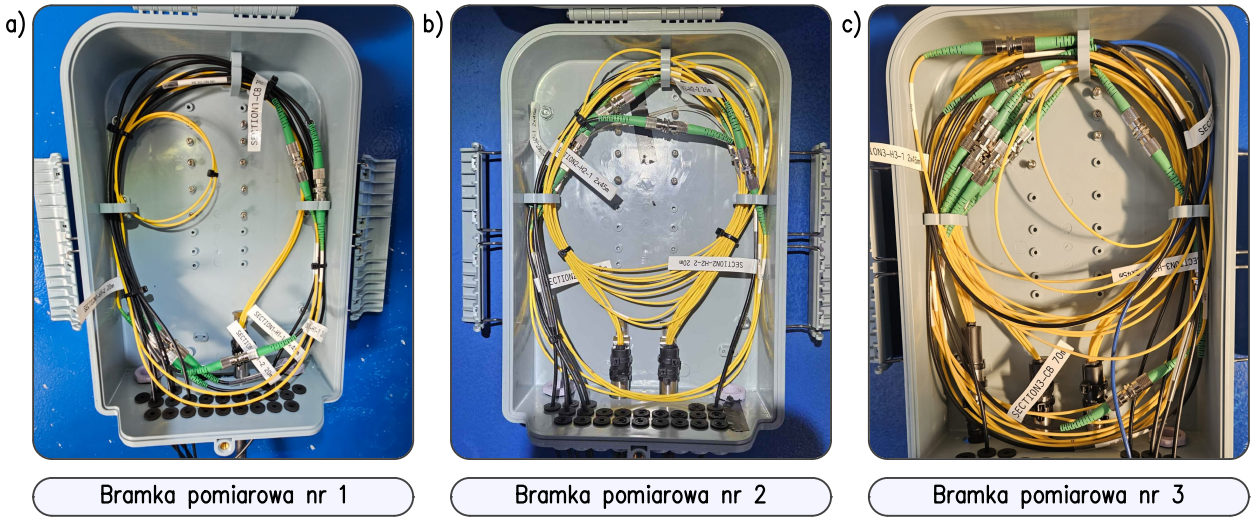

Rysunek 2.17. Skrzynki przyłączeniowe dla każdej z bramek pomiarowych

2.6.4 Pomiar towarzyszący urządzenia dylatacyjnego i łożyska

Pomiarami towarzyszącymi jest monitoring zmiany rozwarcia szczeliny dylatacyjnej oraz przemieszczeń i obrotów łożyska jednokierunkowo przesuwnego. W tym celu wykorzystano przetworniki przemieszczeń firmy *Peltron*. Pomiary te służą do oceny odpowiedzi zabudowanych elementów wyposażenia pod wpływem zmian temperatury oraz obciążeń eksploatacyjnych. Nie są one bezpośrednio wykorzystywane w procesie identyfikacji modelu numerycznego i detekcji masy pojazdów, stanowią jednak uzupełnienie systemu monitoringu. Umożliwiają bowiem kontrolę globalnej pracy całej konstrukcji i w przyszłości mogą zostać wykorzystane w analizach związanych z detekcją anomalii. Wystąpienie uszkodzenia prowadzącego do zmiany przemieszczeń na łożyskach lub urządzeniu dylatacyjnym powinno znaleźć odzwierciedlenie również w odpowiedzi pozostałych czujników zainstalowanych na konstrukcji.

Pomiar zmiany rozwarcia szczeliny dylatacyjnej (Rysunek 2.18a) realizowany jest za pomocą przetworników PLx600 [ST13]. Działanie urządzenia opiera się na pomiarze położenia rdzenia magnetycznego poruszającego się wewnątrz transformatora różnicowego. Zakres pomiarowy wynosi ±300 mm, a rozdzielczość 0,25 mm. Podstawowy błąd odczytów nie przekracza 0,1 % zakresu pomiarowego, a błąd temperaturowy 0,02 %/°C. Czujniki przystosowane są do pracy w temperaturze od –40 °C do 80 °C.

Pomiar obrotu płyty górnej łożyska zrealizowano za pomocą dwóch przetworników PSx20 [ST14], położonych wzdłuż osi podłużnej mostu. Zarejestrowana różnica przemieszczeń pionowych pomiędzy dwoma urządzeniami może posłużyć do wyznaczenia finalnej wartości obrotu. Ich zasada działania jest analogiczna jak w przypadku czujnika PLx600, jednak dodatkowo został on wyposażony w sprężynę zwrotną. Dzięki temu zapewniony jest ciągły kontakt z monitorowanym elementem. Zakres pomiarowy wynosi ±10,0 mm, a rozdzielczość pomiarowa 0,005 mm. Podstawowy błąd odczytów nie przekracza 0,1 % zakresu pomiarowego dla zakresów powyżej 10 mm. Przemieszczenia wzdłużne wyznaczane były natomiast za pomocą czujnika PLx400 [ST13]. Ich zasada działania i charakterystyki są analogiczne jak dla czujnika PLx600, a jedyną różnicą jest zakres pomiarowy, wynoszący ±200 mm (Rysunek 2.18b).

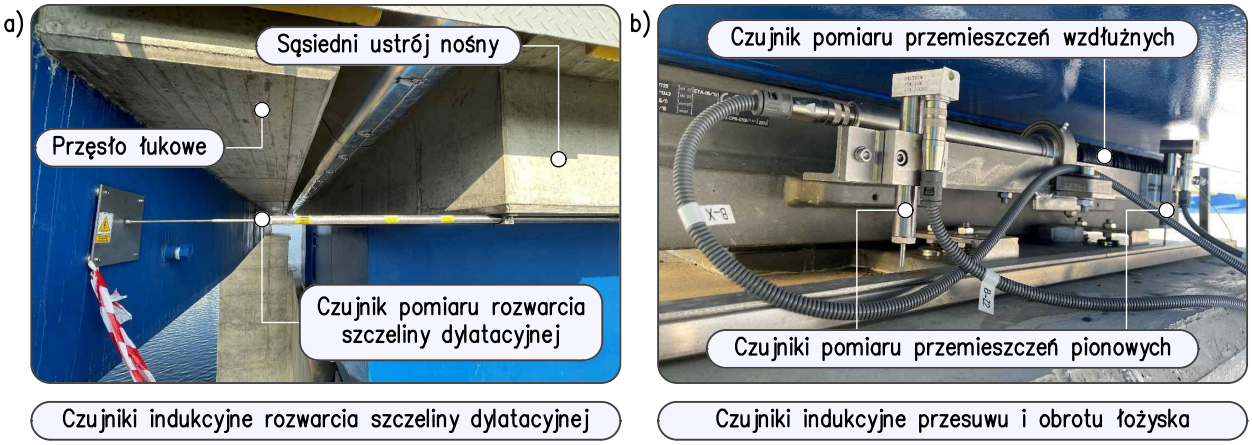

Rysunek 2.18. Pomiar towarzyszący urządzenia dylatacyjnego i łożyska

2.6.5 Metody gromadzenia danych

Rejestracja danych pomiarowych realizowana jest za pomocą interrogatora optycznego MXFS [ST10]. Identyfikuje on odczyty z czujników światłowodowych, odpowiadając tym samym za pomiar zmian długości fali Bragga. Zastosowany interrogator wyposażony jest w osiem złączy optycznych, umożliwiających rejestrację do szesnastu czujników FBG w każdym z nich. W efekcie urządzenie pozwala na synchroniczną rejestrację pomiarów z maksymalnie 128 czujników. Zakres pomiarowy interrogatora obejmuje długości fal w przedziale 1500 – 1600 nm, co odpowiada zakresowi pracy zastosowanych czujników światłowodowych. Umożliwia on pracę w dwóch trybach akwizycji danych. W trybie szybszego próbkowania rejestrowanych jest do 2000 próbek na sekundę, natomiast w wolniejszym, charakteryzującym

się wyższą dokładnością, do 100 próbek na sekundę. Rozdzielczość pomiaru długości fali wynosi poniżej 2 pm w trybie szybkiego próbkowania oraz poniżej 1 pm w trybie dokładnym, natomiast stabilność pomiarów 6 pm oraz 3 pm odpowiednio dla obu trybów rejestracji. Interrogator przystosowany jest do pracy ciągłej w zakresie temperatur od –20 °C do 50 °C oraz wilgotności względnej do 95 %.

Działanie interrogatora bazuje na analizie widma optycznego poszczególnych czujników [ST11]. Każdy z nich posiada indywidualną referencyjną długość fali Bragga, dzięki czemu możliwa jest jego identyfikacja w obrębie wspólnego układu pomiarowego. Interrogator identyfikuje położenie pików odpowiadających poszczególnym siatkom Bragga, a następnie wyznacza zmianę długości fali względem wartości referencyjnej. Przykładowe widmo optyczne dla bramki pomiarowej nr 1 zostało przedstawione na Rysunku 2.19. Przywołany układ pomiarowy składa się z trzech punktów zlokalizowanych na poprzecznicy, a w każdym z nich zainstalowane zostały czujniki odkształceń oraz temperatury. W efekcie cały tor światłowodowy składa się z sześciu kanałów, rozróżniając referencyjną długość fali Bragga dla każdego czujnika. Każdemu z nich przypisywana jest minimalna oraz maksymalna długość fali Bragga, tak aby zakresy poszczególnych pomiarów nie nachodziły na siebie nawzajem. Dzięki temu możliwa staje się identyfikacja konkretnych punktów pomiarowych w całym układzie. Wartości referencyjne długości fali Bragga zostały dobrane na podstawie kart katalogowych producenta czujników.

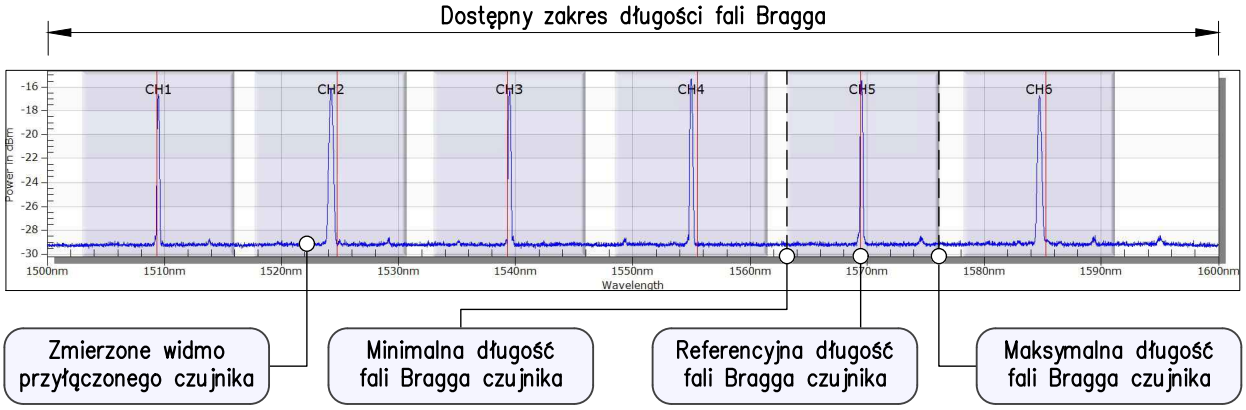

Rysunek 2.19. Przykładowe widmo optyczne identyfikowane przez interrogator MXFS

W szafie teleinformatycznej (Rysunek 2.20) zainstalowany został także rejestrator CX22B-W [ST2] oraz wzmacniacz MX840B [ST9]. CX22B-W odpowiada za komunikację z Interrogatorem oraz zapis danych, pochodzących ze wszystkich światłowodowych układów pomiarowych. Wyposażony jest w procesor Intel Atom Quad Core 1,9 GHz, 4 GB pamięci RAM oraz dysk SSD o pojemności 240 GB. Umożliwia synchroniczną rejestrację do 1000 sygnałów pomiarowych, bazując na oprogramowaniu Catman. Z kolei wzmacniacz MX840B wykorzystywany jest przy pomiarach przemieszczeń i obrotów łożyska oraz rozwarcia szczeliny dylatacyjnej. Urządzenie to wyposażone jest w osiem niezależnych kanałów pomiaro-

wych, umożliwiając rejestrację sygnałów z różnych typów przetworników. Oba urządzenia współpracują z komputerem przemysłowym, umożliwiając synchroniczny pomiar i zapis danych ze wszystkich czujników. Komputer ten odpowiada za obsługę oprogramowania pomiarowego, zapewniając także zdalny dostęp do całego systemu. Został wyposażony w procesor Intel Core i5-13400, płytę główną ASUS Pro Q670M-C-CSM, 32 GB pamięci RAM DDR5 oraz dwa dyski SSD o pojemności 2 TB każdy. Dodatkowo system pomiarowy został zabezpieczony na wypadek braku zasilania, wykorzystując zasilacz awaryjny UPS.

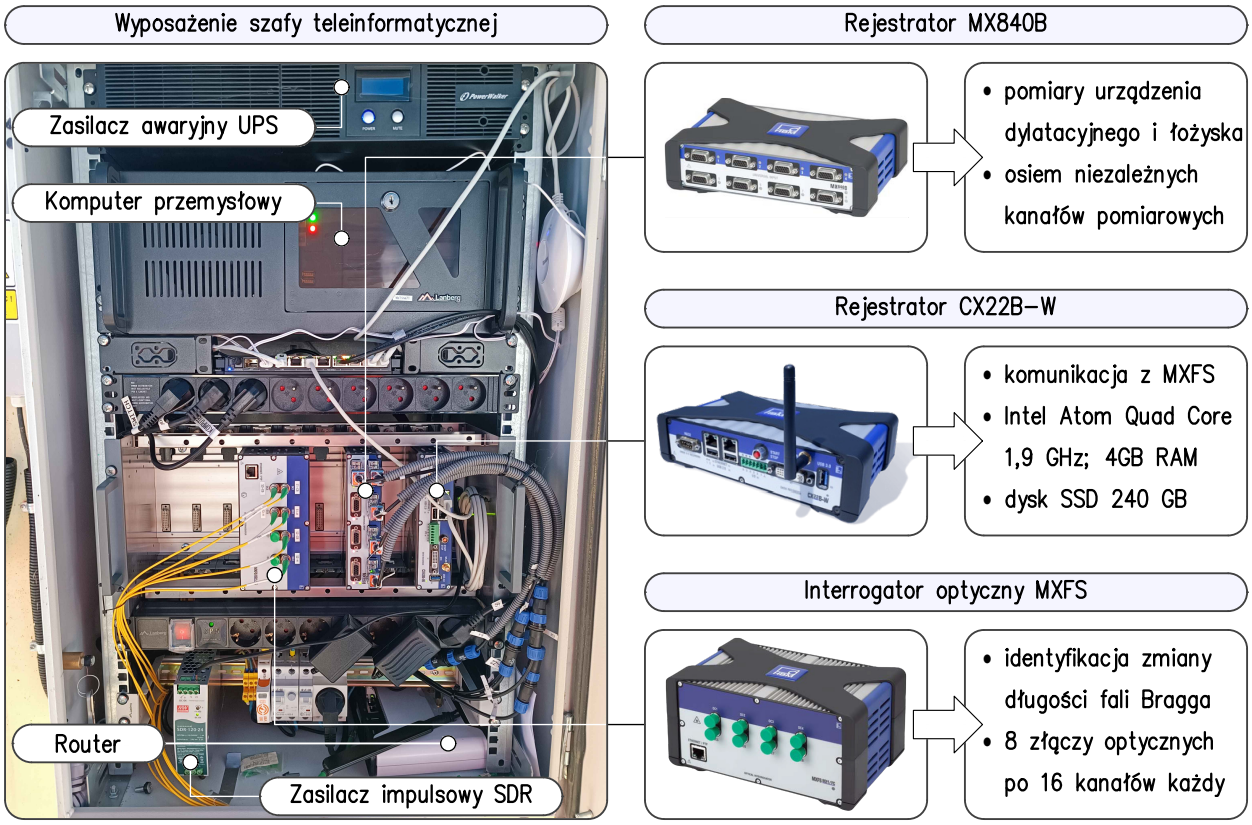

Rysunek 2.20. Wyposażenie szafy teleinformatycznej
Grafiki trzech urządzeń pomiarowych pochodzą z kart katalogowych producenta [ST2, ST9, ST10]

2.6.6 Wyznaczenie niepewności standardowej i rozszerzonej pomiarów

Podawany przez system wynik pomiaru będzie kompletny wtedy, gdy oprócz wartości mezurandu zawiera także związaną z nim niepewność pomiaru. W przypadku przedstawionego systemu mezurandami są wartości odkształceń y_i rejestrowane w poszczególnych punktach pomiarowych, których kolejne indeksy oznaczono jako i. Zależą one od skończonej liczby wielkości wejściowych x_i, gdzie $i \in \{1, \ldots, n\}$, przy czym n oznacza całkowitą liczbę punktów pomiarowych.

Wielkości wejściowe x_i odpowiadają poszczególnym źródłom niepewności pomiaru (Tabela 2.3), tworzącym ogólny budżet niepewności systemu. Wartość mezurandu jest zatem funkcją wielu zmiennych $y_i = f(x_1, x_2, ..., x_{m-1}, x_m)$, gdzie jako m oznaczono liczbę zdefiniowanych źródeł niepewności. Finalna wartość niepewności rozszerzonej pomiarów została wyznaczona metodą typu B.

Tabela 2.3. Przyjęte składowe niepewności standardowej pomiarów

Przyjęte składowe niepewności standardowej pomiarów	
Rozdzielczość urządzenia pomiarowego:	±5 µm/m
Zmiana lokalizacji obciążenia:	±0,50 m
Niepewność pomiaru masy pojazdu:	±138,40 kg
Przesunięcie punktu pomiarowego:	±0,20 m
Zmiana temperatury otoczenia podczas pomiaru:	±5 °C

Wartości składowych niepewności określono na podstawie warunków, w których realizowane były pomiary, a także procedur stosowanych w akredytowanym laboratorium „Zespół Badań Terenowych" Politechniki Śląskiej (nr akredytacji AB 1407). Składowa niepewności związana z urządzeniem pomiarowym została przyjęta na podstawie rozdzielczości czujników, zawartych w kartach technicznych producenta, oraz walidacji laboratoryjnej. Wartości dotyczące lokalizacji obciążenia oraz punktów pomiarowych oszacowano na podstawie możliwych odchyleń oraz dokładności stosowanego urządzenia pomiarowego. Składową związaną z masą pojazdu określono na podstawie wyznaczonej w laboratorium procedury, uwzględniającej niepewność wynikającą z działki elementarnej wagi oraz powtarzalności pomiarów. Składową zmiany temperatury otoczenia oszacowano natomiast na podstawie możliwych zmian warunków środowiskowych oraz dokładności stosowanego urządzenia pomiarowego.

Oszacowanie niepewności standardowej zostało przeprowadzone zgodnie z założeniami opisanymi w [ST1]. W tym celu wyznaczone zostały granice (dolna x^- oraz górna x^+) każdej wielkości wejściowej x_i. Założono przy tym, że wielkości te są opisane przez symetryczny, *a priori* prostokątny rozkład prawdopodobieństwa, w którym można przyjąć z jednakowym prawdopodobieństwem, że wartość wejściowa x_i leży gdziekolwiek wewnątrz utworzonego przedziału $x_i \in [x^-, x^+]$, natomiast prawdopodobieństwo jej występowania poza jego granicami jest zerowe. Następnie wartości graniczne poszczególnych wielkości wejściowych zostały wprowadzone do modelu pomiarowego, wyznaczając odpowiadające im minimalne a^- oraz maksymalne a^+ wartości odkształceń. Estymata $\hat{x}_i$ wpływu danej wielkości wejściowej x_i na wartość mezurandu została określona jako punkt środkowy przedziału $\hat{x}_i = (a^- + a^+)/2$. Odpowiadająca jej wariancja $u^2(\hat{x}_i)$, będąca kwadratem niepewności standardowej, opisana jest zależnością 2-3. Definiując szerokość przedziału jako $2a = a^+ - a^-$ przyjmuje ona postać zgodnie ze wzorem 2-4.

$$u^2(\hat{x}_i) = \frac{(a^+ - a^-)^2}{12} \tag{2-3}$$

$$u^2(\hat{x}_i) = \frac{a^2}{3} \tag{2-4}$$

Następnie niepewność standardową oszacowania wyniku $\hat{y}$ wyznaczono na podstawie wzoru 2-5.

$$u_c(\hat{y}) = \sqrt{\sum_i u^2(\hat{x}_i)} \tag{2-5}$$

Finalnie na podstawie wzoru 2-6 wyznaczono niepewność rozszerzoną. Przyjęto przy tym wartość $k_c = 1{,}65$ dla 95 % przedziału ufności i zadanego rozkładu prostokątnego, zgodnie z założeniami przedstawionymi w aneksie G [ST1]. Wyznaczona względna niepewność rozszerzona systemu pomiarowego wynosi 4,70 %, a schemat jej oszacowania przedstawiono na Rysunku 2.21.

$$U = k_c \cdot u_c(\hat{y}) \tag{2-6}$$

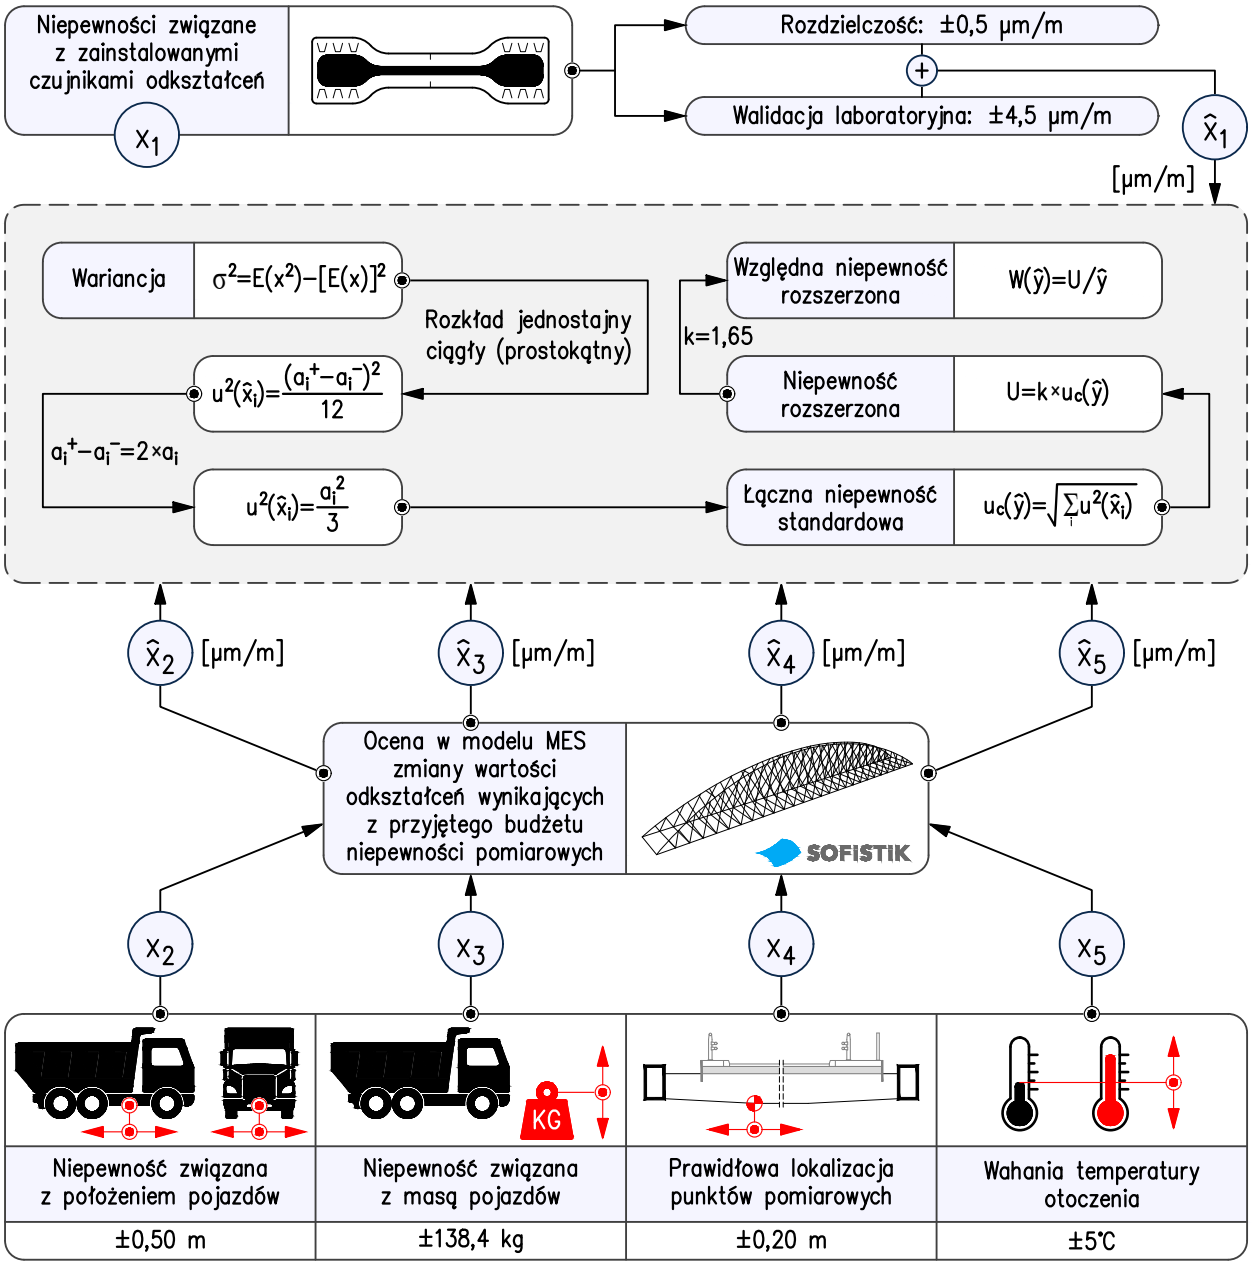

Rysunek 2.21. Schemat wyznaczenia niepewności rozszerzonej

2.7 Podsumowanie

W przedstawionym rozdziale opisano system monitoringu SHM wdrożony na moście łukowym. Jego celem jest realizacja funkcji ważenia pojazdów w ruchu, jako kluczowego źródła danych dla cyfrowego bliźniaka analizowanego obiektu. Wdrożony system obejmuje monitoring odkształceń w siedemnastu punktach pomiarowych z wykorzystaniem optycznych czujników światłowodowych bazujących na technologii siatki Bragga. W każdym punkcie zastosowano również kompensację temperaturową, rozmieszczając w jednym torze światłowodowym naprzemiennie czujniki odkształceń oraz temperatury.

Przed zainstalowaniem systemu przeprowadzone zostały symulacje numeryczne, mające na celu wyznaczenie linii wpływu podstawowych elementów konstrukcyjnych. Dla każdej z poprzecznic wykazały one ograniczony zasięg wpływu obciążenia, wynoszący około 36 m. Taka cecha konstrukcji oznaczała, że odkształcenia danej poprzecznicy pochodzą tylko od pojazdów znajdujących się w jej bezpośrednim sąsiedztwie. Na tej podstawie dobrano rozmieszczenie czujników, analizując trzy niezależne przekroje poprzeczne, określane mianem bramek pomiarowych. Zostały one zlokalizowane w $1/4$, $1/2$ oraz $3/4$ rozpiętości przęsła i gwarantowały separację sygnałów pochodzących z sąsiednich bramek oraz redukcję liczby punktów pomiarowych. Wieszaki natomiast charakteryzowały się globalnym charakterem pracy, odzwierciedlając sumaryczny wpływ wszystkich pojazdów znajdujących się na moście.

Każda z bramek pomiarowych zawierała trzy czujniki zainstalowane na poprzecznicach oraz po jednym na dwóch przeciwległych wieszakach. Dodatkowo druga bramka, zlokalizowana w środku rozpiętości przęsła, zawierała po jednym punkcie pomiarowym na każdej podłużnicy. Przeprowadzone analizy wykazały również zależność pomiędzy rejestrowanymi odkształceniami, a położeniem obciążenia na szerokości jezdni. Dzięki takiej charakterystyce oraz odseparowaniu sygnałów pochodzących z trzech bramek, możliwe będzie określenie dokładnego położenia pojazdu na długości i szerokości jezdni.

Rejestracja odkształceń realizowana jest za pomocą interrogatora MXFS oraz rejestratora CX22B-W. W ramach zainstalowanego systemu przewidziano również pomiar towarzyszący rozwarcia szczeliny dylatacyjnej oraz przemieszczeń i obrotu łożyska. W tym przypadku zapis danych odbywał się za pomocą wzmacniacza MX840B, a do pomiarów wykorzystano przetworniki przemieszczeń liniowych.

Po zainstalowaniu systemu pomiarowego ważnym krokiem weryfikującym jego poprawność działania jest przeprowadzenie badań pod próbnym obciążeniem. Uzyskane wyniki mogą stanowić podstawę dalszych analiz, w tym przeprowadzenia procesu identyfikacji modelu numerycznego. Docelowo, zainstalowany system SHM będzie stanowił podstawę w procesie budowy cyfrowego bliźniaka, bazującego na warstwie informacyjnej łączącej dane pomiarowe oraz modele analityczne. Opracowany system będzie umożliwiał przeprowadzanie bieżących symulacji oraz identyfikację obciążenia eksploatacyjnego.

3 | Badania pod próbnym obciążeniem

Cele rozdziału

Istotnym elementem wdrażanego systemu pomiarowego było przeprowadzenie badań pod próbnym obciążeniem statycznym oraz dynamicznym. W tym celu wykorzystanych zostało dziewięć pojazdów ciężarowych, charakteryzujących się zmienną geometrią oraz masą. Została ona wyznaczona przed rozpoczęciem badań z wykorzystaniem certyfikowanej wagi pomiarowej. Jej wartość mieściła się w przedziale od 27,8 t do 41,5 t. Badania statyczne uwzględniały pięć schematów obciążenia, w tym trzy zlokalizowane bezpośrednio nad każdą bramką pomiarową (oznaczone jako S1, S2 oraz S3), a także dwa niesymetryczne (N1 oraz N2). Badania dynamiczne obejmowały natomiast przejazdy każdego pojazdu z różnymi prędkościami oraz z wykorzystaniem dwóch pasów ruchu. Dodatkowo przeprowadzone zostały badania, w których pojazdy poruszały się w kolumnach oraz w sposób czysto losowy, symulując stochastyczny charakter rzeczywistego ruchu drogowego.

3.1 Wstęp

Badania pod próbnym obciążeniem są skuteczną metodą oceny istniejących i nowo wybudowanych mostów. Opierają się na terenowych pomiarach przemieszczeń, ugięć lub odkształceń, mając na celu weryfikację przestrzennej pracy konstrukcji. Ich zaletą jest nieniszczący charakter oraz minimalny wpływ na badany obiekt. Dzięki kontrolowanym warunkom obciążenia możliwe jest również dokładne powiązanie odpowiedzi konstrukcji z parametrami przejeżdżających pojazdów. Badania tego typu wykorzystywane są często w procesach identyfikacji modeli MES, a także oceny zgodności pracy konstrukcji z przyjętymi założeniami. Przykładowe badania przedstawili Colombani i in. [25], którzy przeprowadzili próbne obciążenie żelbetowego mostu płytowego. Autorzy wykonali pomiary przemieszczeń oraz odkształceń, a uzyskane wyniki posłużyły do identyfikacji modelu numerycznego oraz porównania rzeczywistej odpowiedzi z wynikami symulacji. Wang i in. [132] zrealizowali próbne obciążenie mostu podwieszonego dużej rozpiętości. Przeprowadzone badania obejmowały pomiary ugięć i odkształceń elementów głównych oraz wartości sił w linach. Zheng i in. [150] opisali z kolei próby obciążeniowe na przykładzie mostu trójprzęsłowego. Celem badań była weryfikacja zaproponowanej metody identyfikacji sztywności podpór oraz elementów głównych, bazującej na analizie linii wpływu ugięć, obrotów oraz odkształceń.

Przeprowadzane badania można podzielić na dwie zasadnicze grupy, obejmujące pomiary statyczne oraz dynamiczne. Badania statyczne opierają się na obserwacji zachowania konstrukcji pod zadanym obciążeniem i służą potwierdzeniu nośności obiektu oraz sprężystego charakteru pracy. Z kolei w badaniach dynamicznych najczęstszym celem jest wyznaczenie parametrów modalnych, takich jak częstotliwości czy postacie drgań własnych. Przykład połączenia badań statycznych i dynamicznych przedstawili Dong i in. [33]. Na przykładzie betonowego mostu drogowego autorzy przeprowadzili pomiary odkształceń, przemieszczeń oraz przyspieszeń. Uzyskane wyniki posłużyły następnie do przeprowadzenia analizy modalnej oraz identyfikacji modelu numerycznego. Również Innocenzi i in. [57] opisali znaczenie szerokiego programu badań eksperymentalnych, obejmujących próby statyczne i dynamiczne. Na przykładzie mostu wantowego pokazali rolę przeprowadzonych badań w procesie tworzenia cyfrowych bliźniaków, mających na celu odwzorowanie rzeczywistych obiektów. Li i in. [73] opisali natomiast wyniki badań statycznych i dynamicznych przeprowadzonych dla stalowego mostu kratownicowego eksploatowanego przez blisko 30 lat. Autorzy przedstawili tym samym, że badania pod próbnym obciążeniem są wykonywane również dla konstrukcji istniejących, często poddanych degradacji materiałowej.

Coraz częściej badania pod próbnym obciążeniem realizowane są również na obiektach monitorowanych z wykorzystaniem SHM. Wymaga to jednak pełnej integracji systemu pomiarowego wraz z narzędziami przetwarzania i analizy danych. W takim przypadku jednym z głównych celów badań jest nie tylko weryfikacja pracy konstrukcji, ale także identyfikacja modeli numerycznych, ocena czułości systemu oraz stworzenie bazy danych wykorzystywanych w dalszych analizach. Szczególną grupę badań stanowią przy tym testy realizowane na potrzeby systemów ważenia pojazdów w ruchu. Ich głównym celem jest identyfikacja parametrów obciążenia na podstawie zarejestrowanych pomiarów. Przykładowe badania przedstawili Shi i in. [117], którzy przeprowadzili testy terenowe na moście płytowo-belkowym. Badania obejmowały przejazdy trzech typów pojazdów, różniących się masą całkowitą oraz rozstawem osi. Autorzy rejestrowali przy tym wartości reakcji podporowych na potrzeby identyfikacji parametrów pojazdów. Hajializadeh i in. [48] przeprowadzili z kolei badania pod próbnym obciążeniem mostu kolejowego. Obejmowały one przejazdy wcześniej zważonych składów kolejowych, a zarejestrowane pomiary posłużyły do weryfikacji skuteczności opracowanego algorytmu ważenia pojazdów w ruchu.

Przeprowadzone w niniejszej pracy badania obejmowały zarówno schematy statyczne jak i próby dynamiczne. Do ich przeprowadzenia wykorzystano dziewięć pojazdów o zróżnicowanej masie oraz parametrach geometrycznych. Głównym celem badań była weryfikacja zainstalowanego systemu SHM oraz przyjętych na etapie jego wdrażania założeń. Uzyskane wyniki stanowiły następnie podstawę dalszych analiz, w tym były bazą do identyfikacji modelu MES oraz algorytmów ważenia pojazdów w ruchu.

3.2 Środki obciążające

W celu przeprowadzenia badań pod próbnym obciążeniem wykorzystanych zostało dziewięć pojazdów ciężarowych, w tym po trzy trójosiowe i czteroosiowe, dwa pięcioosiowe oraz jeden sześcioosiowy. Wszystkie pojazdy zostały ponumerowane w celu ich identyfikacji podczas badań, a dokładną charakterystykę każdego z nich przedstawiono w Tabelach 3.1 - 3.4. Uwzględniają one podstawowe parametry w tym geometrię oraz rozstawy i naciski na poszczególne osie. Wymiary gabarytowe (mierzone względem osi kół) oraz masy wszystkich pojazdów przedstawiono natomiast w Tabeli 3.5.

W badaniach uwzględnione zostały pojazdy o różnych długościach, szerokościach oraz rozstawach osi, co umożliwiło odwzorowanie możliwie szerokiego spektrum potencjalnych obciążeń. Dodatkowo każdy z pojazdów charakteryzował się różną masą, która przed badaniem została zweryfikowana za pomocą certyfikowanej wagi pomiarowej. Dane te zostały następnie włączone do modelu numerycznego, który po przeprowadzonym procesie identyfikacji będzie stanowił podstawę dalszych analiz i symulacji.

Tabela 3.1. Parametry pojazdu sześcioosiowego

Parametry pojazdu sześcioosiowego (oznaczonego jako nr 2)

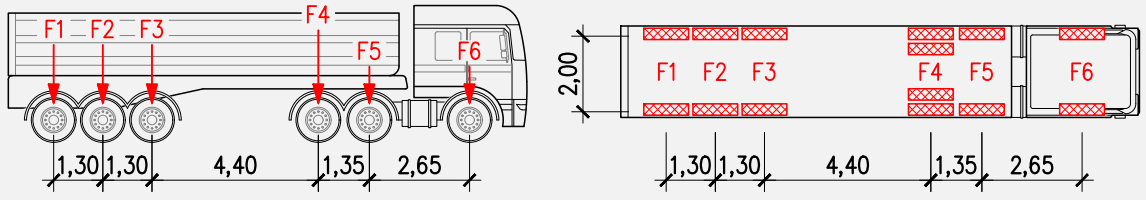

$F_1 = F_2 = F_3 = 78{,}7$ kN $\quad F_4 = 107{,}7$ kN $\quad F_5 = F_6 = 35{,}2$ kN

Tabela 3.2. Parametry pojazdów pięcioosiowych

Parametry pojazdów pięcioosiowych (oznaczone jako nr 1 i nr 3)

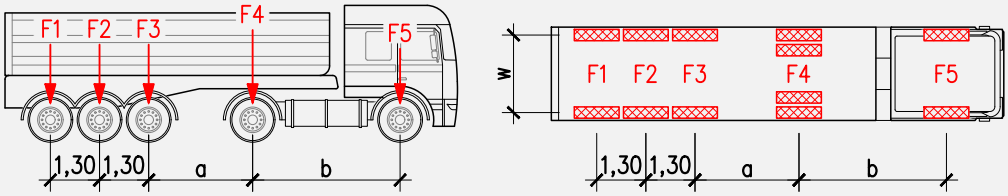

pojazd nr 1:
$a = 2{,}75$ m; $b = 3{,}90$ m
$w = 2{,}05$ m
$F_1 = F_2 = F_3 = 77{,}1$ kN
$F_4 = 105{,}6$ kN
$F_5 = 69{,}0$ kN

pojazd nr 3:
$a = 3{,}55$ m; $b = 3{,}70$ m
$w = 2{,}10$ m
$F_1 = F_2 = F_3 = 78{,}9$ kN
$F_4 = 108{,}0$ kN
$F_5 = 70{,}6$ kN

Tabela 3.3. Parametry pojazdów czteroosiowych

Parametry pojazdów czteroosiowych (oznaczone jako nr 4, 5 i 6)

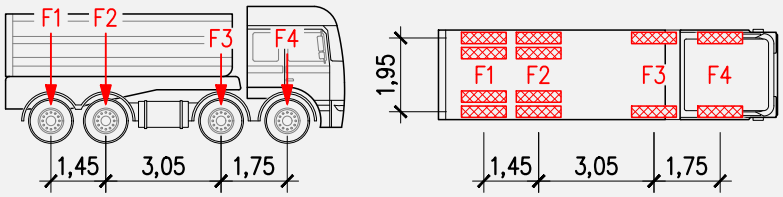

$F_1 = F_2 = 103{,}3$ kN $F_3 = F_4 = 62{,}0$ kN	pojazd nr 4	$F_1 = F_2 = 100{,}5$ kN $F_3 = F_4 = 60{,}3$ kN	pojazd nr 5	$F_1 = F_2 = 102{,}3$ kN $F_3 = F_4 = 61{,}4$ kN	pojazd nr 6

Tabela 3.4. Parametry pojazdów trójosiowych

Parametry pojazdów trójosiowych (oznaczone jako nr 7, 8 i 9)

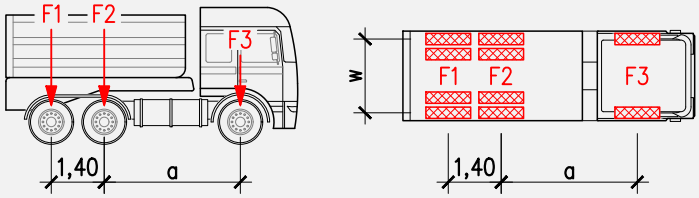

$a = 3{,}30$ m $w = 2{,}15$ m $F_1 = F_2 = 112{,}8$ kN $F_3 = 61{,}4$ kN	pojazd nr 7	$a = 3{,}60$ m $w = 1{,}95$ m $F_1 = F_2 = 109{,}1$ kN $F_3 = F_4 = 59{,}4$ kN	pojazd nr 8	$a = 3{,}20$ m $w = 2{,}20$ m $F_1 = F_2 = 113{,}1$ kN $F_3 = F_4 = 61{,}6$ kN	pojazd nr 9

Tabela 3.5. Wymiary gabarytowe oraz masy wszystkich pojazdów

Wymiary gabarytowe oraz masy wszystkich pojazdów

Nr pojazdu	Masa pojazdu [t]	Długość pojazdu [m]	Szerokość pojazdu [m]
1	40,6	9,25	2,05
2	41,4	11,00	2,00
3	41,5	9,85	2,10
4	33,0	6,25	1,95
5	32,2	6,25	1,95
6	32,7	6,25	1,95
7	28,7	4,70	2,15
8	27,8	5,00	1,95
9	28,9	4,60	2,20

3.3 Badania statyczne

Podczas badań statycznych zrealizowano pięć schematów obciążenia, dobranych w taki sposób, aby wywołać maksymalne wartości odkształceń w wybranych punktach pomiarowych. Obejmowały one trzy schematy zlokalizowane bezpośrednio nad poszczególnymi bramkami pomiarowymi (oznaczone jako S1, S2 oraz S3), a także dwa dodatkowe schematy niesymetryczne (oznaczone jako N1 oraz N2). Badania przeprowadzono przy dziennym oświetleniu, temperaturze do 8 °C, umiarkowanym zachmurzeniu oraz braku opadów i słabym wietrze. Pozwoliło to ograniczyć wpływ czynników zewnętrznych na otrzymywane wyniki pomiarów. W trakcie badań uruchomiony został system pomiarowy, rejestrujący odkształcenia we wszystkich bramkach pomiarowych. Położenie pojazdów dla schematów S1-S3 w przekroju podłużnym oraz poprzecznym przedstawiono na Rysunku 3.1 oraz 3.2.

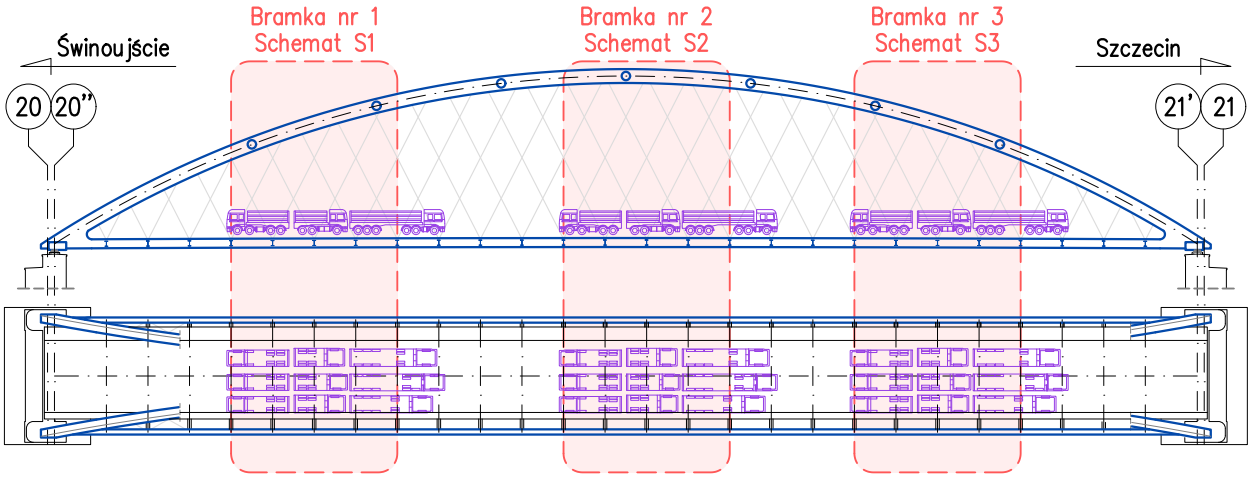

Rysunek 3.1. Założone położenie pojazdów w przekroju podłużnym dla schematów S1-S3

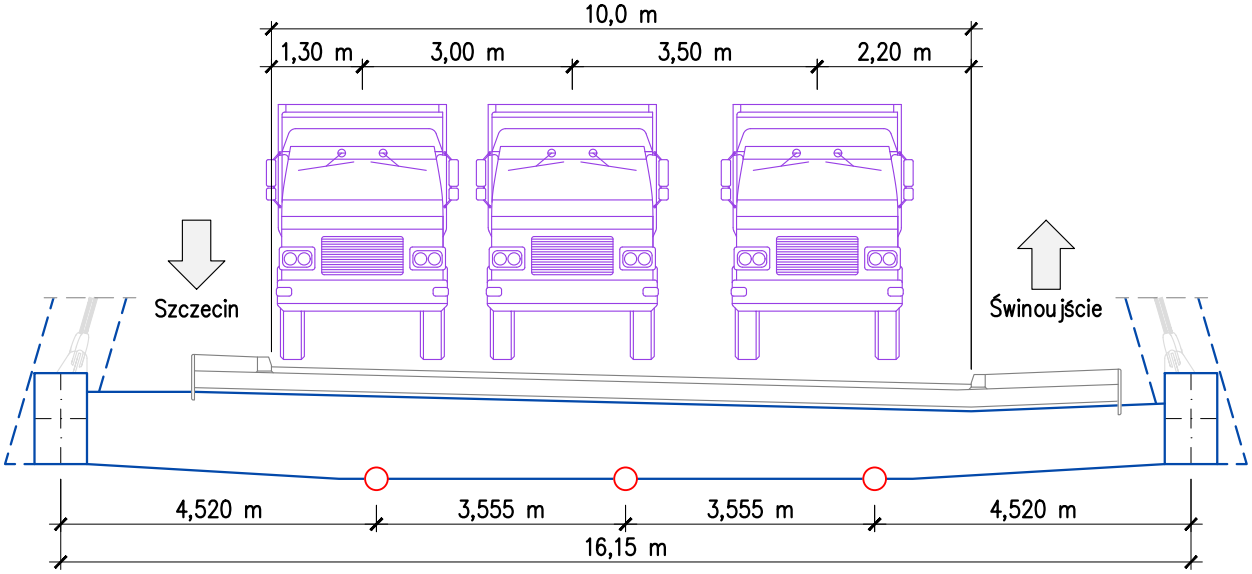

Rysunek 3.2. Założone położenie pojazdów w przekroju poprzecznym dla schematów S1-S3

Każdy przypadek obciążenia obejmował wszystkie dziewięć pojazdów, zapewniając łączną masę przekraczającą 306 t. Przebieg badań dla schematów S1-S3 przedstawiono na Rysunku 3.3.



Rysunek 3.3. Przeprowadzone badania statyczne - schematy S1-S3

Po wykonaniu schematów S1-S3 zrealizowano dodatkowe dwa przypadki obciążenia niesymetrycznego, w których pojazdy zostały rozmieszczone w kolumnie po jednej stronie jezdni. Ich położenie w przekroju podłużnym oraz poprzecznym przedstawiono na Rysunku 3.4 oraz 3.5.

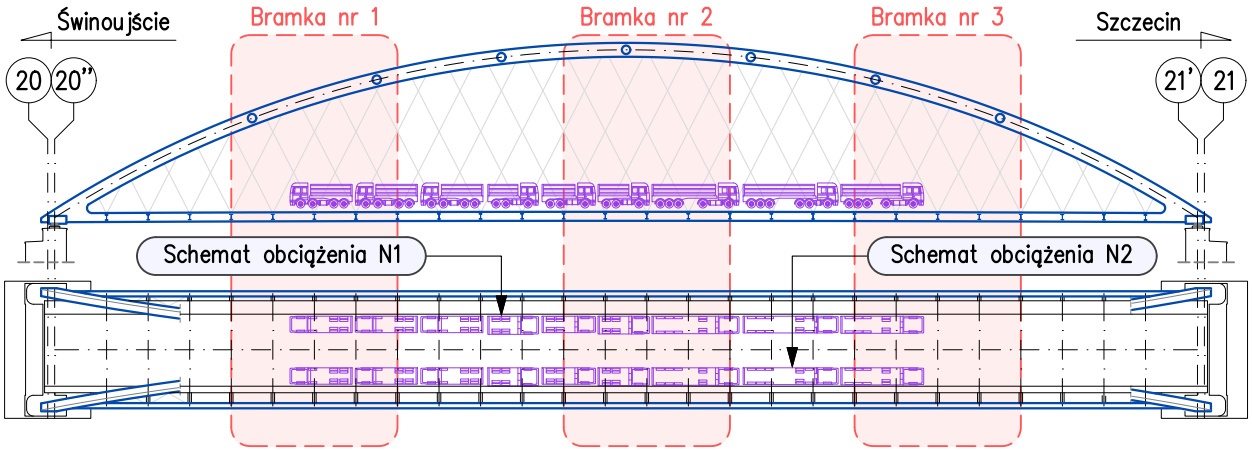

Rysunek 3.4. Założone położenie pojazdów w przekroju podłużnym dla schematów N1 oraz N2

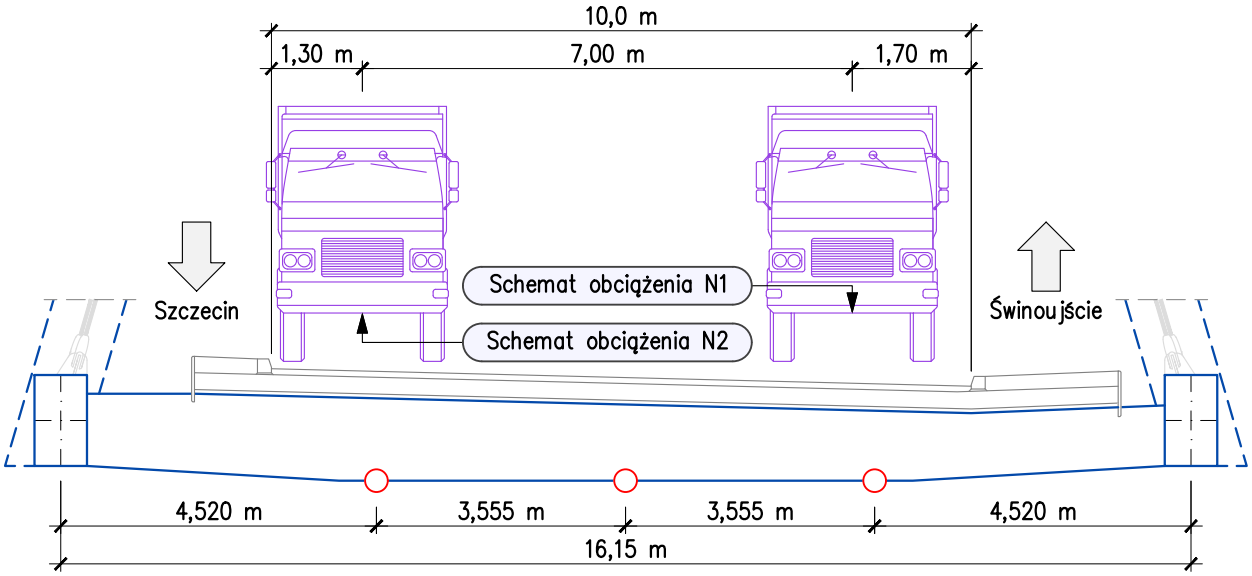

Rysunek 3.5. Założone położenie pojazdów w przekroju poprzecznym dla schematów niesymetrycznych N1 oraz N2

Celem zrealizowanych schematów było wywołanie niesymetrycznego obciążenia, pozwalającego na ocenę rozdziału sił wewnętrznych. W przeciwieństwie do schematów S1-S3, skoncentrowanych na maksymalizacji obciążeń w obrębie danej bramki pomiarowej, przypadki N1 i N2 umożliwiły dodatkową analizę wpływu poprzecznego położenia pojazdów. Przebieg badań przedstawiono na Rysunku 3.6.

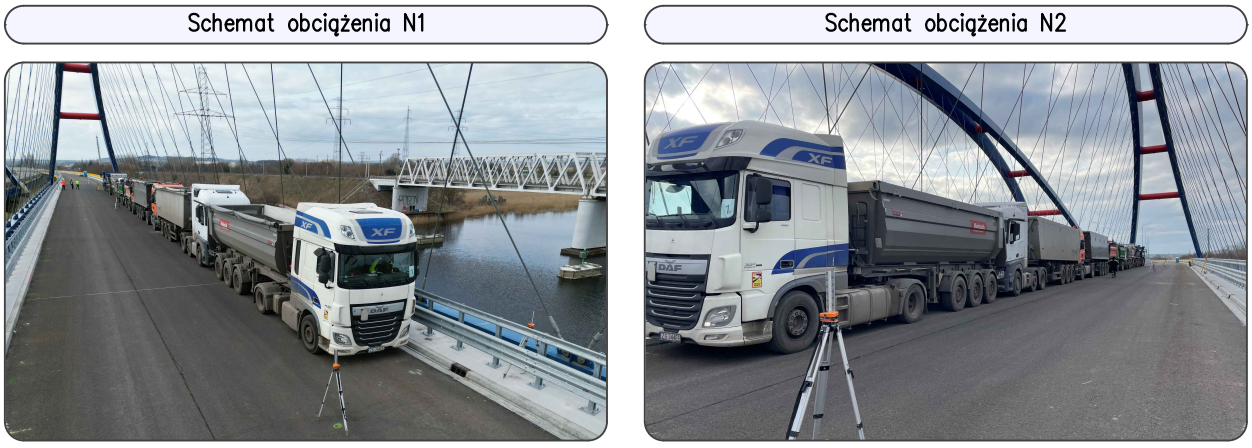

Rysunek 3.6. Przeprowadzone badania statyczne - schematy N1 oraz N2

W każdym przypadku obciążenia statycznego kolejne pomiary realizowano w odstępach dziesięciominutowych. Kontynuowano je do momentu, gdy różnice pomiędzy kolejnymi wskazaniami nie przekraczały granicy 2,0 %. Po zakończeniu pomiarów pojazdy usuwano z obiektu, co umożliwiało rejestrację odkształceń po odciążeniu. W tej fazie wykonano co najmniej dwa kolejne pomiary, również w odstępach dziesięciominutowych, aż do osiągnięcia stabilizacji. Zarejestrowane odkształcenia przedstawiono na Rysunku 3.7 dla schematów S1-S3 oraz na Rysunkach 3.8 i 3.9 dla przypadków N1 oraz N2. Wyniki badań wykorzystano następnie do identyfikacji modelu MES, której przebieg omówiono w Rozdziale 4.

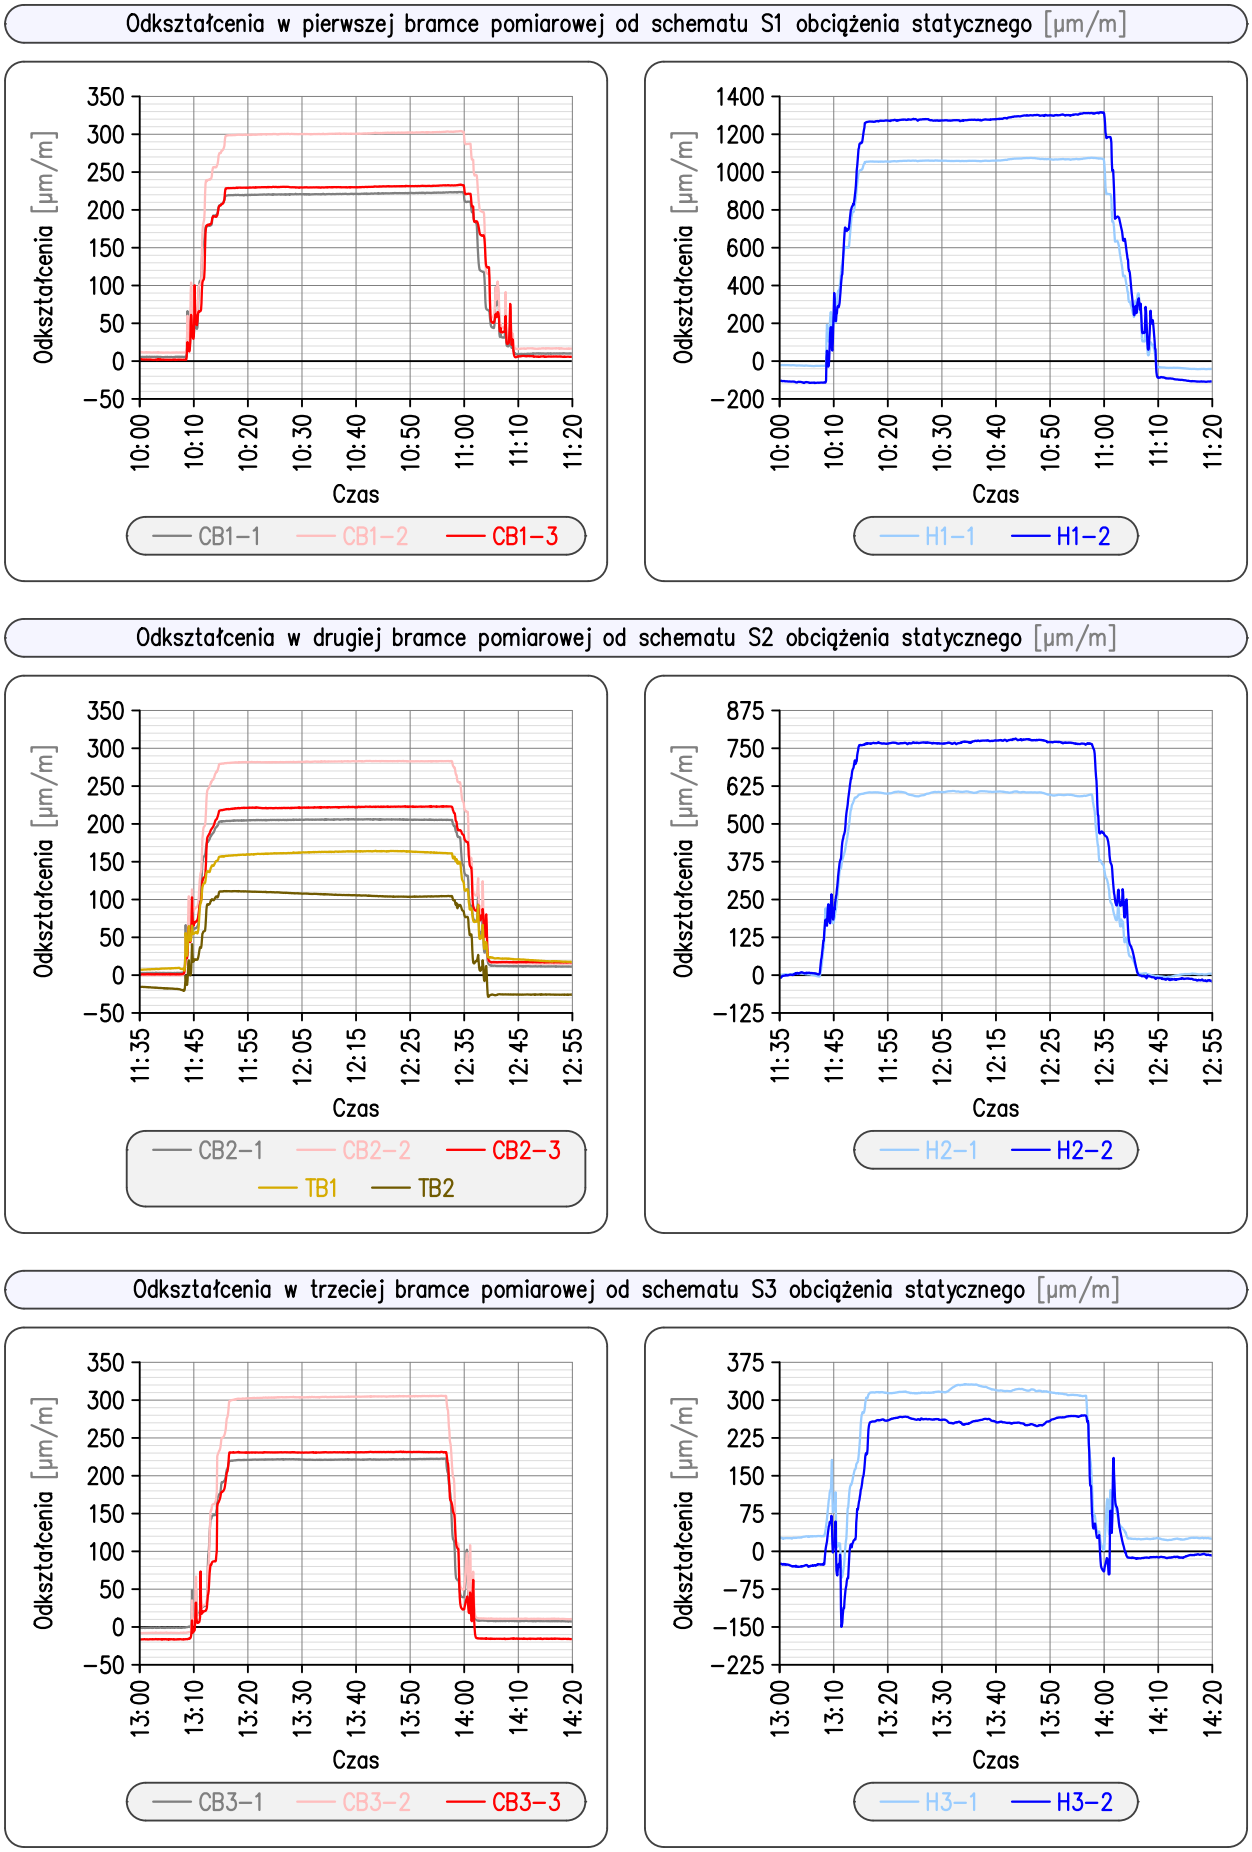

Rysunek 3.7. Wartości odkształceń dla schematów S1-S3

Odkształcenia w pierwszej bramce pomiarowej od schematu N1 obciążenia statycznego [µm/m]

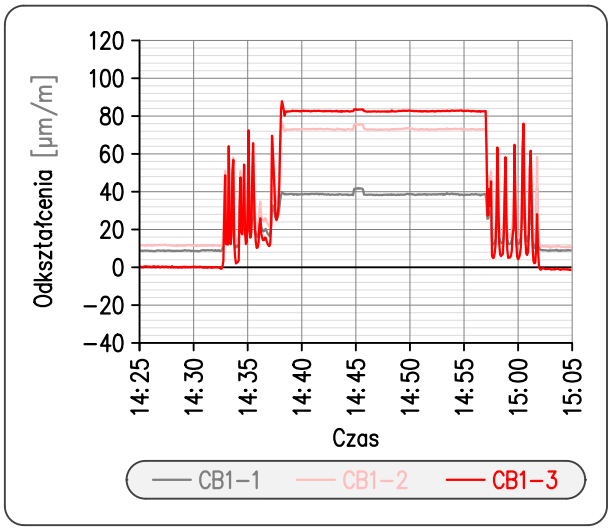

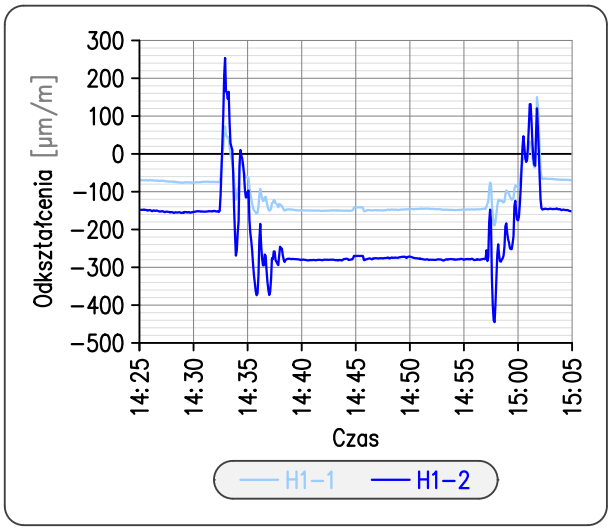

Odkształcenia w drugiej bramce pomiarowej od schematu N1 obciążenia statycznego [µm/m]

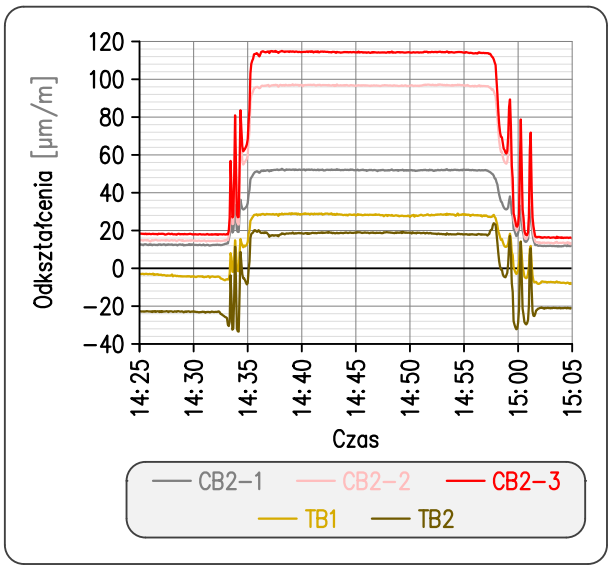

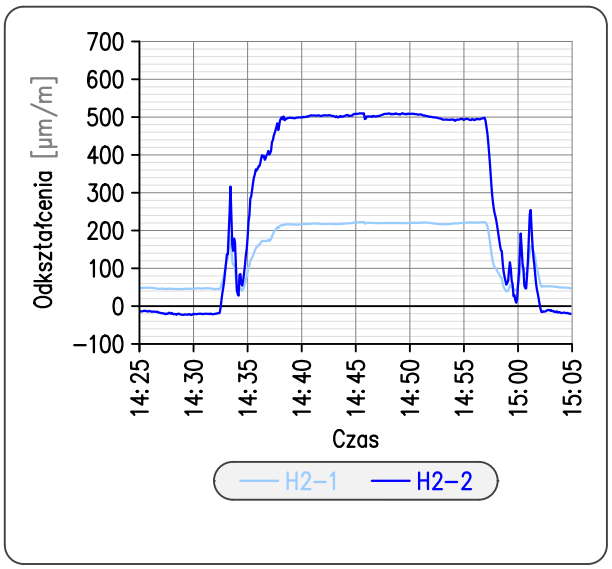

Odkształcenia w trzeciej bramce pomiarowej od schematu N1 obciążenia statycznego [µm/m]

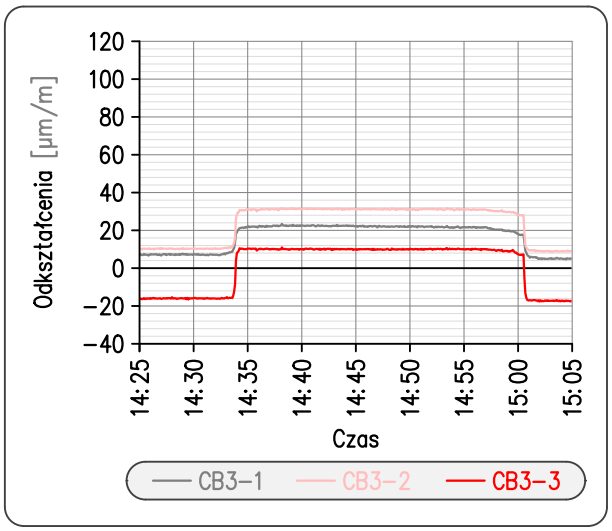

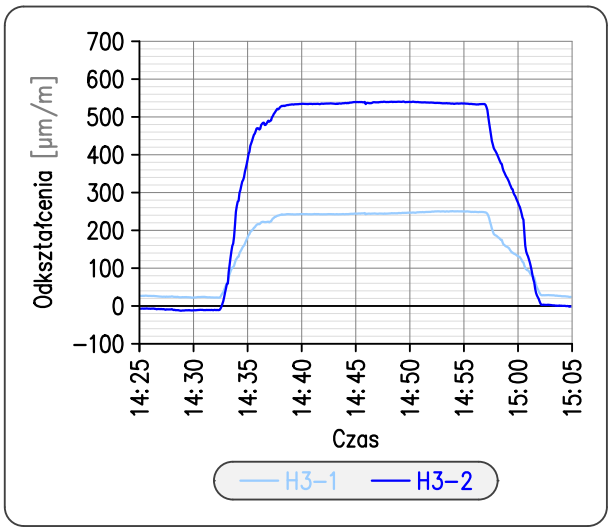

Rysunek 3.8. Wartości odkształceń dla schematu N1

Odkształcenia w pierwszej bramce pomiarowej od schematu N2 obciążenia statycznego [µm/m]

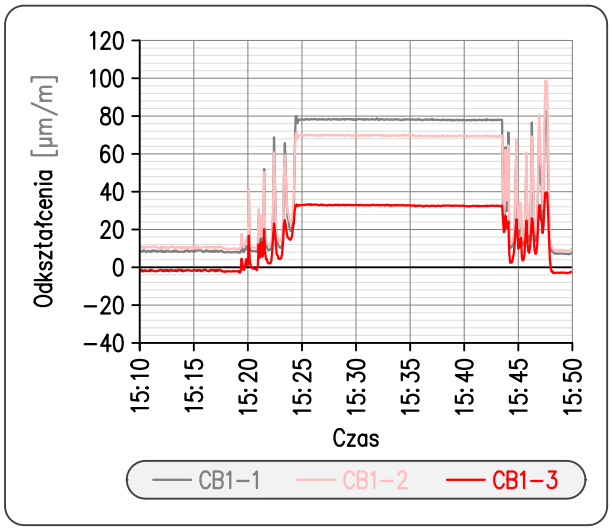

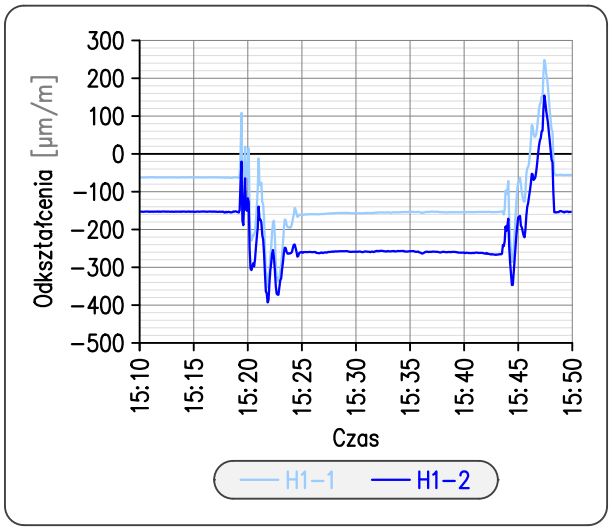

Odkształcenia w drugiej bramce pomiarowej od schematu N2 obciążenia statycznego [µm/m]

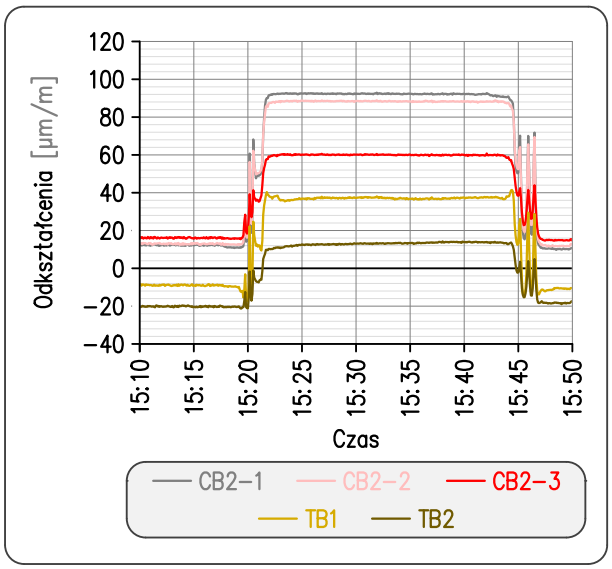

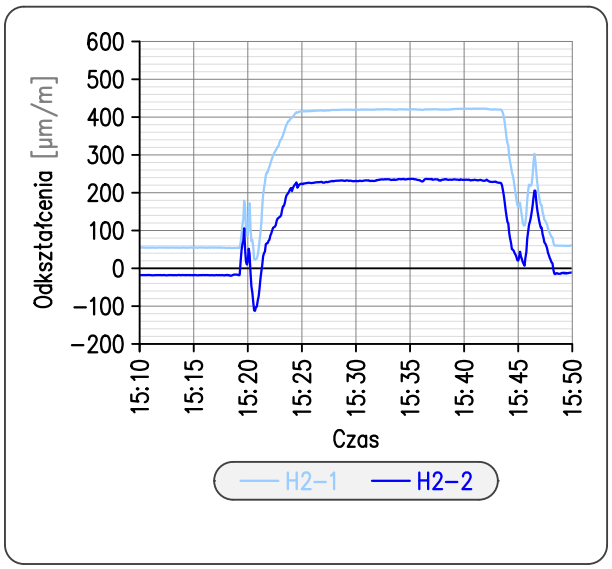

Odkształcenia w trzeciej bramce pomiarowej od schematu N2 obciążenia statycznego [µm/m]

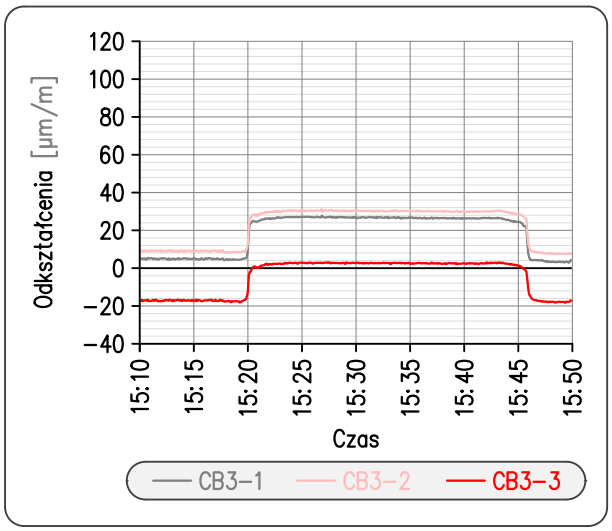

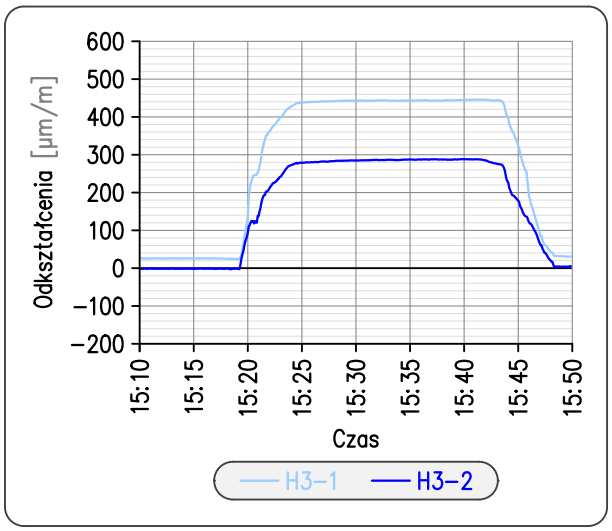

Rysunek 3.9. Wartości odkształceń dla schematu N2

3.4 Badania dynamiczne

3.4.1 Przejazdy pojedynczych pojazdów

Oprócz badań statycznych przeprowadzono również badania pod próbnym obciążeniem dynamicznym z wykorzystaniem pojazdów poruszających się pojedynczo oraz w grupach. Testy obejmowały przejazdy realizowane w dwóch pasach ruchu oraz z różnymi prędkościami, przy wykorzystaniu pojazdów o różnych masach całkowitych. Celem badań była identyfikacja odpowiedzi dynamicznej oraz weryfikacja założeń przeprowadzonej analizy statycznej, mającej na celu odpowiednie dobranie lokalizacji urządzeń pomiarowych. Badania umożliwiły również ocenę poprawności działania systemu, w tym analizę możliwości wykorzystania rejestrowanych danych do identyfikacji pojazdów znajdujących się na obiekcie. Lokalizację punktów pomiarowych oraz pasów ruchu przedstawiono na Rysunku 3.10.

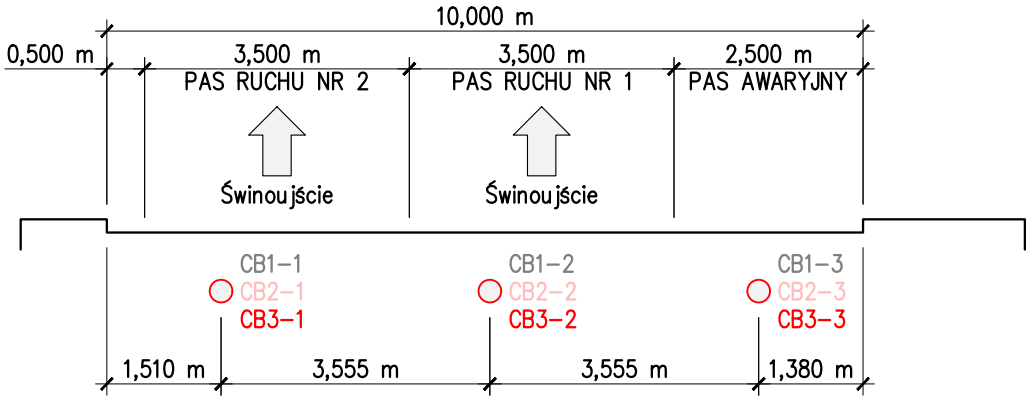

Rysunek 3.10. Przekrój ruchowy oraz lokalizacja punktów pomiarowych i pasów ruchu

Program badań dynamicznych obejmował w pierwszej kolejności przejazdy pojedynczych pojazdów, realizowane w obu pasach ruchu. W celu zapewnienia powtarzalnych warunków pasy te zostały dokładnie wyznaczone z wykorzystaniem słupków prowadzących. Umożliwiało to utrzymanie stałego położenia pojazdu na szerokości jezdni, w szczególności nad każdą z bramek pomiarowych (Rysunek 3.11).



Rysunek 3.11. Przebieg badań dynamicznych z wykorzystaniem pojedynczych pojazdów

Przykładowe przebiegi odkształceń zarejestrowane podczas przejazdu pojedynczego pojazdu przedstawiono na Rysunkach 3.12, 3.13 oraz 3.14. Obejmują one odkształcenia zarejestrowane przez trzy punkty pomiarowe zlokalizowane na poprzecznicy oraz po jednym punkcie zainstalowanym na obu podłużnicach oraz przeciwległych wieszakach. Przedstawione przebiegi zarejestrowano w drugiej bramce pomiarowej, znajdującej się w środku rozpiętości przęsła, podczas przejazdu pojazdu oznaczonego numerem 4, o masie całkowitej 33,04 t. Poruszał się on pasem nr 1 ze stałą prędkością 10 km/h. Na wykresach przedstawiono również znaczniki czasowe odpowiadające chwili wjazdu oraz zjazdu pojazdu z mostu, a także przedział czasowy, w którym znajdował się on bezpośrednio nad bramką pomiarową.

Na podstawie przeprowadzonych badań doświadczalnie potwierdzono założenia przyjęte w analizie statycznej (Punkt 2.5). Zarejestrowane przebiegi odkształceń wskazują na ograniczony zasięg wpływu obciążenia na odkształcenia rejestrowane w punktach pomiarowych poprzecznic oraz podłużnic. Zakres ten wynosi około 36 m i obejmuje obszar bezpośrednio nad analizowaną bramką pomiarową.

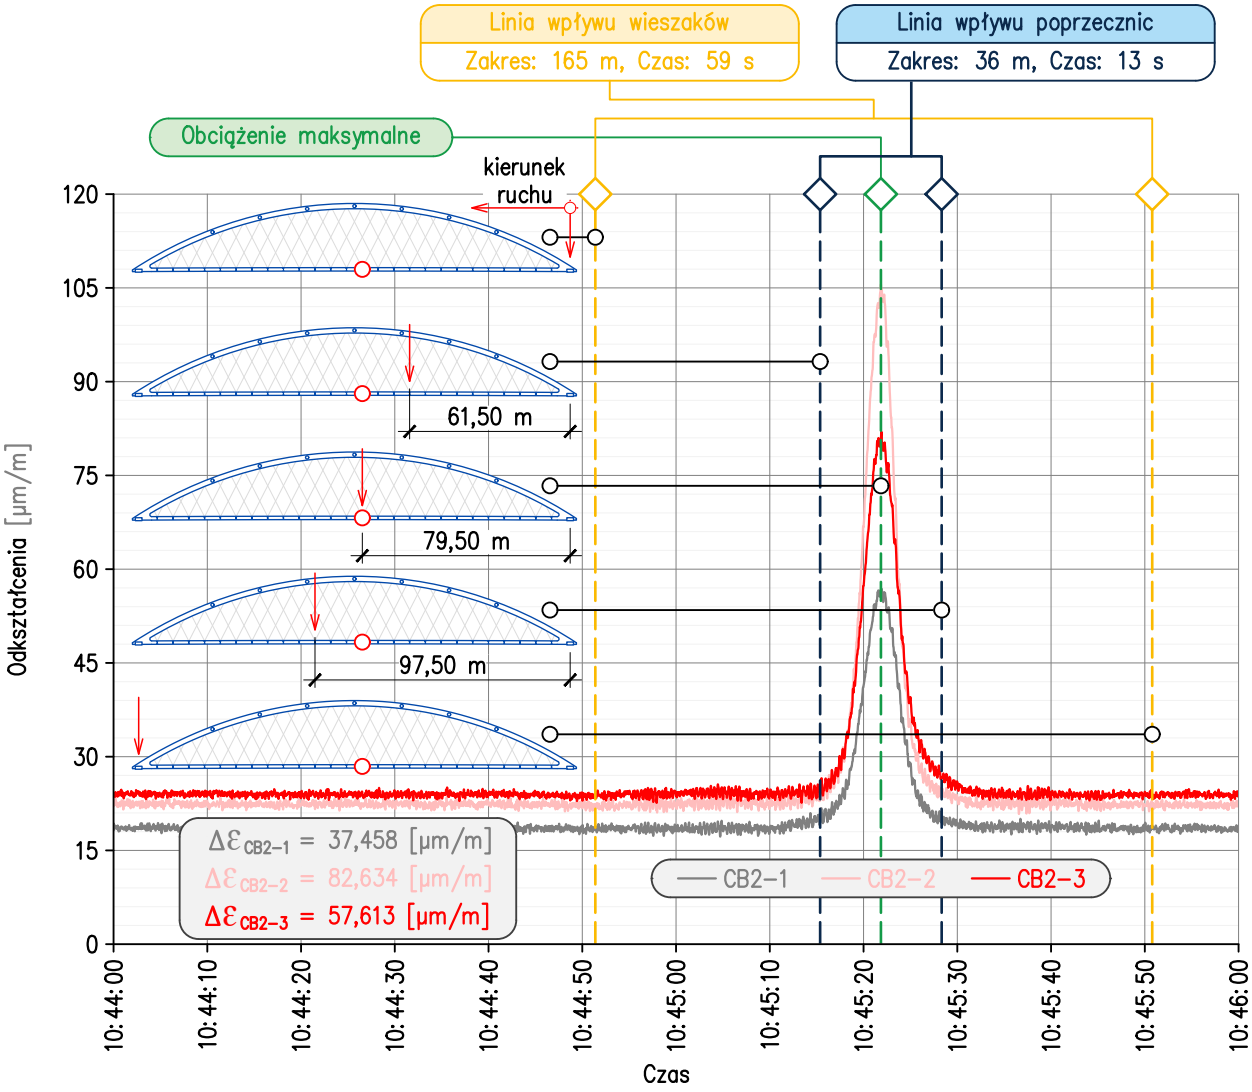

Rysunek 3.12. Wartości odkształceń na poprzecznicach w bramce pomiarowej nr 2 od obciążenia dynamicznego

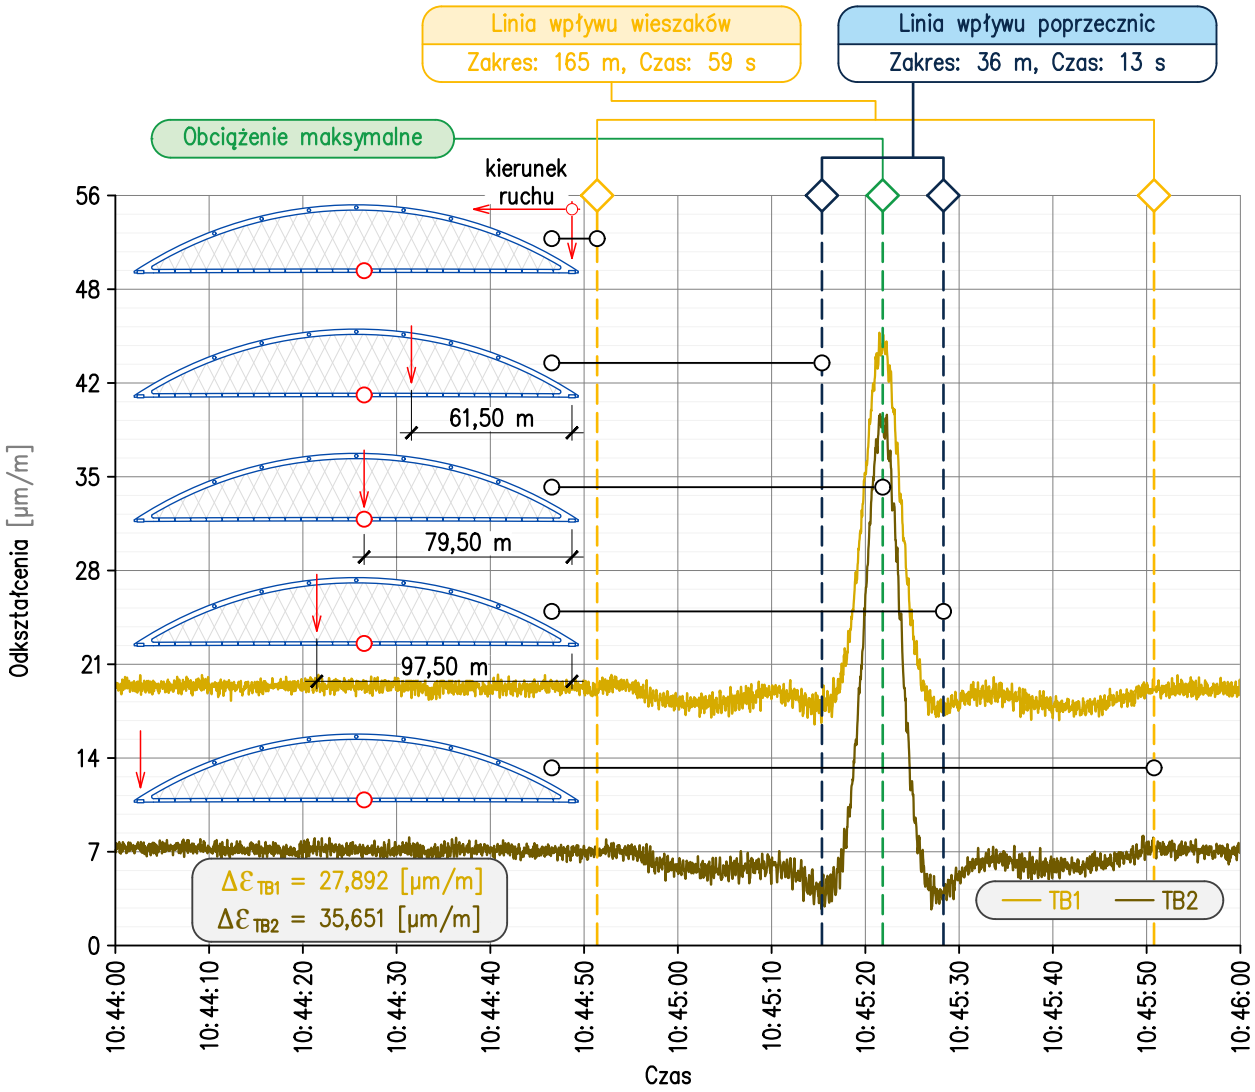

Rysunek 3.13. Wartości odkształceń na podłużnicach w bramce pomiarowej nr 2 od obciążenia dynamicznego

Zakres linii wpływu dla punktów pomiarowych zlokalizowanych na poprzecznicach oraz podłużnicach jest ograniczony. W efekcie pojazd znajdujący się w większej odległości od bramki pomiarowej nie wpływa istotnie na rejestrowane odkształcenia. W przypadku poprzecznic przebieg odkształceń poza obszarem oddziaływania obciążenia pozostaje w przybliżeniu liniowy i obejmuje głównie szum pomiarowy. Z kolei dla podłużnic zauważalne są niewielkie fluktuacje odkształceń, potwierdzające przebieg linii wpływu sił wewnętrznych opisanych w analizie statycznej. Potencjalnie użyteczny staje się zatem system, w którym identyfikacja masy pojazdu odbywa się niezależnie na trzech bramkach, umożliwiając uśrednienie lub walidację krzyżową uzyskiwanych wyników. Szczególnie istotne są przy tym punkty pomiarowe zlokalizowane na poprzecznicach, charakteryzujące się lokalnym charakterem odpowiedzi.

Zastosowanie trzech punktów na poprzecznicy umożliwia również określenie dokładnej trasy przejazdu. Zauważalne są różnice wartości amplitud odkształceń rejestrowanych przez poszczególne punkty pomiarowe, pozwalając tym samym na identyfikację położenia pojazdu na szerokości jezdni.

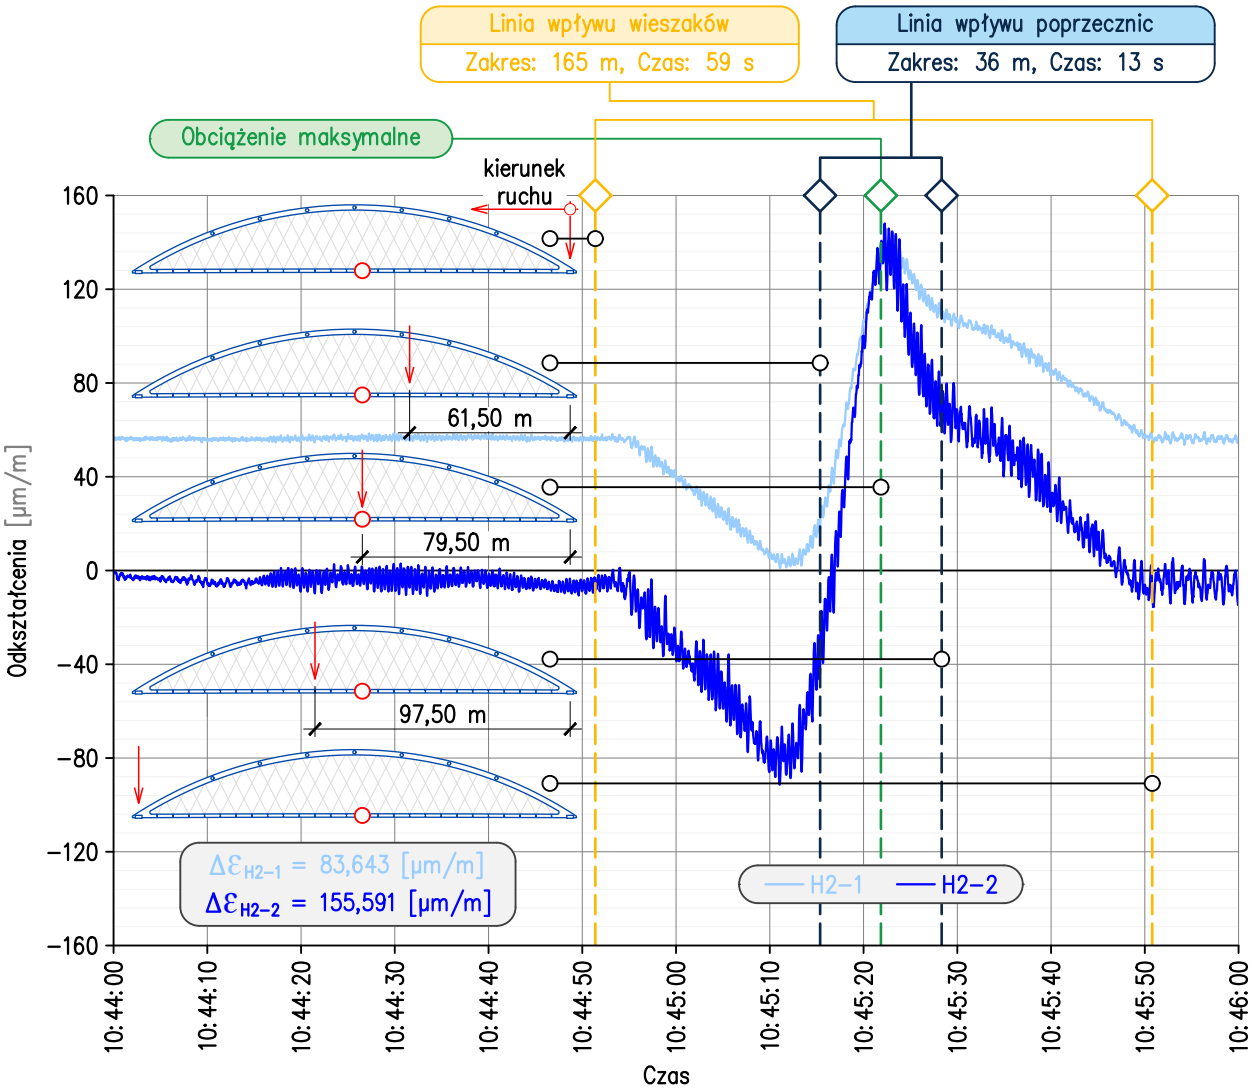

Rysunek 3.14. Wartości odkształceń w wieszakach w bramce pomiarowej nr 2 od obciążenia dynamicznego

Wieszaki charakteryzują się większą wrażliwością na obciążenie występujące poza bezpośrednim obszarem bramki pomiarowej. Odkształcenia zarejestrowane podczas tej samej próby wykazują wyraźnie większy zasięg oddziaływania obciążenia w porównaniu do punktów pomiarowych zlokalizowanych na poprzecznicach. Maksymalne wartości odkształceń osiągane są w chwili przejazdu bezpośrednio nad bramką pomiarową, jednak zauważalny pozostaje również wpływ obciążeń zlokalizowanych w dalszej odległości. W efekcie pojazdy znajdujące się w różnych obszarach mostu wywierają wpływ na rejestrowane odkształcenia. Widoczne są również zróżnicowane poziomy amplitud odkształceń, które są zależne od położenia pojazdu na szerokości jezdni, w tym jego odległości od analizowanego wieszaka.

Każdy z przejazdów ma charakter krótkotrwały, przez co wpływ oddziaływań długotrwałych, w tym termicznych i środowiskowych, pozostaje ograniczony. Ponadto, w procedurze szacowania masy pojazdów analizowane będą zmiany odkształceń pomiędzy stanem nieobciążonym oraz obciążonym, co pozwoli dodatkowo zminimalizować wpływ efektów zewnętrznych.

Przeprowadzone badania obejmowały również szereg innych przejazdów, realizowanych z wykorzystaniem wszystkich dziewięciu pojazdów, poruszających się oboma pasami ruchu. W każdym przypadku obserwowano analogiczny charakter odpowiedzi konstrukcji, różniący się głównie amplitudami rejestrowanych odkształceń. Wyższe wartości amplitud odpowiadały punktom pomiarowym zlokalizowanym bliżej toru przejazdu oraz przypadkom, w których wykorzystywane były pojazdy o większej masie.

Uogólniony trend przebiegu odkształceń dla wszystkich trzech bramek pomiarowych przedstawiono na Rysunku 3.15. Obejmuje on przykładowe przejazdy pojazdu trójosiowego realizowane po obu pasach ruchu. Wykresy przedstawiają charakter odpowiedzi poszczególnych punktów pomiarowych, związany z lokalizacją pojazdu na długości oraz szerokości mostu. Na obecnym etapie analizy nie są istotne bezpośrednie wartości odkształceń, lecz przede wszystkim wpływ położenia pojazdu na otrzymywane pomiary. Etap ten stanowił bowiem wstępną weryfikację poprawności działania zainstalowanego systemu pomiarowego, natomiast analiza wartości amplitud oraz ich wykorzystanie w procesie identyfikacji masy całkowitej i lokalizacji pojazdów przedstawione zostały w dalszej części pracy.

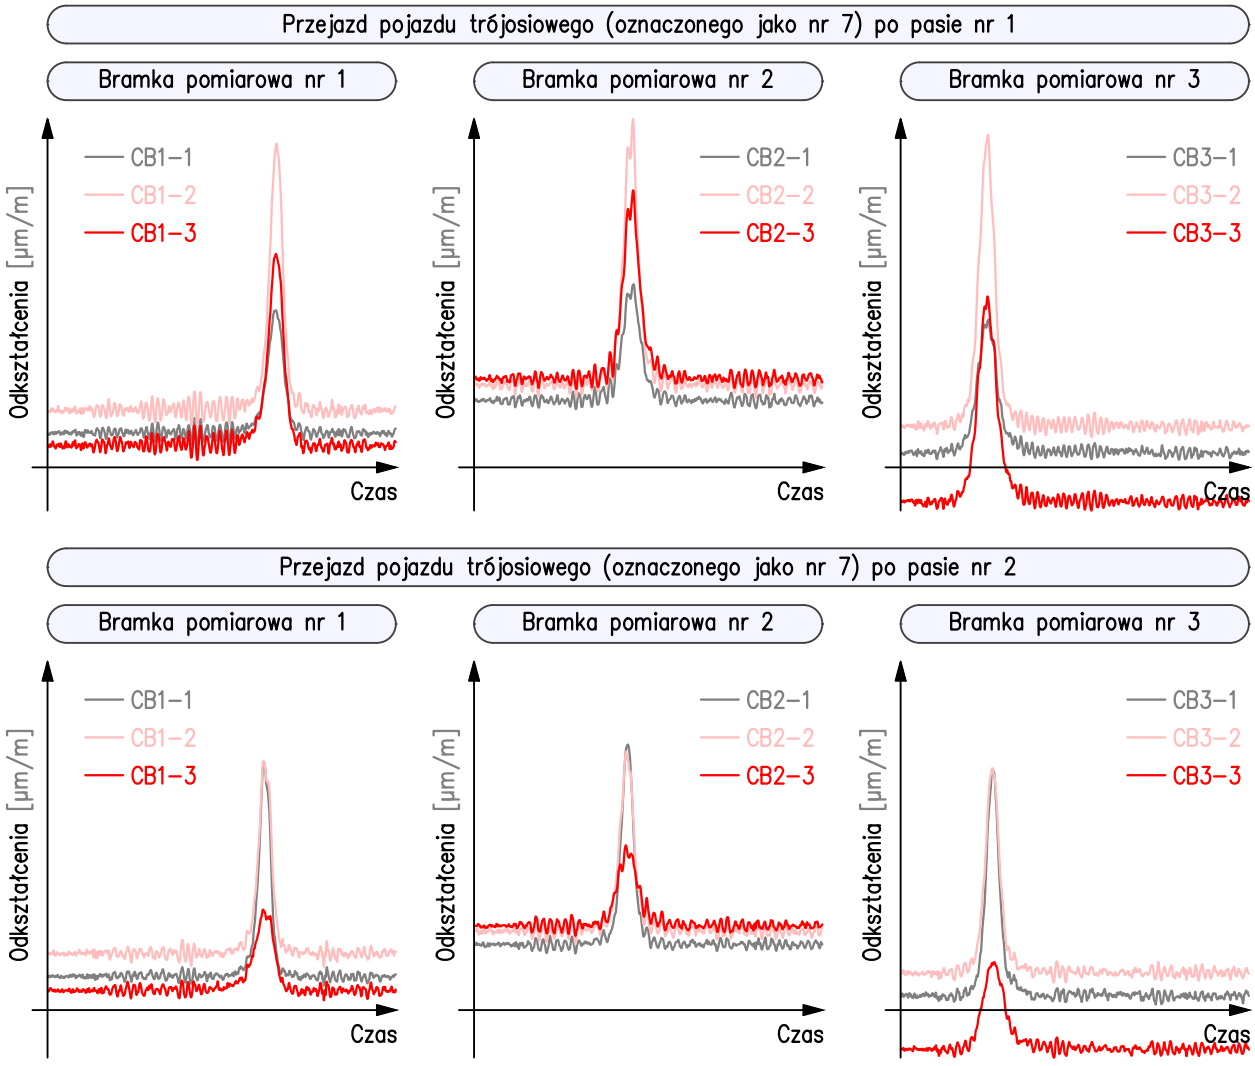

Rysunek 3.15. Uogólniony trend przebiegu odkształceń dla trzech bramek pomiarowych w zależności od położenia pojazdu

Przeprowadzone badanie potwierdza zależność odkształceń od położenia pojazdu na kierunku podłużnym, jak i poprzecznym. Zauważalne są wyraźne przesunięcia chwil występowania maksymalnych wartości odkształceń pomiędzy kolejnymi bramkami pomiarowymi, wynikające z przemieszczania się pojazdu wzdłuż mostu. Badania dynamiczne realizowane były zgodnie z kierunkiem docelowego ruchu, natomiast numeracja bramek pomiarowych odpowiadała rosnącemu kilometrażowi. W efekcie każdy pojazd znajdował się kolejno nad bramką nr 3, następnie nr 2, a pod koniec przejazdu nad bramką nr 1.

Jednocześnie zauważalne są różnice amplitud odkształceń pomiędzy poszczególnymi punktami pomiarowymi w obrębie jednej bramki. Wynikają one z lokalizacji pojazdu na szerokości jezdni, w tym jego odległości od danego punktu pomiarowego. W przypadku przejazdów realizowanych pasem nr 1 większe wartości odkształceń rejestrowane są w trzecim punkcie pomiarowym poprzecznicy, w stosunku do punktu pierwszego. Dla przejazdów realizowanych pasem nr 2 zależność ta ulega odwróceniu. Dodatkowo, podczas przejazdu pasem nr 1 zauważalne są wyraźnie większe wartości odkształceń w drugim punkcie pomiarowym każdej bramki, co wynika z jego lokalizacji bezpośrednio pod tym pasem ruchu.

Analogiczne zależności obserwowano również podczas przejazdów realizowanych z wykorzystaniem innych pojazdów oraz różnych prędkości. Pomimo zmian amplitud odkształceń, wynikających głównie z różnicy masy pojazdów, zachowany pozostawał charakter odpowiedzi dla wszystkich punktów.

3.4.2 Przejazdy w kolumnach

Dodatkowe badania dynamiczne, przeprowadzone na potrzeby przyszłych analiz, obejmowały przejazdy grupowe (Rysunek 3.16). Realizowane były w różnych konfiguracjach, uwzględniając przy tym zmienną liczbę oraz położenie pojazdów. Celem badania była analiza odpowiedzi dynamicznej w warunkach jednoczesnego oddziaływania wielu obciążeń ruchomych. Pozwoliło to na weryfikację możliwości identyfikacji poszczególnych pojazdów w bardziej złożonych warunkach eksploatacyjnych.



Rysunek 3.16. Przebieg badań dynamicznych z wykorzystaniem kolumny trzech pojazdów

Przykładowe wykresy odkształceń dla drugiej bramki pomiarowej przedstawiono na Rysunku 3.17. Obejmują one punkty pomiarowe zainstalowane na poprzecznicy, podłużnicach oraz wieszakach i przedstawiają przejazd kolumny trzech pojazdów pasem nr 1. Dodatkowo kolorem żółtym zaznaczono momenty wjazdu oraz zjazdu pojazdu z mostu, natomiast kolorem niebieskim zakres linii wpływu poprzecznic.

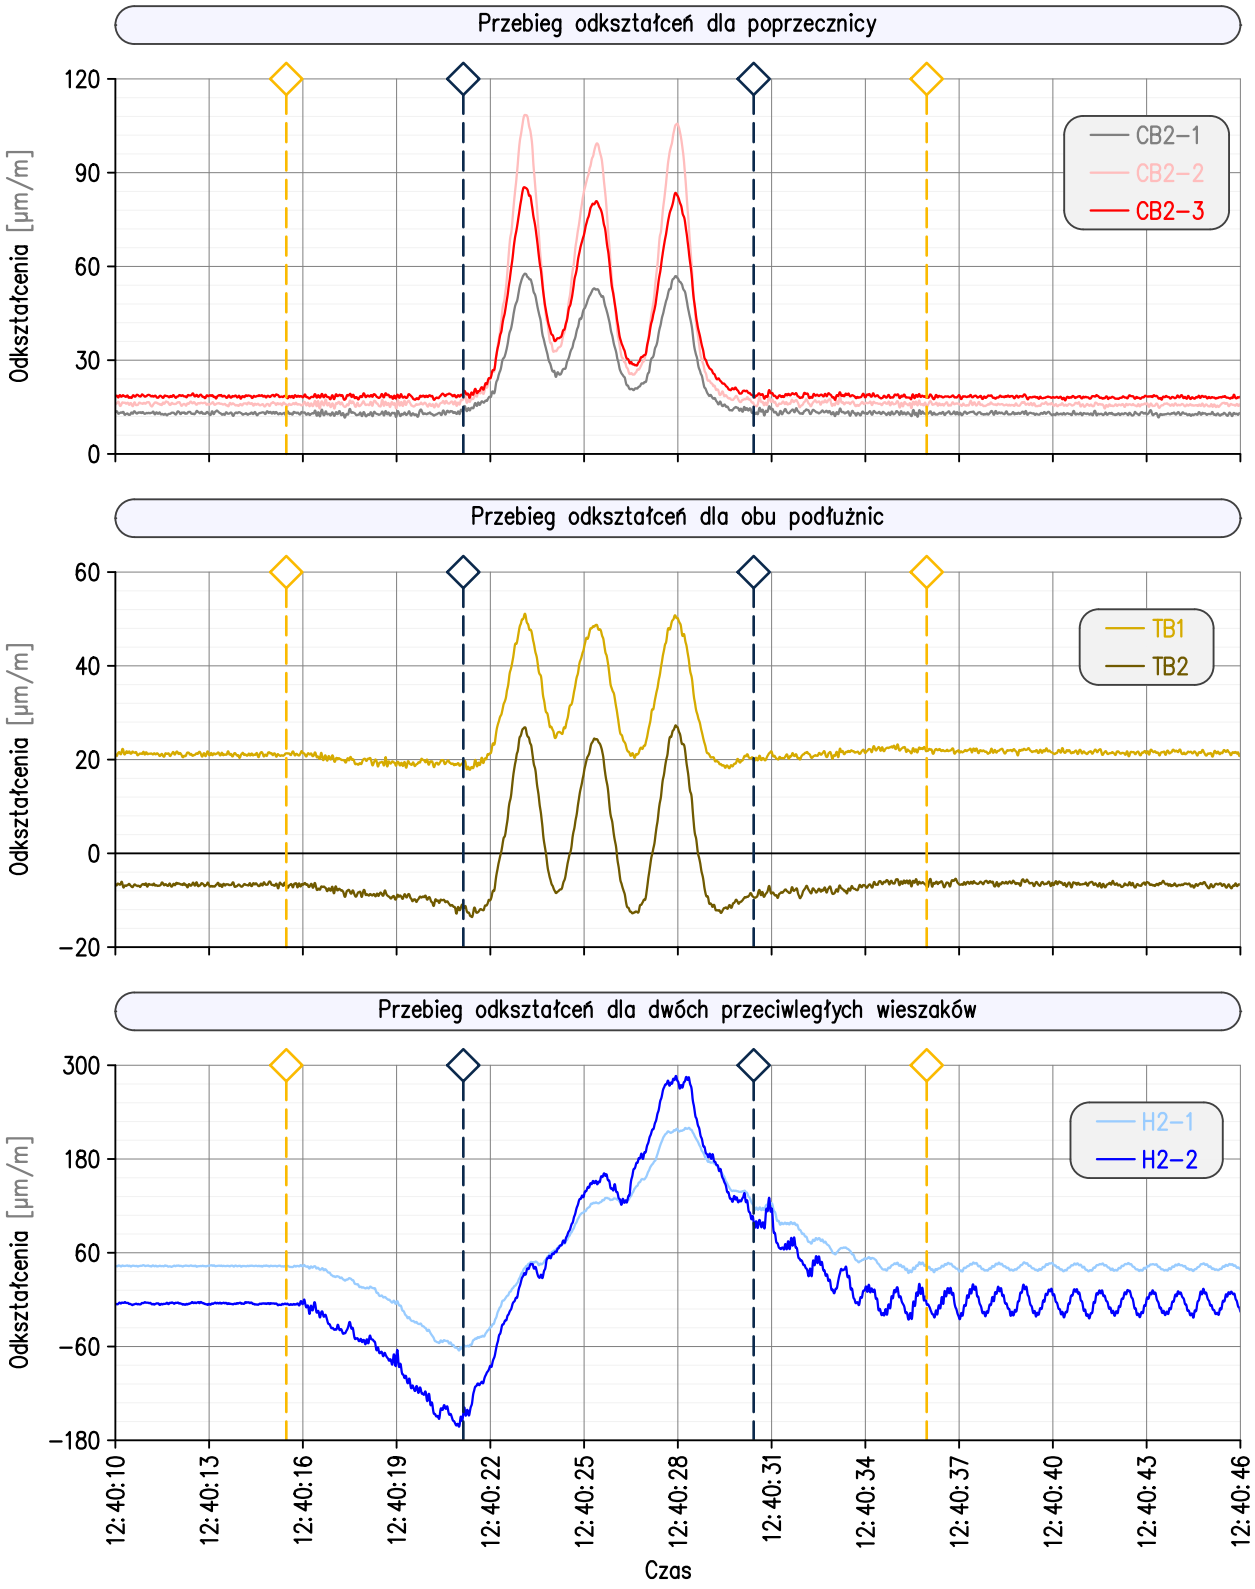

Rysunek 3.17. Wartości odkształceń w bramce pomiarowej nr 2 od przejazdu kolumny trzech pojazdów

Na podstawie zarejestrowanych przebiegów odkształceń potwierdzono lokalny charakter odpowiedzi poprzecznicy także dla przejazdów grupowych. Zauważalne jest wyraźne rozdzielenie maksymalnych wartości odkształceń, odpowiadających kolejnym pojazdom znajdującym się na obiekcie. Poza obszarem bezpośredniego oddziaływania obciążenia przebieg sygnału pozostaje w przybliżeniu stały.

W przypadku podłużnic również występują wyraźne ekstrema wartości odkształceń odpowiadające poszczególnym pojazdom. Równocześnie zauważalne pozostają drobne fluktuacje, występujące praktycznie na całym odcinku obecności pojazdów na obiekcie. Odmienny charakter obserwowany jest natomiast dla wieszaków, dla których wpływ obciążenia utrzymuje się również poza obszarem analizowanej bramki. W efekcie odpowiedź tych punktów zależy od wszystkich pojazdów znajdujących się na moście.

Również w przypadku przejazdów grupowych możliwe jest zidentyfikowanie toru ruchu każdego pojazdu. Uogólniony trend przebiegu odkształceń został przedstawiony na Rysunku 3.18. Obejmuje on przejazdy kolumny składającej się z trzech pojazdów, realizowane oddzielnie dla obu pasów ruchu.

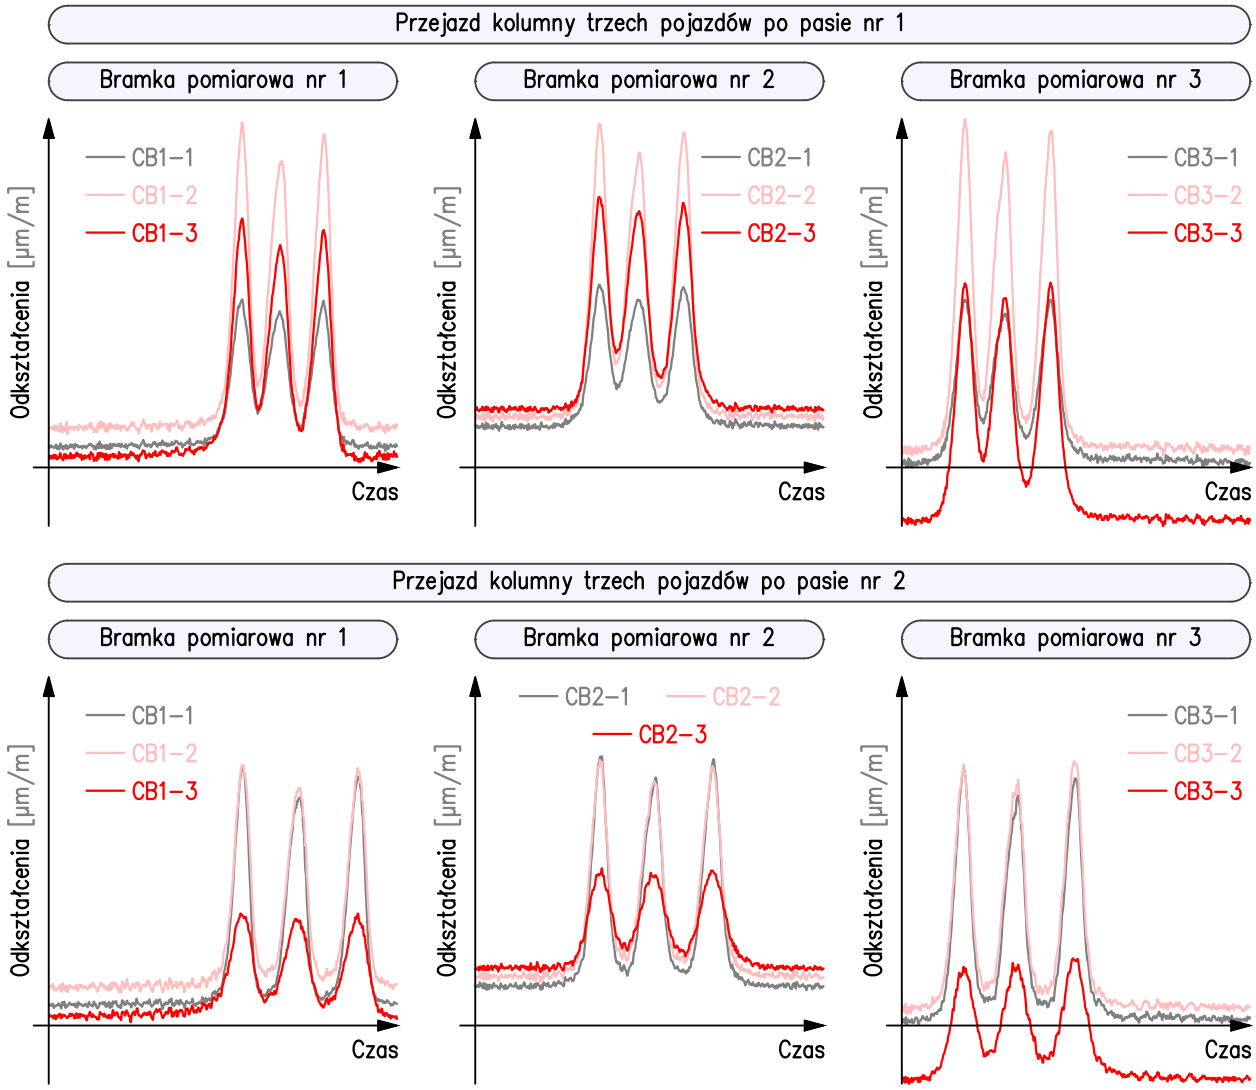

Rysunek 3.18. Uogólniony trend przebiegu odkształceń dla trzech bramek pomiarowych w zależności od położenia kolumny pojazdów

Przedstawione wykresy obrazują charakter odpowiedzi poprzecznic dla wszystkich trzech bramek pomiarowych. Podobnie jak w przypadku przejazdów pojedynczych pojazdów zauważalne są wyraźne różnice amplitud odkształceń pomiędzy poszczególnymi punktami, wynikające z lokalizacji pojazdów na szerokości jezdni. Potwierdza to, że dla przejazdów grupowych oprócz liczby pojazdów istnieje także możliwość identyfikacji ich położenia, ponieważ pozostaje zachowany lokalny charakter odpowiedzi poprzecznic. Analogiczne zależności obserwowano także podczas innych konfiguracji przejazdów, realizowanych z wykorzystaniem różnych pojazdów, poruszających się oboma pasami ruchu.

W celu dodatkowej weryfikacji systemu zrealizowano również przejazdy obejmujące ruch wszystkich dziewięciu pojazdów. Próby przeprowadzono bez narzucania określonych założeń, przyjmując dowolną kolejność pojazdów, odległości między nimi oraz prędkości. Badania obejmowały zarówno przejazdy realizowane oddzielnie każdym z pasów ruchu, jak również jednoczesne, losowe rozmieszczenie pojazdów na obu pasach. Pozwoliło to na odwzorowanie rzeczywistych warunków ruchu (Rysunek 3.19).

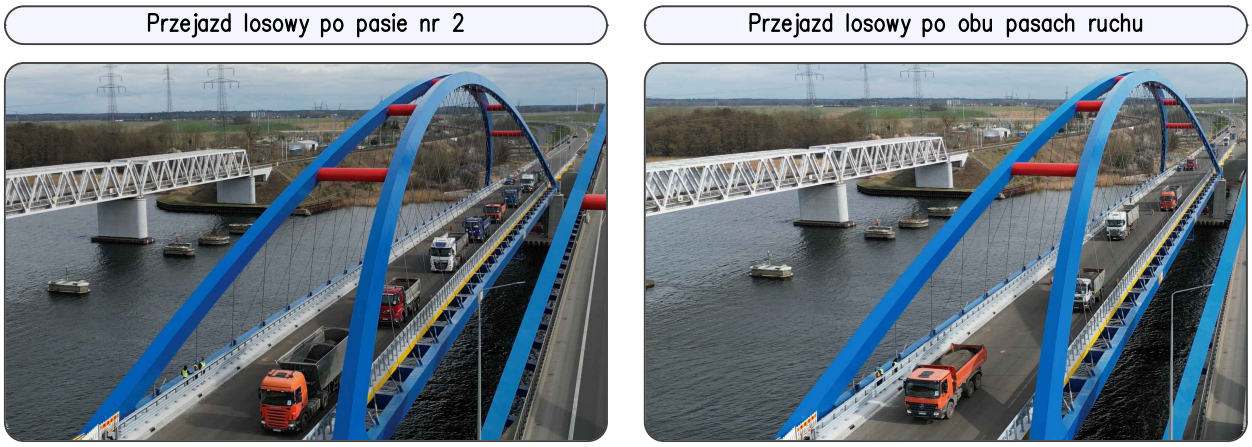

Rysunek 3.19. Przebieg badań dynamicznych przy losowych przejazdach

Przykładowe przebiegi odkształceń przedstawiono na Rysunkach 3.20 oraz 3.21. Obejmują one przejazdy odpowiednio tylko pasem nr 2 oraz z wykorzystaniem obu pasów ruchu. W przypadku przejazdów realizowanych wyłącznie jednym pasem zauważalne są wyraźnie większe wartości amplitud odkształceń rejestrowanych przez punkty pomiarowe zlokalizowane w jego bezpośrednim sąsiedztwie. Dla ruchu realizowanego z wykorzystaniem obu pasów, widoczne są natomiast zmiany amplitud odkształceń pomiędzy poszczególnymi punktami, wynikające z różnego położenia pojazdów na szerokości jezdni.

Pomimo nakładania się oddziaływań pochodzących z wielu pojazdów zachowany pozostaje charakter odpowiedzi poszczególnych punktów pomiarowych. Przeprowadzone badania potwierdziły tym samym możliwość wykorzystania opracowanego systemu do identyfikacji pojazdów w warunkach rzeczywistego ruchu. Dzięki temu możliwe będzie wykorzystanie zainstalowanego systemu do predykcji masy całkowitej pojazdów przejeżdżających przez obiekt oraz dokładnego określenia ich toru jazdy.

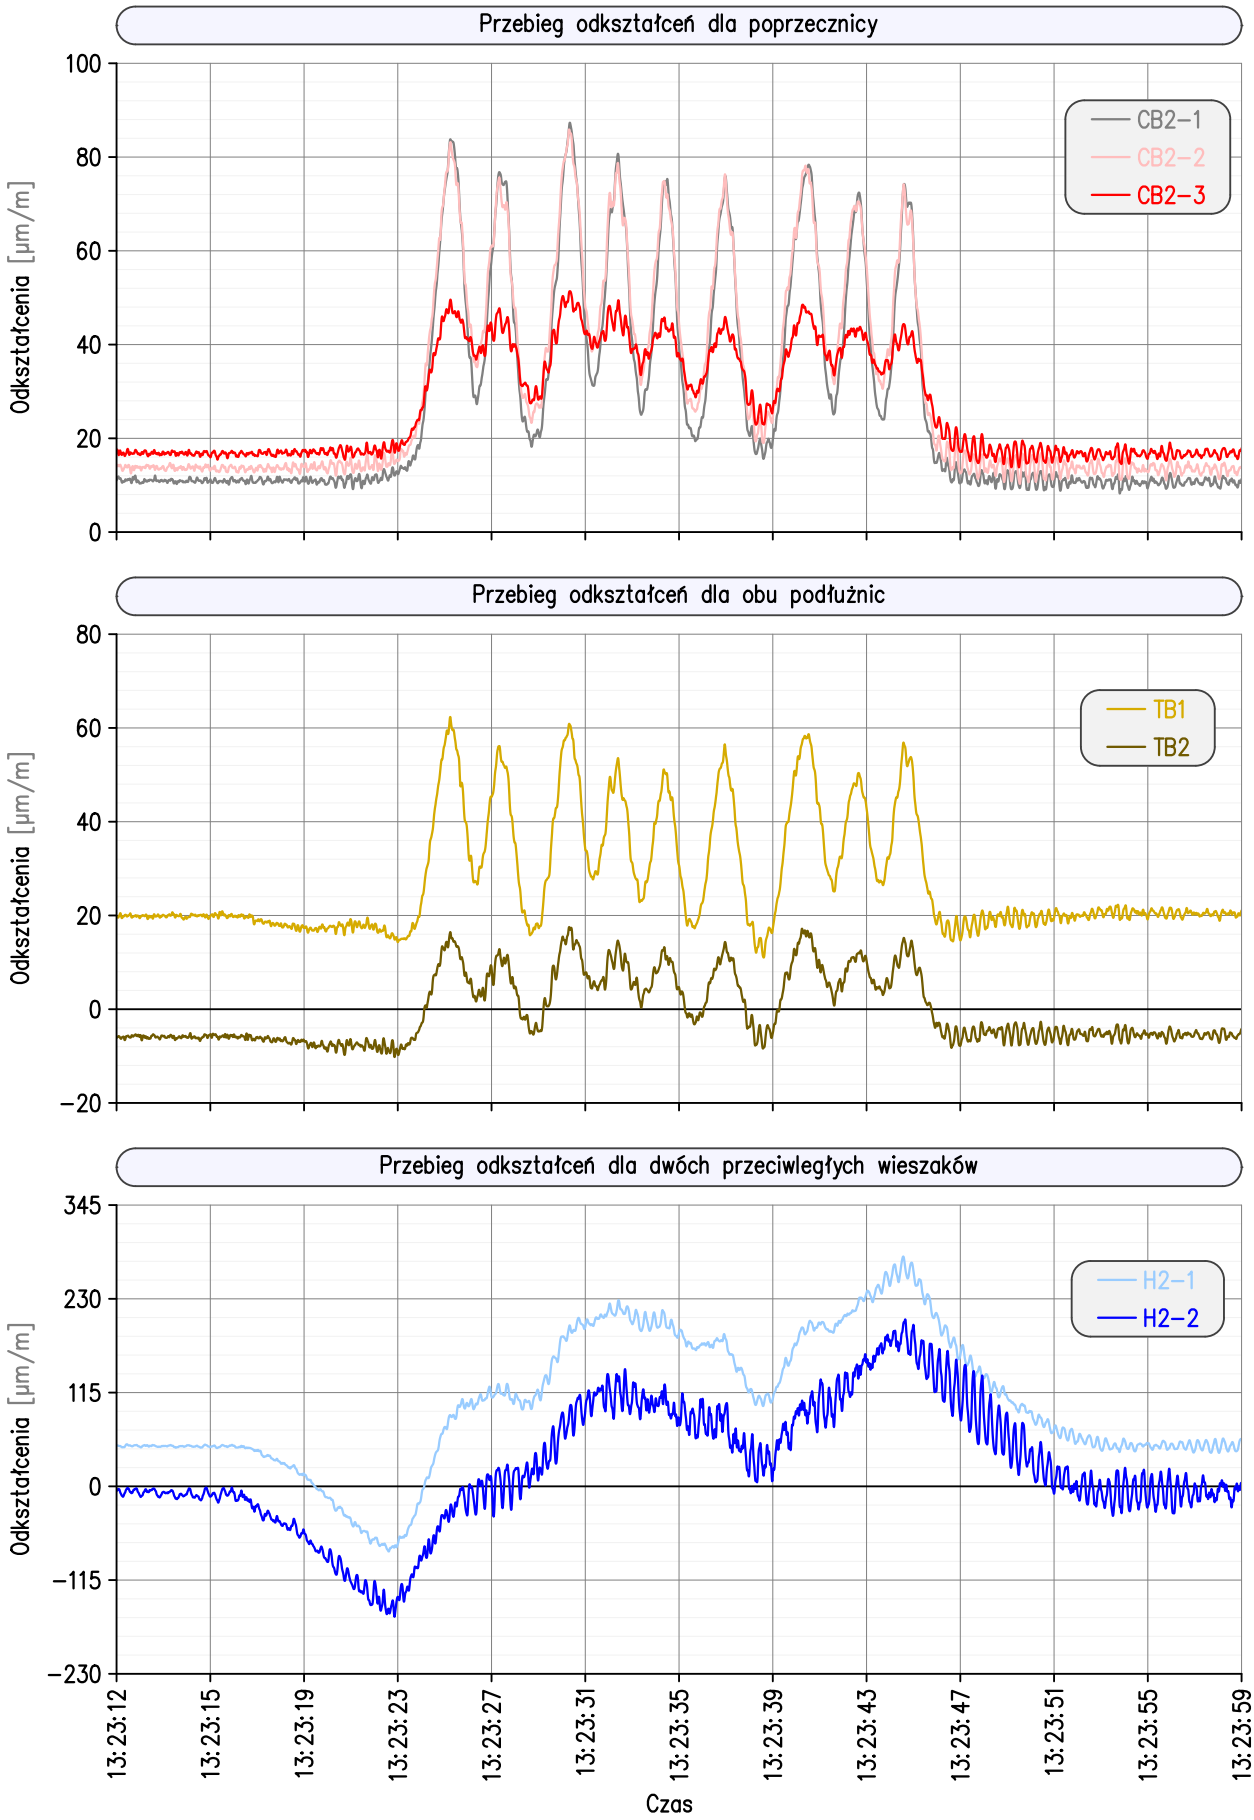

Rysunek 3.20. Wartości odkształceń w bramce pomiarowej nr 2 od przejazdu losowego pasem nr 2

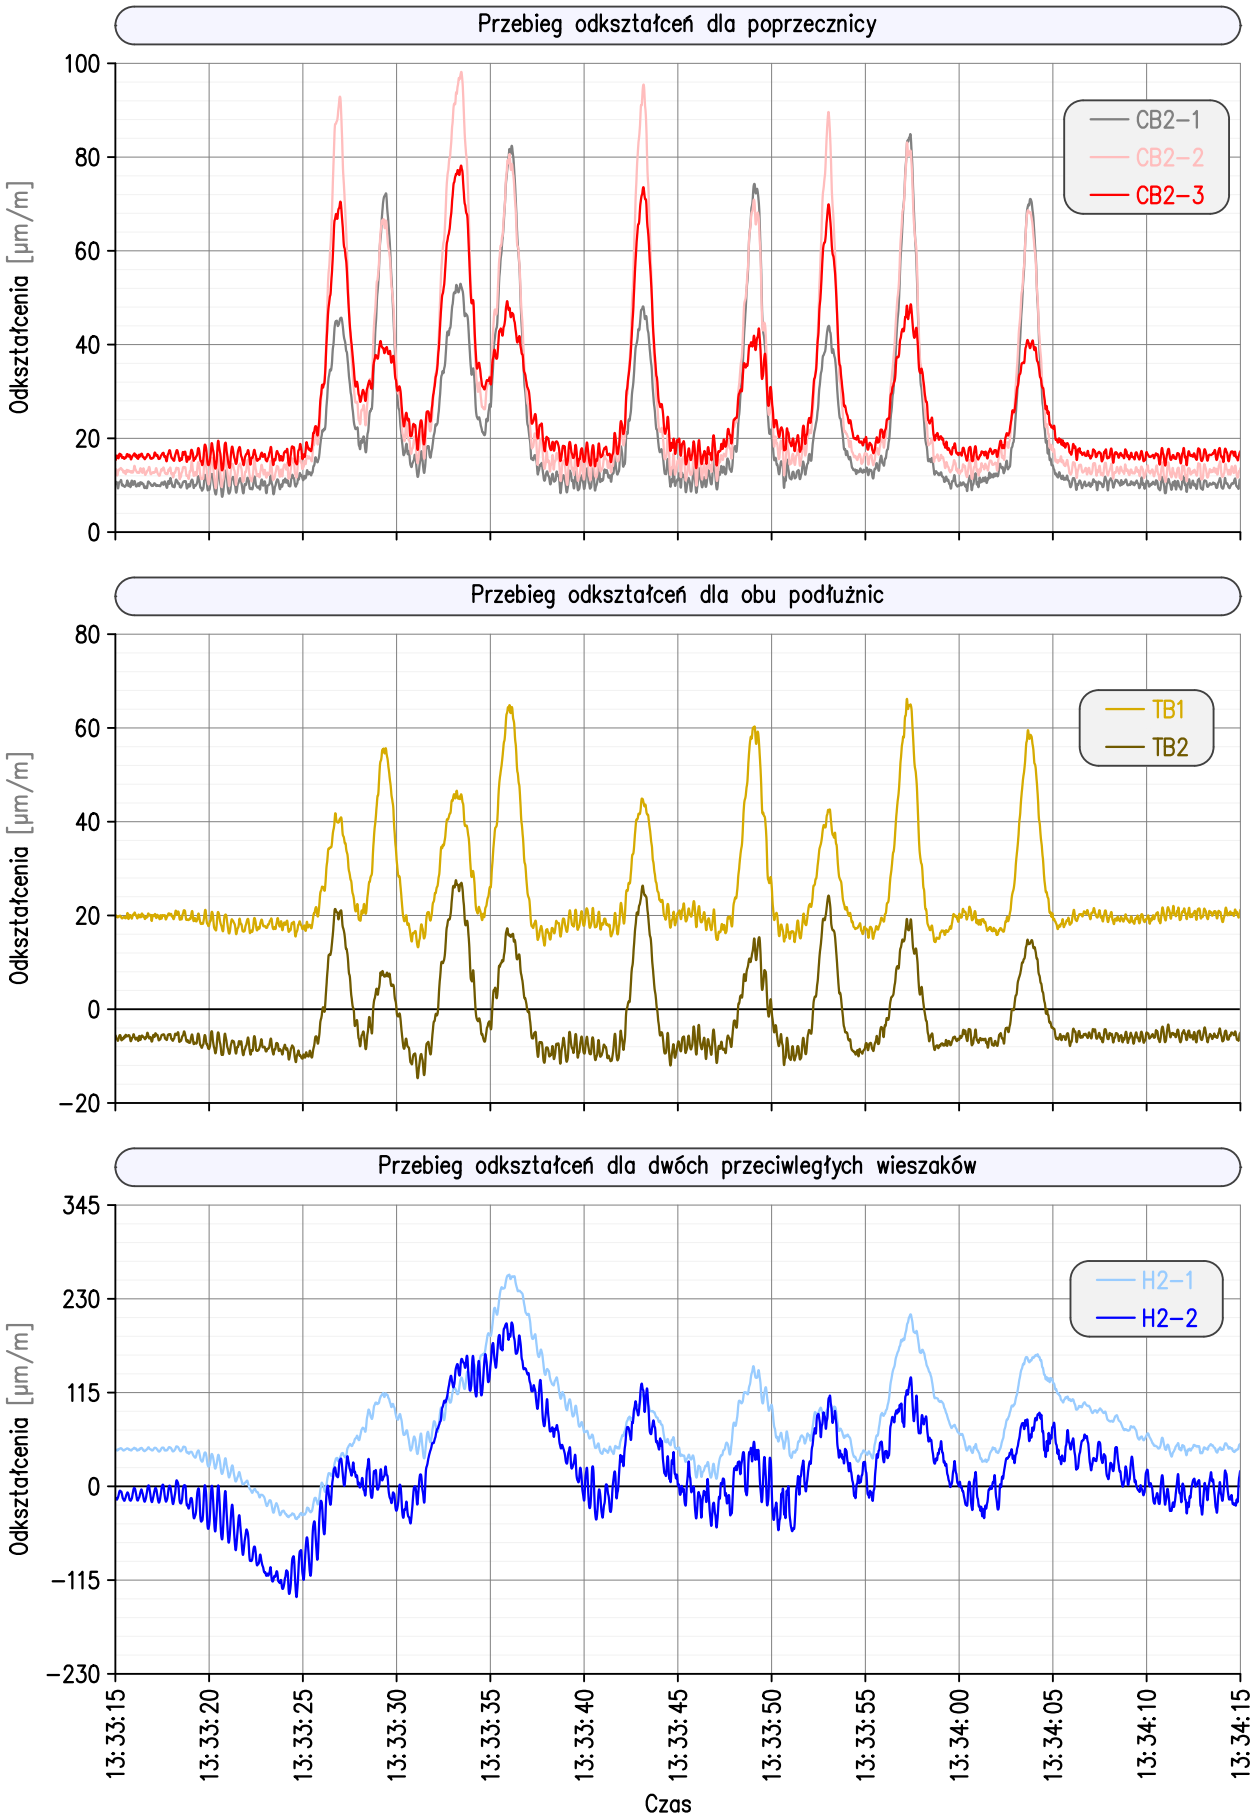

Rysunek 3.21. Wartości odkształceń w bramce pomiarowej nr 2 od przejazdu losowego oboma pasami ruchu

3.5 Podsumowanie

Przeprowadzone badania obejmowały zarówno próby statyczne, jak i dynamiczne, zrealizowane z wykorzystaniem dziewięciu pojazdów ciężarowych. Charakteryzowały się one zróżnicowaną geometrią, w tym liczbą i rozstawem osi oraz zmienną masą, mieszczącą się w przedziale od 27,76 t do 41,52 t.

Podczas badań statycznych przewidziano realizację pięciu schematów obciążenia. Obejmowały one przypadki zlokalizowane bezpośrednio nad każdą bramką pomiarową oraz dodatkowe dwa schematy niesymetryczne. Uzyskane wyniki pozwoliły na określenie poziomu odkształceń w warunkach kontrolowanego obciążenia, które stanowiły podstawę do późniejszej identyfikacji modelu MES. Jednocześnie potwierdzono poprawność działania wdrożonego systemu SHM oraz jakość rejestrowanych danych.

Badania dynamiczne obejmowały z kolei różne konfiguracje obciążenia, na które oprócz przejazdów pojedynczych pojazdów składały się także przejazdy grupowe oraz losowe. Wykonywano je z wykorzystaniem obu pasów ruchu, umożliwiając dzięki temu ocenę systemu w warunkach zbliżonych do rzeczywistego ruchu. Zrealizowane badania potwierdziły wnioski wyciągnięte z przeprowadzonej wcześniej analizy statycznej, na podstawie której wyznaczono teoretyczne linie wpływu charakterystycznych elementów konstrukcyjnych. Wykazano przy tym zależność rejestrowanych odkształceń od położenia pojazdu zarówno na kierunku podłużnym jak i poprzecznym. W szczególności potwierdzony został lokalny charakter pracy poprzecznic, dla których największe wartości odkształceń uzyskiwano w sytuacji, gdy pojazd znajdował się bezpośrednio nad analizowaną bramką pomiarową. W pozostałym obszarze mostu odkształcenia były w przybliżeniu stałe i zawierały głównie szum pomiarowy. Jednocześnie przeprowadzone badania potwierdziły globalny charakter pracy wieszaków, dla których rejestrowane odkształcenia zależały od wszystkich pojazdów znajdujących się w danej chwili na moście.

Uzyskane wyniki potwierdziły poprawność przyjętej lokalizacji punktów pomiarowych oraz zasadność wykorzystania odkształceń rejestrowanych na poprzecznicach do przyszłej identyfikacji obciążeń eksploatacyjnych. Lokalny charakter odpowiedzi, ograniczający wpływ pojazdów znajdujących się poza obszarem danej bramki pomiarowej, stanowi istotną cechę z punktu widzenia systemów ważenia pojazdów w ruchu. W niniejszej pracy bazują one na algorytmach uczenia maszynowego, które wymagają jednak dużych i reprezentatywnych zbiorów treningowych. Wygenerowanie takiego zbioru wyłącznie na podstawie badań doświadczalnych wiązałoby się ze znacznymi kosztami. W związku z tym przeprowadzone badania oprócz potwierdzenia przyjętych założeń posłużyły również do identyfikacji modelu MES. Na jego podstawie wygenerowano syntetyczny zbiór danych, wykorzystywany w późniejszych analizach.

4 | Identyfikacja modelu numerycznego MES

Cele rozdziału

Niniejszy rozdział przedstawia zautomatyzowany proces identyfikacji modelu MES. Jego celem jest możliwie wierne odwzorowanie rzeczywistej konstrukcji oraz uzyskanie jej numerycznej reprezentacji o wysokiej zgodności z wynikami pomiarów. Proces ten integruje algorytm genetyczny, model zastępczy oparty na sieci neuronowej oraz dane pochodzące z badań pod próbnym obciążeniem. Zmienne decyzyjne procesu identyfikacji stanowią wartości modułów sprężystości poszczególnych elementów konstrukcyjnych, natomiast sygnałami wyjściowymi są zmierzone odkształcenia w wybranych punktach pomiarowych. Proces optymalizacji polega następnie na minimalizacji funkcji celu opisującej rozbieżność pomiędzy odpowiedzią modelu, a wartościami pomiarowymi. Identyfikację przeprowadzono w dwóch wariantach, wykorzystując do oceny każdego rozwiązania model MES oraz jego aproksymację opartą na sieci neuronowej. Uzyskane wyniki wskazują na porównywalną skuteczność obu podejść, przy czym zastosowanie modelu zastępczego pozwoliło na istotne ograniczenie kosztu obliczeniowego oraz osiągnięcie niższej wartości funkcji celu. Dla osobników w ostatnim pokoleniu wynosiła ona średnio 2,65 w porównaniu do 2,98 dla bezpośredniej identyfikacji z wykorzystaniem modelu MES. Przedstawiono także analizę wpływu parametrów algorytmu genetycznego oraz zmiennych decyzyjnych na przebieg procesu optymalizacji.

4.1 Wstęp

Symulacje numeryczne bazujące na metodzie elementów skończonych MES wspomagają ocenę oraz analizę konstrukcji inżynierskich. Jednak ze względu na stosowane uproszczenia oraz występujące niepewności modele te mogą wykazywać rozbieżności względem rzeczywistej pracy konstrukcji. Wymagają zatem przeprowadzenia procesu, dążącego do zapewnienia zgodności ich symulacji z badaniami doświadczalnymi. W ujęciu teoretycznym jest to zadanie identyfikacji, które najczęściej sprowadzane jest do problemu optymalizacyjnego. Podejście takie wdrażane jest w badaniach obejmujących wiele typów konstrukcji, w tym budynki, turbiny wiatrowe czy budowle hydrotechniczne. Przykładowe badania przeprowadzili Cai i in. [19], którzy zaproponowali metodę identyfikacji modelu MES budynku wysokościowego. Wykorzystali w tym celu dane pozyskane z akcelerometrów, opierając proces identyfikacji

na algorytmie optymalizacyjnym roju cząstek. Avci i in. [12] również identyfikowali model numeryczny budynku wysokościowego, wykorzystując w tym celu operacyjną analizę modalną. Autorzy kalibrowali w modelu parametry masy, modułów sprężystości oraz sztywności skrętnej słupów i ścian. Xu i in. [139] przedstawili natomiast w swoich badaniach proces identyfikacji modelu numerycznego morskiej turbiny wiatrowej. Autorzy zastosowali hybrydowy system pomiarowy, obejmujący akcelerometry i tensometry, kalibrując parametry sztywnościowe podłoża gruntowego. Sevieri i in. [116] opisali z kolei proces identyfikacji modelu MES na przykładzie betonowej zapory wodnej. Jako dane referencyjne posłużyły wyniki badań materiałowych oraz dane pochodzące z monitoringu konstrukcji. Autorzy przedstawili w swojej pracy procedurę zdefiniowaną w ramach podejścia bayesowskiego.

Identyfikacja modeli numerycznych MES stanowi również istotne zagadnienie w inżynierii mostowej. W praktyce proces ten bardzo często realizowany jest w sposób manualny, opierając się na iteracyjnej modyfikacji parametrów modelu. Jednak coraz więcej badań skupia się na automatyzacji tego procesu, wykorzystując w tym celu algorytmy optymalizacyjne, metody bayesowskie czy modele uczenia maszynowego. Lin i in. [75] przedstawili identyfikację nieliniowego modelu MES mostu wantowego. Autorzy wykorzystali dane pomiarowe pozyskane ze stołu sejsmicznego oraz systemu monitoringu, wykorzystując do identyfikacji algorytm optymalizacyjny roju cząstek. Baisthakur i in. [13] opisali natomiast przykład stalowego mostu kratownicowego. Jego model numeryczny identyfikowali za pomocą zmodyfikowanego algorytmu Monte Carlo, wykorzystując pozyskane dane modalne. Y. Zheng i in. [151] identyfikowali z kolei model numeryczny podwieszonej kładki dla pieszych. Autorzy kalibrowali przy tym parametry materiałowe betonu i stali zbrojeniowej, wykorzystując odpowiedzi dynamiczne konstrukcji.

Zapewnienie zgodności pomiędzy symulacjami numerycznymi, a wynikami badań eksperymentalnych stanowi element wielu współczesnych zagadnień inżynierskich. Obejmuje to między innymi detekcję i identyfikację uszkodzeń konstrukcji, analizę trwałości zmęczeniowej czy wdrażanie systemów monitoringu SHM. Giagopoulos i in. [42] zaproponowali procedurę szacowania uszkodzeń zmęczeniowych konstrukcji z wykorzystaniem zidentyfikowanego modelu MES. Został on włączony do szacowania naprężeń zmęczeniowych w miejscach nieobjętych pomiarami. Z kolei Zhang i in. [147] na przykładzie stalowej kładki dla pieszych przedstawili metodę detekcji uszkodzeń. W jednym systemie zintegrowali modele uczenia maszynowego wraz z procesem identyfikacji modelu numerycznego MES.

Skuteczność procesu identyfikacji modeli MES jest silnie uzależniona od sposobu sformułowania zadania optymalizacyjnego. Istotne znaczenie ma przy tym dobór zmiennych decyzyjnych, funkcji celu oraz odpowiednich metod i algorytmów. Duże znaczenie tych zagadnień podkreślają liczne badania, przedstawiające różnorodne podejścia do procesu identyfikacji modeli numerycznych.

4.2 Przegląd literatury

4.2.1 Identyfikacja modeli MES w ujęciu teorii identyfikacji układów

Zapewnienie zgodności modeli numerycznych z wynikami badań doświadczalnych stanowi istotne zagadnienie w wielu dyscyplinach naukowych. Problem ten może być rozpatrywany w ujęciu teorii identyfikacji układów, w której wyróżnia się trzy podstawowe klasy zagadnień: analizę, syntezę oraz identyfikację (Rysunek 4.1). Podział ten odnosi się do relacji pomiędzy sygnałami wejściowymi, wyjściowymi oraz modelem, opisującym zachowanie danego układu. Pojęcie analizy zakłada znajomość modelu oraz sygnałów wejściowych, a jej celem jest wyznaczenie sygnałów wyjściowych. Podejście to odpowiada klasycznym obliczeniom numerycznym, w tym analizom MES, w których dla zdefiniowanych danych i parametrów modelu wyznaczana jest odpowiedź konstrukcji. Z kolei zadanie odwrotne, często zwane syntezą, wymaga znajomości odpowiedzi układu oraz modelu, poszukując sygnałów wejściowych. Finalnie, trzecim zagadnieniem jest identyfikacja, która dla zadanych sygnałów wejściowych oraz wyjściowych ma za zadanie wyznaczyć model opisujący zależności między nimi.

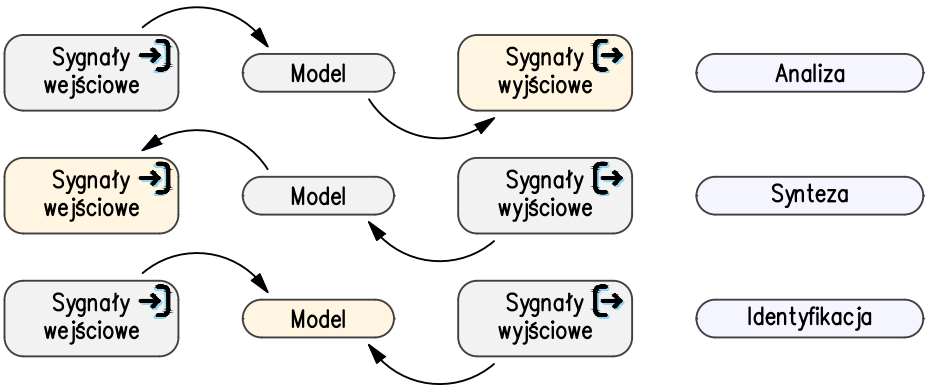

Rysunek 4.1. Schemat analizy, syntezy oraz identyfikacji

Proces zapewnienia zgodności modelu MES z wynikami badań doświadczalnych stanowi zatem przykład identyfikacji. Głównym celem tego zadania jest stworzenie modelu matematycznego układu przy użyciu danych pomiarowych. Ostateczny problem polega na znalezieniu takiego modelu spośród dostępnych kandydatów, który możliwie najlepiej będzie odwzorowywał dane eksperymentalne. Dostępne w literaturze badania rozwiązują tak sformułowany problem z wykorzystaniem różnych metod, najczęściej sprowadzając go do zadania optymalizacyjnego, w którym minimalizowana jest rozbieżność pomiędzy odpowiedzią modelu, a danymi doświadczalnymi. Przykładowe badania przedstawił Maroli [86], który wykorzystując modele sieci neuronowych generował równania opisujące dyskretne układy dynamiczne. Praca ta stanowiła przykład ogólnego podejścia do identyfikacji układów, które znajduje również szerokie zastosowanie w zagadnieniach związanych z identyfikacją modeli numerycznych MES.

Przykład takich badań przedstawili Ghannadi i in. [41], którzy wykorzystując algorytmy optymalizacyjne identyfikowali model numeryczny na potrzeby detekcji uszkodzeń. Autorzy minimalizowali w swoim podejściu dwie funkcje celu, oparte odpowiednio na zmianach częstotliwości oraz postaci drgań własnych. Podobne badania przedstawili Tran i in. [127], którzy w swoim podejściu również skupili się na analizie odpowiedzi dynamicznej konstrukcji. Do identyfikacji modelu MES wykorzystali natomiast algorytm optymalizacyjny roju cząstek PSO (*ang. Particle Swarm Optimization*).

Identyfikacja modeli MES jest także częstym zagadnieniem poruszanym w inżynierii mostowej. Liczne badania naukowe opisują implementację tego zagadnienia, wykorzystywanego do identyfikacji pojazdów, detekcji anomalii czy wykrywania uszkodzeń. Sygnały wejściowe wykorzystywane w tych podejściach najczęściej pochodzą bezpośrednio z badań pod próbnym obciążeniem lub z systemów monitoringu SHM. Obejmują przy tym zarówno analizę odpowiedzi statycznej, jak i dynamicznej konstrukcji, wykorzystując do tego celu algorytmy optymalizacyjne oraz modele uczenia maszynowego. Przykładowe badania przedstawili Luo i in. [80], którzy do identyfikacji modelu MES wykorzystali dane pochodzące z wizji komputerowej. Z wykorzystaniem tej metody, autorzy określali dokładne obciążenie pochodzące od pojazdów, a następnie przeprowadzali symulacje MES. Analizowali przy tym modele ciągłych mostów belkowych, uwzględniając w funkcji celu charakterystyki dynamiczne konstrukcji oraz odpowiedzi pochodzące od obciążeń statycznych. Song i in. [118] zaproponowali natomiast identyfikację modelu MES, wykorzystując w tym celu wartości przemieszczeń. Proponowane rozwiązanie autorzy przedstawili na przykładzie mostu stalowego, dla którego przeprowadzili badania pod próbnym obciążeniem statycznym. De Angelis i in. [27] opisali z kolei przykład mostu sprężonego, na którym również przeprowadzili podobne badania. Zebrane dane wykorzystali do identyfikacji modelu MES, podkreślając przy tym skuteczność badań pod próbnym obciążeniem w dokładnym określeniu charakteru pracy konstrukcji.

Dostępne w literaturze badania opisują także przypadki identyfikacji modeli MES, w których wykorzystana została specyfika pracy badanej konstrukcji. Dane pomiarowe często pochodzą z zainstalowanych systemów monitoringu SHM, wykorzystując także linie wpływu charakterystycznych elementów konstrukcyjnych. Przykładowe badania przedstawili Hekič i in. [52], którzy do identyfikacji modelu MES mostu sprężonego wykorzystali linię wpływu odkształceń. Wyprowadzili ją korzystając z dwóch pojazdów kalibracyjnych oraz danych eksperymentalnych uzyskanych z systemu SHM. Autorzy kalibrowali w modelu MES parametry modułów sprężystości, wpływając jednocześnie na globalną sztywność całego obiektu. Lee i in. [67] zaproponowali natomiast metodę identyfikacji modelu MES konstrukcji mostowej, wykorzystując linię wpływu przemieszczeń pod obciążeniem ruchomym. Dzięki temu byli w stanie określić zależność między obciążeniem, a przemieszczeniem, która jest bezpośrednio związana z globalną

sztywnością konstrukcji. W tym celu wykorzystali metody wizji komputerowej oraz uczenia głębokiego. Podobne podejście przedstawili Tao i in. [123], którzy zaproponowali metodę wyznaczania linii wpływu dla mostów belkowych z wykorzystaniem synchronizacji położenia pojazdu oraz systemu czujników. Następnie wykorzystali je do identyfikacji modelu MES oraz oceny nośności konstrukcji.

Analizy numeryczne okazują się skuteczne w symulacjach złożonych konstrukcji, jednak z natury bazują na pewnych założeniach. Zawierają przez to szereg niepewności i uproszczeń, mogąc odbiegać od rzeczywistych odpowiedzi konstrukcji. Ograniczenia te stają się bardziej widoczne przy zastosowaniu systemów monitoringu SHM, gdzie nałożenie się niedokładności modelowych, szumu pomiarowego czy zmienności obciążeń może znacząco wpływać na dokładność prognoz numerycznych. W związku z tym zagadnienie identyfikacji modeli MES staje się kluczowe, skupiając obecne badania na wielu metodach, przyjmujących w tym procesie różne rodzaje zmiennych decyzyjnych.

4.2.2 Zmienne decyzyjne wykorzystywane w procesach identyfikacji modeli MES

Proces identyfikacji modeli MES wiąże się bezpośrednio z koniecznością określenia zbioru zmiennych decyzyjnych. Ich kalibracja prowadzi do minimalizacji różnic pomiędzy wartościami mierzonymi eksperymentalnie, a odpowiedzią numeryczną modelu. W praktyce zmienne decyzyjne najczęściej odpowiadają parametrom fizycznym modelu, które można podzielić na parametry sztywnościowe, warunki brzegowe oraz właściwości geometryczne i związane z masą. Dobór zmiennych decyzyjnych jest ściśle uzależniony od rodzaju danych pomiarowych oraz charakteru analizowanej odpowiedzi konstrukcji.

Większość dostępnych w literaturze badań koncentruje się na kalibracji parametrów związanych ze sztywnością konstrukcji. W zależności od schematu statycznego dominująca może być sztywność osiowa lub giętna, opisywana odpowiednio przez iloczyny EA oraz EI. Wielkościami zależnymi od geometrii są w tym przypadku odpowiednio pole przekroju poprzecznego oraz moment bezwładności na zginanie, a parametrem wspólnym jest moduł sprężystości. Dlatego też jego kalibracja jest najbardziej powszechna w obecnych badaniach, ponieważ pozwala na uwzględnienie zarówno sztywności osiowej jak i giętnej. Przykładowe badania przedstawili Rabi i in. [110], którzy identyfikowali model MES trójprzęsłowego mostu stalowego. Wykorzystując algorytm genetyczny kalibrowane były moduły sprężystości stali konstrukcyjnej. Również Park i in. [99] identyfikowali model numeryczny mostu stalowego, wykorzystując dane z długoterminowego monitoringu SHM. Jako zmienne decyzyjne autorzy przyjęli parametry modułów sprężystości elementów głównych oraz łożysk. Z kolei Aloisio i in. [5] identyfikowali model MES wieloprzęsłowego mostu sprężonego, wykorzystując dane z analizy modalnej. Jako zmienne decyzyjne autorzy przyjęli moduły sprężystości betonu dźwigarów oraz płyty pomostowej, traktując je jako główne parametry wpływające na odpowiedź dynamiczną konstrukcji.

Dostępne w literaturze badania jako zmienne decyzyjne przyjmują także warunki brzegowe, które najczęściej rozpatrywane są łącznie z właściwościami materiałowymi. Malekghaini i in. [84] opisali dwuetapowe podejście do identyfikacji modelu MES sprężonych dźwigarów mostowych. W pierwszym kroku autorzy kalibrowali parametry liniowe modelu, związane głównie ze sztywnością warunków brzegowych oraz właściwościami materiałowymi. W drugim etapie identyfikowali natomiast wytrzymałość betonu na ściskanie, która posłużyła do oceny stanu technicznego konstrukcji. Z kolei He i in. [50] przedstawili proces identyfikacji modelu MES kładki dla pieszych. Jako zmienne decyzyjne wykorzystane zostały sztywności elementów symulujących interakcję gruntu z konstrukcją oraz moduł sprężystości płyty betonowej i cięgien. Lin i in. [76] przedstawili natomiast identyfikację modelu MES mostu wiszącego. Wykorzystując linie wpływu oraz przemieszczenia wywołane obciążeniem termicznym kalibrowane były sztywności elementów obrotowych i translacyjnych, symulujących w modelu MES warunki podparcia.

Jako zmienne decyzyjne mogą być także przyjmowane parametry geometryczne, jednak podejście to występuje w literaturze znacznie rzadziej. Badania takie przedstawili Barros i in. [14], którzy oprócz zmiennych decyzyjnych w postaci właściwości materiałowych i sztywności warunków brzegowych, wykorzystali także parametry geometryczne. Autorzy kalibrowali w swoim podejściu gęstość oraz moduł sprężystości, a także geometrię przekrojów poprzecznych oraz sztywność połączeń i podparcia nitowanego mostu stalowego. Parametry geometryczne jako zmienne decyzyjne przyjęli także w swojej pracy Lee i in. [68], którzy wykorzystali dane pochodzące z chmury punktów. Na jej podstawie kalibrowali współrzędne węzłów modelu, traktując je jako zmienne decyzyjne opisujące geometrię konstrukcji.

Również rozkład masy, w tym ciężar własny oraz wpływ elementów niekonstrukcyjnych może być brany pod uwagę jako zmienne decyzyjne. Podejście to jest szczególnie istotne w analizach dynamicznych, gdzie rozkład masy ma bezpośredni wpływ na wartości częstotliwości i postacie drgań własnych. Talebi i in. [122] przedstawili proces identyfikacji modelu MES kładki dla pieszych. Zmienne decyzyjne w tym podejściu obejmowały zarówno właściwości materiałowe, jak i warunki brzegowe oraz ciężar własny konstrukcji. Autorzy kalibrowali te wielkości, minimalizując rozbieżności pomiędzy częstotliwościami drgań własnych uzyskanych numerycznie i eksperymentalnie. Podobne podejście przedstawili Svendsen i in. [120], którzy identyfikowali model numeryczny MES kratowego mostu stalowego. Jako zmienne decyzyjne autorzy wykorzystali między innymi masę elementów niekonstrukcyjnych.

Dobór zmiennych decyzyjnych stanowi jeden z kluczowych etapów identyfikacji modeli MES. Niezależnie jednak od przyjętego zbioru parametrów, każdy wariant modelu wymaga oceny jego zgodności z danymi pomiarowymi. W tym celu definiowana jest funkcja celu, stanowiąca podstawę procesu optymalizacji. Umożliwia ona ilościowe porównanie odpowiedzi modelu z wynikami pomiarów.

4.2.3 Funkcja celu zadania optymalizacyjnego

Proces identyfikacji modeli MES często sprowadzany jest do zadania optymalizacyjnego, co wiąże się z koniecznością zdefiniowania funkcji celu. W najbardziej powszechnym przypadku określa ona rozbieżność pomiędzy danymi pomiarowymi, a odpowiedzią numeryczną modelu. Duże znaczenie tego zagadnienia podkreślili w swoich badaniach Di Re i in. [32]. Przeprowadzili oni analizę sześciu różnych funkcji celu w problemie optymalizacyjnym identyfikacji modelu MES, a następnie wdrożyli swoje rozwiązanie na dwóch obiektach o konstrukcji odpowiednio żelbetowej oraz zespolonej stalowo-betonowej. Podczas analiz kalibrowali moduł sprężystości płyty pomostowej tych obiektów, analizując skuteczność każdej z proponowanych funkcji celu. Autorzy badali powszechnie stosowaną funkcję opartą na rozbieżnościach między wartościami numerycznymi, a rzeczywistymi, analizując dodatkowo funkcje koncentrujące się na częstotliwościach oraz postaciach drgań własnych. Podkreślili przy tym, że odpowiednio dobrana funkcja celu może wpłynąć na zwiększenie dokładności metod identyfikacji modeli MES.

Zdefiniowana w problemie identyfikacji funkcja celu może uwzględniać odpowiedzi statyczne lub dynamiczne, w tym przemieszczenia, odkształcenia czy częstotliwości i postacie drgań własnych. Martini i in. [87] opisali metodę opartą na wizji komputerowej, na podstawie której określali linie wpływu przemieszczeń. Następnie, zostały one wykorzystane w procesie identyfikacji na przykładzie modelu mostu zbudowanego w warunkach laboratoryjnych. Fang i in. [34] wykorzystali z kolei odpowiedź dynamiczną mostu podwieszonego. Na podstawie analizy modalnej wyznaczyli częstotliwości i postacie drgań własnych, identyfikując model numeryczny z wykorzystaniem optymalizacji bayesowskiej.

Funkcja celu równie często ma charakter wielokryterialny, uwzględniając w swojej definicji zarówno odpowiedzi statyczne, jak i dynamiczne. Przykładowe badania opisali w swojej pracy Qin i in. [108], którzy na przykładzie mostu podwieszonego zaproponowali funkcję celu uwzględniającą zgodność kształtu przemieszczeń, położenia osi obojętnej oraz częstotliwości drgań własnych. Także Lv i in. [81] uwzględnili odpowiedź statyczną oraz dynamiczną konstrukcji. Również na przykładzie mostu podwieszonego, autorzy analizowali ugięcie w środku przęsła oraz trzy pierwsze częstotliwości drgań własnych.

W najprostszym ujęciu, funkcja celu przyjmuje postać sumy kwadratów różnic pomiędzy odpowiedzią numeryczną modelu, a danymi pomiarowymi. Jednak w przypadku, gdy w jednym problemie identyfikacji łączy ona wiele typów danych, często definiowana jest z wykorzystaniem współczynników wagowych. Badania takie przedstawili Qin i in. [106], którzy zaproponowali metodę współczynników wagowych, bazującą na błędach względnych zmierzonych wartości przemieszczeń oraz częstotliwości drgań własnych. Proponowane podejście autorzy przetestowali na przykładzie mostu podwieszonego, wykazując poprawę dokładności identyfikacji modelu MES w porównaniu do metody równej wagi. Istotne

badania opisali także Kim i in. [66], proponując ramy identyfikacji modeli numerycznych istniejących mostów przy wykorzystaniu danych heterogenicznych. Autorzy zwrócili szczególną uwagę, że niewłaściwy dobór wag może prowadzić do dominacji wybranych składników funkcji celu oraz ograniczenia efektywnego wykorzystania informacji pochodzących z różnych typów pomiarów.

W bardziej zaawansowanych ujęciach funkcja celu może być dodatkowo uzupełniona o człony regularyzacyjne. Ograniczają one niestabilność rozwiązania oraz przeciwdziałają nadmiernemu dopasowaniu modelu do danych pomiarowych. Rezaiee-Pajand i in. [111] zaproponowali w swojej pracy połączenie algorytmu Lanczosa oraz regularyzacji Tichonova w celu opracowania hybrydowej metody regularyzacyjnej. Autorzy zwalidowali przedstawioną metodę na przykładzie mostu zespolonego stalowo-betonowego, wykazując jej skuteczność w przypadku danych niekompletnych i obarczonych szumem pomiarowym. Yin [142] zaproponował natomiast podejście regularyzacji bayesowskiej w zadaniu identyfikacji modelu numerycznego kładki dla pieszych. Hiperparametry regularyzacji estymowane były w sposób adaptacyjny, a do rozwiązania problemu optymalizacyjnego zastosowano metodę Gaussa–Newtona.

Niezależnie od przyjętej postaci funkcji celu, jej minimalizacja wymaga zastosowania odpowiednich metod optymalizacyjnych. W związku z tym w literaturze przedstawiono liczne badania, obejmujące zarówno podejścia deterministyczne, jak i algorytmy stochastyczne oraz metody hybrydowe.

4.2.4 Metody wykorzystywane w procesach identyfikacji modeli MES

Opisywane we współczesnych badaniach podejścia do identyfikacji modeli MES coraz częściej opierają się na integracji różnych metod numerycznych oraz algorytmów optymalizacyjnych. Wśród nich można wyróżnić metody deterministyczne, w tym algorytmy gradientowe takie jak metoda Gaussa–Newtona czy Levenberga–Marquardta, a także algorytmy inspirowane biologicznie oraz metody bayesowskie. Jednak coraz częściej wykorzystywane są również podejścia hybrydowe, łączące w jednym procesie zalety różnych metod optymalizacyjnych. Takie podejście pozwala na zwiększenie efektywności poszukiwania rozwiązania oraz poprawę stabilności procesu identyfikacji. Dostępne w literaturze badania przedstawiają wykorzystanie szerokiego spektrum metod, uzależniając wybór konkretnej z nich od charakteru analizowanego problemu, danych pomiarowych oraz kosztu obliczeniowego.

W praktyce zadanie minimalizacji funkcji celu formułuje się najczęściej w postaci nieliniowego problemu najmniejszych kwadratów. Może być ono rozwiązywane z wykorzystaniem metod gradientowych, które na podstawie pochodnych funkcji celu wyznaczają kierunek poszukiwań optymalnego rozwiązania. Przykładowe badania przedstawili Mazzotti i in. [89], wykorzystując algorytm Gaussa-Newtona z dodatkowymi technikami regularyzacji multiplikatywnej. W zaproponowanym podejściu metodę tę wykorzystano do kalibracji parametrów sztywności filara mostowego na podstawie danych pozyskanych

z przeprowadzonej analizy modalnej. Z kolei Bartilson i in. [15] wykorzystali minimalizację Levenberga-Marquardta wraz z regularyzacją bayesowską, którą wdrożyli do identyfikacji modelu mostu wiszącego.

W procesach identyfikacji modeli MES coraz częściej wykorzystywane są także metody oparte na filtrze Kalmana, a analizę porównawczą jego różnych wariantów opisali Astroza i in. [11]. Badania te nie zostały przeprowadzone na obiektach mostowych, jednak ich wyniki wskazują na skuteczność tych metod w identyfikacji nieliniowych modeli MES, co umożliwia ich potencjalne wykorzystanie także w inżynierii mostowej. Implementację tych metod w obiektach mostowych przedstawił w swoich badaniach również zespół pod kierunkiem Astroza [10]. Tym razem autorzy przedstawili proces identyfikacji modelu numerycznego mostu drogowego, z wykorzystaniem nieliniowego filtru Kalmana. Analizie poddali różne zestawy pomiarowe, uwzględniając przyspieszenia, przemieszczenia oraz odkształcenia. Z kolei Li i in. [69] zaproponowali procedurę identyfikacji modelu MES kratownicowej kładki dla pieszych. Wykorzystali w tym celu metodę inwersji Kalmana oraz dane pochodzące z badań pod próbnym obciążeniem. Następnie porównali zaproponowaną metodę z algorytmem Levenberga–Marquardta, wykazując jej wysoką dokładność, szczególnie w warunkach obecności szumu pomiarowego.

Przedstawione w literaturze badania, opisujące zagadnienia identyfikacji modeli MES, obejmują często iteracyjne techniki optymalizacyjne, wśród których można wymienić optymalizację bayesowską. Podejścia te są często wspomagane przez szereg innych metod pomocniczych, wśród których najpopularniejszymi są modele uczenia maszynowego. Przykładowe badania przedstawili Li i in. [71], którzy do identyfikacji modelu numerycznego stalowej kładki dla pieszych wykorzystali także autoenkoder wariacyjny. Podobne podejście opisali Qin i in. [107], którzy wykorzystując metody bayesowskie wspomagane modelem Kriginga identyfikowali model numeryczny mostu kolejowego dużych prędkości.

Oprócz metod bayesowskich bardzo często wykorzystywane są inne techniki optymalizacyjne w tym algorytmy inspirowane biologicznie. Malveiro i in. [85] opisali identyfikację modelu MES stalowo-betonowego mostu kolejowego. Autorzy wykorzystali algorytm genetyczny w celu dostosowania zgodności między doświadczalnymi parametrami modalnymi, a odpowiedzią numeryczną modelu. W tym celu przeprowadzili badania pod próbnym obciążeniem dynamicznym, przyjmując jako zmienne decyzyjne procesu optymalizacji grubość płyty pomostowej oraz sztywność podpór. Tran-Ngoc i in. [128] przedstawili natomiast proces identyfikacji wieloprzęsłowego mostu kratownicowego, w którym wykorzystali hybrydowy algorytm metaheurystyczny. Autorzy połączyli tym samym zalety algorytmu genetycznego oraz ulepszonego algorytmu przeszukiwania kukułki. Z kolei Tiprak i in. [125] wykorzystali w swoim podejściu algorytm roju cząstek. Identyfikowali oni model numeryczny mostu sprężonego, wykorzystując rzeczywiste dane pomiarowe pochodzące z badań pod próbnym obciążeniem.

4.2.5 Modele zastępcze

Przedstawione metody optymalizacyjne w większości przypadków są podejściem iteracyjnym, w którym bezpośrednie wykorzystywanie modelu MES jest kosztowne obliczeniowo. Z tego powodu wiele obecnych badań skupia się na wykorzystaniu modeli zastępczych, które odpowiednio przygotowane i wytrenowane powinny zastąpić pierwotne modele numeryczne. W tym celu implementowane są różne metody, z których najpopularniejsze jest wykorzystanie modeli sieci neuronowych. Takie podejście zapewnia znaczną redukcję kosztu obliczeniowego oraz czasu, potrzebnego do przeprowadzenia pełnego procesu identyfikacji. Przykładowe badania przedstawili He i in. [49], którzy jako model zastępczy wykorzystali falkową sieć neuronową w połączeniu z algorytmem optymalizacji napędzanej wiatrem. Proponowane rozwiązanie autorzy wdrożyli do identyfikacji modelu numerycznego trójprzęsłowego mostu belkowego. Z kolei Ni i in. [95] jako model zastępczy zastosowali głęboką sieć neuronową. Autorzy wdrożyli swoje rozwiązanie na moście płytowym, analizując odpowiedź konstrukcji w zakresie ugięć i częstotliwości drgań własnych. Cheng i in. [23] na przykładzie mostu wiszącego przeanalizowali natomiast efektywność trzech różnych modeli zastępczych, w tym sieci neuronowej z radialną funkcją bazową. Autorzy przedstawili wnioski, że o ile same modele zastępcze mogą znacznie zredukować koszt obliczeniowy to wybór konkretnego z nich nie wpływa istotnie na jakość identyfikacji modeli numerycznych.

Równie często w procesach identyfikacji modeli MES wykorzystywane są zastępcze modele Kriginga, powszechnie implementowane wspólnie z innymi metodami. Badania takie przedstawili Schnellenbach-Held i in. [115], którzy opisali proces identyfikacji modelu czteroprzęsłowego mostu sprężonego. Wdrożona przez autorów metoda obejmowała interakcję modelu Kriginga oraz algorytmu genetycznego i nieliniowej analizy głównych składowych PCA (*ang. Principal Component Analysis*). Podobne badania przedstawili również Wu i in. [137], którzy wykorzystali model Kriginga, przedstawiając proces identyfikacji modeli mostów o konstrukcji kratownicowej i łukowej. Prezentowane przez autorów podejście opierało się na danych dynamicznych, w tym częstotliwościach i kształtach modalnych.

Pomimo, że wykorzystanie sieci neuronowych jako modeli zastępczych jest najbardziej powszechne, dostępne są także badania przedstawiające alternatywne rozwiązania. Zhou i in. [152] opisali proces identyfikacji modelu mostu łukowego, wykorzystując w tym celu zastępczy model oparty na metodzie powierzchni odpowiedzi RSM (*ang. Response Surface Methodology*). Rozwiązanie to autorzy wdrożyli na moście kompozytowym o znacznej rozpiętości. Ahmad i in. [1] przedstawili natomiast wykorzystanie regresji procesów Gaussa, do identyfikacji jednoprzęsłowego modelu mostu sprężonego. Wykorzystując następnie algorytm roju cząstek autorzy kalibrowali parametr sztywności łożysk, dopasowując go do częstotliwości drgań własnych, zidentyfikowanych na podstawie pomiarów terenowych.

4.2.6 Podsumowanie

Dostępne w literaturze badania poruszające zagadnienie identyfikacji modeli numerycznych często podkreślają duże znaczenie danych pomiarowych pozyskanych z badań pod próbnym obciążeniem. Równocześnie jednak wskazuje się na ich istotne ograniczenia, związane przede wszystkim z wysokimi kosztami. W efekcie nie wszystkie opisywane w literaturze przypadki bazują na próbach obciążeniowych, ale wykorzystują również rozwiązania alternatywne. Przykładowe badania przedstawili Guan i in. [46], którzy zaproponowali metodę identyfikacji modelu MES opartą na długoterminowych danych, pochodzących z systemów monitoringu. W zaproponowanym podejściu stochastyczne obciążenia ruchu, opisane poprzez ich charakterystyki statystyczne, traktowane są jako obciążenie statyczne, zastępując tym samym badania pod próbnym obciążeniem. Takie podejścia wiążą się z większą niepewnością danych pomiarowych, niż w przypadku klasycznych badań pod próbnym obciążeniem.

Dodatkowo w literaturze rzadko analizowane jest kompleksowe podejście integrujące algorytmy optymalizacyjne, modele zastępcze oraz dane eksperymentalne w jednym spójnym procesie identyfikacji. Znaczna część proponowanych podejść jest ponadto weryfikowana w warunkach laboratoryjnych lub na uproszczonych modelach konstrukcji, co ogranicza możliwość bezpośredniego przeniesienia uzyskanych wyników do rzeczywistych obiektów inżynierskich. W warunkach eksploatacyjnych występują bowiem dodatkowe źródła niepewności, obejmujące zmienność obciążeń, wpływ warunków środowiskowych czy niedokładności pomiarowe, wpływające na końcowy efekt identyfikacji modelu. Przykładowe badania przeprowadzili Luo i in. [79], którzy do identyfikacji modeli MES zaproponowali podejście bayesowskie. Metoda ta została przedstawiona na modelu trójprzęsłowego mostu wykonanego w warunkach laboratoryjnych, obejmując jako dane ugięcia oraz parametry modalne. Z kolei Ao i in. [8] przedstawili proces identyfikacji modelu MES kładki dla pieszych wykonanej w skali laboratoryjnej. W procedurze optymalizacyjnej autorzy wykorzystali algorytm simpleksowy, przedstawiając również kompensację uproszczeń modelu poprzez modyfikację parametrów materiałowych.

W poniższym rozdziale zaproponowano podejście do identyfikacji modelu MES, wdrożone na rzeczywistym obiekcie mostowym. Łączy ono w jednym spójnym systemie ciągły monitoring konstrukcji SHM, algorytmy optymalizacyjne oraz modele zastępcze. W przedstawionej metodologii wykorzystano zarówno klasyczne podejście oparte na bezpośrednich analizach MES, jak i wariant z zastosowaniem modelu zastępczego, bazującego na sieci neuronowej. Proces identyfikacji przeprowadzono z wykorzystaniem algorytmu genetycznego, analizując jednocześnie wpływ jego parametrów na jakość uzyskiwanych rozwiązań. Proponowane podejście stanowi zatem rozwinięcie opisanych w literaturze metod, łącząc je w jeden spójny system pomiarowy, wdrożony na moście znacznej rozpiętości [102].

4.3 Implementacja algorytmu genetycznego w procesie identyfikacji modelu MES

4.3.1 Założenia i przyjęte parametry algorytmu genetycznego

Poprawne wdrożenie SHM wymaga uzyskania wiarygodnych modeli numerycznych. W tym celu po zainstalowaniu systemu przeprowadzone zostały badania pod próbnym obciążeniem, które pozwoliły zweryfikować przestrzenną pracę konstrukcji oraz posłużyły jako dane wejściowe w procesie identyfikacji modelu MES. Proces ten stanowi klasyczny przykład problemu optymalizacyjnego, w którym dąży się do minimalizacji lub maksymalizacji zadanej funkcji celu. Do jego rozwiązania mogą zostać wykorzystane różne heurystyki, w tym między innymi algorytm genetyczny, będący jednym z najczęściej wykorzystywanych narzędzi w tego typu zadaniach. Przeprowadzona optymalizacja miała na celu kalibrację parametrów materiałowych podstawowych elementów konstrukcyjnych, wpływających na ogólną sztywność. Realizowano to poprzez minimalizację różnic między odkształceniami zmierzonymi przez system SHM, a wynikami symulacji MES w ściśle określonych punktach pomiarowych. Ich dobór uwzględniał przeprowadzone analizy statyczne oraz podział obiektu na trzy niezależne bramki pomiarowe.

Zdefiniowana populacja algorytmu genetycznego $\mathbf{P} = \{\mathbf{x}_1, \ldots, \mathbf{x}_m\}$ składała się z m kandydatów, z których każdy $\mathbf{x}_i \in \mathbf{P}$ stanowił d-elementowy wektor reprezentujący zestaw modułów sprężystości kolejnych elementów konstrukcyjnych $\mathbf{x}_i = (E_1^{(i)}, \ldots, E_d^{(i)})$, przy czym jako $E_j^{(i)}$ oznaczono moduł sprężystości j-tego elementu konstrukcyjnego, dla $j \in \{1, \ldots, d\}$ oraz $i \in \{1, \ldots, m\}$. Dla każdego elementu moduły te były dobierane niezależnie, aby jak najwierniej odwzorować odkształcenia zmierzone podczas badań pod próbnym obciążeniem. Zdefiniowanych zostało pięć odrębnych wartości dla elementów stalowych $E_1, \ldots, E_5$, obejmujących odpowiednio podłużnice, poprzecznice, łuki, ściągi i wieszaki oraz czternaście wartości dla płyty pomostowej $E_6, \ldots, E_{19}$. Podejście to opierało się na założeniu, że segmenty pomostu mogą charakteryzować się różną sztywnością ze względu na lokalne zachowanie konstrukcji w tych obszarach. W celu zachowania symetrii modelu, moduły $E_6, \ldots, E_{19}$ zdefiniowano dla połowy rozpiętości (14 segmentów z 27), a następnie odbito lustrzanie. Każdy z segmentów stanowił natomiast jeden obszar pomiędzy dwiema sąsiednimi poprzecznicami.

Moduły sprężystości $E_j^{(i)}$ stanowią bezpośrednią składową sztywności osiowej ($E_j^{(i)}A$) oraz giętnej ($E_j^{(i)}I$), łączących wpływ właściwości materiałowych oraz geometrycznych. Zmiana ich wartości umożliwia nie tylko korektę niepewności materiałowych, lecz także pośrednie uwzględnienie zmian parametrów geometrycznych w ogólnej sztywności konstrukcji. W związku z tym moduły sprężystości były traktowane jako zmienne decyzyjne procesu optymalizacyjnego. W tym celu zdefiniowano także wektory wartości granicznych $\mathbf{x}_{\min}$ oraz $\mathbf{x}_{\max}$ modułów, które mogły być generowane przez algorytm. Okre-

ślono je dla każdej składowej $E_j^{(i)}$, przy czym dla $j \in \{1, \ldots, 5\}$ odpowiadającej elementom stalowym przyjmowały wartości 160 – 240 GPa, natomiast dla $j \in \{6, \ldots, 19\}$ odpowiadającej płycie pomostowej 5 – 45 GPa. Zdefiniowane granice $\mathbf{x}_{\text{min}}$ oraz $\mathbf{x}_{\text{max}}$ przekraczają wartości standardowe dla stali konstrukcyjnej i betonu, co wynika z przedstawionego założenia, że powinny one odzwierciedlać różne czynniki wpływające na ogólną sztywność konstrukcji. Należą do nich między innymi wprowadzone dodatkowe usztywnienia, które ze względu na zastosowane w modelu MES uproszczenia nie zawsze są w pełni zdefiniowane w geometrii przekroju. Dodatkowo w rzeczywistej konstrukcji mogą wystąpić luzy montażowe i produkcyjne, tarcie oraz niedokładności w zakresie właściwości geometrycznych, materiałowych i konstrukcyjnych. Rozszerzenie zakresu granicznego modułów sprężystości pozwala także na uwzględnienie sztywności elementów niekonstrukcyjnych takich jak nawierzchnie, krawężniki czy bariery.

W przeprowadzonym procesie identyfikacji wykorzystane zostały dwa podejścia. W pierwszym z nich do oceny poszczególnych osobników wykorzystywany był model MES, natomiast w drugim został on zastąpiony przez model sieci neuronowej. Rozwiązanie to pozwoliło na znaczące zmniejszenie kosztu obliczeniowego oraz umożliwiło wielorazowe testowanie algorytmu genetycznego. W pierwszym podejściu zostało przyjętych 20 pokoleń po 150 osobników, natomiast w drugim przeprowadzono analizę wrażliwości wybranych parametrów algorytmu genetycznego i wybrano najbardziej optymalną architekturę. Kolejne iteracje obejmowały trzy podstawowe operatory: selekcję, krzyżowanie oraz mutację.

W pierwszej kolejności przeprowadzono operację selekcji, której celem było ukierunkowanie populacji w stronę lepiej przystosowanych rozwiązań. W opisanym przypadku zastosowano selekcję turniejową, podczas której losowanych było pięciu kandydatów (ze zwracaniem i równym prawdopodobieństwem wylosowania). Z tak utworzonej grupy wybrane zostało jedno najlepsze rozwiązanie, charakteryzujące się najmniejszą wartością funkcji celu. Cały proces był następnie powtarzany, aż do uzyskania zbioru rodzicielskiego o liczebności równej początkowej liczbie kandydatów $m = 150$. Następnie, został on przekazany do kolejnej fazy reprodukcji, w której wykorzystano symulowane krzyżowanie binarne (*ang. Simulated Binary Crossover, SBX*). Polegało ono na losowym wyborze ze zbioru rodzicielskiego dwóch osobników $\mathbf{x}_1^{\text{cr}}$ oraz $\mathbf{x}_2^{\text{cr}}$, na podstawie których wyznaczono rozwiązania potomne $\mathbf{y}_1^{\text{cr}}$ oraz $\mathbf{y}_2^{\text{cr}}$, zgodnie z procedurą opisaną przez Deb [28] i przytoczoną we wzorach 4-1 do 4-6. Ponieważ osobniki $\mathbf{x}_1^{\text{cr}}$ oraz $\mathbf{x}_2^{\text{cr}}$ stanowią 19-elementowe wektory potencjalnych rozwiązań, procedurę tę przeprowadzono niezależnie dla każdej składowej. Wartości $\mathbf{y}_1^{\text{cr}}$ oraz $\mathbf{y}_2^{\text{cr}}$ wyznaczono na podstawie wzorów 4-1 oraz 4-2.

$$\mathbf{y}_1^{\text{cr}} = \frac{1}{2}\left[\mathbf{x}_1^{\text{cr}} + \mathbf{x}_2^{\text{cr}} - \beta(\mathbf{x}_2^{\text{cr}} - \mathbf{x}_1^{\text{cr}})\right] \tag{4-1}$$

$$\mathbf{y}_2^{\text{cr}} = \frac{1}{2}\left[\mathbf{x}_1^{\text{cr}} + \mathbf{x}_2^{\text{cr}} + \beta(\mathbf{x}_2^{\text{cr}} - \mathbf{x}_1^{\text{cr}})\right] \tag{4-2}$$

Wektory $\mathbf{y}_1^{\text{cr}}$ oraz $\mathbf{y}_2^{\text{cr}}$ rozwiązań potomnych uzależnione są od parametru rozkładu prawdopodobieństwa β, obliczanego na podstawie wzorów 4-3 oraz 4-4. W parametrze tym uwzględniany jest także czynnik losowy w postaci parametru u dobieranego dla każdej iteracji z przedziału $[0, 1]$.

$$\text{Jeżeli } u \leq \frac{1}{\alpha}: \quad \beta = (\alpha \cdot u)^{\frac{1}{\eta_{\text{cr}}+1}} \tag{4-3}$$

$$\text{Jeżeli } u > \frac{1}{\alpha}: \quad \beta = \left(\frac{1}{2 - \alpha \cdot u}\right)^{\frac{1}{\eta_{\text{cr}}+1}} \tag{4-4}$$

Głównym parametrem przyjmowanym na etapie krzyżowania jest parametr redystrybucji η_{cr}, kontrolujący rozrzut rozwiązań potomnych względem osobników rodzicielskich. Zastosowanie niższej wartości tego wskaźnika odpowiada utworzeniu rozwiązań $\mathbf{y}_1^{\text{cr}}$ oraz $\mathbf{y}_2^{\text{cr}}$ bardziej oddalonych od zdefiniowanej pary rodzicielskiej $\mathbf{x}_1^{\text{cr}}$ oraz $\mathbf{x}_2^{\text{cr}}$. Pozwala to na przeszukiwanie większej przestrzeni rozwiązań i zapobiega szybszej zbieżności do lokalnego minimum, co jest szczególnie istotne w problemach wielomodalnych. W przeprowadzonym procesie kalibracji przyjęto wartość $\eta_{\text{cr}} = 0{,}60$. Dodatkowo parametr rozkładu prawdopodobieństwa β uzależniony jest od parametru pomocniczego α obliczanego na podstawie wzoru 4-5. Przyjęte natomiast granice $\mathbf{x}_{\text{min}}$ oraz $\mathbf{x}_{\text{max}}$ dla każdej składowej wektora potencjalnych rozwiązań są uwzględniane poprzez parametr ρ (Wzór 4-6).

$$\alpha = 2 - \rho^{-(\eta_{\text{cr}}+1)} \tag{4-5}$$

$$\rho = 1 + \frac{2}{\mathbf{x}_2 - \mathbf{x}_1} \cdot \min\left[\mathbf{x}_1 - \mathbf{x}_{\text{min}},\ \mathbf{x}_{\text{max}} - \mathbf{x}_2\right] \tag{4-6}$$

Ostatnim operatorem algorytmu genetycznego była mutacja. W przeciwieństwie do etapu krzyżowania jest ona przeprowadzana na pojedynczych osobnikach, ze stosunkowo małym prawdopodobieństwem wystąpienia. W przedstawionym procesie kalibracji przyjęta została mutacja wielomianowa, przytoczona we wzorach 4-7 do 4-10 i opisana szczegółowo przez Deb i in. [29]. Z przedstawionych przez autorów analiz wynika, że zastosowanie mutacji umożliwia wprowadzenie niewielkich perturbacji w zbiorze potencjalnych rozwiązań. Prowadzi to do zwiększenia różnorodności populacji oraz wspomaga efektywne przeszukiwanie przestrzeni rozwiązań. Jednak mutacja sama w sobie nie jest w stanie skutecznie eksplorować tej przestrzeni, ale dopiero uzupełniając wcześniejsze etapy reprodukcji przyczynia się do zwiększenia skuteczność algorytmu genetycznego. Prawdopodobieństwo mutacji przyjęto na poziomie 10 %, a nową wartość $\mathbf{y}^{\text{mut}}$ osobnika potomnego $\mathbf{x}^{\text{mut}}$ uzyskanego na etapie krzyżowania obliczano niezależnie dla każdej składowej tego wektora na podstawie wzoru 4-7.

$$\mathbf{y}^{\text{mut}} = \mathbf{x}^{\text{mut}} + \delta \cdot (\mathbf{x}_{\text{max}} - \mathbf{x}_{\text{min}}) \tag{4-7}$$

Wektor $\mathbf{y}^{\text{mut}}$ uzależniony jest od zdefiniowanych granic $\mathbf{x}_{\text{min}}$ oraz $\mathbf{x}_{\text{max}}$ odpowiadających wektorowi $\mathbf{x}^{\text{mut}}$, a także parametru mutacji δ. Parametr ten wyznaczany jest na podstawie wzorów 4-8 oraz 4-9.

$$\text{Jeżeli } u \leq 0{,}5: \quad \delta = \left[2u + (1-2u)\cdot(1-\mu)^{\eta_{\text{mut}}+1}\right]^{\frac{1}{\eta_{\text{mut}}+1}} - 1, \tag{4-8}$$

$$\text{Jeżeli } u > 0{,}5: \quad \delta = 1 - \left[2(1-u) + (2u-1)\cdot(1-\mu)^{\eta_{\text{mut}}+1}\right]^{\frac{1}{\eta_{\text{mut}}+1}} \tag{4-9}$$

Również na etapie mutacji wprowadzany jest czynnik losowości u, dobierany z przedziału $[0, 1]$. Parametr δ uzależniony jest także od parametru redystrybucji η_{mut}, którego odpowiednia wartość dla większości problemów optymalizacyjnych zawiera się w przedziale $\eta_{\text{mut}} \in [20, 100]$ [46]. Mniejsze wartości tego parametru sprzyjają bardziej eksploracyjnym zmianom w przestrzeni rozwiązań, stąd przyjęto $\eta_{\text{mut}} = 20$. Należy także wyznaczyć parametr μ, zależny od wartości konkretnej składowej osobnika poddawanego mutacji $\mathbf{x}^{\text{mut}}$ oraz wyznaczonych wartości granicznych $\mathbf{x}_{\text{min}}$ oraz $\mathbf{x}_{\text{max}}$ (Wzór 4-10).

$$\mu = \frac{\min\left[\mathbf{x}^{\text{mut}} - \mathbf{x}_{\text{min}},\ \mathbf{x}_{\text{max}} - \mathbf{x}^{\text{mut}}\right]}{\mathbf{x}_{\text{max}} - \mathbf{x}_{\text{min}}} \tag{4-10}$$

Zestawienie przyjętych w algorytmie genetycznym parametrów przedstawiono w Tabeli 4.1.

Tabela 4.1. Przyjęte parametry algorytmu genetycznego

Przyjęte parametry algorytmu genetycznego	
Podstawowe parametry	
Rozmiar populacji	$m = 150$
Liczba pokoleń	20
Liczba zmiennych decyzyjnych (modułów sprężystości E)	$d = 19$
Selekcja	
Algorytm selekcji	Selekcja turniejowa
Liczba osobników w każdym turnieju selekcji	5
Liczba osobników wybranych na etapie selekcji	1
Krzyżowanie	
Algorytm krzyżowania	Symulowane krzyżowanie binarne
Parametr redystrybucji	$\eta_{\text{cr}} = 0{,}60$
Mutacja	
Algorytm mutacji	Mutacja wielomianowa
Prawdopodobieństwo wystąpienia mutacji	10 %
Parametr redystrybucji	$\eta_{\text{mut}} = 20$

4.3.2 Funkcja celu

Do oceny jakości każdego rozwiązania przyjęta została funkcja celu $f(\mathbf{x})$, zdefiniowana jako suma modułów błędów względnych pomiędzy odkształceniami $\mathbf{x}_{p,k}$ uzyskanymi z modelu MES, a wartościami pomiarowymi z badań pod próbnym obciążeniem $\mathbf{x}_{0,p,k}$. Końcowa wartość funkcji celu została obliczona jako suma wszystkich składowych przypadków statycznych $p \in \{1, \ldots, c_\mathrm{s}\}$, przy założeniu realizacji $c_\mathrm{s} = 5$ schematów. Dla każdego przypadku p zdefiniowany został indywidualny zbiór punktów pomiarowych G_p, dla których wyznaczana była wartość funkcji celu. Założenie to wynika z ograniczonego zasięgu powierzchni wpływu przedstawionego w analizie statycznej (punkt 2.5) i potwierdzonego w badaniach pod próbnym obciążeniem (punkt 3.3). Funkcję celu obliczano zgodnie z zależnością 4-11.

$$f(\mathbf{x}) = \sum_{p=1}^{c_\mathrm{s}} \sum_{k \in G_p} \left| \frac{\mathbf{x}_{p,k} - \mathbf{x}_{0,p,k}}{\mathbf{x}_{0,p,k}} \right| \tag{4-11}$$

Przyjęta funkcja celu jest proporcjonalna do miary średniego bezwzględnego błędu procentowego MAPE (*ang. Mean Absolute Percentage Error*), z pominięciem czynnika uśredniającego n, określającego całkowitą liczbę punktów pomiarowych $n = \sum_{p=1}^{c_\mathrm{s}} n_p$, gdzie $n_p = |G_p|$. Modyfikacja ta nie wpływa jednak na przebieg procesu optymalizacji, ponieważ nie zmienia położenia minimum funkcji, a jedynie jej wartość liczbową. W przeprowadzonym procesie kalibracji przywoływane są obie miary, ponieważ pełnią one odmienne funkcje interpretacyjne. Funkcja celu $f(\mathbf{x})$ służy bezpośrednio do sterowania procesem optymalizacji, natomiast MAPE, jako powszechnie stosowana miara jakości dopasowania modelu, jest czytelniejsza interpretacyjnie. Wartość MAPE wyrażona jest zależnością 4-12.

$$\mathrm{MAPE} = \frac{100}{n} \sum_{p=1}^{c_\mathrm{s}} \sum_{k \in G_p} \left| \frac{\mathbf{x}_{p,k} - \mathbf{x}_{0,p,k}}{\mathbf{x}_{0,p,k}} \right| = \frac{100}{n} f(\mathbf{x}) \tag{4-12}$$

Zbiór punktów pomiarowych G_p zależy od konkretnego przypadku obciążenia p, co wynika ze specyfiki pracy badanej konstrukcji. Przeprowadzone analizy oraz badania pod próbnym obciążeniem wykazały lokalny charakter odkształceń rejestrowanych w punktach pomiarowych zlokalizowanych na poprzecznicach. Obciążenie przyłożone bezpośrednio nad daną bramką pomiarową generuje znaczące wartości odkształceń w jej obrębie, przy jednoczesnym pomijalnym wpływie na pozostałe bramki. W tych obszarach rejestrowane są wartości zbliżone do poziomu szumu pomiarowego, które nie powinny być uwzględniane w procesie kalibracji modelu. Przykładowe wartości odkształceń zarejestrowane przez czujniki zainstalowane na poprzecznicach przedstawiono na Rysunku 4.2. Obejmują one dziewięć punktów pomiarowych na wszystkich trzech bramkach oraz schemat obciążenia S1.

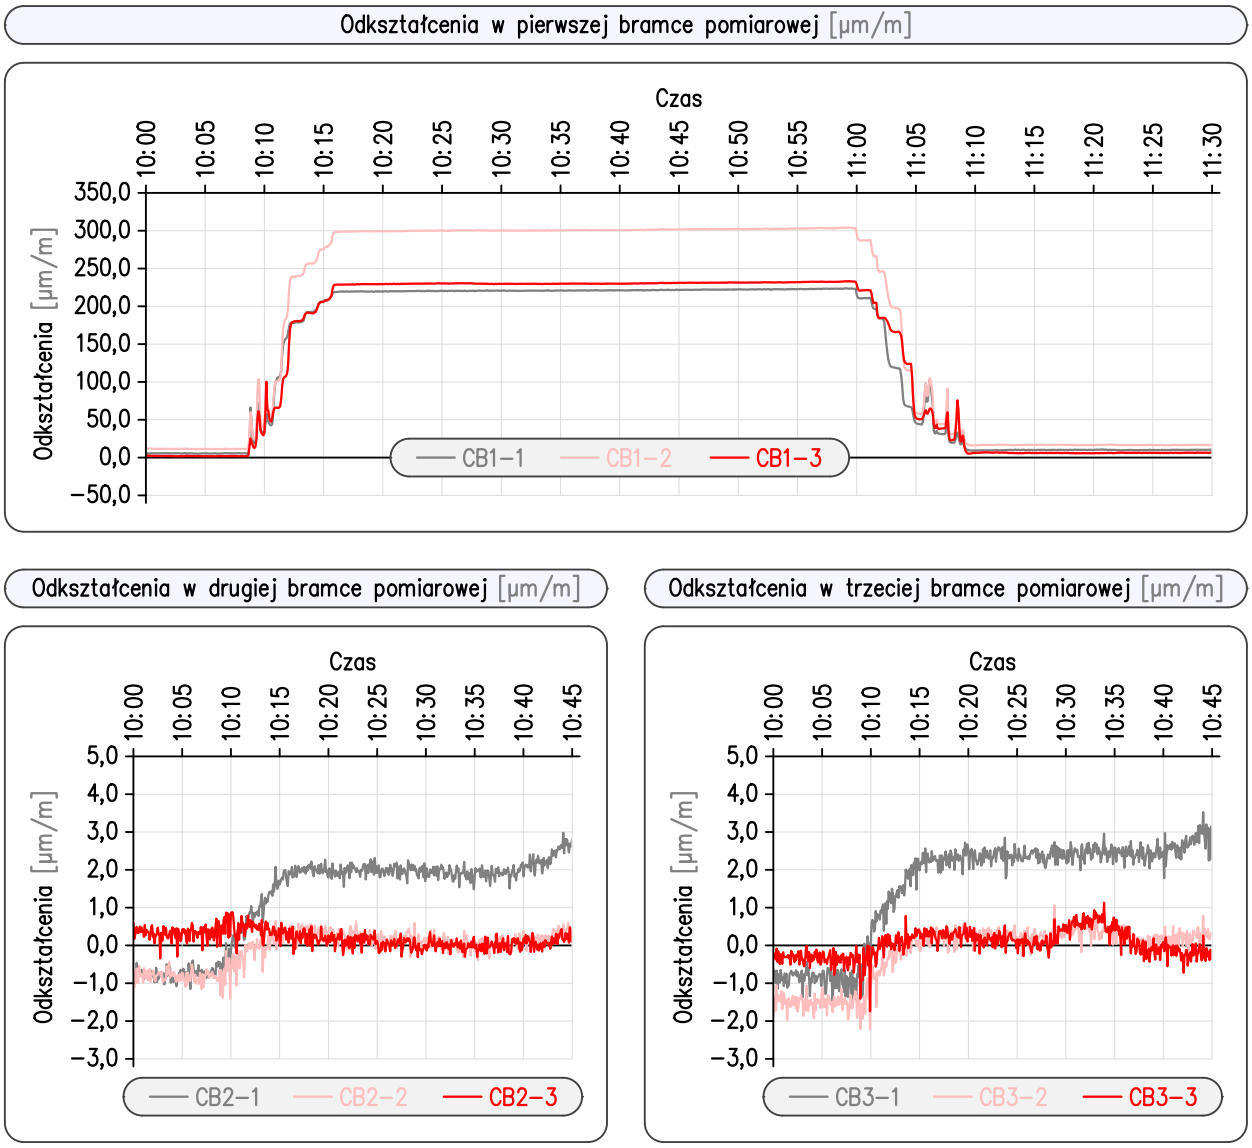

Rysunek 4.2. Przykładowe odczyty odkształceń na poprzecznicach ze wszystkich trzech bramek pomiarowych dla schematu obciążenia S1

Dla przypadków obciążenia S1, S2 oraz S3 zbiór G_p obejmował punkty pomiarowe znajdujące się na pojedynczej poprzecznicy odpowiadającej bramce pomiarowej zlokalizowanej w miejscu przyłożenia obciążenia. Dodatkowo uwzględniono punkty pomiarowe zainstalowane na przeciwległych wieszakach danej bramki, natomiast w przypadku schematu S2 również punkty na podłużnicach. W konfiguracjach niesymetrycznych N1 oraz N2, zbiór G_p obejmował punkty pomiarowe zlokalizowane po jednej stronie przekroju poprzecznego konstrukcji, odpowiadającej miejscu przyłożenia obciążenia. Składały się na niego trzy punkty zlokalizowane na wieszakach, skrajny punkt pomiarowy trzech poprzecznic oraz pojedynczy punkt na podłużnicy. W efekcie przyjęty zestaw danych obejmuje łącznie $\sum_{p=1}^{c_\mathrm{s}} n_p = 31$ punktów pomiarowych rozdzielonych pomiędzy $c_\mathrm{s} = 5$ przypadków obciążenia (Tabela 4.2), przy czym liczebność poszczególnych zbiorów $n_p = |G_p|$ jest zróżnicowana.

Tabela 4.2. Punkty pomiarowe wchodzące w skład zbioru G_p w zależności od przypadku obciążenia

Punkty pomiarowe wchodzące w skład zbioru G_p w zależności od przypadku obciążenia

Przypadki próbnego obciążenia S1-S3 położone centralnie nad bramkami pomiarowymi

Numer schematu	Punkty pomiarowe poprzecznic	Punkty pomiarowe wieszaków	Punkty pomiarowe podłużnic
S1	CB1-1, CB1-2, CB1-3	H1-1, H1-2	-
S2	CB2-1, CB2-2, CB2-3	H2-1, H2-2	TB1, TB2
S3	CB3-1, CB3-2, CB3-3	H3-1, H3-2	-

Przypadki niesymetryczne N1 oraz N2

Numer schematu	Punkty pomiarowe poprzecznic	Punkty pomiarowe wieszaków	Punkty pomiarowe podłużnic
N1	CB1-3, CB2-3, CB3-3	H1-2, H2-2 H3-2	TB2
N2	CB1-1, CB2-1, CB3-1	H1-1, H2-1 H3-1	TB1

Zdefiniowana funkcja celu koncentruje się na efektach wywołanych przez schematy obciążenia statycznego. Wynika to z faktu, że nadrzędnym celem kalibracji jest odwzorowanie parametrów sztywności, co wymaga określenia zależności pomiędzy przyłożonym obciążeniem, a odpowiedzią konstrukcji. Obciążenia statyczne były także realizowane w kontrolowanych warunkach, przy jednoczesnym stosunkowo niskim poziomie szumu pomiarowego. Dodatkowo analizowany obiekt jest konstrukcją o znacznej rozpiętości i dużej sztywności, przez co charakteryzuje się małymi efektami dynamicznymi, związanymi z obciążeniami eksploatacyjnymi. Odpowiedź konstrukcji generowana podczas pojedynczego przejazdu ma charakter krótkotrwały i jest zdominowana przez składową quasi-statyczną, bezpośrednio związaną z masą pojazdu. Odbywający się ruch można zatem traktować jak obciążenie zbliżone do stałego. Założenie to potwierdziły badania pod próbnym obciążeniem dynamicznym, które wykazały odporność analizowanej konstrukcji na efekty dynamiczne. Wpływało na to wysokie tłumienie oraz niski współczynnik przewyższenia dynamicznego (WPD, Wzór 4-13). Dodatkowo wpływ efektów dynamicznych jest redukowany poprzez analizę przyrostów odkształceń $\Delta\varepsilon$, a nie ich wartości bezwzględnej generowanej przez konkretny przypadek obciążenia. Określono różnicę między odkształceniami zmierzonymi w stanie obciążenia, a wartościami odniesienia w stanie nieobciążonym. Przykładowe wykresy odkształceń dla wybranych punktów pomiarowych przedstawiono na Rysunku 4.3. Zlokalizowane są one w środku rozpiętości obiektu, co wynika z faktu, że charakteryzują się największą podatnością na ewentualne wpływy dynamiczne. Przedstawione wykresy obejmują przejazdy pojazdu nr 4 po pasie nr 1 z różnymi prędkościami, odpowiednio 10 km/h i 70 km/h, a także przejazd losowy symulujący rzeczywisty ruch.

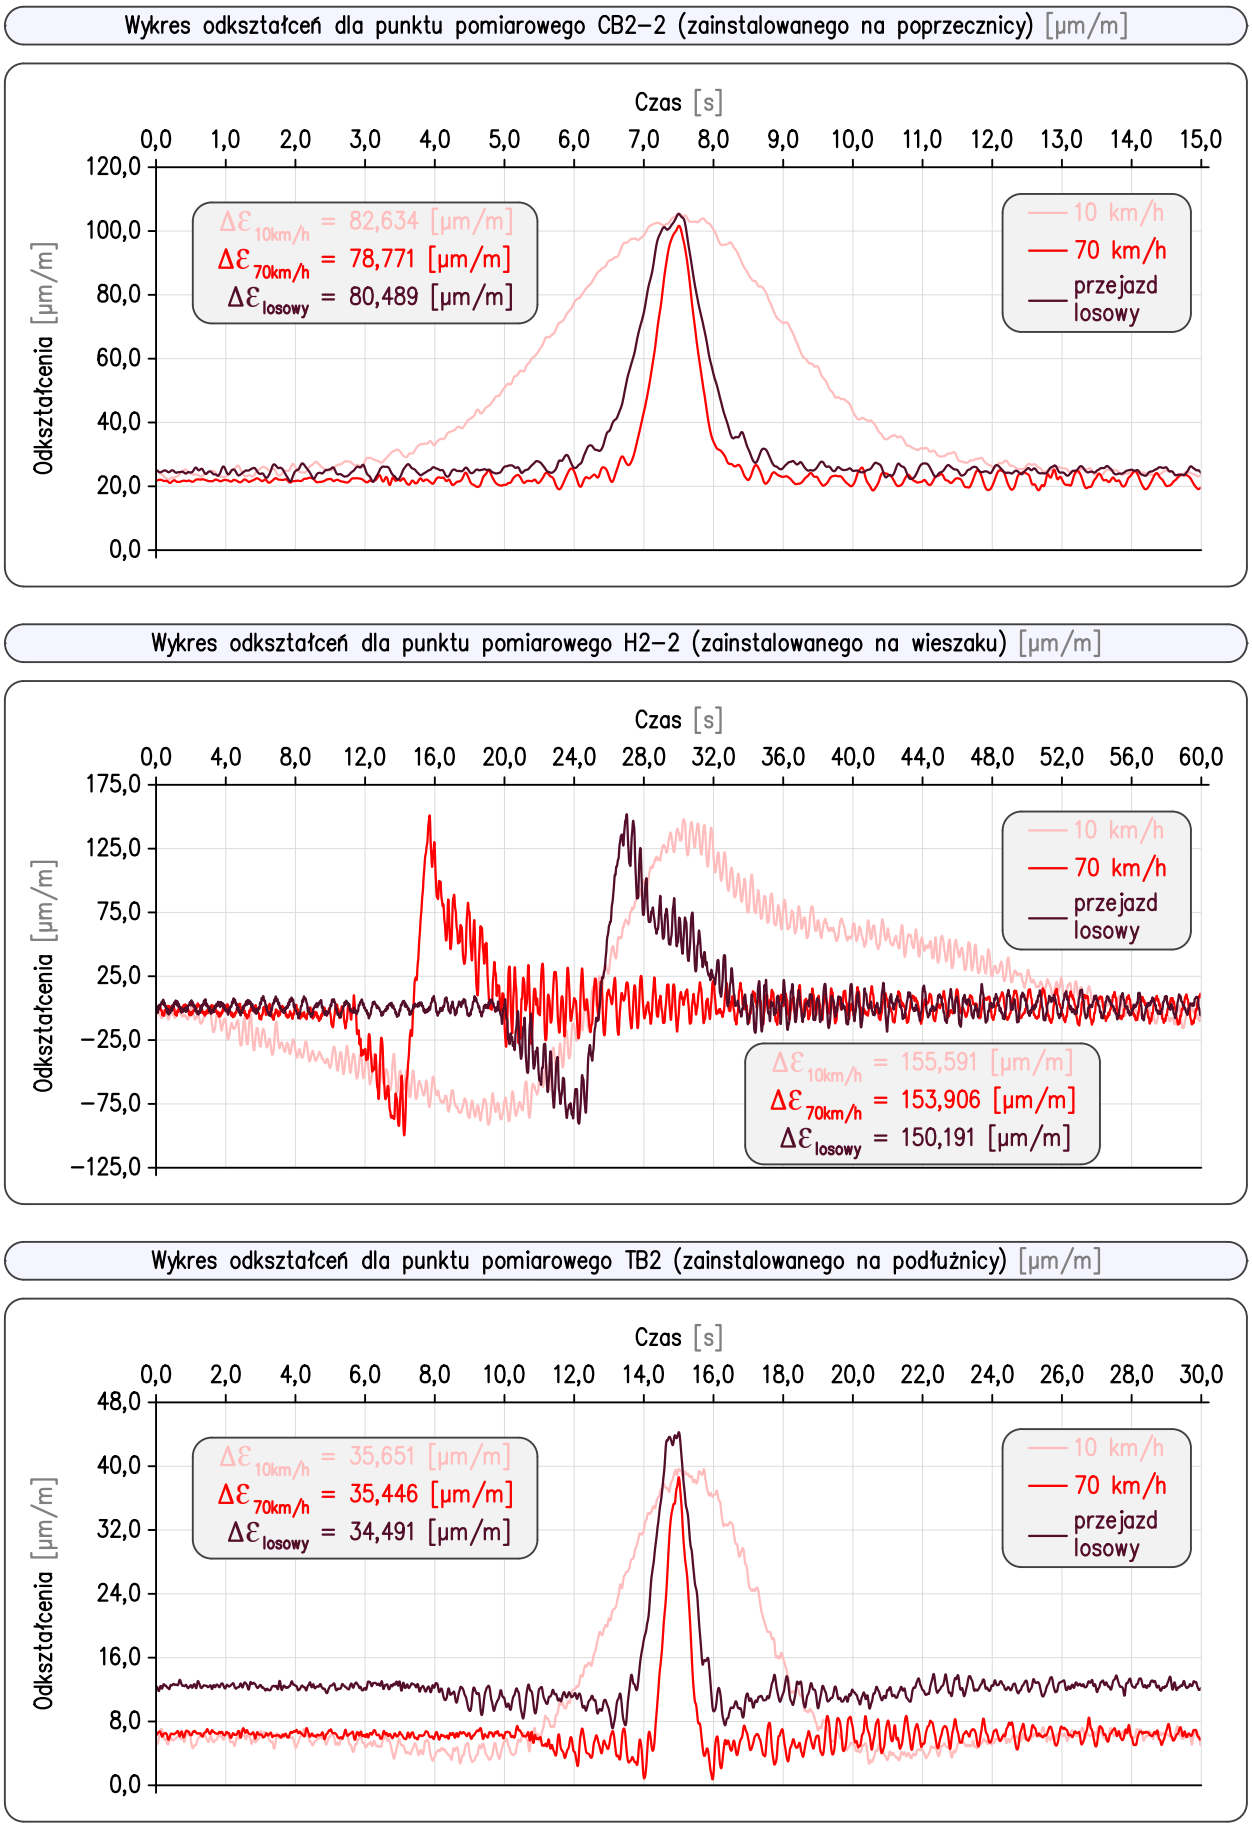

Rysunek 4.3. Przykładowe przyrosty odkształceń dla przejazdu pojedynczego pojazdu z różnymi prędkościami

Przeprowadzone badania wykazały zbliżone przyrosty odkształceń $\Delta\varepsilon$, niezależnie od prędkości ruchu. Na podstawie zależności 4-13 wyznaczono współczynnik przewyższenia dynamicznego, przyjmując jako odniesienie obciążenie quasi-statyczne $\Delta\varepsilon_{\text{stat}}$ odpowiadające przejazdowi z prędkością 10 km/h. Wartość współczynnika określono jako średnią ilorazów przyrostów odkształceń uzyskanych dla przejazdów dynamicznych z różnymi prędkościami $\Delta\varepsilon_{\text{dyn}}$ do wartości referencyjnej $\Delta\varepsilon_{\text{stat}}$. Porównania prowadzono dla przejazdów obejmujących ten sam pojazd oraz pas ruchu, przy różnych prędkościach, gdzie jako p_{d} oznaczono indeks rozpatrywanego przejazdu, a jako c_{d} liczbę analizowanych przejazdów. Przykładowy przejazd korespondujący z Rysunkiem 4.3 przedstawiono w Tabeli 4.3. Wartości współczynnika zbliżone do jedności wskazują na pomijalny wpływ efektów dynamicznych.

$$\text{WPD} = \frac{1}{c_{\text{d}}} \sum_{p_{\text{d}}=1}^{c_{\text{d}}} \frac{\Delta\varepsilon_{\text{dyn}}}{\Delta\varepsilon_{\text{stat}}} \tag{4-13}$$

Tabela 4.3. Wartości odkształceń i współczynnika przewyższenia dynamicznego dla przykładowego przejazdu

Wartości odkształceń dla przykładowego przejazdu z różnymi prędkościami				
	10 km/h [μm/m]	70 km/h [μm/m]	Losowy przejazd [μm/m]	WPD [-]
CB1-1	40,619	39,205	40,565	0,9819
CB1-2	83,567	84,046	85,925	1,0170
CB1-3	61,247	57,377	61,480	0,9703
CB2-1	37,458	36,139	37,175	0,9786
CB2-2	82,634	78,771	80,489	0,9637
CB2-3	57,613	53,920	55,705	0,9514
CB3-1	42,855	41,089	44,921	1,0035
CB3-2	90,375	88,558	91,487	0,9961
CB3-3	65,213	63,652	63,762	0,9769
H1-1	134,977	137,599	136,075	1,0138
H1-2	240,091	243,075	245,009	1,0165
H2-1	83,643	84,324	84,258	1,0078
H2-2	155,591	153,906	150,191	0,9772
H3-1	59,509	58,191	61,113	1,0024
H3-2	52,892	53,619	54,002	1,0174
TB1	27,892	28,065	27,026	0,9876
TB2	35,651	35,446	34,491	0,9809
	Wartość współczynnika przewyższenia dynamicznego:			0,9908

W celu porównania otrzymanych wyników przed identyfikacją i po jej przeprowadzeniu, wyznaczono wartość funkcji celu $f(\mathbf{x})$ dla pierwotnego modelu MES. Zestawione zostały wartości odkształceń uzyskane z systemu SHM oraz modelu, odpowiednio dla przypadków obciążenia S1-S3 (Tabela 4.4) oraz N1-N2 (Tabela 4.5), a także składowe wartości funkcji celu i bezwzględnego błędu procentowego. Łączna wartość funkcji celu wyniosła 4,848, co odpowiadało wartości MAPE na poziomie 15,65 %.

Tabela 4.4. Wartości odkształceń uzyskane z pierwotnego modelu MES: schematy S1-S3

Wartości odkształceń uzyskane z pierwotnego modelu MES: schematy S1-S3				
	Wartości odkształceń otrzymanych z systemu SHM [μm/m]	Wartości odkształceń otrzymanych z modelu MES [μm/m]	Bezwzględny błąd procentowy [%]	Cząstkowa wartość funkcji celu [-]
CB1-1	213,639	236,874	10,88	0,109
CB1-2	287,092	324,230	12,94	0,129
CB1-3	226,633	247,563	9,24	0,092
H1-1	1083,440	1226,396	13,19	0,132
H1-2	1386,006	1101,406	20,53	0,205
		Łączna wartość funkcji celu dla schematu S1:		0,667
		Wartość MAPE dla wszystkich punktów schematu S1:		13,36 %
CB2-1	201,031	226,592	12,71	0,127
CB2-2	279,084	308,470	10,53	0,105
CB2-3	216,412	236,547	9,30	0,093
H2-1	603,519	873,515	44,74	0,447
H2-2	762,571	767,738	0,68	0,007
TB1	147,681	143,658	2,72	0,027
TB2	128,812	129,366	0,43	0,004
		Łączna wartość funkcji celu dla schematu S2:		0,810
		Wartość MAPE dla wszystkich punktów schematu S2:		11,59 %
CB3-1	220,361	237,619	7,83	0,078
CB3-2	308,004	328,045	6,51	0,065
CB3-3	247,962	249,309	0,54	0,005
H3-1	285,511	413,755	44,92	0,449
H3-2	285,224	340,272	19,30	0,193
		Łączna wartość funkcji celu dla schematu S3:		0,790
		Wartość MAPE dla wszystkich punktów schematu S3:		15,82 %

Tabela 4.5. Wartości odkształceń uzyskane z pierwotnego modelu MES: schematy N1-N2

Wartości odkształceń uzyskane z pierwotnego modelu MES: schematy N1-N2				
	Wartości odkształceń otrzymanych z systemu SHM [μm/m]	Wartości odkształceń otrzymanych z modelu MES [μm/m]	Bezwzględny błąd procentowy [%]	Cząstkowa wartość funkcji celu [-]
CB1-3	82,254	81,080	1,43	0,014
CB2-3	96,938	114,902	18,53	0,185
CB3-3	25,994	29,536	13,63	0,136
H1-2	–126,932	–69,264	45,43	0,454
H2-2	515,912	488,010	5,41	0,054
H3-2	543,202	500,379	7,88	0,079
TB2	41,411	31,233	24,58	0,246
	Łączna wartość funkcji celu dla schematu N1:			1,168
	Wartość MAPE dla wszystkich punktów schematu N1:			16,70 %
CB1-1	70,528	72,584	2,92	0,029
CB2-1	81,946	96,964	18,33	0,183
CB3-1	22,207	24,322	9,52	0,095
H1-1	–99,108	–75,833	23,48	0,235
H2-1	360,982	498,058	37,97	0,380
H3-1	413,289	509,838	23,36	0,234
TB1	46,905	34,837	25,73	0,257
	Łączna wartość funkcji celu dla schematu N2:			1,413
	Wartość MAPE dla wszystkich punktów schematu N2:			20,19 %

Analiza wyników wskazuje na istotne rozbieżności między modelem MES, a rzeczywistą odpowiedzią konstrukcji. Wartości składowe MAPE dla poszczególnych przypadków obciążenia wykazują znaczne zróżnicowanie, przyjmując wartości od 11,59 % dla schematu S2 do nawet 20,19 % dla przypadku niesymetrycznego N2. Szczególnie istotne różnice można zaobserwować w punktach pomiarowych zlokalizowanych na wieszakach, gdzie bezwzględne błędy procentowe wynosiły nawet około 45 %. Dla poprzecznic i podłużnic uzyskano natomiast lepszą zgodność z pomiarami, osiągając maksymalne wartości MAPE wynoszące około 18 %. Uzyskane wyniki potwierdzają zasadność przeprowadzenia procesu identyfikacji modelu MES, w celu wierniejszego odwzorowania rzeczywistej pracy konstrukcji.

4.3.3 Implementacja sieci neuronowej jako modelu zastępczego

Modele sieci neuronowych są powszechnie stosowanymi algorytmami uczenia maszynowego, wykorzystywanymi zarówno w problemach klasyfikacyjnych jak i regresyjnych. W literaturze przedstawiono liczne badania obrazujące ich skuteczne zastosowania, w których z powodzeniem zastępują klasyczne obliczenia MES. Wykorzystanie modeli zastępczych w metodach optymalizacyjnych umożliwia znaczną redukcję kosztu obliczeniowego, prowadząc do usprawnienia oceny potencjalnych rozwiązań. Przedstawiony proces identyfikacji został zatem przeprowadzony w dwóch niezależnych podejściach, w których do oceny każdego rozwiązania wykorzystano model MES oraz zastępczy model bazujący na sieci neuronowej. Zadanie to stanowi przykład problemu regresyjnego, w którym na podstawie określonych danych wejściowych szacowano wartości odkształceń w ściśle zdefiniowanych punktach pomiarowych.

Modele sieci neuronowych miały za zadanie zastąpić kosztowne obliczeniowo symulacje numeryczne. Zbiór danych treningowych składał się z wyników analiz MES przygotowanych specjalnie na potrzeby procesu uczenia sieci. Dane wejściowe stanowiły d-elementowe wektory, reprezentujące zmienne decyzyjne procesu optymalizacyjnego $\mathbf{x}^{(r)} \in \mathbb{R}^d$, dla $d = 19$, gdzie jako r oznaczono indeks kolejnej próbki zbioru danych. Obejmowały one wartości modułów sprężystości poszczególnych elementów konstrukcyjnych $E_1, \ldots, E_{19}$. Dane wyjściowe stanowiły natomiast n-elementowe wektory $\mathbf{y}^{(r)} \in \mathbb{R}^n$ zawierające wartości odkształceń wyznaczone na podstawie analiz MES, gdzie n określa liczbę punktów pomiarowych dla wszystkich przypadków obciążenia statycznego $n = \sum_{p=1}^{c_s} n_p$, co w analizowanym przypadku wynosi $n = 31$. Odkształcenia te zostały zdefiniowane dla punktów odpowiadających zbiorom G_p (Tabela 4.2), przyjętym w definicji funkcji celu $f(\mathbf{x})$ (Wzór 4-11).

Model sieci neuronowej trenowano na zbiorze danych wygenerowanych na podstawie symulacji MES dla losowo dobranych wartości zmiennych decyzyjnych $\mathbf{x}^{(r)}$, należących do przedziału ograniczonego przez wektory $\mathbf{x}_{\text{min}}$ oraz $\mathbf{x}_{\text{max}}$. Generowanie zbioru danych zostało zautomatyzowane z wykorzystaniem interfejsu API (*ang. Application Programming Interface*) środowiska SOFiSTiK. Opracowany algorytm umożliwiał wielokrotne uruchamianie obliczeń MES na podstawie plików wsadowych zawierających definicję geometrii, właściwości materiałowych oraz przypadków obciążeń, a następnie zapis wyników odkształceń w postaci uporządkowanego zbioru danych. W modelu obciążeń uwzględniono zestawy sił skupionych odpowiadające układom osi pojazdów wykorzystywanych podczas badań pod próbnym obciążeniem. Pojazdy te rozmieszczano w różnych pozycjach na obiekcie, przypisując im zróżnicowane wartości masy całkowitej przy zachowaniu proporcji rozkładu obciążenia na poszczególne osie. Takie podejście pozwoliło na wygenerowanie syntetycznego zbioru danych obejmującego 1000 próbek, który odwzorowywał szeroki zakres możliwych scenariuszy obciążenia konstrukcji (Rysunek 4.4).

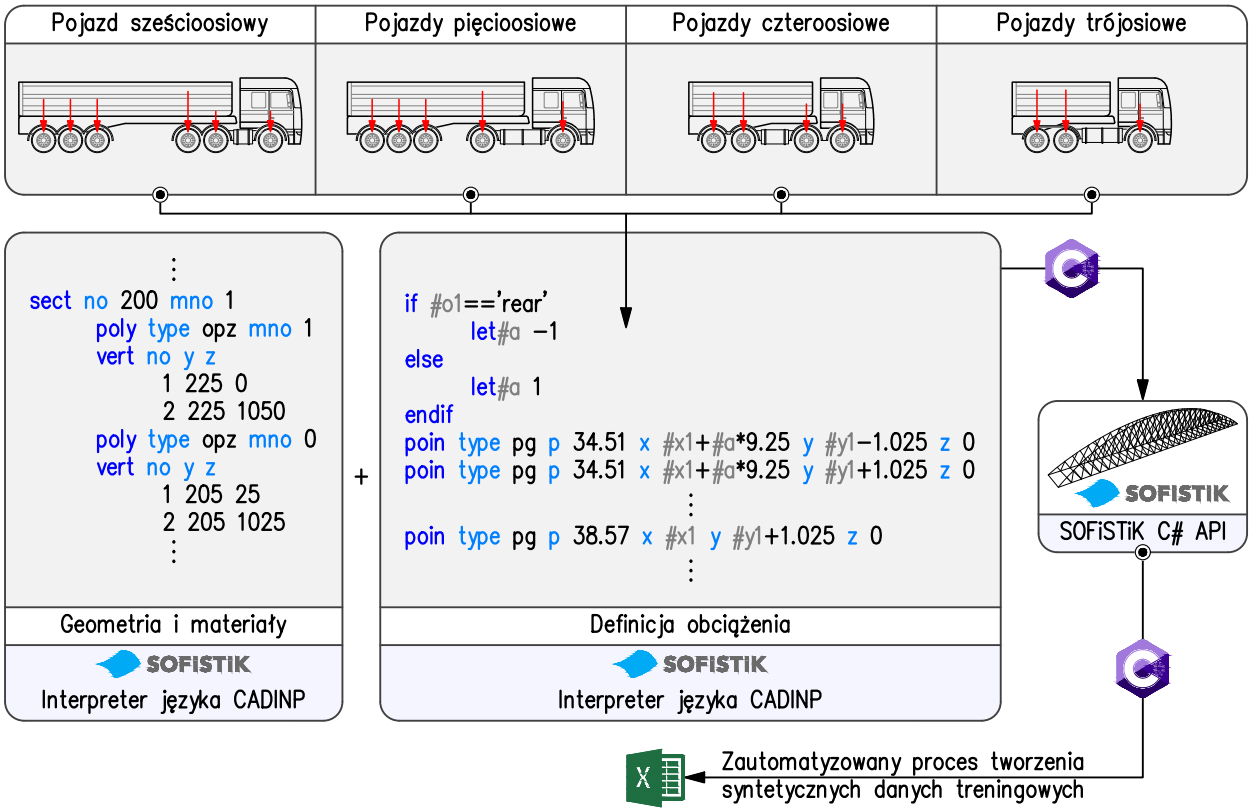

Rysunek 4.4. Zautomatyzowany proces tworzenia syntetycznych danych treningowych

Wygenerowane dane podzielono na zbiór treningowy obejmujący 720 próbek oraz zbiór walidacyjny, złożony z 180 próbek. Wartości predykcyjne wyznaczane są na podstawie propagacji w przód, polegającej na przekształceniu danych wejściowych przez kolejne warstwy sieci. Obliczenie sygnałów wyjściowych $h_{\boldsymbol{\theta}}(\mathbf{X})$ realizowane jest zgodnie z zależnością 4-14, w której macierz cech wejściowych $\mathbf{X}$ poddawana jest przekształceniu afinicznemu z wykorzystaniem macierzy wag $\mathbf{W}$ oraz wektora obciążeń $\mathbf{b}$, a następnie jest przekształcana przez nieliniową funkcję aktywacji ϕ. Macierz $\mathbf{X}$ tworzona jest przez wektory danych wejściowych $\mathbf{x}^{(r)}$, odpowiadające poszczególnym próbkom.

$$h_{\boldsymbol{\theta}}(\mathbf{X}) = \phi(\mathbf{XW} + \mathbf{b}) \tag{4-14}$$

W rzeczywistości proces uczenia modelu sieci neuronowej stanowi przykład zadania optymalizacyjnego, w którym parametry modelu $\boldsymbol{\theta} = \mathbf{W}, \mathbf{b}$ występują jako zmienne decyzyjne. Celem procesu uczenia jest wyznaczenie minimum globalnego funkcji straty, umożliwiającego uzyskanie zdolności uogólniania modelu na nowych, niezaobserwowanych danych. W przedstawionym podejściu wykorzystana została funkcja straty Hubera $L(h_{\boldsymbol{\theta}}(\mathbf{X}), \mathbf{Y})$, gdzie jako $\mathbf{Y}$ oznaczono macierz cech wyjściowych, na którą składają się poszczególne wektory $\mathbf{y}^{(r)}$. Łączy ona w sobie cechy średniego błędu kwadratowego (*ang. Mean Squared Error, MSE*) oraz średniego błędu bezwzględnego (*ang. Mean Absolute Error, MAE*). Funkcja ta określana jest dla zbioru danych jako średnia wartość funkcji straty wyznaczonej dla poszczególnych

próbek $\mathbf{x}^{(r)}$ oraz $\mathbf{y}^{(r)}$, gdzie jako n_r oznaczono liczbę próbek w zbiorze treningowym (Wzór 4-15). Dodatkowo dla każdej próbki definiowana jest wartość jednostkowa $l^{(r)}$ zgodnie z zależnością 4-16. Dla małych różnic między przewidywaniem $h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})$, a rzeczywistością $\mathbf{y}^{(r)}$ przyjmuje postać funkcji kwadratowej, zachowując się jak MSE gdy $|h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) - \mathbf{y}^{(r)}| \leq \delta_\mathrm{L}$ oraz postać liniową i charakter MAE dla większych różnic $|h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) - \mathbf{y}^{(r)}| > \delta_\mathrm{L}$. Ze względu na zastosowaną normalizację przyjęto próg przejścia między częścią kwadratową, a liniową $\delta_\mathrm{L} = 1$, co odpowiada typowej skali błędu. W konsekwencji dla większości próbek funkcja straty przyjmuje charakter kwadratowy, natomiast część liniowa aktywowana jest dla większych odchyleń, pełniąc rolę mechanizmu ograniczającego wpływ wartości odstających.

$$L(h_{\boldsymbol{\theta}}(\mathbf{X}), \mathbf{Y}) = \frac{1}{n_\mathrm{r}} \sum_{r=1}^{n_\mathrm{r}} l^{(r)} \tag{4-15}$$

$$l^{(r)} = L(h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}), \mathbf{y}^{(r)}) = \begin{cases} \frac{1}{2}\left(h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) - \mathbf{y}^{(r)}\right)^2 & \text{dla } |h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) - \mathbf{y}^{(r)}| \leq \delta_\mathrm{L} \\ \delta_\mathrm{L}\left(|h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) - \mathbf{y}^{(r)}| - \frac{1}{2}\delta_\mathrm{L}\right) & \text{dla } |h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) - \mathbf{y}^{(r)}| > \delta_\mathrm{L} \end{cases} \tag{4-16}$$

W procesie uczenia wykorzystana została metoda stochastycznego spadku wzdłuż gradientu (*ang. Stochastic Gradient Descent, SGD*), której celem było wyznaczenie kierunku najszybszego wzrostu wartości funkcji straty. W praktycznej implementacji proces wyznaczania gradientów realizowany jest z wykorzystaniem mechanizmu propagacji wstecznej (*ang. Backpropagation*) dostępnego w bibliotekach Keras oraz TensorFlow, opartego na różniczkowaniu automatycznym. Istotnym elementem wpływającym na zdolność modelu do odwzorowania nieliniowych zależności pomiędzy danymi wejściowymi a wartościami wyjściowymi jest także wybór funkcji aktywacji ϕ. W ramach przeprowadzonych analiz rozważono cztery typy, różniące się charakterystyką oraz przebiegiem pochodnych (Rysunek 4.5).

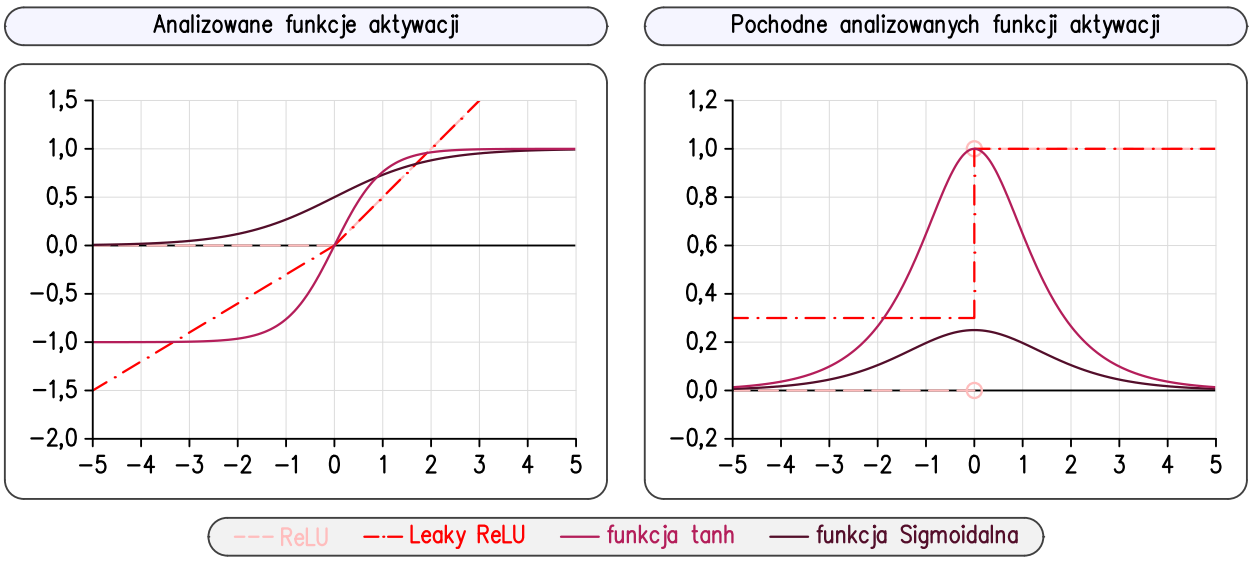

Rysunek 4.5. Analizowane funkcje aktywacji i ich pochodne

Dobór architektury oraz hiperparametrów realizowany był z wykorzystaniem optymalizacji bayesowskiej, w której przestrzeń rozwiązań przeszukiwana jest iteracyjnie na podstawie wyników uzyskanych w poprzednich krokach. W procesie tym optymalizowano liczbę warstw, liczbę neuronów w poszczególnych warstwach, funkcję aktywacji oraz wartość współczynnika uczenia. W praktycznej implementacji zastosowano optymalizator Adam (*ang. Adaptive Moment Estimation*), minimalizując wartości funkcji straty na zbiorze walidacyjnym. Implementację opisanego procesu przedstawiono na Rysunku 4.6.

Jako dodatkowe kryterium zastosowano mechanizm wczesnego zatrzymania, przyjmując maksymalnie 100 kolejnych epok bez poprawy wartości funkcji straty na zbiorze walidacyjnym. W modelu końcowym przyjęto parametry **W** oraz **b** odpowiadające minimalnej wartości funkcji straty uzyskanej na tym zbiorze. Jako podstawową metrykę w procesie uczenia oraz strojenia hiperparametrów przyjęto funkcję straty Hubera (Wzór 4-15 i 4-16). Krzywe uczenia dla wszystkich analizowanych wariantów przedstawiono na Rysunku 4.7, przy czym przebieg odpowiadający najlepszemu modelowi został wyróżniony.

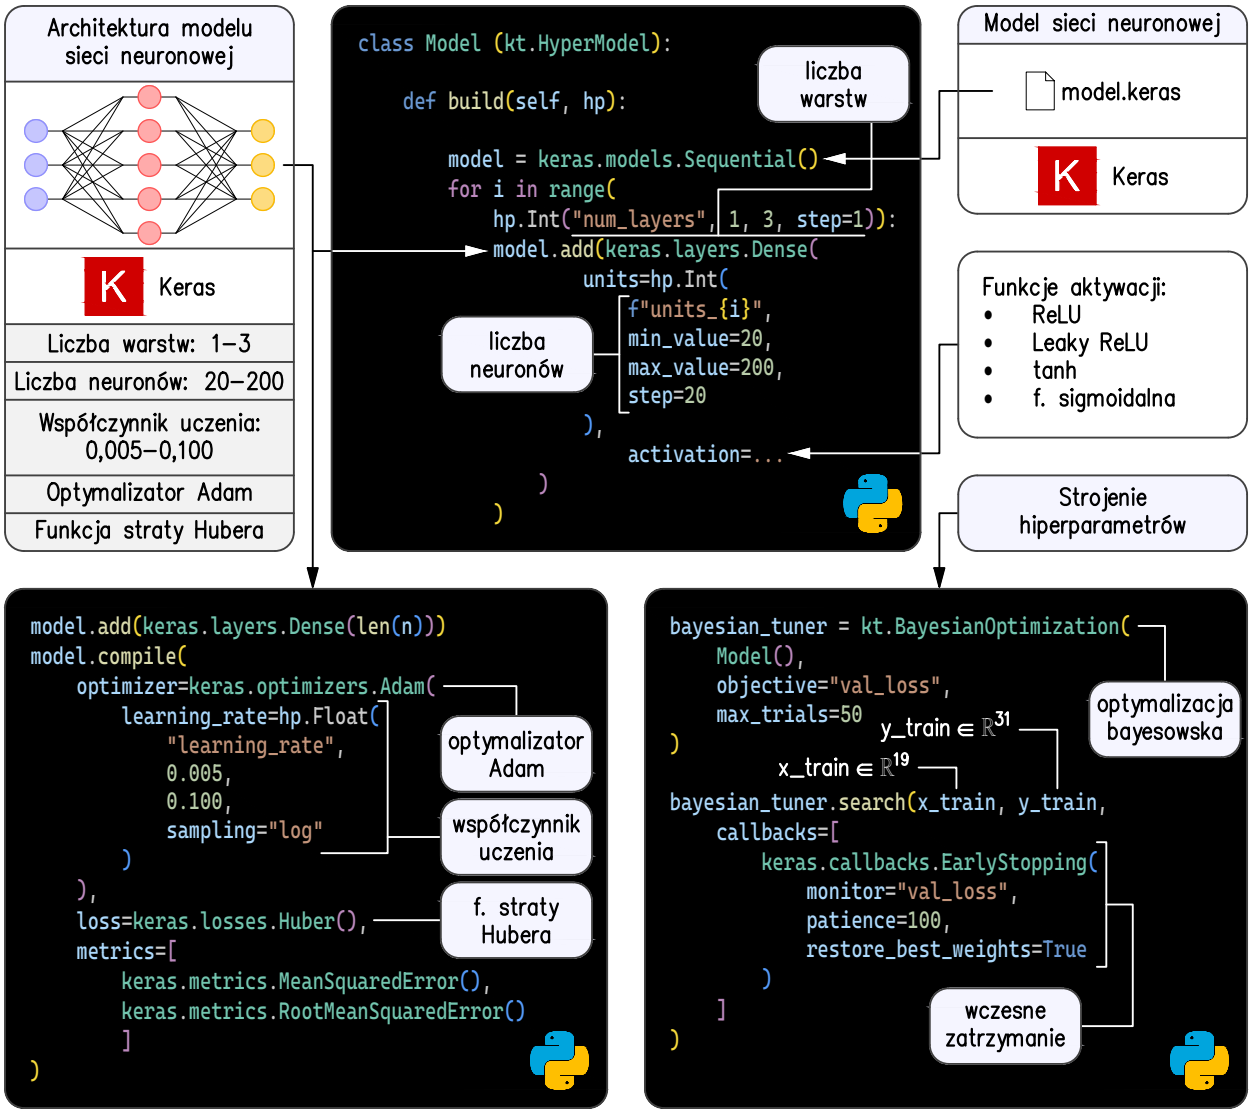

Rysunek 4.6. Implementacja modelu zastępczego sieci neuronowej

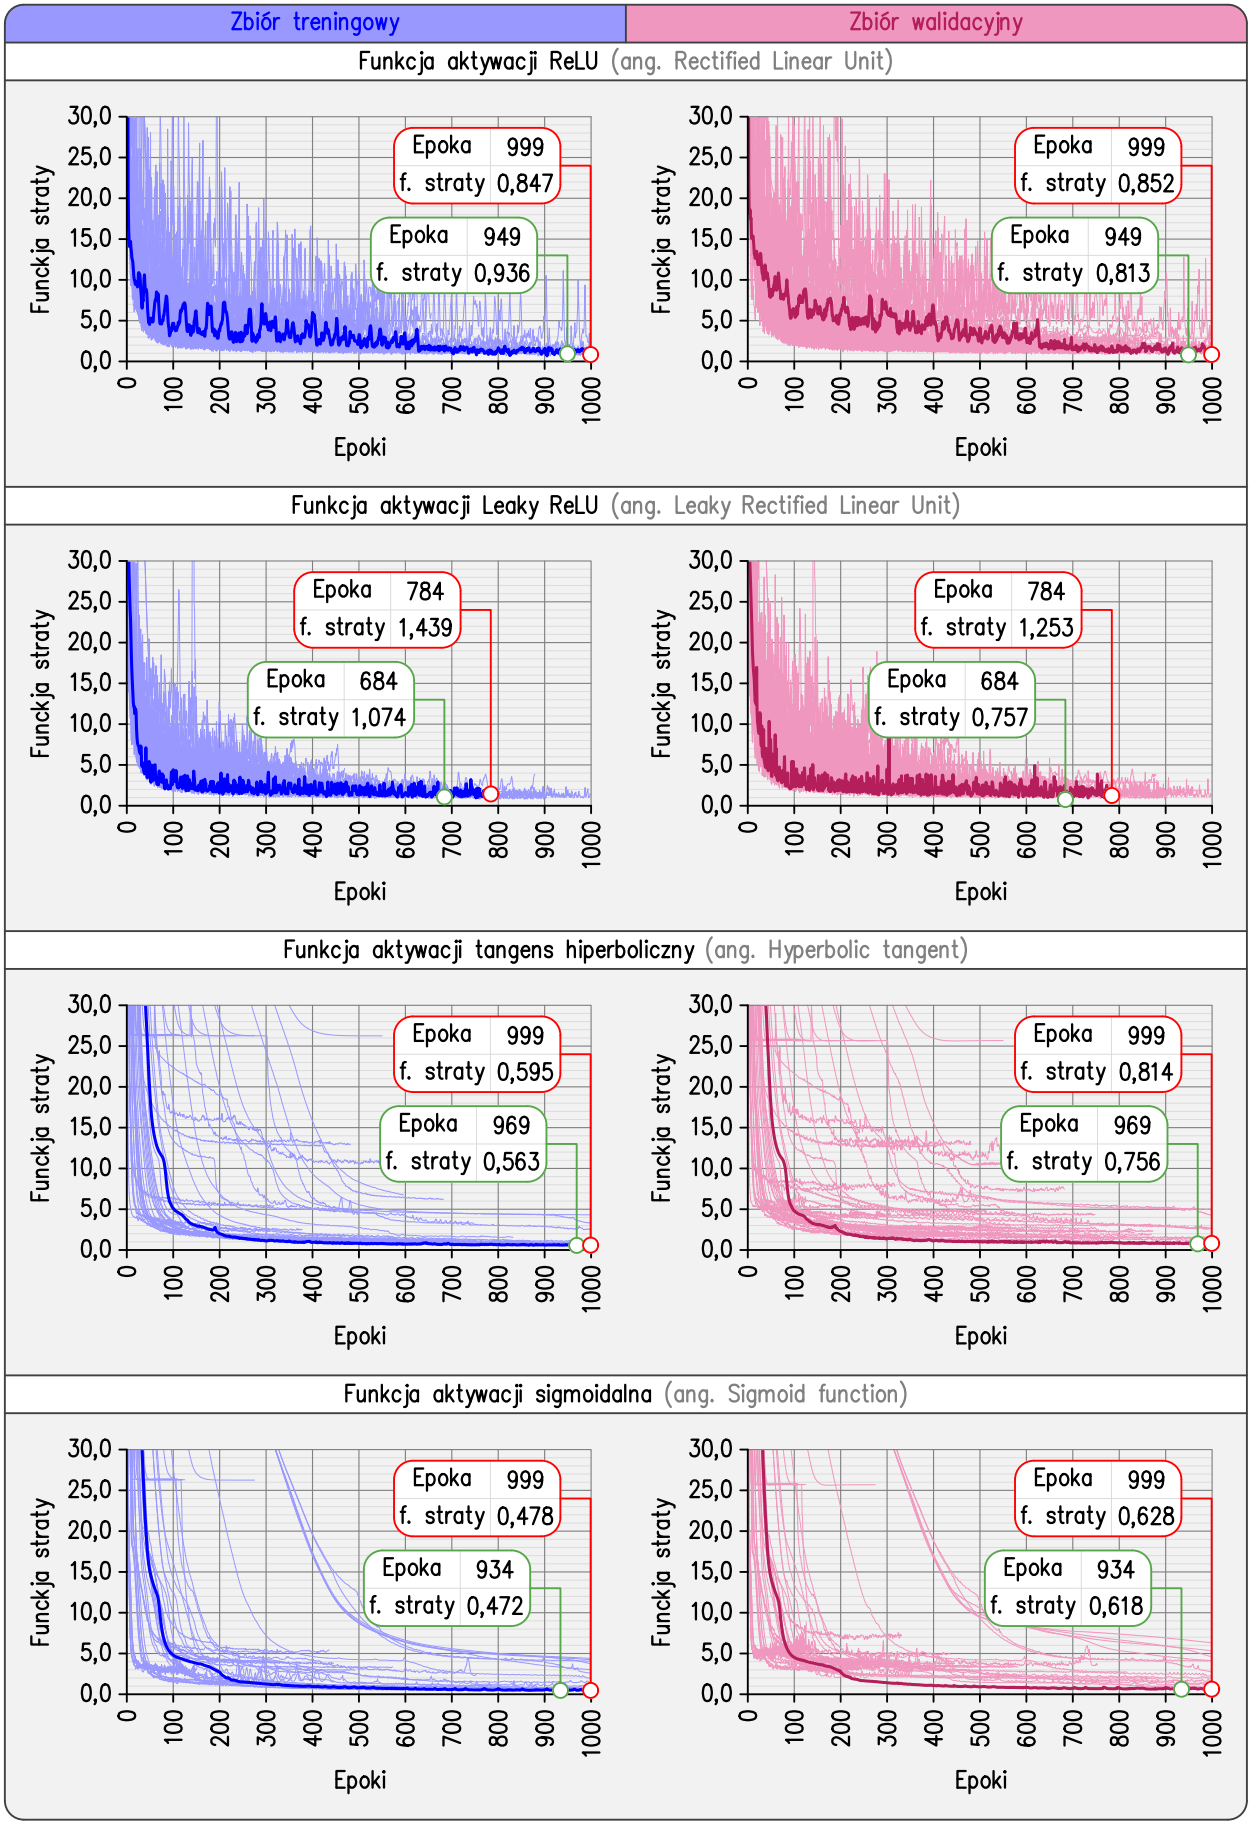

Rysunek 4.7. Krzywe uczenia dla różnych funkcji aktywacji modeli sieci neuronowych

W ramach optymalizacji bayesowskiej wygenerowano 50 modeli dla każdej z analizowanych funkcji aktywacji. Proces ten pozwalał na określenie optymalnej architektury oraz wartości hiperparametrów, dla których funkcja straty osiąga minimalną wartość na zbiorze walidacyjnym. Początkowe iteracje obejmowały całkowicie losowy dobór hiperparametrów, natomiast kolejne modele generowane były w sposób adaptacyjny na podstawie wyników uzyskanych w poprzednich krokach. Lewa kolumna Rysunku 4.7 przedstawia krzywe uczenia dla zbioru treningowego, natomiast prawa dla zbioru walidacyjnego. Zielonymi etykietami oznaczono epokę odpowiadającą minimalnej wartości funkcji straty dla zbioru walidacyjnego, natomiast czerwonymi ostatnią epokę procesu uczenia najlepszego modelu, wynikającą z osiągnięcia stagnacji lub przyjętego limitu, zdefiniowanego na poziomie tysiąca epok.

Analiza krzywych uczenia wskazuje na istotne różnice w zachowaniu modeli. Zastosowanie funkcji aktywacji ReLU oraz Leaky ReLU prowadzi do zbieżności w kierunku stosunkowo niskich wartości funkcji straty (poniżej 2,0 dla większości wariantów). Jednocześnie ujawniają one istotne fluktuacje, wynikające ze stochastycznego charakteru procesu treningowego. W przypadku funkcji Leaky ReLU obserwuje się jednak wyraźne ograniczenie tych wahań oraz większą stabilność procesu uczenia, co przekłada się na bardziej regularny przebieg krzywych uczenia. Najlepszy model wykorzystujący funkcję aktywacji ReLU osiągnął w 949. epoce wartości funkcji straty 0,936 dla zbioru treningowego i 0,813 dla zbioru walidacyjnego, natomiast dla funkcji Leaky ReLU odpowiednio 1,074 i 0,757 w 684. epoce.

Modele wykorzystujące jako funkcję aktywacji tangens hiperboliczny lub funkcję sigmoidalną częściej ulegały stagnacji przy wyższych wartościach funkcji straty. Charakterystyka ta może wskazywać na większą podatność na lokalne minima, co jednak nie uniemożliwia uzyskania modeli o wysokiej dokładności. Najlepsze modele wykorzystujące funkcję aktywacji tangens hiperboliczny osiągają w 969. epoce wartości funkcji straty wynoszące 0,563 i 0,756 dla zbioru treningowego i walidacyjnego, natomiast dla funkcji sigmoidalnej odpowiednio 0,472 i 0,618, uzyskane w 934. epoce. W obu przypadkach występuje niewielkie nadmierne dopasowanie, które jednak nie wpływa istotnie na jakość predykcji.

Architektury badane podczas procesu strojenia hiperparametrów zostały zestawione w Tabeli 4.6. Na podstawie przedstawionych wyników, wnioskować można, że modele wykorzystujące funkcje aktywacji ReLU oraz Leaky ReLU wymagają większej liczby warstw i neuronów w celu skutecznego odwzorowania zależności nieliniowych. Z kolei zastosowanie funkcji sigmoidalnej lub tangensa hiperbolicznego pozwala na uzyskanie porównywalnych wartości funkcji straty przy prostszych architekturach sieci. Niezależnie jednak od zastosowanej funkcji aktywacji, najlepsze modele charakteryzują się niską wartością funkcji straty, co potwierdza skuteczność przyjętej procedury strojenia hiperparametrów.

Tabela 4.6. Architektury sieci neuronowej przyjęte w analizie optymalizacji bayesowskiej

Architektury sieci neuronowej przyjęte w analizie optymalizacji bayesowskiej

		ReLU	Leaky ReLU	tanh	f. sigmoid
Łączna liczba architektur		50	50	50	50
Liczba architektur w zależności od liczby warstw ukrytych	1	21	16	34	30
	2	9	10	12	8
	3	20	24	4	11
Średnia liczba neuronów w warstwie ukrytej		204,4	214,0	149,6	178,8
Wartość funkcji straty dla zbioru walidacyjnego	średnia	2,342	2,213	7,614	5,084
	min	0,813	0,757	0,756	0,618

Oprócz funkcji straty wykorzystano dodatkową miarę zgodności predykcji Q, pozwalającą na ocenę wartości predykcyjnych względem rzeczywistych. Dla każdej próbki $\mathbf{x}^{(r)}$ rozważano wektor wartości rzeczywistych $\mathbf{y}^{(r)} \in \mathbb{R}^n$ oraz odpowiadający mu wektor predykcji $h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)}) \in \mathbb{R}^n$. Poszczególne składowe tych wektorów oznaczono odpowiednio jako $y_j^{(r)}$ oraz $h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})_j$, dla $j = 1, \ldots, n$.

Dla każdej próbki oraz każdej składowej wektora wyjściowego wyznaczano iloraz wartości minimalnej do maksymalnej z wartości bezwzględnych predykcji $h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})_j$ i wartości rzeczywistej $y_j^{(r)}$. Następnie wartości te uśredniano po wszystkich składowych $n = 31$ oraz próbkach n_d, gdzie jako n_d oznaczono liczbę próbek w rozważanym zbiorze danych, przy czym dla zbioru treningowego $n_\mathrm{d} = 720$, natomiast dla zbioru testowego $n_\mathrm{d} = 100$.

$$Q = \frac{1}{n_\mathrm{d}} \sum_{r=1}^{n_\mathrm{d}} \left(\frac{1}{n} \sum_{j=1}^{n} \frac{\min\left(|y_j^{(r)}|, |h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})_j|\right)}{\max\left(|y_j^{(r)}|, |h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})_j|\right)} \right) \tag{4-17}$$

Miara Q jest funkcją ograniczoną i nieujemną, przyjmującą wartości z przedziału $(0, 1]$ i spełniającą warunek $Q = 1 \iff h_{\boldsymbol{\theta}}(\mathbf{x}^{(r)})_j = y_j^{(r)}$ dla każdej próbki i każdej składowej. Dla rosnącej rozbieżności pomiędzy wartościami rzeczywistymi i przewidywanymi wartość miary Q maleje w sposób monotoniczny. Miara Q nie uwzględnia jednak bezwzględnej wielkości błędu, co oznacza, że identyczne wartości mogą odpowiadać różnym poziomom błędu bezwzględnego. Wykorzystanie tej cechy jest szczególnie uzasadnione w analizowanym problemie, w którym wartości odkształceń mogą przyjmować różny rząd wielkości w zależności od lokalizacji punktu pomiarowego oraz przypadku obciążenia. Miara ta pozwala zatem na porównywanie jakości predykcji w sposób niezależny od lokalnej skali odpowiedzi konstrukcji.

Przeprowadzona walidacja najlepszych modeli na zbiorze treningowym i testowym wykazała niewielkie różnice w wielkościach funkcji straty (od 0,641 dla funkcji sigmoidalnej do 0,783 dla funkcji ReLU) oraz miary zgodności predykcji Q (od 0,992 dla funkcji sigmoidalnej i tangensa hiperbolicznego do 0,993 dla funkcji ReLU oraz Leaky ReLU). Wskazuje to na zbliżoną zdolność odwzorowania zależności pomiędzy danymi wejściowymi i wyjściowymi, niezależnie od zastosowanej funkcji aktywacji. Każda z nich umożliwia zatem uzyskanie modeli o wysokiej zgodności predykcji, a różnice pomiędzy nimi mają charakter drugorzędny. W związku z tym jako kryterium wyboru finalnej architektury modelu zastępczego przyjęto stabilność odwzorowania zależności między danymi wejściowymi i wyjściowymi, ocenianą pośrednio na podstawie przebiegu krzywych uczenia (Rysunek 4.7). W kontekście zastosowania modelu zastępczego w procesie optymalizacji istotne jest bowiem nie tylko osiągnięcie minimalnej wartości funkcji straty i wysokiej miary zgodności predykcji, lecz również zapewnienie ciągłości i ograniczenia fluktuacji predykcji w całej przestrzeni rozwiązań. Z tego względu preferowane są modele o bardziej stabilnym przebiegu procesu uczenia, które wykazują mniejszą wrażliwość na ewentualne zmiany hiperparametrów. Na tej podstawie jako model zastępczy przyjęto sieć neuronową wykorzystującą funkcję aktywacji Leaky ReLU, składającą się z trzech warstw ukrytych o liczbie neuronów odpowiednio 20-200-100. Najlepsze modele dla każdej z funkcji aktywacji przedstawiono w Tabeli 4.7.

Tabela 4.7. Ocena najlepszych modeli sieci neuronowych w zależności od funkcji aktywacji

Ocena najlepszych modeli sieci neuronowych w zależności od funkcji aktywacji

		ReLU	**Leaky ReLU**	**tanh**	**f. sigmoid**
Liczba warstw ukrytych		1	3	2	2
Liczba neuronów w warstwach ukrytych		200	20-200-100	20-160	20-160
Funkcja straty	zbiór treningowy	0,721	0,648	0,606	0,508
	zbiór testowy	0,783	0,739	0,763	0,641
Miara zgodności predykcji Q	zbiór treningowy	0,994	0,994	0,993	0,994
	zbiór testowy	0,993	0,993	0,992	0,992

Przyjętą architekturę modelu zastępczego sieci neuronowej zwalidowano na 100-elementowym zbiorze testowym, poprzez porównanie rzeczywistych wartości odkształceń z predykcjami modelu (Rysunek 4.8). Funkcji straty osiągnęła wartość 0,739, natomiast miara zgodności predykcji Q wartość 0,993. Krzywa $y = x$ odpowiada idealnemu dopasowaniu, dla którego miara $Q = 1{,}0$.

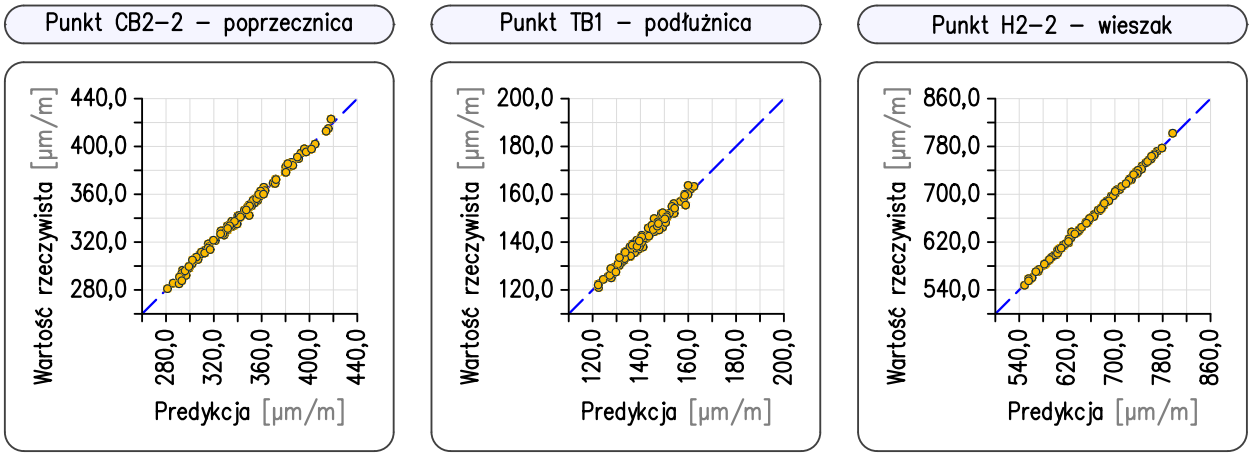

Rysunek 4.8. Proces walidacji na zbiorze testowym dla wybranych punktów pomiarowych

Istotną kwestią w ocenie przydatności modelu jest określenie rozmiaru zbioru danych niezbędnych do osiągnięcia wysokiej zgodności predykcji z danymi rzeczywistymi. W tym kontekście, dla modelu opartego na funkcji aktywacji Leaky ReLU, przeanalizowano funkcję straty i wydajność dla różnych rozmiarów zbioru treningowego. Na podstawie wyników przedstawionych w Tabeli 4.8 można wnioskować, że wykorzystując co najmniej 250 próbek uczących model jest wystarczający do dalszego wdrożenia, osiągając wartość miary zgodności predykcji powyżej 98,0 % zarówno dla zbioru treningowego, jak i testowego. Mniejsze zbiory treningowe skracają czasu treningu, redukując jednocześnie zdolność generalizacji i osiągając miarę zgodności predykcji poniżej 90,0 %, odpowiednio 73,8 % dla 25 próbek, 85,9 % dla 50 próbek i 89,8 % dla 100 próbek w zbiorze testowym. Rosnąca rozbieżność między zgodnością predykcji uzyskaną dla zbioru treningowego i testowego wskazuje także na efekt nadmiernego dopasowania. Zmniejsza to praktyczną użyteczność modelu trenowanego na zbiorze treningowym liczącym 100 i mniej próbek. Podobne wyniki uzyskano dla innych architektur przedstawionych w Tabeli 4.7, przy czym 250 próbek w zbiorze treningowym zapewnia wartość miary Q na poziomie co najmniej 98,0 % i marginalny efekt nadmiernego dopasowania.

Tabela 4.8. Wpływ rozmiaru zbioru treningowego na wartość funkcji straty i dokładność modeli

Wpływ rozmiaru zbioru treningowego na wartość funkcji straty i dokładność modeli

Rozmiar zbioru treningowego		**25**	**50**	**100**	**250**	**500**
Czas trenowania [hh:mm:ss]		00:05:11	00:10:23	00:20:45	00:51:53	01:43:45
Funkcja straty	zbiór treningowy	34,137	10,948	13,064	2,001	1,726
	zbiór testowy	86,036	45,763	30,925	3,223	2,251
Miara zgodności predykcji Q	zbiór treningowy	0,868	0,958	0,949	0,987	0,988
	zbiór testowy	0,738	0,859	0,898	0,982	0,986

4.3.4 Integracja modelu zastępczego sieci neuronowej w algorytmie genetycznym

Proces identyfikacji wraz z implementacją algorytmu optymalizacyjnego opiera się na modelu MES opracowanym w środowisku SOFiSTiK i realizowany był w dwóch alternatywnych podejściach. W obu przypadkach algorytm genetyczny operuje na populacji kandydatów $\mathbf{x}_i \in \mathbb{R}^d$, gdzie $d = 19$, reprezentujących rozkład modułów sprężystości elementów konstrukcyjnych $E_1, \ldots, E_{19}$. Dla każdego potencjalnego rozwiązania wyznaczana jest wartość funkcji celu $f(\mathbf{x})$, definiowana na podstawie różnic pomiędzy odkształceniami uzyskanymi z modelu, a wartościami pomiarowymi systemu SHM.

W pierwszym podejściu wszystkie potencjalne rozwiązania wyznaczone przez algorytm genetyczny są niezależnie oceniane na podstawie bezpośrednich analiz numerycznych (Rysunek 4.9a). Dla każdego kandydata $\mathbf{x}_i$ generowany jest odrębny model MES o innym rozkładzie sztywności. Następnie wyznaczane są odkształcenia w punktach pomiarowych oraz obliczana jest wartość funkcji celu $f(\mathbf{x})$. W rezultacie funkcja ta przyjmuje wartości uzyskane bezpośrednio z symulacji MES i jest minimalizowana w celu dostosowania odpowiedzi statycznej do rzeczywistych wartości zmierzonych przez system SHM. Podejście to zapewnia wysoką dokładność odwzorowania odpowiedzi konstrukcji, jednak wiąże się z istotnym kosztem obliczeniowym wynikającym z konieczności wielokrotnego wykonywania analiz MES.

Drugie podejście zostało opracowane w celu redukcji kosztu obliczeniowego, poprzez wykorzystanie modelu zastępczego opartego na sieci neuronowej (Rysunek 4.9b). W tym przypadku analizy MES wykorzystane zostały wyłącznie na etapie przygotowania zbioru danych uczących $(\mathbf{x}^{(r)}, \mathbf{y}^{(r)})$, na podstawie których trenowany był model. Po zakończeniu procesu uczenia został on wykorzystany do bezpośredniej oceny kandydatów w algorytmie genetycznym, zastępując kosztowne obliczeniowo symulacje MES. Dla każdego wektora zmiennych decyzyjnych $\mathbf{x}^{(r)}$ wyznaczane były predykcje odkształceń $\mathbf{y}^{(r)}$, które następnie służyły do obliczenia wartości funkcji celu $f(\mathbf{x})$. Podejście to prowadzi do znaczącego skrócenia czasu obliczeń przy zachowaniu poprawnego odwzorowania odpowiedzi konstrukcji.

Obie metody zostały zaimplementowane w środowisku C#, obejmując integrację API oprogramowania SOFiSTiK oraz realizację wszystkich operacji algorytmu genetycznego. W celu przygotowania zbioru danych uczących przeprowadzono 1000 analiz MES dla różnych rozkładów sztywności, które posłużyły do treningu oraz walidacji modelu sieci neuronowej. Ze względu na wysoką efektywność obliczeniową modelu zastępczego możliwe było przeprowadzenie wielu niezależnych procesów kalibracji. Wykorzystano w tym celu modele sieci neuronowych o różnych konfiguracjach hiperparametrów, aktualizując także liczbę kandydatów w każdym pokoleniu algorytmu genetycznego. W rezultacie do dalszych analiz został wykorzystany model, dla którego uzyskano najkorzystniejsze wartości funkcji celu $f(\mathbf{x})$.

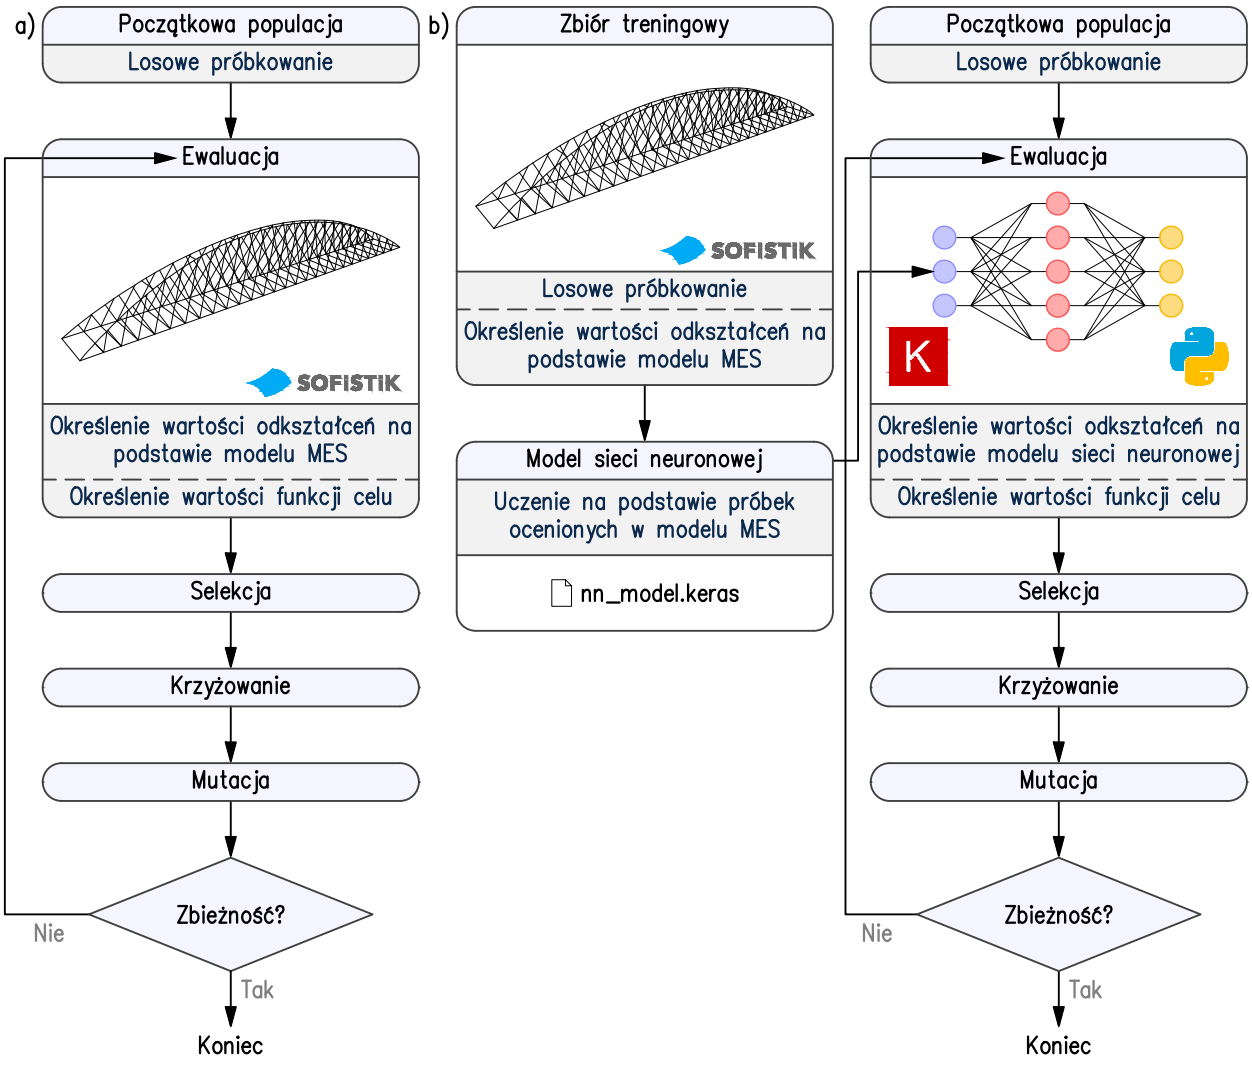

Rysunek 4.9. Procedura kalibracji modelu numerycznego
a) bazująca na modelach MES; b) wykorzystująca zastępczy model sieci neuronowych

Dla każdego kandydata w pierwszym podejściu identyfikacji (Rysunek 4.9a) generowane były dwa pliki tekstowe, jeden z rozszerzeniem *.dat* oraz drugi z rozszerzeniem *.txt*. Plik *.dat* definiuje topologię modelu MES, obejmującą właściwości geometryczne, warunki brzegowe oraz przypadki obciążeń. Zmienne decyzyjne przechowywane są natomiast w pliku *.txt*, który jest następnie importowany do pliku *.dat* i wykorzystywany w procesie generowania modelu MES. Wartości modułów sprężystości wprowadzane są w postaci unikalnych symboli literałowych dla elementów stalowych oraz jako lista wartości liczbowych dla płyty pomostowej. Obliczenia realizowane są poprzez wywołanie dedykowanego procesu z podaniem ścieżki do silnika MES *sps.exe* oraz odpowiedniego pliku *.dat* (Rysunek 4.10).

Po przeprowadzeniu obliczeń dostęp do wyników MES uzyskiwany jest z wykorzystaniem funkcji API *sof_cdb_init*, natomiast zamknięcie bazy danych realizowane jest za pomocą funkcji *sof_cdb_close*. Odczyt wartości odkształceń w wybranych punktach pomiarowych realizowany jest z wykorzystaniem struktury *cs_beam_for*, a dalsze przetwarzanie danych wykonywane jest bezpośrednio w pętli oblicze-

niowej. Uzyskane wyniki zapisywane są w skoroszytach programu Excel, które stanowią docelową postać danych wykorzystywanych w dalszych analizach. Opisana procedura realizowana jest niezależnie dla każdego kandydata w kolejnych pokoleniach algorytmu genetycznego.



Rysunek 4.10. Implementacja procesu identyfikacji modelu numerycznego MES

W drugim podejściu (Rysunek 4.9b), zamiast bezpośrednich obliczeń MES wykorzystano regresyjny model zastępczy oparty na sieci neuronowej. Zbiory treningowe, walidacyjne i testowe zostały wygenerowane zgodnie z metodą przedstawioną na Rysunku 4.10, jednak bez przekazywania wygenerowanych

rozwiązań do operatorów algorytmu genetycznego. Modele sieci neuronowych były trenowane i oceniane niezależnie w środowisku Python, z wykorzystaniem bibliotek Keras oraz TensorFlow. Po zakończeniu procesu uczenia, końcowy model zapisywany był w postaci pliku *.keras*.

Integracja modelu zastępczego z algorytmem genetycznym została zrealizowana w środowisku C#, zgodnie ze schematem przedstawionym na Rysunku 4.11. W tym celu opracowany został dedykowany skrypt Python odpowiedzialny za wczytanie wytrenowanego modelu oraz realizację predykcji na podstawie danych wejściowych przekazywanych z poziomu aplikacji C#. Dane te występują w postaci ciągu znaków zawierającego wartości zmiennych decyzyjnych, które następnie przekształcane są do postaci wektora i podawane na wejście modelu sieci neuronowej. Uruchomienie skryptu realizowane jest z poziomu języka C# jako proces systemowy z wykorzystaniem interpretera *python.exe*. Takie rozwiązanie umożliwia bezpośrednią wymianę danych pomiędzy środowiskami, gdzie metoda *WriteLine* wykorzystywana jest do przesyłania danych wejściowych, natomiast *ReadLine* do odbioru wyników predykcji. Zastosowane rozwiązanie umożliwia wielokrotne wywoływanie modelu sieci neuronowej w ramach jednego procesu, bez konieczności jego ponownej inicjalizacji. Ma to istotne znaczenie z punktu widzenia efektywności obliczeniowej, umożliwiając wykorzystanie modelu zastępczego w sposób ciągły w kolejnych pokoleniach algorytmu genetycznego.

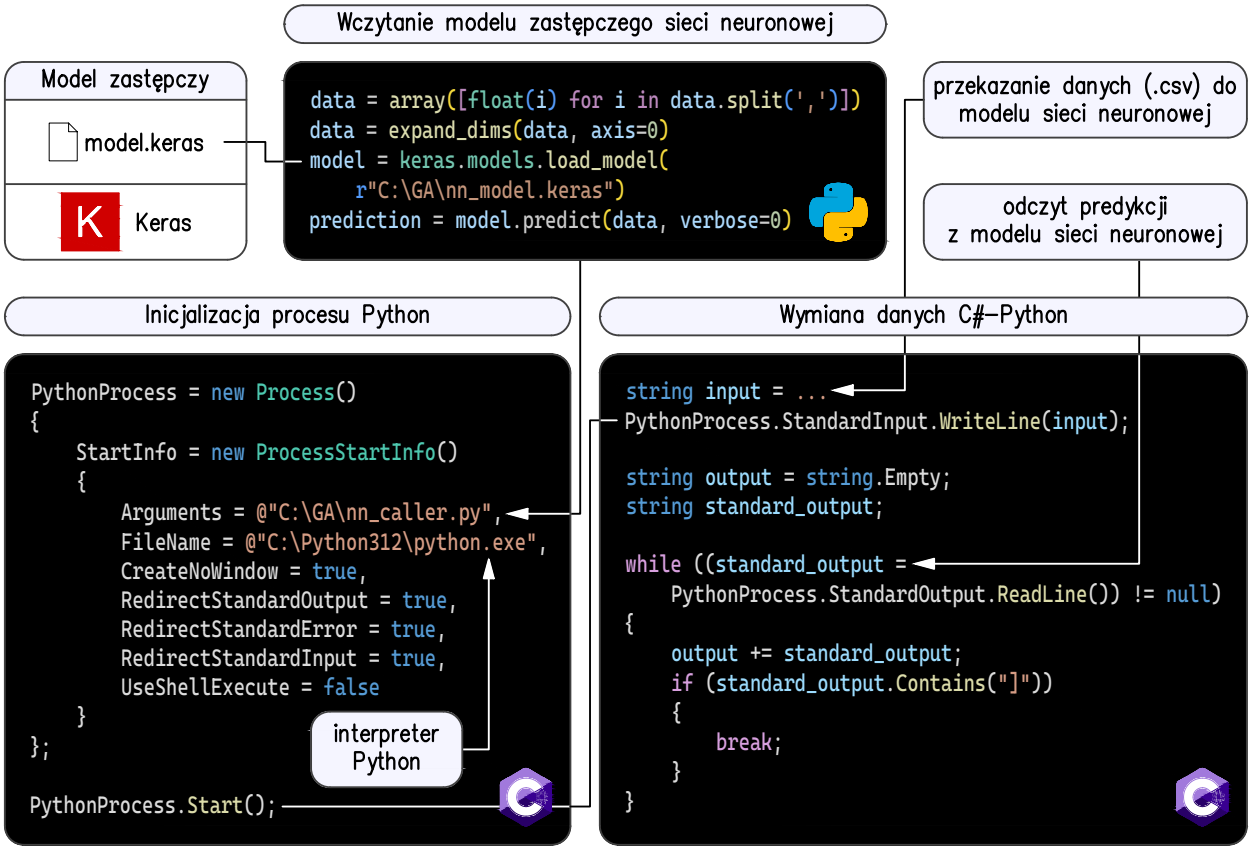

Rysunek 4.11. Implementacja procesu identyfikacji z wykorzystaniem modelu zastępczego opartego na sieci neuronowej

4.4 Rezultaty identyfikacji modelu MES

4.4.1 Analiza wrażliwości zmiennych decyzyjnych

Pierwszym krokiem w opracowaniu założeń dla zadania optymalizacyjnego było przeprowadzenie analizy wrażliwości. Miała ona na celu określenie wpływu poszczególnych zmiennych decyzyjnych na wartość funkcji celu. Ostatecznie przedstawione zadanie identyfikacji modelu MES zostało zredukowane do 19 zmiennych, przyjmujących wartości modułów sprężystości przypisanych do elementów stalowych i pasm płyty pomostowej. W pierwszej kolejności zmiennej decyzyjnej E_1 przypisano stałą wartość odpowiadającą założonej minimalnej wartości modułu sprężystości stali, wynoszącej 160 GPa. Na podstawie tego kroku wygenerowano przypadki, w których wartości pozostałych zmiennych wybierane były w sposób losowy. Zestaw rozwiązań oceniono za pomocą modelu MES, ostatecznie określając minimalne i maksymalne możliwe wartości odkształceń, będących składowymi funkcji celu. Proces powtórzono, przypisując zmiennej decyzyjnej E_1 maksymalną wartość modułu, wynoszącą 240 GPa, również określając zakres możliwych odkształceń. Wpływ zmiennej E_1 jest następnie widoczny poprzez przesunięcie zakresu odkształceń, jakie można uzyskać dla jej skrajnych wartości. W kolejnych korkach procedurę oceny powtórzono dla zmiennych decyzyjnych od E_2 do E_{19}, tworząc zestawy zakresów odkształceń (Rysunek 4.12). Przedstawiono na nim przykładowe zakresy dla trzech punktów, reprezentujących wszystkie elementy stalowe oraz każdą z bramek pomiarowych. Dla każdej z nich analizowano wpływ przypadku obciążenia znajdującego się w jej bezpośrednim sąsiedztwie, odpowiednio S1, S2 oraz S3.

Rysunek 4.12a przedstawia zakresy odkształceń dla punktu pomiarowego CB1-1 zlokalizowanego na poprzecznicy w pierwszej bramce pomiarowej. Na wartość odkształceń w tym punkcie wpływa przede wszystkim, co oczywiste, moduł sprężystości poprzecznic E_2 oraz w mniejszym stopniu podłużnic E_1. Zauważalny jest także wpływ modułów sprężystości tych pasm płyty pomostowej, które znajdują się w obszarze badanej bramki pomiarowej E_{10}, E_{11} oraz E_{12}. Przeprowadzone analizy potwierdziły ograniczoną powierzchnię wpływu odkształceń, w których charakterystyki płyty pomostowej w dalszych przekrojach następujących po rozpatrywanym elemencie nie powodowały znaczącego przesunięcia zakresu. Rysunek 4.12b przedstawia natomiast zakresy dla punktu pomiarowego TB1 zlokalizowanego na podłużnicy w drugiej bramce pomiarowej. Największy wpływ na odkształcenia miał tutaj moduł sprężystości wieszaków E_5, a w dalszej kolejności moduł samych podłużnic E_1. Również tutaj widoczny jest wpływ modułów sprężystości pasm płyty pomostowej E_{18} oraz E_{19}, znajdujących się w bezpośrednim sąsiedztwie analizowanego przekroju. Z kolei na Rysunku 4.12c przedstawiono zakresy odkształceń w punkcie pomiarowym H3-1 zlokalizowanym na wieszaku w trzeciej bramce pomiarowej. Również w tym przypadku największy wpływ na wartość odkształceń wywiera moduł sprężystości wieszaków

E_5, a w dalszej kolejności moduł łuków E_3 oraz podłużnic E_1. Również pasma płyty pomostowej mają pośredni wpływ na wartości odkształceń i powinny być uwzględniane w zbiorze zmiennych decyzyjnych.

Przypadek obciążenia S1; bramka pomiarowa nr 1; punkt CB1–1 (poprzecznica)

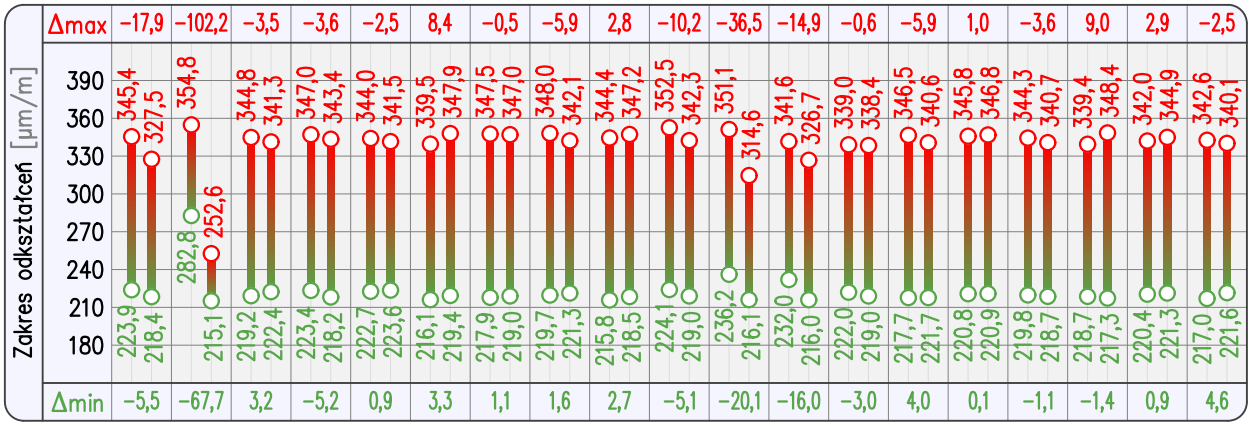

Przypadek obciążenia S2; bramka pomiarowa nr 2; punkt TB1 (podłużnica)

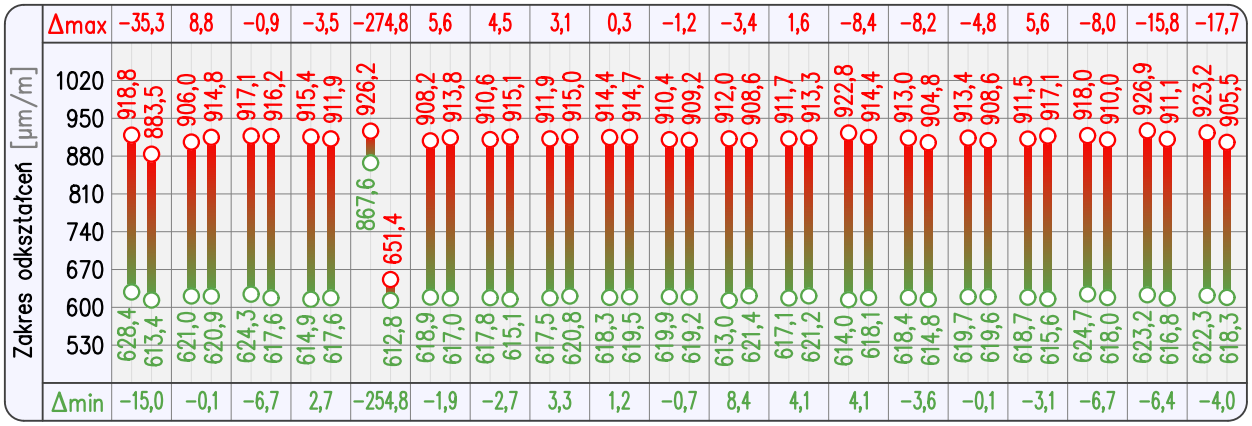

Przypadek obciążenia S3; bramka pomiarowa nr 3; punkt H3–1 (wieszak)

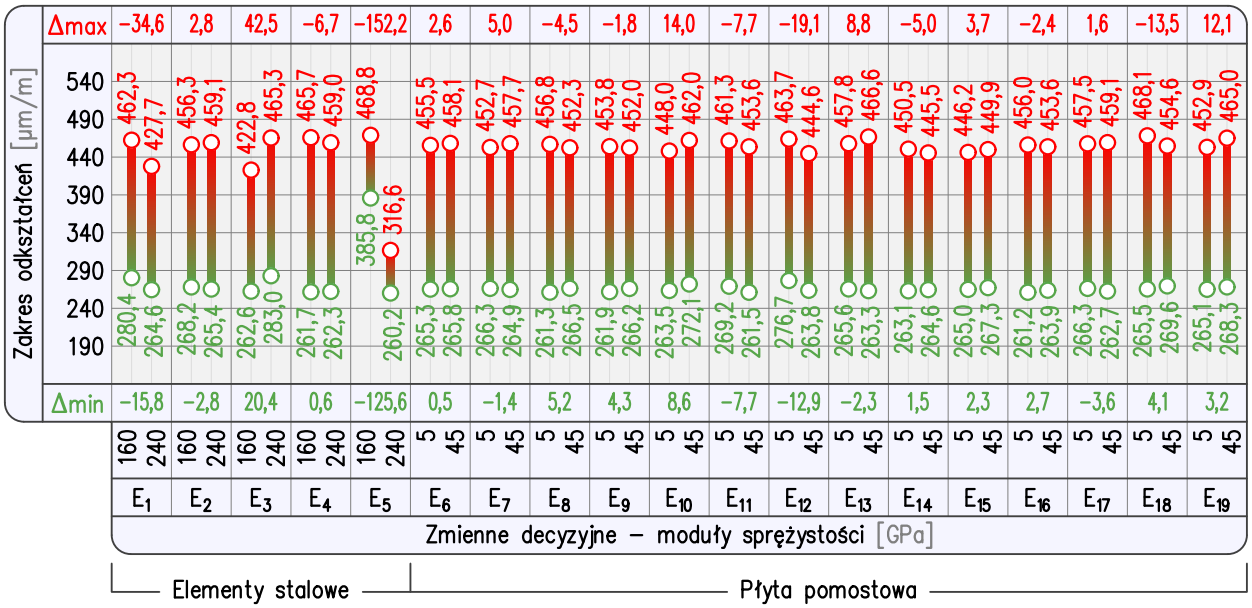

Rysunek 4.12. Zakres odkształceń dla granicznych wartości zmiennych decyzyjnych dla wybranych punktów pomiarowych

4.4.2 Analiza wrażliwości parametrów algorytmu genetycznego

Przedstawione podejście, bazujące na algorytmie genetycznym, cechuje się znacznym stopniem losowości, co powoduje generowanie różnych rozwiązań w każdym przebiegu. W związku z tym istotnym krokiem była ocena odporności proponowanego podejścia oraz wpływu parametrów algorytmu na jakość otrzymywanych rozwiązań. W tym celu dobrano cztery zestawy parametrów, modyfikując prawdopodobieństwo mutacji oraz liczbę osobników wybieranych na etapie selekcji. Rozpatrzono także różne liczebności populacji, przyjmując od 20 do 300 osobników. Dla każdej konfiguracji wykonano 50 niezależnych iteracji, zestawiając w formie wykresów pudełkowych średnie wartości funkcji celu dla wszystkich osobników z ostatniego pokolenia (Rysunek 4.13). Przedstawiono na nich wartości minimalne, maksymalne oraz kwartyle funkcji celu. Rezultaty te zestawiono również w Tabeli 4.9, wraz z wartościami średnimi, wariancją i odchyleniem standardowym.

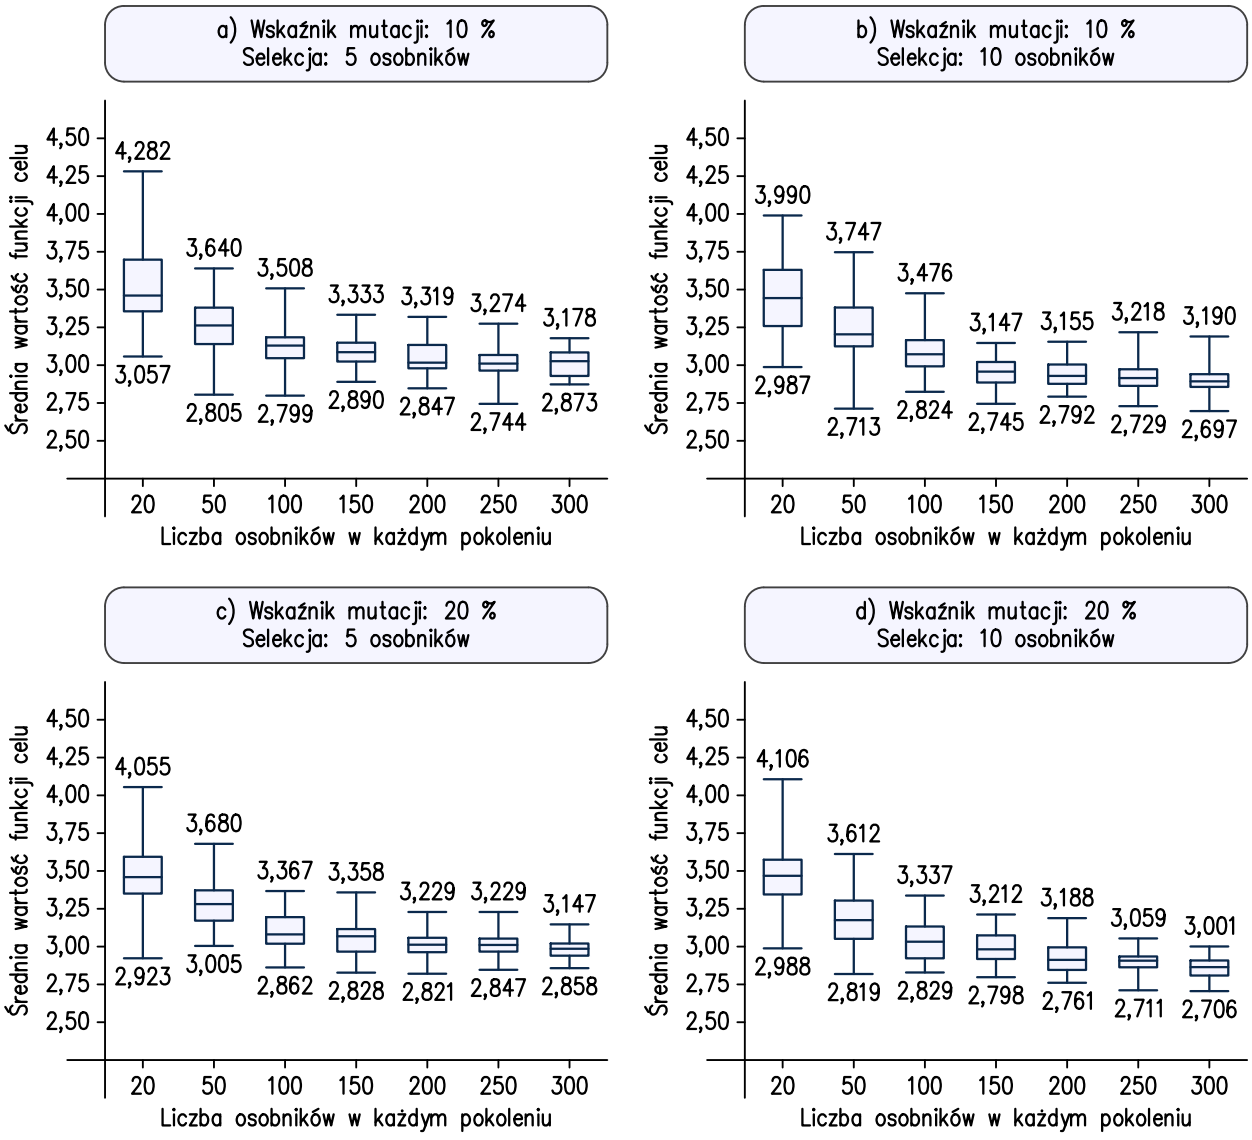

Rysunek 4.13. Wartości funkcji celu osiągnięte dla różnych parametrów algorytmu genetycznego cz. 1

Tabela 4.9. Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 1

Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 1

a) Wskaźnik mutacji 10 %; selekcja turniejowa 5 osobników

Liczba osobników	20	50	100	150	200	250	300
Wartość minimalna	3,057	2,805	2,799	2,890	2,847	2,744	2,873
Wartość maksymalna	4,282	3,640	3,508	3,333	3,319	3,274	3,178
Wartość średnia	3,503	3,264	3,129	3,092	3,043	3,010	3,016
1. kwartyl	3,356	3,140	3,046	3,024	2,979	2,964	2,929
2. kwartyl (mediana)	3,461	3,263	3,130	3,086	3,017	3,011	3,026
3. kwartyl	3,698	3,381	3,184	3,149	3,134	3,067	3,085
Wariancja	0,0629	0,0334	0,0157	0,0091	0,0104	0,0086	0,0067
Odchylenie standardowe	0,2509	0,1826	0,1255	0,0955	0,1019	0,0927	0,0822

b) Wskaźnik mutacji 10 %; selekcja turniejowa 10 osobników

Liczba osobników	20	50	100	150	200	250	300
Wartość minimalna	2,987	2,713	2,824	2,745	2,792	2,729	2,697
Wartość maksymalna	3,990	3,747	3,476	3,147	3,155	3,218	3,190
Wartość średnia	3,451	3,229	3,091	2,955	2,942	2,919	2,898
1. kwartyl	3,259	3,125	2,992	2,886	2,877	2,863	2,856
2. kwartyl (mediana)	3,444	3,204	3,072	2,957	2,929	2,915	2,893
3. kwartyl	3,630	3,381	3,166	3,021	3,005	2,973	2,940
Wariancja	0,0590	0,0341	0,0199	0,0102	0,0064	0,0079	0,0061
Odchylenie standardowe	0,2430	0,1847	0,1411	0,1011	0,0798	0,0887	0,0778

c) Wskaźnik mutacji 20 %; selekcja turniejowa 5 osobników

Liczba osobników	20	50	100	150	200	250	300
Wartość minimalna	2,923	3,005	2,862	2,828	2,821	2,847	2,858
Wartość maksymalna	4,055	3,680	3,367	3,358	3,229	3,229	3,147
Wartość średnia	3,465	3,280	3,100	3,053	3,009	3,006	2,983
1. kwartyl	3,351	3,171	3,019	2,967	2,963	2,967	2,940
2. kwartyl (mediana)	3,459	3,281	3,081	3,068	3,013	3,011	2,986
3. kwartyl	3,594	3,372	3,195	3,116	3,058	3,053	3,020
Wariancja	0,0476	0,0220	0,0180	0,0119	0,0064	0,0061	0,0038
Odchylenie standardowe	0,2181	0,1484	0,1342	0,1092	0,0799	0,0779	0,0616

Tabela 4.9. Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 1 - cd.

Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 1

d) Wskaźnik mutacji 20 %; selekcja turniejowa 10 osobników

Liczba osobników	20	50	100	150	200	250	300
Wartość minimalna	2,988	2,819	2,829	2,798	2,761	2,711	2,706
Wartość maksymalna	4,106	3,612	3,337	3,212	3,188	3,059	3,001
Wartość średnia	3,476	3,198	3,035	2,993	2,922	2,897	2,859
1. kwartyl	3,345	3,051	2,923	2,918	2,846	2,863	2,809
2. kwartyl (mediana)	3,468	3,175	3,032	2,982	2,912	2,907	2,864
3. kwartyl	3,575	3,304	3,133	3,074	2,995	2,935	2,908
Wariancja	0,0468	0,0289	0,0151	0,0114	0,0091	0,0046	0,0043
Odchylenie standardowe	0,2162	0,1701	0,1230	0,1068	0,0955	0,0679	0,0657

Wzrost liczebności populacji prowadzi do zmniejszenia zmienności wartości funkcji celu we wszystkich analizowanych konfiguracjach algorytmu. Cechuje się to zarówno spadkiem wariancji, jak i odchylenia standardowego, które systematycznie maleją wraz ze wzrostem liczby osobników. Największa poprawa występuje w początkowym zakresie, do osiągnięcia około 100-150 osobników, w którym występuje wyraźny spadek wartości średnich oraz zawężenie przedziału pomiędzy kwartylami. Dalsze zwiększanie liczebności populacji nie gwarantuje już istotnej poprawy jakości rozwiązań, a jedynie niewielkie redukcje zmienności. Przy liczebności 150-300 osobników wartości funkcji celu stabilizują się, co potwierdza zarówno zbliżony poziom wartości średnich, jak i niewielkie różnice pomiędzy medianą, a pozostałymi kwartylami. Świadczy to o osiągnięciu stanu zbieżności algorytmu, w którym dalsze zwiększanie liczebności populacji nie prowadzi już do istotnej poprawy rozwiązania.

Porównanie poszczególnych konfiguracji wskazuje natomiast, że zwiększenie liczebności selekcji turniejowej z 5 do 10 osobników ma wyraźny wpływ na poprawę wyników optymalizacji. Dla wszystkich analizowanych liczebności populacji występują niższe wartości średnie oraz mediany funkcji celu w przypadku większej próby losowanej na etapie selekcji. Zabieg ten powoduje skuteczniejsze eliminowanie słabszych rozwiązań, a w efekcie szybsze ukierunkowanie populacji w stronę lepiej przystosowanych rozwiązań. Efekt ten jest szczególnie zauważalny dla większych populacji, liczących powyżej 150 osobników, dla których różnice między wariantami stają się wyraźniejsze. Natomiast wpływ wskaźnika mutacji jest już mniej jednoznaczny, a jego zwiększenie z 10 % do 20 % nie wpływa na poprawę jakości rozwiązań. Potwierdza to, że mutacja pełni głównie rolę mechanizmu wspomagającego eksplorację, natomiast jej znaczenie w końcowej jakości rozwiązań jest mniejsze niż wpływ selekcji.

Uzyskane wyniki jednoznacznie wskazują, że liczebność selekcji turniejowej stanowi jeden z kluczowych parametrów, wpływających na efektywność działania algorytmu genetycznego. W związku z tym przeprowadzono dodatkowe analizy dla większych wartości tego parametru tj. odpowiednio 20 i 30 losowanych osobników, przy zachowaniu pierwotnych wskaźników mutacji. Analizy ograniczono do populacji o liczebności co najmniej 150 osobników, odrzucając mniejsze pokolenia, charakteryzujące się wyraźnie gorszą jakością rozwiązań. Dodatkowo dla mniejszych populacji o liczebności 20 lub 50 osobników zastosowanie większego poziomu selekcji jest nieuzasadnione. Wykresy pudełkowe, zawierające wyniki analiz przedstawiono na Rysunku 4.14, natomiast szczegółowe zestawienie w Tabeli 4.10.

W przypadku selekcji 20 osobników widoczny jest dalszy spadek wartości funkcji celu w porównaniu do wcześniejszych konfiguracji. Towarzyszy temu niski poziom zmienności wyników, co potwierdzają niewielkie wartości wariancji oraz odchylenia standardowego. Zwiększenie liczebności selekcji do 30 osobników nie prowadzi już natomiast do znaczącej poprawy, a w niektórych przypadkach wartości średnie funkcji celu są nawet nieznacznie wyższe. Zbyt duży poziom selekcji może zatem ograniczyć różnorodność populacji i prowadzić do przedwczesnej zbieżności algorytmu. Jednak dla poziomu selekcji 30 osobników oraz wskaźnika mutacji 20 % i liczebności populacji 300 kandydatów uzyskano najlepszy model, charakteryzujący się wartością funkcji celu wynoszącą 2,63. Jest to także jedyna konfiguracja, dla której wszystkie iteracje algorytmu osiągnęły wartości funkcji celu poniżej 3,0.

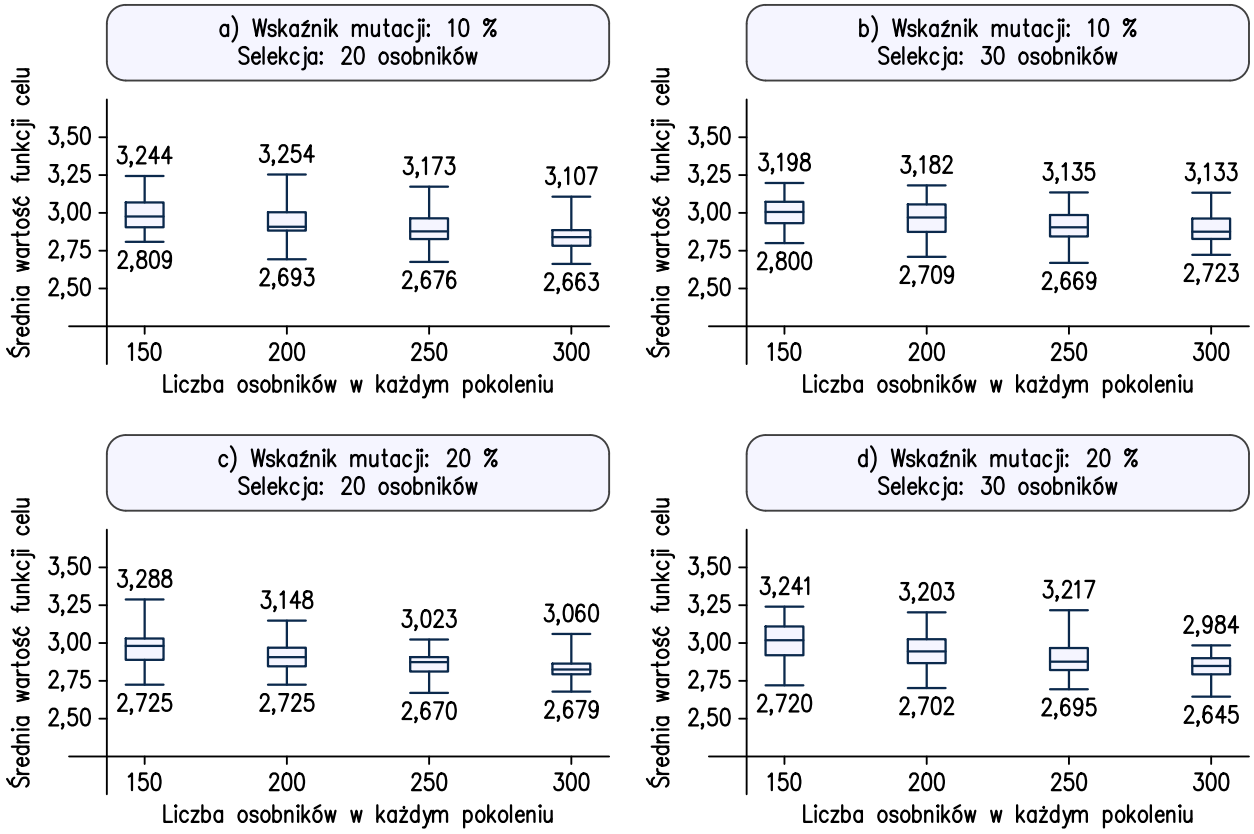

Rysunek 4.14. Wartości funkcji celu osiągnięte dla różnych parametrów algorytmu genetycznego cz. 2

Tabela 4.10. Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 2

Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 2

a) Wskaźnik mutacji 10 %; selekcja turniejowa 20 osobników

Liczba osobników	150	200	250	300
Wartość minimalna	2,809	2,693	2,676	2,663
Wartość maksymalna	3,244	3,254	3,173	3,107
Wartość średnia	2,984	2,936	2,894	2,841
1. kwartyl	2,905	2,883	2,827	2,782
2. kwartyl (mediana)	2,976	2,908	2,878	2,839
3. kwartyl	3,069	3,004	2,964	2,886
Wariancja	0,0106	0,0126	0,0112	0,0072
Odchylenie standardowe	0,1030	0,1121	0,1058	0,0850

b) Wskaźnik mutacji 10 %; selekcja turniejowa 30 osobników

Liczba osobników	150	200	250	300
Wartość minimalna	2,800	2,709	2,669	2,723
Wartość maksymalna	3,198	3,182	3,135	3,133
Wartość średnia	3,006	2,961	2,911	2,888
1. kwartyl	2,932	2,874	2,844	2,828
2. kwartyl (mediana)	3,006	2,970	2,905	2,875
3. kwartyl	3,073	3,056	2,986	2,963
Wariancja	0,0090	0,0128	0,0101	0,0095
Odchylenie standardowe	0,0951	0,1133	0,1005	0,0973

c) Wskaźnik mutacji 20 %; selekcja turniejowa 20 osobników

Liczba osobników	20	50	100	150
Wartość minimalna	2,725	2,725	2,670	2,679
Wartość maksymalna	3,288	3,148	3,023	3,060
Wartość średnia	2,974	2,915	2,864	2,831
1. kwartyl	2,889	2,846	2,812	2,793
2. kwartyl (mediana)	2,981	2,907	2,874	2,825
3. kwartyl	3,030	2,969	2,907	2,864
Wariancja	0,0153	0,0094	0,0071	0,0060
Odchylenie standardowe	0,1237	0,0971	0,0845	0,0772

Tabela 4.10. Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 2 - cd.

Rozkład wartości funkcji celu dla zadanych parametrów algorytmu genetycznego cz. 2

d) Wskaźnik mutacji 20 %; selekcja turniejowa 30 osobników

Liczba osobników	150	200	250	300
Wartość minimalna	2,720	2,702	2,695	2,645
Wartość maksymalna	3,241	3,203	3,217	2,984
Wartość średnia	3,013	2,946	2,900	2,848
1. kwartyl	2,919	2,867	2,821	2,793
2. kwartyl (mediana)	3,019	2,945	2,877	2,848
3. kwartyl	3,109	3,025	2,967	2,900
Wariancja	0,0160	0,0132	0,0131	0,0051
Odchylenie standardowe	0,1264	0,1149	0,1142	0,0715

4.4.3 Proces identyfikacji z wykorzystaniem modelu MES

Pierwszym podejściem optymalizacyjnym był standardowy algorytm genetyczny składający się z 20 pokoleń po 150 osobników. Dla każdego kandydata generowany był indywidualny model MES, który uwzględniał parametry materiałowe oraz zwracał poziomy odkształceń w punktach pomiarowych. Na ich podstawie wyznaczano wartości funkcji celu. Na Rysunku 4.15 dla czterech wybranych pokoleń algorytmu przedstawiono przykładowe rozkłady trzech par zmiennych decyzyjnych:

- moduły sprężystości podłużnic (E_1) i poprzecznic (E_2),
- moduły sprężystości wieszaków (E_5) i łuków (E_3),
- moduły sprężystości pierwszego (E_6) oraz drugiego pasma płyty pomostowej (E_7).

W pierwszym pokoleniu wszystkie rozwiązania generowane są losowo, skutkując znacznym rozproszeniem osobników w przestrzeni rozwiązań. W kolejnych, można natomiast zaobserwować stopniową koncentrację osobników w określonych obszarach, co jest wynikiem działania operatorów selekcji oraz krzyżowania. Preferowane są rozwiązania o niższych wartościach funkcji celu, przez co populacja zaczyna skupiać się wokół korzystniejszych regionów. W efekcie już od 10. pokolenia widoczna jest stopniowa zbieżność rozwiązań, prowadząca do ich późniejszej stabilizacji. Dla każdej z par zmiennych decyzyjnych można jednak zauważyć pojedyncze rozwiązania odstające od głównego skupiska. Są one efektem działania operatora mutacji, który wprowadza losowe zmiany w populacji. Ich obecność ma istotne znaczenie, ponieważ umożliwia eksplorację nowych obszarów przestrzeni rozwiązań oraz zapobiega przedwczesnej zbieżności algorytmu do minimum lokalnego. Wraz z kolejnymi pokoleniami liczba takich rozwiązań maleje, a ich odchylenie od głównego skupiska staje się coraz mniejsze.

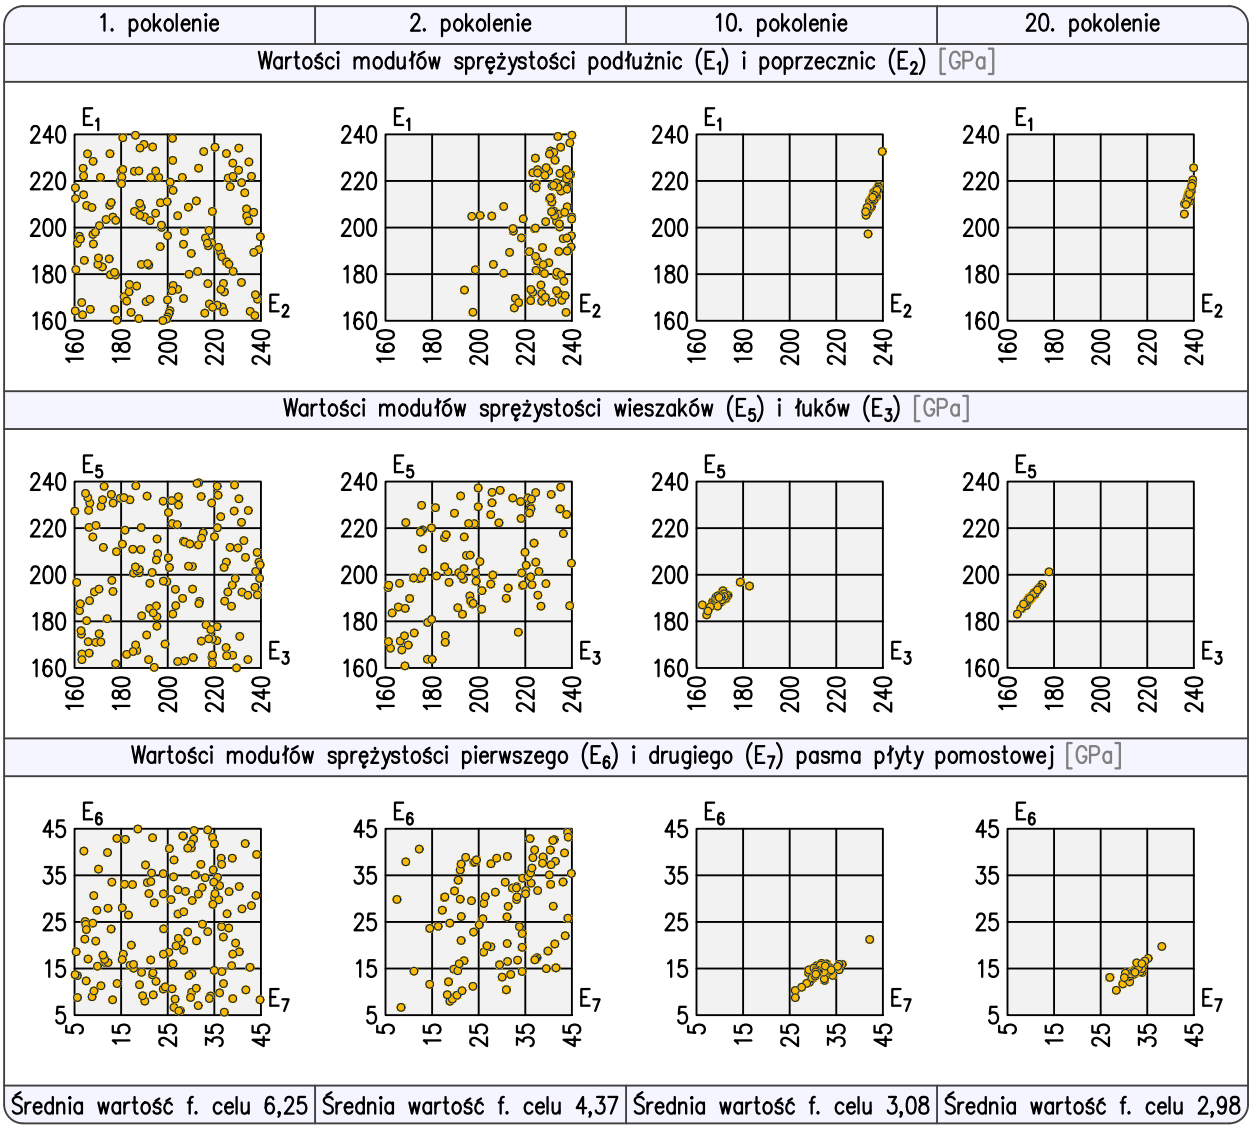

Rysunek 4.15. Rezultaty identyfikacji osiągnięte w pierwszym podejściu - ewaluacja za pomocą modelu MES

Wartości funkcji celu również przedstawiają proces zbieżności algorytmu osiągając coraz niższe wartości w kolejnych pokoleniach. Pierwsza populacja rozwiązań, będąca wynikiem losowego doboru zmiennych decyzyjnych, charakteryzuje się średnią wartością funkcji celu na poziomie 6,25. Już w drugim pokoleniu, po zastosowaniu operatorów genetycznych, wartość ta zmniejszyła się do poziomu 4,37. Dziesiąte pokolenie charakteryzowało się wartością funkcji celu równą 3,08, a w ostatnim dwudziestym pokoleniu wartość ta osiągnęła 2,98. Z każdym kolejnym pokoleniem obszar przestrzeni rozwiązań ulega stopniowemu zawężeniu. Dodatkowo, najbardziej dynamiczne zmiany wartości funkcji celu oraz rozkładu zmiennych decyzyjnych obserwowane są w początkowych pokoleniach. Wynika to z szybkiej eliminacji osobników o najsłabszym przystosowaniu i jest charakterystycznym zjawiskiem algorytmów genetycznych. W późniejszych pokoleniach algorytm koncentruje się na dostrajaniu dobrych rozwiązania, a zatem wykazuje też mniejszą poprawę wartości funkcji celu.

4.4.4 Proces identyfikacji z wykorzystaniem modelu zastępczego sieci neuronowej

Drugie podejście identyfikacji obejmowało wykorzystanie modelu zastępczego, bazującego na sieci neuronowej. Ostateczny model składał się z trzech warstw ukrytych o liczbie neuronów odpowiednio 20-200-100, wykorzystujący funkcję aktywacji Leaky ReLU. Dla każdego osobnika w algorytmie genetycznym, odkształcenia zostały wygenerowane bezpośrednio za pomocą modelu zastępczego, bez konieczności generowania dedykowanych modeli MES. Dzięki temu podejściu koszt obliczeniowy został znacząco zredukowany, bez obniżania wydajności samego procesu. Na Rysunku 4.16 przedstawione zostały wyniki proponowanego podejścia, uwzględniające rozkłady tych samych trzech par zmiennych decyzyjnych co w pierwszym wariancie optymalizacji. Po przeprowadzonej analizie wpływu parametrów algorytmu genetycznego przyjęto konfigurację składającą się z 300 kandydatów w każdym pokoleniu, z poziomem mutacji 20 % i liczebnością selekcji turniejowej 30 osobników.

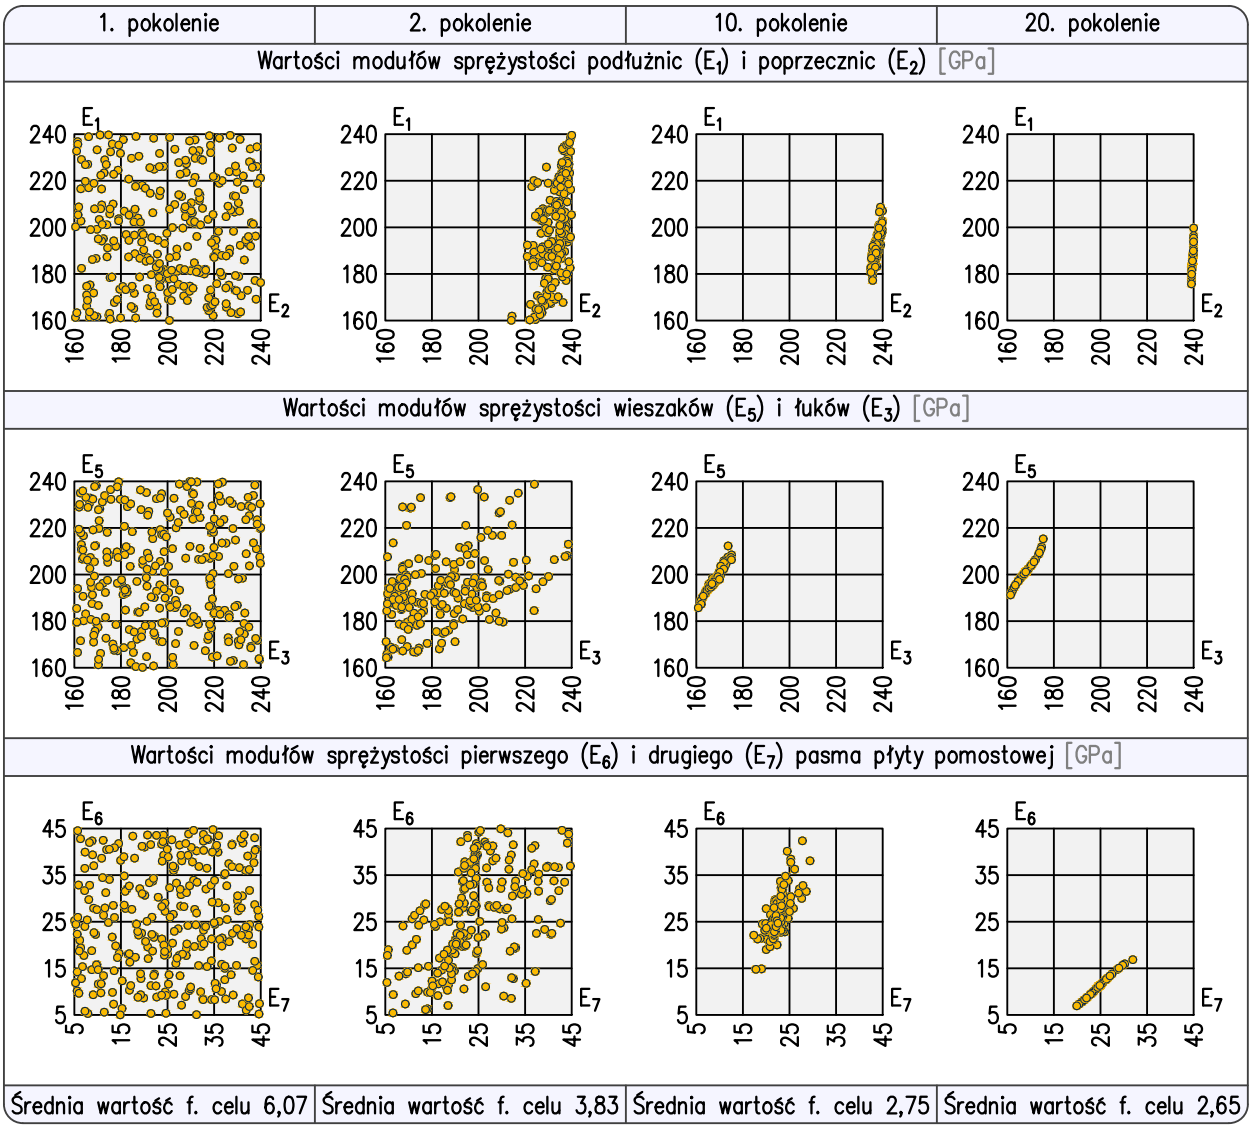

Rysunek 4.16. Wyniki identyfikacji osiągnięte w drugim podejściu - ewaluacja za pomocą modelu zastępczego

Przebieg procesu optymalizacji zachowuje podobny charakter jak w przypadku podejścia wykorzystującego model MES, jednak już od pierwszych pokoleń widoczna jest szybsza zbieżność rozwiązań. Średnia wartość funkcji celu dla wszystkich osobników 20. pokolenia wynosiła 2,65, natomiast najlepszy model osiągnął wartość 2,63, co odpowiadało średniemu bezwzględnemu błędowi procentowemu na poziomie 8,41 %. Wartości rzeczywiste i predykcyjne modelu zestawiono w Tabelach 4.11 oraz 4.12.

Tabela 4.11. Wartości odkształceń uzyskane z finalnego modelu MES: schematy S1-S3

Wartości odkształceń uzyskane z finalnego modelu MES: schematy S1-S3				
	Wartości odkształceń otrzymanych z systemu SHM [μm/m]	Wartości odkształceń otrzymanych z modelu MES [μm/m]	Bezwzględny błąd procentowy [%]	Cząstkowa wartość funkcji celu [-]
CB1-1	213,639	226,220	5,89	0,059
CB1-2	287,092	300,590	4,70	0,047
CB1-3	226,633	227,750	0,49	0,005
H1-1	1083,440	1044,900	3,56	0,036
H1-2	1386,006	929,040	32,97	0,330
			Łączna wartość funkcji celu dla schematu S1:	0,477
			Wartość MAPE dla wszystkich punktów schematu S1:	9,52 %
CB2-1	201,031	214,640	6,77	0,068
CB2-2	279,084	282,560	1,25	0,012
CB2-3	216,412	216,080	0,15	0,002
H2-1	603,519	736,510	22,04	0,220
H2-2	762,571	643,850	15,57	0,156
TB1	147,681	144,060	2,45	0,025
TB2	128,812	128,920	0,08	0,001
			Łączna wartość funkcji celu dla schematu S2:	0,484
			Wartość MAPE dla wszystkich punktów schematu S2:	6,90 %
CB3-1	220,361	230,830	4,75	0,048
CB3-2	308,004	308,830	0,27	0,003
CB3-3	247,962	233,670	5,76	0,058
H3-1	285,511	325,890	14,14	0,141
H3-2	285,224	267,890	6,08	0,061
			Łączna wartość funkcji celu dla schematu S3:	0,311
			Wartość MAPE dla wszystkich punktów schematu S3:	6,20 %

Tabela 4.12. Wartości odkształceń uzyskane z finalnego modelu MES: schematy N1-N2

Wartości odkształceń uzyskane z finalnego modelu MES: schematy N1-N2				
	Wartości odkształceń otrzymanych z systemu SHM [μm/m]	Wartości odkształceń otrzymanych z modelu MES [μm/m]	Bezwzględny błąd procentowy [%]	Cząstkowa wartość funkcji celu [-]
CB1-3	82,254	75,58	8,11	0,081
CB2-3	96,938	104,470	7,77	0,078
CB3-3	25,994	27,480	5,72	0,057
H1-2	–126,932	–86,600	31,77	0,318
H2-2	515,912	397,470	22,96	0,230
H3-2	543,202	433,750	20,15	0,201
TB2	41,411	41,400	0,03	0,000
	Łączna wartość funkcji celu dla schematu N1:			0,965
	Wartość MAPE dla wszystkich punktów schematu N1:			13,79 %
CB1-1	70,528	67,880	3,75	0,038
CB2-1	81,946	88,530	8,03	0,080
CB3-1	22,207	22,010	0,89	0,009
H1-1	–99,108	–92,930	6,23	0,062
H2-1	360,982	407,360	12,85	0,128
H3-1	413,289	442,230	7,00	0,070
TB1	46,905	46,620	0,61	0,006
	Łączna wartość funkcji celu dla schematu N2:			0,393
	Wartość MAPE dla wszystkich punktów schematu N2:			5,62 %

Zestawione w Tabelach 4.11 oraz 4.12 wyniki potwierdzają wysoką skuteczność podejścia, wykorzystującego model zastępczy sieci neuronowej. W większości punktów pomiarowych uzyskano relatywnie niskie wartości błędu, a większe rozbieżności obserwowane są jedynie w przypadku niektórych punktów zlokalizowanych na wieszakach. Dodatkowo, wartości zmiennych decyzyjnych uzyskanych w obu podejściach nie są identyczne. Nie wskazuje to jednak na nieprawidłowe działanie algorytmu, a wynika z jego stochastycznego charakteru. Oba podejścia rozpoczynają bowiem optymalizację od różnego zestawu kandydatów, generowanych losowo w pierwszym pokoleniu, zawierając również czynnik losowości w przeprowadzanych operacjach genetycznych. W konsekwencji rozwiązania uzyskane w kolejnych przebiegach algorytmu nie będą identyczne, lecz będą dążyć w kierunku globalnego optimum.

4.5 Podsumowanie

Identyfikacja modeli MES jest ważnym etapem weryfikacji systemu monitoringu SHM, umożliwiając jednocześnie ocenę zgodności symulacji numerycznych z rzeczywistą pracą konstrukcji. W przedstawionym podejściu proces ten został sformułowany jako problem optymalizacyjny, mający na celu zminimalizowanie rozbieżności pomiędzy odpowiedzią numeryczną modelu, a badaniami doświadczalnymi. Głównym wkładem przeprowadzonego zadania jest jego rzeczywiste wdrożenie na moście znacznej rozpiętości, co nie jest powszechne w obecnych badaniach. Rozwiązanie to obejmuje integrację systemu monitoringu SHM, analiz numerycznych, a także modeli uczenia maszynowego i optymalizacji. W tym celu wykorzystano algorytm genetyczny oraz model zastępczy oparty na sieci neuronowej, pozwalający na ograniczenie kosztu obliczeniowego przeprowadzanych analiz MES. Proces optymalizacji obejmował 19 zmiennych decyzyjnych, realizując ocenę modelu poprzez zdefiniowaną funkcję celu. Minimalizowała ona rozbieżności między symulacjami, a badaniami pod próbnym obciążeniem statycznym.

Przeprowadzone badania potwierdziły skuteczność algorytmu genetycznego w zadaniach identyfikacji modeli numerycznych konstrukcji mostowych. Zaproponowana metoda umożliwiła analizę znacznie większej liczby wariantów w porównaniu z klasycznym podejściem manualnym, pozwalając także na lepsze rozpoznanie przestrzeni rozwiązań. Jednocześnie wykazano możliwość skutecznego odwzorowania zależności pomiędzy zmiennymi decyzyjnymi w postaci właściwości materiałowych, a odpowiedzią konstrukcji, wykorzystując w tym celu nieliniowe modele regresyjne. Zastosowanie modelu zastępczego pozwoliło natomiast na znaczące zminimalizowanie kosztu obliczeniowego, zachowując przy tym dobrą zgodność wyników z bezpośrednimi analizami MES. Finalnie uzyskany model charakteryzował się wartością funkcji celu na poziomie 2,630, co odpowiadało wartości MAPE równej 8,41 %. Pierwotny model, wykonany na podstawie danych projektowych, uzyskał natomiast wartość funkcji celu równą 4,848, oraz błąd MAPE na poziomie 15,65 %. Przeprowadzone analizy wykazały również, że możliwe jest uzyskanie efektywnego modelu zastępczego niezależnie od zastosowanej funkcji aktywacji. Jednakże funkcje ReLU oraz LeakyReLU wymagają bardziej złożonych architektur, obejmujących większą liczbę warstw i neuronów, w porównaniu z funkcjami nieliniowymi. Z drugiej strony funkcje sigmoidalna oraz tangens hiperboliczny wiążą się z większym ryzykiem stagnacji wokół relatywnie dużej wartości funkcji straty.

Przedstawione podejście potwierdziło możliwość integracji w jednym środowisku obliczeniowym modeli numerycznych, algorytmów optymalizacyjnych oraz metod uczenia maszynowego. Rozwiązanie takie nie jest powszechne w inżynierii lądowej, szczególnie dla rzeczywistych konstrukcji dużych rozpiętości o znacznej złożoności geometrycznej i obliczeniowej. Stąd też głównym wkładem prezentowanego podejścia jest jego bezpośrednie wdrożenie na obiekcie będącym częścią infrastruktury krytycznej.

5 | Predykcja masy całkowitej pojazdów z wykorzystaniem algorytmów uczenia maszynowego

Cele rozdziału

Zidentyfikowany model numeryczny MES pozwolił na wygenerowanie syntetycznego zbioru danych obejmującego różne położenia pojazdów oraz odpowiadające im wartości odkształceń. Tak przygotowane dane wykorzystano następnie do opracowania modeli sieci neuronowych, służących do szacowania masy całkowitej pojazdów. W docelowym systemie rejestrowane odkształcenia stanowiły zatem dane wejściowe modelu regresyjnego, który zwracał na wyjściu szacowaną masę pojazdu. Przed finalną implementacją opracowanego rozwiązania konieczne było jednak opracowanie metod przetwarzania danych oraz doboru optymalnej architektury sieci. W pierwszej kolejności wykorzystano filtr Butterwortha, dzięki któremu zarejestrowane odkształcenia zostały pozbawione ewentualnych wpływów dynamicznych oraz innych zaburzeń, mogących wystąpić podczas ruchu pojazdu. Następnie opracowano procedurę automatycznego doboru architektury sieci neuronowych, wykorzystując w tym celu algorytm optymalizacyjny roju cząstek. Finalnie wdrożone rozwiązanie obejmowało zastosowanie trzech niezależnych modeli, szacujących masę pojazdu oddzielnie dla każdej bramki pomiarowej. Ostateczna wartość odpowiadała średniej arytmetycznej wszystkich trzech oszacowań. Uzyskane wyniki potwierdziły wysoką skuteczność opracowanego podejścia, które może zostać wykorzystane także w bardziej złożonych warunkach ruchu. Przeprowadzone testy obejmowały bowiem nie tylko przejazdy pojedynczych pojazdów, ale również przejazdy grupowe oraz analizę wpływu prędkości przejazdu i dodatkowych wzbudzeń dynamicznych.

5.1 Wstęp

Monitorowanie stanu konstrukcji stało się w ostatnich latach interdyscyplinarną dziedziną badań. Integruje w swoim obszarze nie tylko elementy inżynierii lądowej, ale również zagadnienia z zakresu przetwarzania danych oraz metod informatycznych i matematycznych. Jeden z głównych obszarów zainteresowań stanowią w niej obiekty mostowe, co wynika z istotnej roli jaką odgrywają w ogólnej sieci transportowej. Z tego względu dokładna wiedza o rzeczywistych obciążeniach eksploatacyjnych może stanowić cenne źródło informacji, wykorzystywanych do oceny stanu technicznego konstrukcji.

Wraz ze wzrostem natężenia ruchu oraz rosnącym udziałem transportu ciężkiego i ponadnormatywnego, obiekty mostowe coraz częściej zaliczane są do infrastruktury o znaczeniu strategicznym. Ich niezawodność wpływa bezpośrednio na funkcjonowanie całej sieci transportowej, stąd istotne staje się pozyskanie wiarygodnych informacji o rzeczywistych obciążeniach działających na konstrukcję. Odpowiedzią na potrzebę monitorowania ruchu drogowego stały się systemy ważenia pojazdów WIM (*ang. Weigh-In-Motion*). Ich tradycyjne odmiany bazują na czujnikach instalowanych bezpośrednio w nawierzchni, umożliwiając szacowanie oddziaływań eksploatacyjnych na podstawie pomiarów odkształceń. Trwałość takich rozwiązań jest jednak zwykle mocno ograniczona, co wynika z dużego cyklu obciążeń oraz wpływu czynników środowiskowych. Ewentualna naprawa lub konserwacja jest z kolei kosztowna oraz inwazyjna, wymagając czasowego zmniejszenia przepustowości ruchu. Ograniczenia te mogą jednak zostać rozwiązane poprzez wprowadzenie bezkontaktowych metod ważenia pojazdów BWIM (*ang. Bridge Weigh-In-Motion*). W podejściu tym to sam most wykorzystywany jest jako platforma wagowa, określając poziom oddziaływań eksploatacyjnych na podstawie odpowiedzi konstrukcji. Znaczący rozwój tego podejścia obejmuje implementację różnych technik i algorytmów, na które składają się między innymi metody oparte na liniach wpływu, uczeniu maszynowym czy metodach wizji komputerowej.

W kontekście infrastruktury drogowej głównym wyzwaniem metod ważenia pojazdów jest uwzględnienie problemu związanego z niedeterministyczną naturą, niepewnym położeniem i różnorodnością scenariuszy ruchu. Dotyczy to zarówno parametrów samych pojazdów, takich jak masa, geometria czy liczba osi, jak również warunków przejazdu, obejmujących prędkość, tor ruchu oraz wzajemne oddziaływanie kilku pojazdów. Dodatkową niepewnością są efekty dynamiczne, które modyfikując odpowiedź konstrukcji utrudniają jednoznaczną interpretację rejestrowanych sygnałów. W rezultacie skuteczność procesu ważenia zależy nie tylko od jakości zastosowanych czujników, ale również od metod przetwarzania oraz analizy pozyskanych danych. Pomimo tych wyzwań znaczna część rozwiązań bazuje wyłącznie na analizach numerycznych, podczas gdy dostępne badania terenowe są często przeprowadzane w kontrolowanych warunkach. Takie podejście ogranicza jednak możliwość oceny jego skuteczności w rzeczywistym ruchu, który cechuje się większą zmiennością oraz występowaniem losowych zakłóceń. Z tego względu szczególnego znaczenia nabierają rozwiązania wdrożone na rzeczywistych obiektach mostowych, umożliwiające walidację opracowanych metod w warunkach eksploatacyjnych.

Rosnące zainteresowanie systemami ważenia pojazdów w ruchu znalazło odzwierciedlenie w licznych pracach naukowych. Obejmują one podejścia, różniące się wykorzystywanymi czujnikami, rejestrowanymi danymi oraz metodami przetwarzania i analizy sygnałów. Taka różnorodność podkreśla złożoność analizowanego zagadnienia oraz szeroki zakres czynników wpływających na jego skuteczność.

5.2 Przegląd literatury

5.2.1 Metodologia ważenia pojazdów w ruchu

Systemy ważenia pojazdów w ruchu pozwalają określić masę całkowitą pojazdu, obciążenia poszczególnych osi, ich liczbę czy rozstaw. Pośrednio umożliwiają także określenie położenia pojazdu oraz jego prędkości, analizując najczęściej czas przejazdu pomiędzy kolejnymi punktami pomiarowymi. Rozwiązania tego typu znajdują coraz szersze zastosowanie i są wykorzystywane w procesach identyfikacji przeciążonych pojazdów, detekcji anomalii ruchu oraz wspomagania monitorowania infrastruktury.

Prowadzone obecnie badania dzielą metody ważenia pojazdów na dwie zasadnicze grupy. Pierwszą z nich stanowią klasyczne systemy WIM, wykorzystujące czujniki instalowane bezpośrednio w nawierzchni drogowej. Drugą grupę tworzą z kolei systemy BWIM, w których funkcję urządzenia pomiarowego pełni sam obiekt mostowy. W podejściu tym identyfikacja masy realizowana jest na podstawie odpowiedzi konstrukcji, obejmującej między innymi analizę odkształceń czy przemieszczeń. Porównanie metod ważenia pojazdów przedstawili w swojej pracy Stawska i in. [119], analizując cztery różne techniki pomiarowe. Obejmowały one wagi przenośne, stacjonarne stacje ważenia pojazdów oraz metody WIM i BWIM. Autorzy wykorzystali przy tym około 150 pojazdów ciężarowych, wykazując wysoką dokładność metod ważenia dynamicznego. Różnice pomiędzy zastosowanymi metodami dotyczyły nie tylko sposobu realizacji pomiarów, ale również stosowanych czujników, metod przetwarzania danych oraz źródeł niepewności wpływających na dokładność szacowania masy całkowitej pojazdów.

5.2.2 Klasyczne systemy WIM

Klasyczne systemy ważenia pojazdów w ruchu bazują na czujnikach montowanych bezpośrednio w nawierzchni, umożliwiając pomiar masy pojazdu poprzez kontakt koła z zastosowanym urządzeniem pomiarowym. Rozwiązania te charakteryzują się jednak ograniczoną trwałością, wynikającą z dużej liczby cykli obciążeniowych oraz wpływu warunków środowiskowych. W praktyce stosowane są różne technologie pomiarowe, obejmujące między innymi płyty gnące, ogniwa wagowe czy czujniki piezoelektryczne. Przykładowe badania przedstawili Gajda i in. [38], którzy wdrożyli system ważenia pojazdów w ruchu bazujący na czujnikach kwarcowych oraz płytach gnących. Autorzy zwrócili uwagę na wpływ wielu czynników zewnętrznych na jakość uzyskiwanych pomiarów, analizując między innymi stan nawierzchni oraz oddziaływanie warunków środowiskowych. Wspomnieli również, że niepewność pomiarowa nadal stanowi istotne ograniczenie systemów WIM, które w wielu przypadkach wykorzystywane są jedynie do preselekcji, wspomagając ważenie statyczne. Mahmood i in. [83] opracowali natomiast system WIM bazujący na czujnikach światłowodowych z siatką Bragga, które umieścili w nawierzchni jezdni. W celu

wyznaczenia masy pojazdów autorzy połączyli dane pomiarowe z modelem numerycznym oraz algorytmami uczenia maszynowego. Interesujące badania przedstawili z kolei Birgin i in. [17], którzy wdrożyli podejście alternatywne, wykorzystując materiał kompozytowy. W proponowanym rozwiązaniu funkcję elementu pomiarowego pełniła sama nawierzchnia drogowa, która umożliwiała rejestrację zmian oporu elektrycznego wywołanego przejazdem pojazdu. Uzyskane wyniki wykazały błędy szacowania masy dochodzące do 20 %, co wskazuje, że proponowane rozwiązanie wymaga jednak dalszego rozwoju.

Dostępne w literaturze badania opisują wpływ wielu czynników zewnętrznych na jakość uzyskiwanych wyników. Do głównych z nich należą między innymi stan nawierzchni, położenie pojazdu, jego prędkość czy oddziaływania środowiskowe. Przykładową analizę przeprowadzili Haider i in. [47], którzy określili wpływ szorstkości nawierzchni, prędkości przejazdu oraz konfiguracji czujników na dokładność systemów WIM. Analizując trzy typy nawierzchni, autorzy wykazali, że wzrost szorstkości prowadzi do zwiększenia błędów detekcji masy całkowitej pojazdu. Zaobserwowali również, że negatywny wpływ był szczególnie widoczny przy większych prędkościach przejazdu, dla których błędy pomiarowe osiągały wartości kilkudziesięciu procent. Kompleksową analizę czynników wpływających na wiarygodność systemów WIM przeprowadzili Brzozowski i in. [18], badając między innymi wpływ prędkości, efektów dynamicznych oraz lokalizacji obciążenia. Autorzy wykazali, że jednym z najistotniejszych źródeł błędów jest położenie pojazdu względem urządzeń pomiarowych. Już niewielkie różnice pomiędzy lokalizacją koła i czujnika prowadziły do zauważalnego pogorszenia dokładności pomiarów. Dla odległości mniejszych niż 50 cm obserwowano podwyższone błędy oszacowania masy całkowitej pojazdów, natomiast przy przesunięciu przekraczającym 170 cm błąd pomiaru osiągał nawet 30 %. Podobne wnioski przedstawili Yang i in. [140], którzy opisali niepewność wynikającą z różnicy pomiędzy rzeczywistym położeniem koła a lokalizacją czujnika. Autorzy podkreślili, że pomiary punktowe są bardzo wrażliwe na tego typu efekt, który może prowadzić do znacznego pogorszenia dokładności szacowania masy pojazdów. Przedstawione badania potwierdzają zatem, że odstępstwa od normatywnego przejazdu mogą stanowić istotne źródło niepewności pomiarowej w systemach WIM. Jednym z możliwych sposobów ograniczenia opisywanych problemów jest wykorzystanie samego mostu jako elementu pomiarowego. W podejściu tym bazuje się na odpowiedzi konstrukcji rejestrowanej pod wpływem obciążeń eksploatacyjnych.

5.2.3 Detekcja masy pojazdów z wykorzystaniem konstrukcji mostu

Pierwsze koncepcje ważenia pojazdów w ruchu, wykorzystujące odpowiedź konstrukcji mostowej pojawiły się w Stanach Zjednoczonych w latach 70. XX wieku. Jedną z pionierskich prac były badania prowadzone przez Goble'a, Mosesa oraz Pavia, których wyniki opublikowano w 1976 roku [43]. Autorzy przeprowadzili pomiary na dziesięciu mostach o konstrukcji belkowo-płytowej rejestrując przebiegi odkształ-

ceń wywołane przejazdami pojazdów ciężarowych. Zbierali przy tym informacje o ich typie, położeniu oraz odstępach pomiędzy kolejnymi pojazdami. Porównując część przejazdów z wagą stacjonarną wykazali, że możliwe jest wykorzystanie odpowiedzi konstrukcji do identyfikacji obciążeń eksploatacyjnych. W przedstawionej pracy metoda ta nie została jednak nazwana jako BWIM (*ang. Bridge Weigh--In-Motion*), stąd też za jej formalny początek częściej uznawane są badania Mosesa z 1979 roku [93]. W proponowanym podejściu wykorzystane zostały czujniki ruchu oraz tensometry zainstalowane na elementach głównych mostu drogowego. Wdrożony algorytm w pierwszej kolejności filtrował pozyskane dane, a następnie szacował masę pojazdu poprzez minimalizację błędu najmniejszych kwadratów.

Dalszy rozwój metod ważenia pojazdów w ruchu obejmował w głównej mierze implementacje coraz bardziej zaawansowanych algorytmów i technik przetwarzania danych. W ciągu ostatnich pięciu dekad opracowano systemy BWIM, które stopniowo ewoluowały wraz z trwającym postępem technologicznym oraz rosnącymi możliwościami obliczeniowymi. W wielu współczesnych implementacjach podstawę identyfikacji obciążeń stanowią linie wpływu odkształceń, przemieszczeń czy sił wewnętrznych. Często metody te są również wspomagane dodatkowymi algorytmami przetwarzania danych, zwiększając tym samym dokładność szacowania masy całkowitej pojazdów. Przykładowe badania przedstawili Zhang i in. [145], którzy wdrożyli metodę największej wiarygodności uwzględniając przy tym postacie linii wpływu oraz szum pomiarowy. Przeprowadzona przez autorów walidacja numeryczna oraz terenowa wykazała, że w porównaniu z algorytmem Mosesa podejście to lepiej sprawdza się dla pojazdów charakteryzujących się niewielkimi rozstawami osi w stosunku do rozpiętości przęsła. Jian i in. [59] wykorzystali natomiast metodę powierzchni wpływu, którą dodatkowo połączyli z technikami wizji komputerowej. Na podstawie obrazów z kamer autorzy identyfikowali położenie pojazdów oraz ich osi, a następnie wykorzystując powierzchnie wpływu odkształceń określali masę całkowitą pojazdu. Interesujący kierunek rozwoju BWIM przedstawili z kolei Moghadam i in. [92], którzy wykorzystali dane pochodzące z systemu monitoringu SHM do wyznaczenia rzeczywistych linii wpływu odkształceń. Opracowane rozwiązanie umożliwiło identyfikację obciążeń również w sytuacji jednoczesnej obecności większej liczby pojazdów na moście. Autorzy wykazali tym samym, że dane pomiarowe rejestrowane przez systemy SHM mogą stanowić istotny element wspomagający rozwój i zwiększający dokładność metod BWIM.

Coraz więcej współczesnych badań wskazuje na silną zależność pomiędzy ważeniem pojazdów w ruchu, a systemami pomiarowymi SHM. W rozwiązaniach tych wykorzystywane są pomiary odkształceń, przemieszczeń czy obrotów charakterystycznych elementów konstrukcyjnych. Dzięki temu możliwe jest opracowanie i walidacja metod BWIM na podstawie danych rzeczywistych, a nie wyłącznie analiz numerycznych. Szczególnie często opisywane są w literaturze rozwiązania wykorzystujące czujni-

ki światłowodowe z siatką Bragga FBG (*ang. Fiber Bragg Grating*). Przykładowe badania przedstawili Alamandala i in. [3], którzy analizowali odkształcenia rejestrowane w dwóch punktach pomiarowych. Oprócz identyfikacji masy pojazdów wyznaczali również ich prędkość, wykorzystując różnicę czasu pomiędzy zmianami długości fali Bragga obserwowanymi w kolejnych czujnikach. Zhang i in. [146] połączyli natomiast czujniki światłowodowe z analizą linii wpływu odkształceń. Autorzy wykazali przy tym, że jednym z najważniejszych czynników wpływających na dokładność identyfikacji masy pojazdu jest jego położenie na szerokości jezdni. Z kolei Oskoui i in. [96] wykorzystali czujniki FBG do pomiaru obrotów elementów głównych w rejonie przyczółka. W proponowanym podejściu zarejestrowane wartości powiązali z liniami wpływu, umożliwiając tym samym oszacowanie masy całkowitej pojazdów.

Obserwowany w ostatnich latach znaczny rozwój w dziedzinie uczenia maszynowego i sztucznej inteligencji znalazł odzwierciedlenie także w systemach detekcji masy pojazdów. W tym celu wykorzystywane są różne metody i algorytmy, pracujące bezpośrednio na rejestrowanych danych pomiarowych. Wśród stosowanych rozwiązań wyróżnić można zarówno klasyczne modele regresyjne i klasyfikacyjne jak również metody uczenia głębokiego. Istotnym elementem budowy takich modeli jest określenie odpowiedniego rozmiaru zbioru danych oraz dobór optymalnej architektury [103]. Szinyéri i in. [121] do ważenia pojazdów w ruchu wykorzystali podejście bazujące na sieciach neuronowych oraz pomiarach odkształceń. Opracowane modele trenowano na syntetycznym zbiorze danych, wygenerowanym z wykorzystaniem zweryfikowanego modelu numerycznego. Wang i in. [129], wykorzystując akcelerometry zainstalowane przy urządzeniu dylatacyjnym, opracowali natomiast podejście BWIM bazujące na konwolucyjnych sieciach neuronowych. Zaletą tego rozwiązania był lokalny charakter realizowanych pomiarów, ograniczający wpływ pojazdów znajdujących się w większej odległości od czujnika. Również Zhou i in. [153] skupili się na analizie parametrów dynamicznych. Zarejestrowane sygnały przekształcali do postaci dwuwymiarowych spektrogramów z wykorzystaniem analizy czasowo-częstotliwościowej. Następnie do identyfikacji klas obciążeń pojazdów wykorzystali głęboką splotową sieć neuronową.

Równie często w systemach BWIM wykorzystywane są metody wizji komputerowej. Przykładowe badania opisali Zhu i in. [155], łącząc widzenie komputerowe z pomiarami odkształceń. Wykorzystane algorytmy uczenia głębokiego pozwoliły autorom na określenie masy pojazdów oraz ich trajektorii ruchu. He i in. [51] klasyczne czujniki zastąpili natomiast dwiema kamerami. Pierwsza umożliwiała monitorowanie przemieszczeń konstrukcji, a druga identyfikowała położenie pojazdu. Do oszacowania masy wykorzystano z kolei klasyczny algorytm Mosesa. Podobne podejście przedstawili Zhao i in. [148], którzy powiązali rejestrowaną odpowiedź konstrukcji z rzeczywistym położeniem osi pojazdu. Rozwiązanie to umożliwiło identyfikację masy, jednak zostało zwalidowane wyłącznie w warunkach laboratoryjnych.

5.2.4 Podsumowanie i określenie luki badawczej

Przedstawione w literaturze badania potwierdzają duży potencjał metod ważenia pojazdów w ruchu. Współczesne rozwiązania wykorzystują coraz bardziej zaawansowane algorytmy przetwarzania danych, obejmujące między innymi analizę pracy konstrukcji czy modele uczenia maszynowego. Pomimo osiągania często wysokiej dokładności szacowania masy pojazdów, wiele z nich nadal charakteryzuje się ograniczoną walidacją terenową. Znaczna część badań prowadzona jest bowiem wyłącznie z wykorzystaniem danych numerycznych lub obejmuje niewielką liczbę scenariuszy ruchu, realizowanych w warunkach quasi-kontrolowanych. W takich przypadkach zakłada się zwykle określone położenie pojazdu, stałą prędkość przejazdu lub ograniczoną liczbę pojazdów mogących znajdować się w danej chwili na moście. Powoduje to, że rzeczywiste warunki ruchu nie są w pełni odwzorowane. Przykład takich badań opisali Wang i in. [134], którzy przedstawili metodę BWIM bazującą na rekurencyjnych sieciach neuronowych z komórkami pamięci krótkotrwałej i mechanizmem uwagi. Zaawansowane rozwiązanie zapewniało wysoką dokładność szacowania masy pojazdów, jednak zostało zwalidowane wyłącznie na danych numerycznych. Podobne podejście przedstawił również Grishyn [45]. Opracowana metoda została przetestowana na wynikach symulacji MES, wymagając dodatkowo znajomości prędkości pojazdu.

Stosowane obecnie rozwiązania bardzo często wymagają określenia parametrów wejściowych. Dotyczy to między innymi liczby i rozstawu osi, prędkości przejazdu czy położenia pojazdu na moście. Pomimo tego, że takie podejścia często pozwalają osiągać wysoką dokładności identyfikacji obciążeń, w praktyce pozyskanie wszystkich danych wejściowych dla rzeczywistego ruchu nie zawsze jest możliwe. Przykładowe badania przedstawił Moghadam [91], opisując metodę NOR BWIM (*ang. Nothing-on--Road*). Wymagała ona wcześniejszego określenia liczby osi pojazdu, ich rozstawu oraz prędkości przejazdu. Przeprowadzone przez autora badania stanowią istotny wkład w rozwój metod BWIM, eliminując potrzebę kalibracji systemu dla różnych prędkości ruchu. Zostały jednak przeprowadzone na danych numerycznych oraz w warunkach kontrolowanych, pozostawiają tym samym otwartą kwestię odporności rozwiązania na rzeczywiste warunki ruchu, w tym jednoczesny przejazd przez obiekt wielu pojazdów.

Rzeczywisty ruch drogowy charakteryzuje się znaczną losowością i obejmuje zmienną prędkość, różne tory ruchu czy wzajemne oddziaływanie pojazdów. W związku z tym istotnym zagadnieniem staje się zapewnienie stabilności systemu na możliwie szeroki zakres czynników niekontrolowanych. Przeprowadzone badania skoncentrowano zatem na analizie możliwie szerokiego scenariusza obciążeń. Uwzględniono nie tylko pojedyncze pojazdy, ale również przejazdy grupowe oraz losowe, obejmujące zróżnicowane prędkości oraz wpływ dodatkowych efektów dynamicznych.

5.3 Założenia wdrożonego rozwiązania

Celem opracowanego rozwiązania była identyfikacja pojazdów znajdujących się na moście oraz predykcja ich masy całkowitej. W tym celu wykorzystano modele sieci neuronowych, które jako dane wejściowe przyjmowały wartości odkształceń, zwracając na wyjściu szacowaną masę pojazdu. Warunkiem poprawnego działania modeli jest jednak zapewnienie dostępu do wiarygodnych i reprezentatywnych danych uczących. Próba utworzenia takiego zbioru na podstawie badań pod próbnym obciążeniem byłaby praktycznie niemożliwa, ponieważ wiązałaby się z dużą czasochłonnością oraz znacznymi kosztami. W związku z tym jako źródło danych wykorzystano model MES, za pomocą którego wygenerowano syntetyczny zbiór treningowy obejmujący różne konfiguracje obciążenia. Reprezentatywność danych zapewniono natomiast poprzez jego identyfikację, przeprowadzoną na podstawie próbnych obciążeń.

Dane treningowe zostały wygenerowane niezależnie dla każdej bramki pomiarowej. W procesie tym wykorzystane zostały wyłącznie czujniki zainstalowane na poprzecznicach, które zgodnie z przeprowadzonymi analizami charakteryzują się najbardziej lokalnym charakterem pracy. Dzięki ograniczonemu zakresowi linii wpływu rejestrowane odkształcenia zależą głównie od pojazdów znajdujących się w bezpośrednim sąsiedztwie analizowanej bramki pomiarowej. Stąd podczas generowania zbioru danych, masa oraz położenie pojazdu na szerokości jezdni były dobierane losowo, natomiast lokalizacja na długości obiektu była ograniczona do zakresu wpływu danej bramki. W trakcie kolejnych analiz numerycznych symulowano zatem różne konfiguracje położenia oraz masy pojazdu. Wygenerowano w ten sposób trzy niezależne zbiory danych, z których każdy obejmował 54 000 przykładów uczących.

Ogólny schemat opracowanego rozwiązania przedstawiono na Rysunku 5.1. Predykcja masy całkowitej pojazdu realizowana jest niezależnie dla każdej bramki pomiarowej. Wykorzystano w tym celu pomiary odkształceń w trzech punktach poprzecznicy, rejestrowane z częstotliwością 100 Hz. Zebrane dane zostały następnie przetworzone za pomocą filtru Butterwortha o nieskończonej odpowiedzi impulsowej. Stosuje on konstrukcję dolnoprzepustową i przetwarza sygnał w przód i w tył, aby uzyskać zniekształcenie zerowej fazy. Wyznaczone w ten sposób wartości odkształceń pozbawione są ewentualnych wpływów dynamicznych oraz innych zaburzeń, mogących wystąpić podczas przejazdu pojazdu.

Na podstawie przetworzonego sygnału dla każdego z czujników obliczana jest prosta średnia krocząca. Dzieli ona przebieg odkształceń na przedziały czasowe, obliczając w każdym z nich średnią arytmetyczną pomiarów. Jej zadaniem jest identyfikacja momentu pojawienia się obciążenia w obrębie analizowanej bramki oraz wyznaczenie wartości odkształceń odpowiadającej stanowi nieobciążonemu. Wykrycie charakterystycznej zmiany przebiegu sygnału powoduje zakończenie dalszego wyznaczania średniej i przyjęcie wartości z ostatniego przedziału czasowego jako poziomu referencyjnego. Maksy-

malne odkształcenia określane są natomiast z przetworzonego sygnału i odpowiadają sytuacji, w której pojazd znajduje się bezpośrednio nad analizowaną bramką pomiarową. Wyznaczona następnie różnica pomiędzy stanem obciążonym oraz nieobciążonym stanowi dane wejściowe modelu sieci neuronowej.

Wdrożone rozwiązanie obejmuje trzy niezależne modele, z których każdy przypisany jest do konkretnej bramki pomiarowej. Dzięki takiemu rozwiązaniu oraz przy wykorzystaniu lokalnego charakteru pracy poprzecznic możliwe staje się uzyskanie trzech niezależnych oszacowań masy całkowitej pojazdu. Finalna wartość predykcyjna jest natomiast uśrednieniem wartości, uzyskanych ze wszystkich bramek.

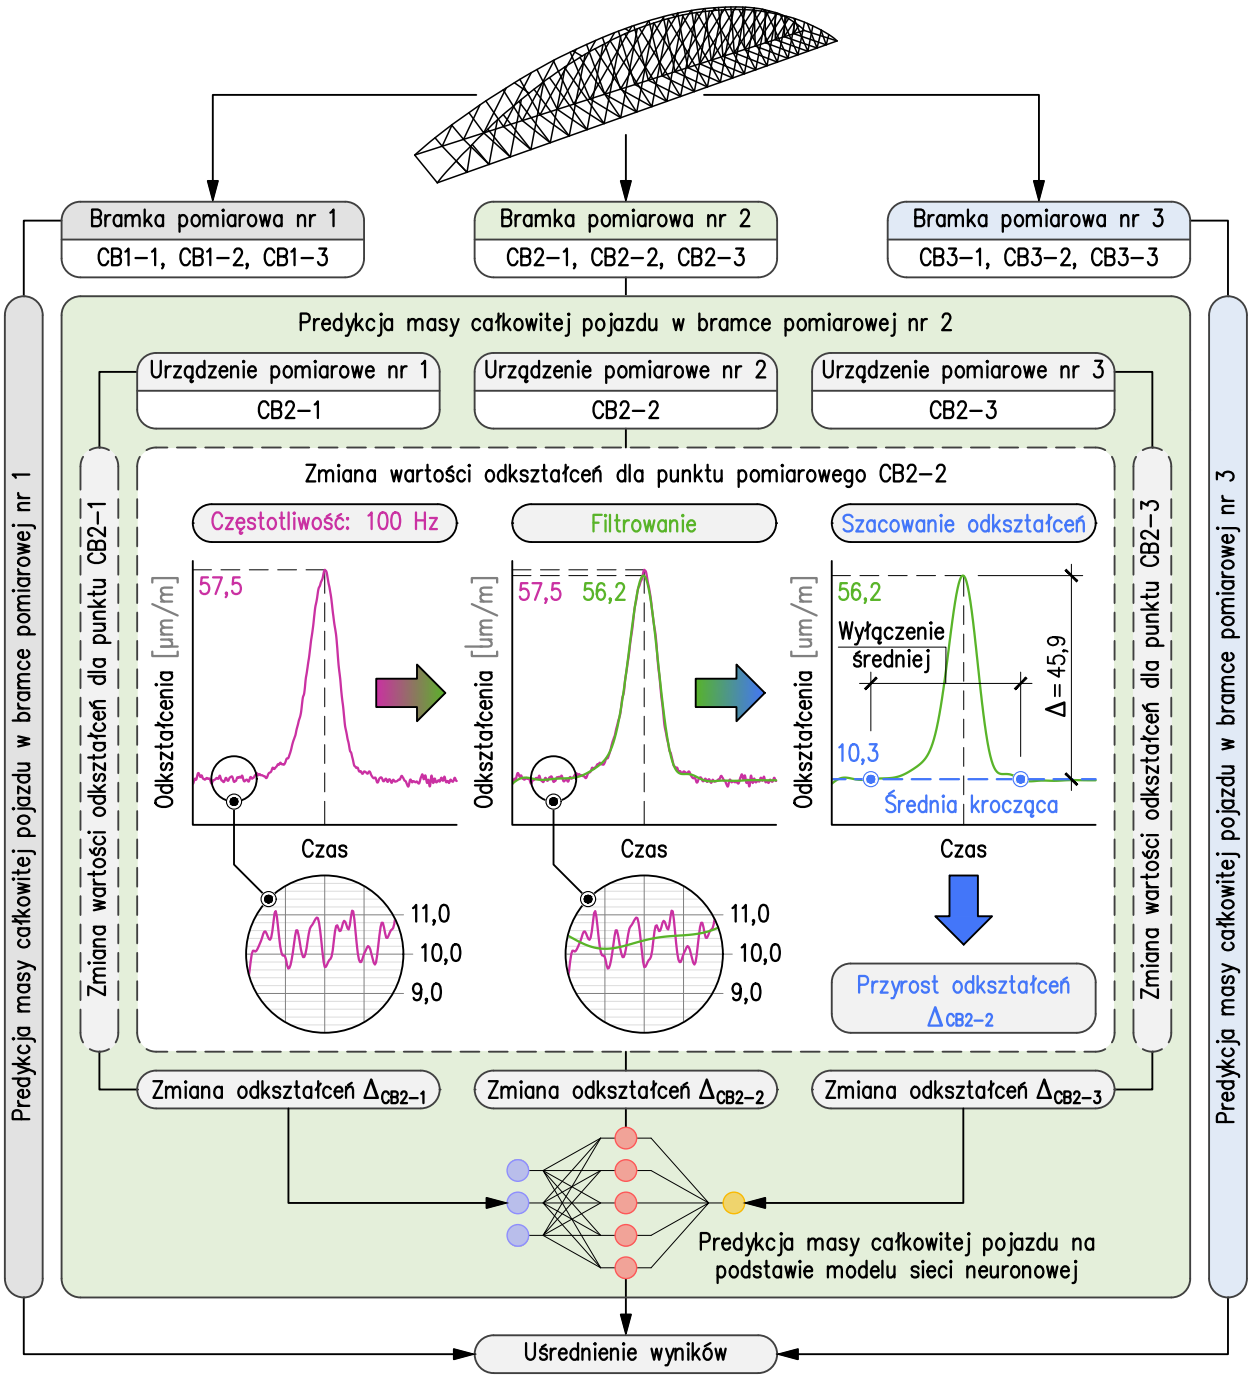

Rysunek 5.1. Schemat wdrożonego systemu ważenia pojazdów w ruchu

5.4 Metody przetwarzania zarejestrowanego sygnału

Proces przetwarzania sygnału został zaimplementowany w środowisku Python, a następnie był wywoływany z poziomu aplikacji nadrzędnej. Takie rozwiązanie umożliwiało bezpośrednią wymianę danych pomiędzy oboma środowiskami. Dedykowany skrypt wykonywał następnie operacje filtrowania oraz identyfikacji lokalnych ekstremów, zwracając przetworzone wyniki do głównej aplikacji.

W pierwszym etapie zarejestrowane odkształcenia poddawano filtracji z wykorzystaniem filtru Butterwortha. Celem tego procesu było ograniczenie składowych wysokoczęstotliwościowych, które nie były bezpośrednio związane z przejazdem pojazdu. Zastosowano filtr szóstego rzędu o częstotliwości granicznej 1 Hz, realizując filtrowanie metodą przód–tył. Takie podejście wyeliminowało przesunięcie fazowe charakterystyczne dla filtrów o nieskończonej odpowiedzi impulsowej. Następnie przeprowadzono analizę sygnału, identyfikując lokalne ekstrema odkształceń, odpowiadające obecności pojazdu nad analizowaną bramką pomiarową. Filtrowanie oraz detekcję punktów ekstremalnych zrealizowano z wykorzystaniem biblioteki SciPy, a szczegółową implementację przedstawiono na Rysunku 5.2.

Po zakończeniu filtracji wyznaczano wartość referencyjną odkształceń odpowiadającą stanowi nieobciążonemu. W tym celu zastosowana została prosta średnia krocząca, obliczana dla kolejnych przedziałów czasowych. Następnie analizowano przebieg sygnału w poszukiwaniu cech wskazujących na początek oddziaływania pojazdu. Za cechy charakterystyczne przyjęto odkształcenie różniące się od średniej o co najmniej 3 µm/m lub występowanie trendu rosnącego obejmującego nie mniej niż 95 % próbek analizowanego przedziału. Po spełnieniu przynajmniej jednego z powyższych warunków proces wyznaczania średniej kroczącej był zatrzymywany, a średnia arytmetyczna z ostatniego przedziału stanowiła wartość referencyjną odpowiadającą stanowi nieobciążonemu. Przyjęte progi zostały zdefiniowane jako parametry systemu, dzięki czemu mogły być modyfikowane w dowolnym momencie.

Po wyznaczeniu wartości odpowiadających stanowi obciążonemu oraz nieobciążonemu obliczano ich różnicę. Stanowiła ona przyrost odkształceń wywołany przejazdem pojazdu i była przekazywana do modelu regresyjnego sieci neuronowych. Podobnie jak w przypadku filtrowania model został zaimplementowany w środowisku Python i był wywoływany z poziomu aplikacji nadrzędnej (Rysunek 5.3).

W pierwszej kolejności wczytano modele odpowiadające poszczególnym bramkom pomiarowym. Następnie na podstawie identyfikatora analizowanej bramki wybierano model wykorzystywany do szacowania masy pojazdu. Po przekazaniu danych wejściowych przeprowadzano proces predykcji, przesyłając uzyskane wyniki do aplikacji nadrzędnej. Całe zadanie realizowano w sposób ciągły w zamkniętej pętli obliczeniowej, umożliwiając bieżącą analizę kolejnych pojazdów rejestrowanych przez system.

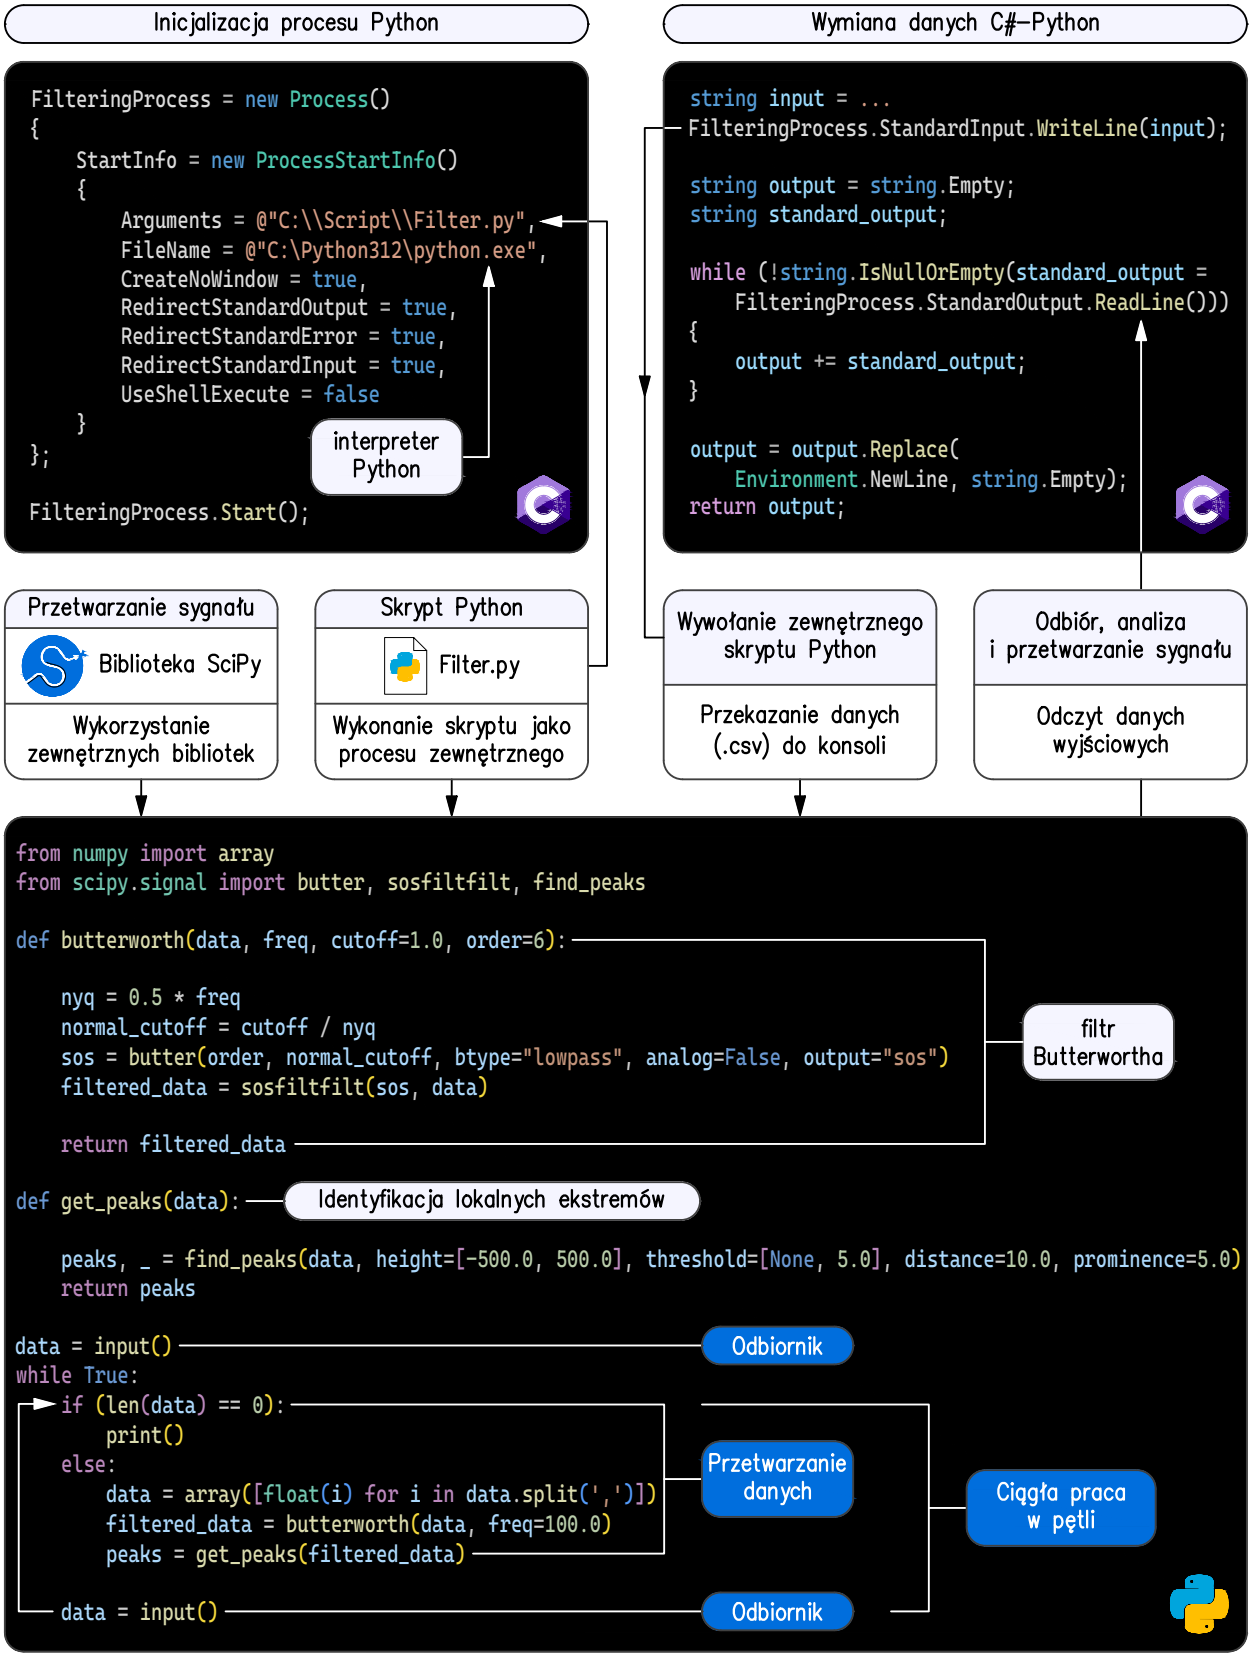

Rysunek 5.2. Implementacja procesu filtrowania oraz detekcji punktów ekstremalnych

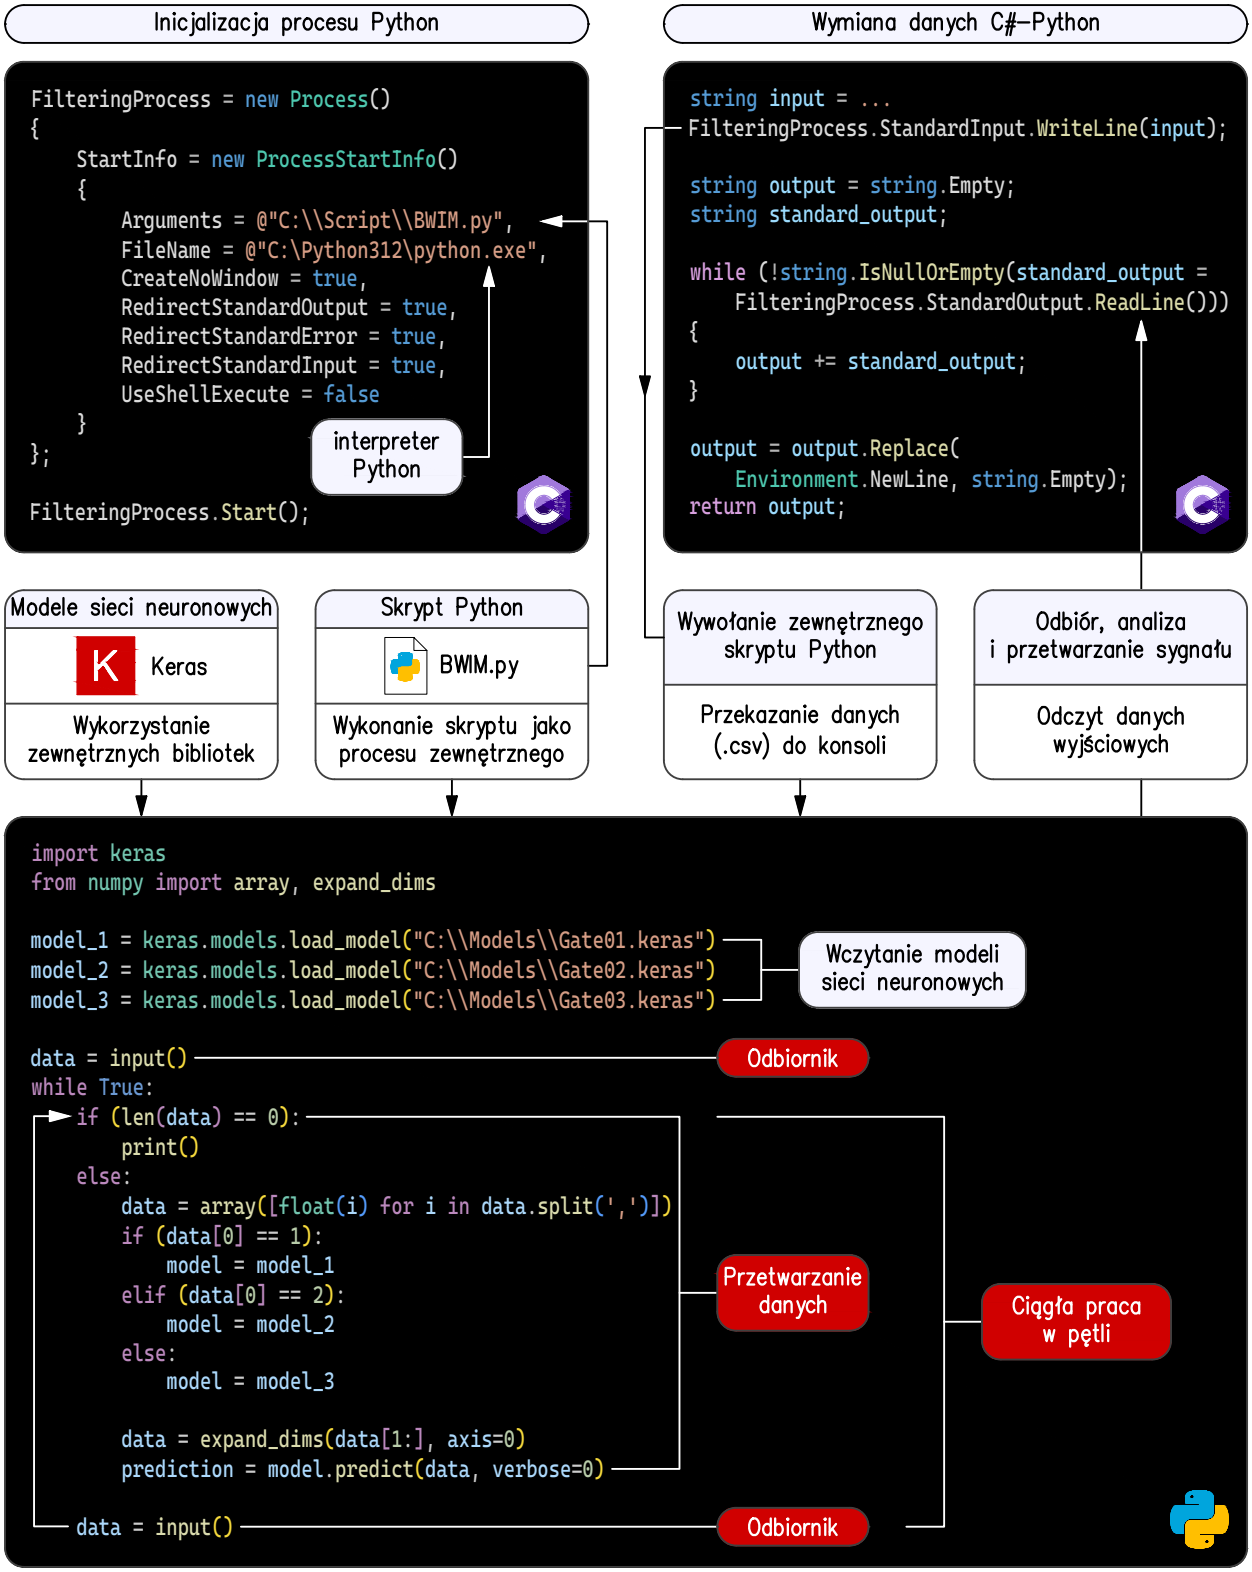

Rysunek 5.3. Implementacja algorytmów predykcyjnych sieci neuronowych

5.5 Procedura doboru architektury modeli sieci neuronowych

Szacowanie masy całkowitej pojazdów przeprowadzane jest z wykorzystaniem modeli sieci neuronowych. W pierwszej kolejności konieczne jest jednak określenie ich optymalnej architektury, której wybór ma kluczowe znaczenie dla osiągnięcia wysokiej jakości predykcji. Wpływa ona bezpośrednio na zdolność modelu do odwzorowania nieliniowych zależności pomiędzy rejestrowanymi odkształceniami, a rzeczywistą masą pojazdu. Niewystarczająco złożone modele mogą prowadzić do zjawiska niedouczenia (*ang. Underfitting*), skutkującego dużymi błędami predykcji. Z kolei nadmiernie rozbudowane architektury zwiększają ryzyko przetrenowania modelu (*ang. Overfitting*), ograniczając jego zdolność do generalizacji na nowych, niezaobserwowanych dotąd danych. Proces doboru architektury sieci obejmuje jednoczesną analizę wielu parametrów, a każda rozpatrywana konfiguracja wymaga przeprowadzenia pełnego procesu treningowego oraz walidacyjnego. W związku z tym zagadnienie to sformułowano w postaci zadania optymalizacyjnego, do którego rozwiązania wykorzystano algorytm roju cząstek.

Zaproponowany przez Kennediego i Eberharta [64] algorytm roju cząstek PSO (*ang. Particle Swarm Optimization*) jest metaheurystyczną metodą obliczeniową, inspirowaną zachowaniem stada zwierząt. Operuje on na n-elementowym zbiorze potencjalnych rozwiązań zwanym rojem, którego składowe określane są jako cząstki. Każda cząstka i opisana jest poprzez wektor położenia $\mathbf{x}_i = (x_{i1}, \ldots, x_{im})$ oraz odpowiadający mu wektor prędkości $\mathbf{v}_i = (v_{i1}, \ldots, v_{im})$, zdefiniowane w m-wymiarowej przestrzeni rozwiązań, gdzie jako m przyjęto liczbę zmiennych decyzyjnych problemu optymalizacyjnego. Wektor położenia cząstki reprezentuje aktualne rozwiązanie zadania, z kolei wektor prędkości określa kierunek, zwrot oraz intensywność zmian poszczególnych parametrów sieci w kolejnych iteracjach algorytmu.

W przedstawionym podejściu wektor położenia cząstki odpowiada konkretnej architekturze modelu sieci neuronowej. W kolejnych iteracjach t algorytmu aktualizowana jest wartość prędkości każdej składowej j wektora $\mathbf{v}_i$, zgodnie z zależnością 5-1. Proces ten uwzględnia poprzednie położenie cząstki $x_{ij}^{(t-1)}$ oraz jej prędkość $v_{ij}^{(t-1)}$, a także wartość p_{ij} odpowiadającą składowej j najlepszego położenia osiągniętego przez cząstkę i, jak również najlepsze rozwiązanie znalezione przez cały rój G_j.

$$v_{ij}^{(t)} = w v_{ij}^{(t-1)} + c_1 r_1 \left(p_{ij} - x_{ij}^{(t-1)} \right) + c_2 r_2 \left(G_j - x_{ij}^{(t-1)} \right) \tag{5-1}$$

Wpływ dotychczasowej prędkości cząstki regulowany jest przez współczynnik inercji w, odpowiadający za zachowanie informacji o wcześniejszym kierunku ruchu. Współczynniki c_1 oraz c_2 określane odpowiednio jako kognitywny oraz socjalny definiują natomiast wpływ najlepszego rozwiązania lokalnego oraz globalnego na aktualizowaną wartość prędkości. Wielkości r_1 oraz r_2 przyjmują z kolei losowe wartości z przedziału $[0, 1]$, nadając procesowi optymalizacji charakter stochastyczny. Nowe położenie

$x_{ij}^{(t)}$ cząstki wyznaczane jest jako suma jej poprzedniego położenia oraz aktualnej prędkości (Wzór 5-2).

$$x_{ij}^{(t)} = x_{ij}^{(t-1)} + v_{ij}^{(t)} \tag{5-2}$$

W analizowanym zadaniu zmiennymi decyzyjnymi procesu optymalizacyjnego były liczba warstw, liczba neuronów w pierwszej warstwie, współczynnik redukcyjny, współczynnik uczenia oraz funkcja aktywacji. Dodatkowo przyjęto założenie, zgodnie z którym liczba neuronów w pierwszej warstwie przyjmowała wartości będące potęgami liczby 2. Ograniczono tym samym przestrzeń poszukiwań do reprezentatywnych konfiguracji o zróżnicowanej złożoności oraz wyeliminowano konieczność analizowania podobnych architektur, które zazwyczaj nie prowadzą do istotnych różnic w jakości predykcji. Liczba neuronów w kolejnych warstwach była natomiast wyznaczana przy wykorzystaniu współczynnika redukcyjnego, przy zachowaniu malejącej liczby neuronów w kolejnych warstwach sieci. Rosnące architektury prowadzą bowiem do szybkiego wzrostu liczby wag, co przekłada się na wydłużenie czasu treningu oraz zwiększenie kosztu obliczeniowego i ryzyka przetrenowania modelu.

Definicję przestrzeni rozwiązań oraz inicjalizację położenia i prędkości cząstek przedstawiono na Rysunku 5.4. Każdą cząstkę opisano za pomocą pięcioelementowego wektora położenia, którego składowe odpowiadały parametrom definiującym architekturę modelu sieci neuronowej. Początkowe położenia cząstek generowano losowo, w obrębie przyjętych granic przestrzeni rozwiązań. Analogicznie inicjalizowano również prędkości cząstek, dla których przyjmowano losowe wartości z przedziału $[-1, 1]$.

Inicjalizacja położenia cząstek

```python
def initialize_particles(num_particles):
    particles = []
    for _ in range(num_particles):
        particle = [
            random.randint(layer_min, layer_max),
            random.randint(0, len(neurons)-1),
            random.normal(loc=0, scale=1),
            random.uniform(lr_min, lr_max),
            random.randint(activation_min,
                           activation_max)
        ]
        particles.append(particle)
    return particles
```

Definicja przestrzeni rozwiązań

```python
layer_min = 1; layer_max = 5
neurons = [32, 64, 128, 256]
lr_min = np.log10(0.0005); lr_max = np.log10(0.1)
activation_min = 0; activation_max = 6
```

Inicjalizacja prędkości cząstek

```python
def initialize_velocities(num_particles):
    return [
        [random.uniform(-1, 1) for _ in range(5)]
        for _ in range(num_particles)
    ]
```

Rysunek 5.4. Definicja przestrzeni rozwiązań wraz z inicjalizacją położenia oraz prędkości każdej cząstki

Liczbę warstw ukrytych ograniczono do zakresu od 1 do 5, natomiast liczba neuronów w pierwszej warstwie mogła przyjmować jedną z czterech wartości: 32, 64, 128 lub 256. Funkcja aktywacji była natomiast kodowana za pomocą indeksu przyjmującego wartości od 0 do 6, który odpowiadał kolej-

nym funkcjom: ReLU, Leaky ReLU, tanh, ELU, SELU, GELU oraz Swish. Współczynnik redukcyjny inicjalizowany był na podstawie zmiennej losowej o rozkładzie normalnym, przyjmując średnią równą 0 oraz odchylenie standardowe równe 1. Zaletą takiego rozwiązania jest skupienie większości początkowych rozwiązań w pobliżu wartości średniej rozkładu. Z kolei współczynnik uczenia analizowano w zakresie od 0,0005 do 0,1. Z uwagi na możliwość przyjmowania wartości różniących się o kilka rzędów wielkości zastosowano skalę logarytmiczną, umożliwiającą równomierne przeszukiwanie przestrzeni rozwiązań.

Przed rozpoczęciem procesu treningowego każda cząstka poddawana była procesowi dekodowania (Rysunek 5.5). Liczba warstw oraz neuronów w pierwszej warstwie mogły przyjmować wyłącznie wartości naturalne, dlatego odpowiednie składowe wektora położenia zostały zaokrąglone do najbliższej liczby całkowitej. Podobne podejście zostało zastosowane w przypadku funkcji aktywacji, której wybór realizowany był na podstawie wartości indeksu odpowiadającego jednej z analizowanych funkcji. Współczynnik uczenia wyznaczono natomiast poprzez odwrotną transformację logarytmu dziesiętnego, uzyskując jego rzeczywistą wartość wykorzystywaną podczas treningu kolejnych wariantów sieci.

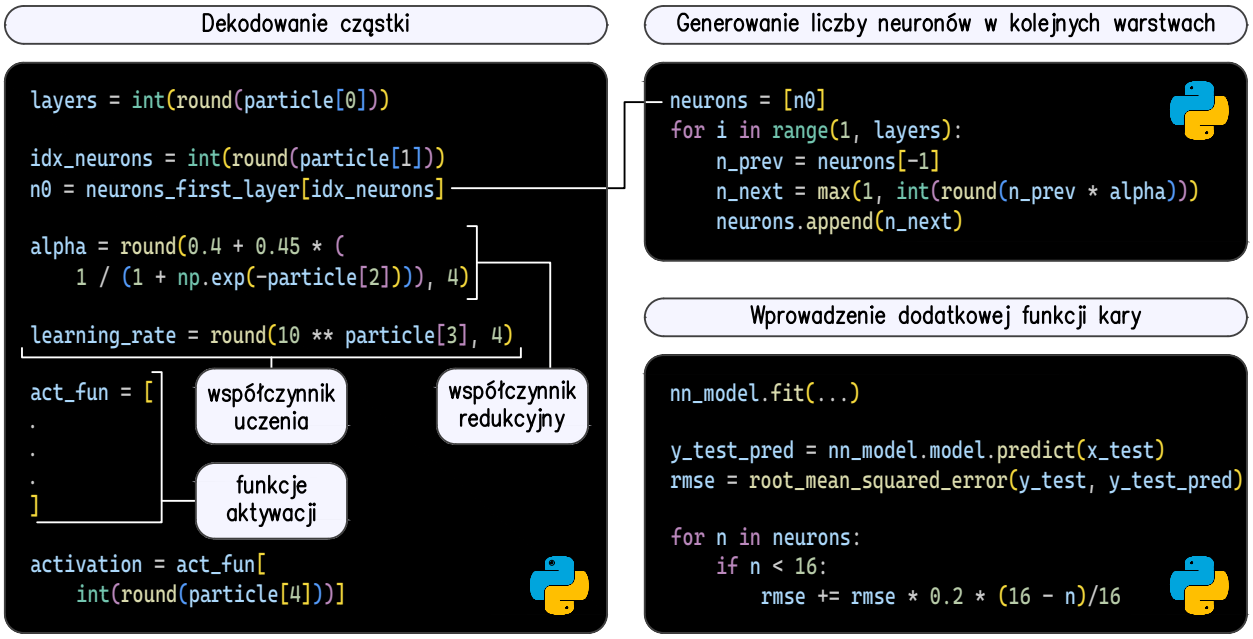

Rysunek 5.5. Proces dekodowania cząstki oraz wyznaczenia wartości funkcji celu

Współczynnik redukcyjny α wyznaczono przy wykorzystaniu funkcji logistycznej opisanej zależnością 5-3, w której jako x_ij oznaczono wartość składowej j wektora położenia cząstki, odpowiadającą współczynnikowi redukcyjnemu. Funkcja ta jest szeroko stosowana w zagadnieniach optymalizacyjnych, umożliwiając ograniczenie wartości parametru do zadanego przedziału. Jej ciągły i monotoniczny charakter sprawia, że niewielkie zmiany położenia cząstki prowadzą do proporcjonalnych zmian współczynnika redukcyjnego. Zastosowanie takiego przekształcenia pozwoliło na uzyskanie wartości z prze-

działu od 0,4 do 0,85, niezależnie od analizowanej składowej wektora położenia. Wyeliminowano tym samym konfiguracje prowadzące do nadmiernie szybkiego zmniejszania liczby neuronów w kolejnych warstwach oraz przypadki, w których kolejne warstwy miały bardzo zbliżone rozmiary.

$$\alpha = 0{,}4 + 0{,}45 \cdot \frac{1}{1 + e^{-x_i j}} \tag{5-3}$$

Rozmiar kolejnych warstw sieci wyznaczano jako iloczyn liczby neuronów warstwy poprzedniej oraz współczynnika redukcyjnego α, po zaokrągleniu do najbliższej liczby całkowitej. Rozwiązanie to pozwalało na automatyczne generowanie architektur o malejącej liczbie neuronów w kolejnych warstwach, przy jednoczesnym zachowaniu kontroli nad tempem redukcji ich liczby. Każda konfiguracja sieci oceniana była z wykorzystaniem pierwiastka średniego błędu kwadratowego RMSE (*ang. Root Mean Squared Error*), wprowadzając dodatkowo składnik kary zwiększający wartość błędu dla warstw zawierających mniej niż szesnaście neuronów (Wzór 5-4), gdzie jako $J(k)$ oznaczono finalną wartość błędu RMSE, a jako k liczbę neuronów w danej warstwie. Rozwiązanie takie miało na celu ograniczenie generowania nadmiernie uproszczonych architektur, które mogą prowadzić do pogorszenia jakości predykcji.

$$J(k) = \text{RMSE}(k) \left[1 + 0{,}2 \frac{16 - k}{16} 1_{\{k<16\}} \right] \tag{5-4}$$

Na podstawie wektora położenia każdej cząstki generowane były kolejne modele sieci neuronowych. Implementację tego procesu przedstawiono na Rysunku 5.6, wykorzystując optymalizator Adam (*ang. Adaptive Moment Estimation*), oraz minimalizując wartość funkcji straty Hubera. Tak przygotowany model był trenowany, a następnie stanowił pojedyncze rozwiązanie oceniane przez algorytm PSO.

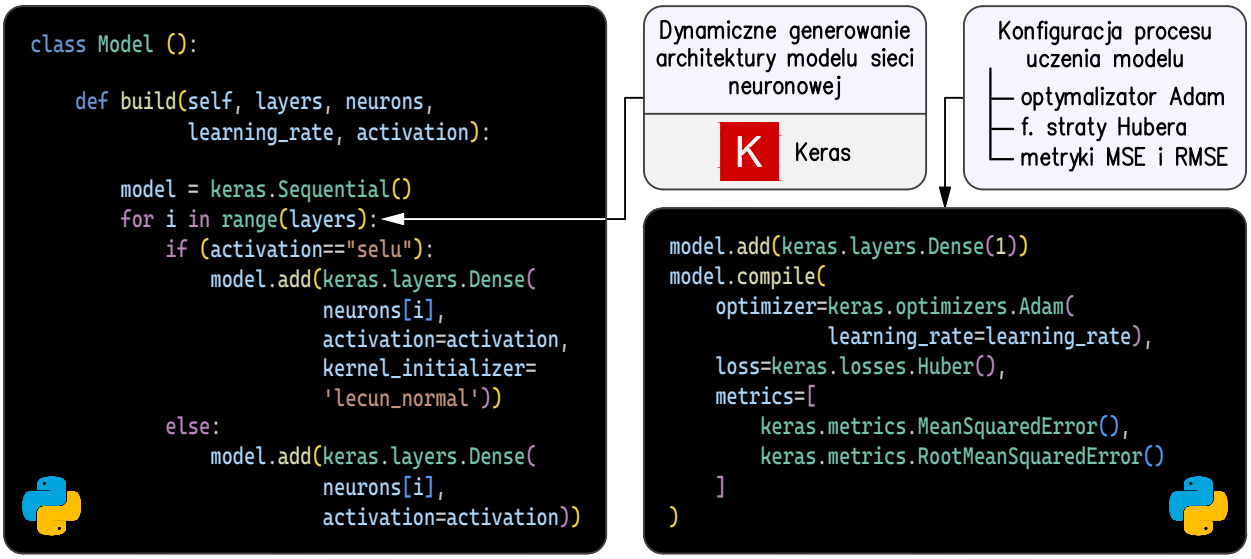

Rysunek 5.6. Dynamiczne generowanie architektury modelu sieci neuronowej na podstawie danych uzyskanych z algorytmu PSO

W celu zachowania wszystkich cząstek wewnątrz zdefiniowanej przestrzeni rozwiązań oraz przeciwdziałania stagnacji położenia w pobliżu granic zdefiniowano dodatkowy mechanizm odbicia. W przypadku przekroczenia dopuszczalnego zakresu położenie cząstki było odbijane względem odpowiedniej granicy przestrzeni rozwiązań. Jednocześnie następowała zmiana zwrotu oraz redukcja odpowiadającej jej prędkości, którą wyznaczano jako iloczyn jej poprzedniej wartości oraz współczynnika, dobieranego losowo z przedziału 0,3 – 0,7. Rozwiązanie to zapewniło stabilizację procesu optymalizacji, w którym każda cząstka osiągająca granicę przestrzeni rozwiązań wracała do jej wnętrza.

Algorytm optymalizacyjny przeprowadzono dla $t_{\text{max}} = 30$ iteracji, zakładając rój liczący 20 cząstek. Wartość współczynnika inercji w była wyznaczana niezależnie w każdej iteracji t, zmieniając się liniowo w przedziale od $w_{\text{min}} = 0{,}4$ do $w_{\text{max}} = 0{,}9$. Współczynnik ten wyznaczano na podstawie Wzoru 5-4.

$$w = w_{\text{max}} - \frac{(w_{\text{max}} - w_{\text{min}}) \cdot t}{t_{\text{max}}} \tag{5-5}$$

Przyjęte wartości współczynników kognitywnych i socjalnych dla wszystkich pięciu składowych wektora położenia cząstki przedstawiono w Tabeli 5.1. Z kolei architektury cechujące się najmniejszą wartością RMSE dla każdej z bramek pomiarowych zestawiono w Tabeli 5.2.

Tabela 5.1. Przyjęte wartości współczynników algorytmu PSO

Przyjęte wartości współczynników algorytmu PSO

	Składowe wektora położenia cząstki				
Współczynnik	**Liczba warstw**	**Liczba neuronów w pierwszej warstwie**	**Współ. redukcyjny**	**Współ. uczenia**	**Funkcja aktywacji**
$c_1 = c_2$	1,00	1,50	1,50	0,25	1,00

Tabela 5.2. Przyjęte architektury sieci neuronowych dla każdej bramki pomiarowej

Przyjęte architektury sieci neuronowych dla każdej bramki pomiarowej

					Kolejne warstwy sieci					
Bramka	**Liczba warstw**	α	λ	ϕ	1	2	3	4	5	RMSE [kg]
1	4	0,8483	0,0008	GELU	256	217	184	156	-	97,0
2	3	0,5720	0,0119	GELU	256	146	84	-	-	115,3
3	4	0,6896	0,0061	Swish	128	88	61	42	-	110,8

α - współczynnik redukcyjny λ - współczynnik uczenia ϕ - funkcja aktywacji

5.6 Predykcja masy całkowitej pojazdów

5.6.1 Przejazdy pojedynczych pojazdów

W pierwszej kolejności skuteczność wdrożonego rozwiązania przeanalizowano dla przejazdów pojedynczych. Zrealizowano osiemnaście prób, w których wszystkie dziewięć pojazdów poruszało się zgodnie z kierunkiem docelowego ruchu odpowiednio prawym oraz lewym pasem. Ze względu na lokalizację bramek pomiarowych pojazd kolejno przejeżdżał przez bramki nr 3, 2 oraz 1. Przykładowe wyniki uzyskane dla wszystkich trzech bramek przedstawiono na Rysunkach 5.7 oraz 5.8. Obejmują one zarejestrowane odkształcenia oraz przebiegi po filtracji dla tego samego czteroosiowego pojazdu poruszającego się odpowiednio prawym oraz lewym pasem ruchu. Dodatkowo, dla każdej bramki pomiarowej zamieszczono przyrosty odkształceń odpowiadające różnicy pomiędzy stanem obciążonym, a nieobciążonym.

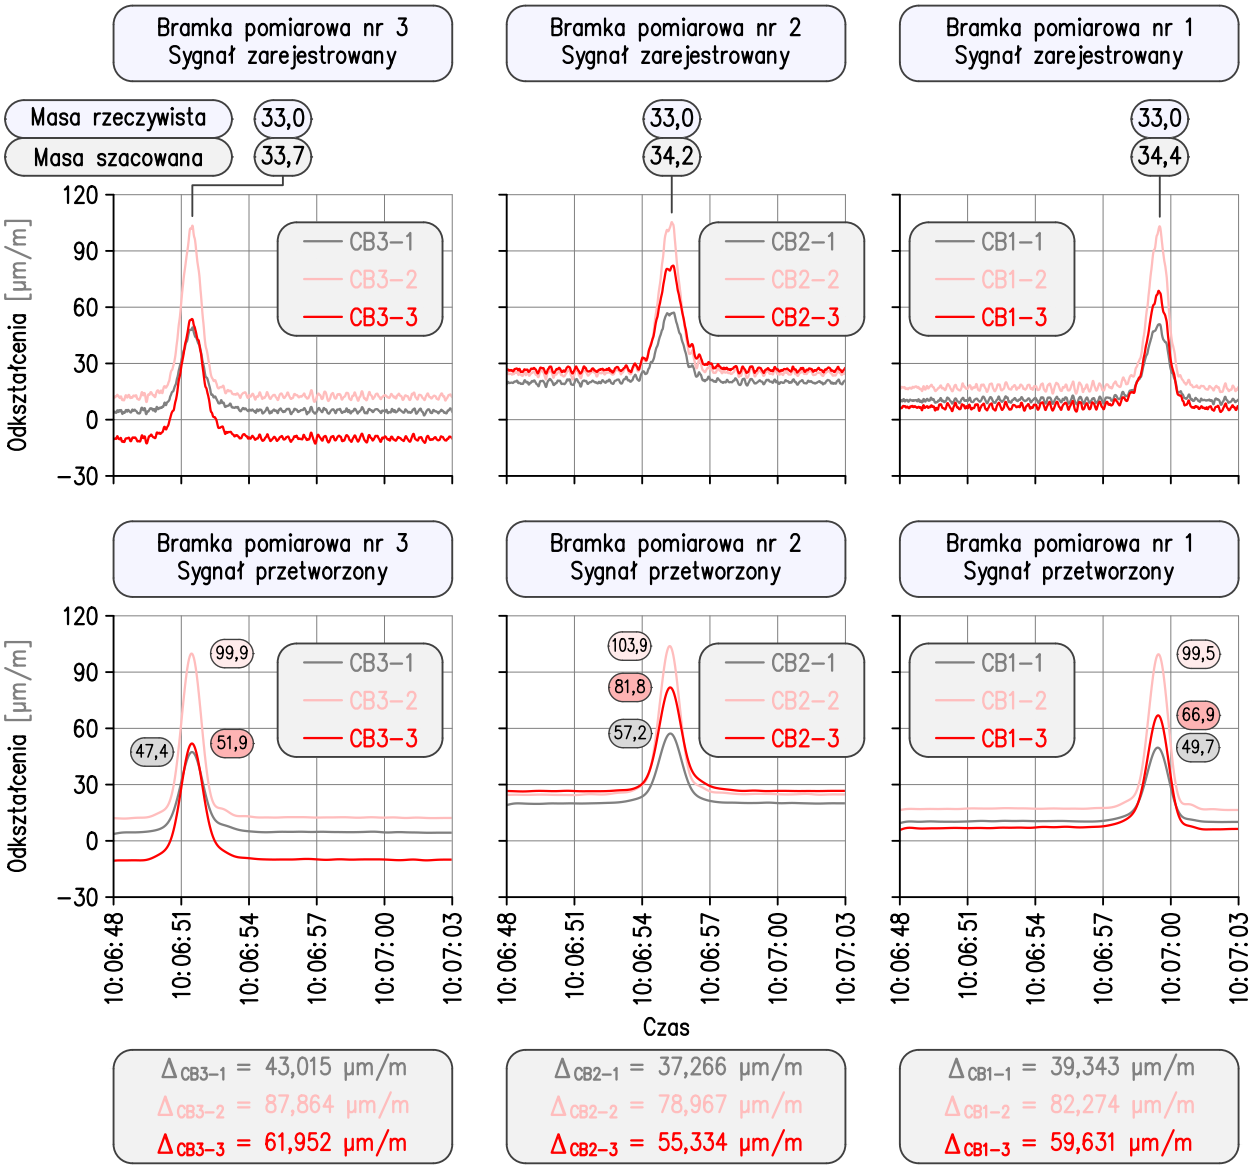

Rysunek 5.7. Szacowana masa pojazdu czteroosiowego poruszającego się prawym pasem ruchu

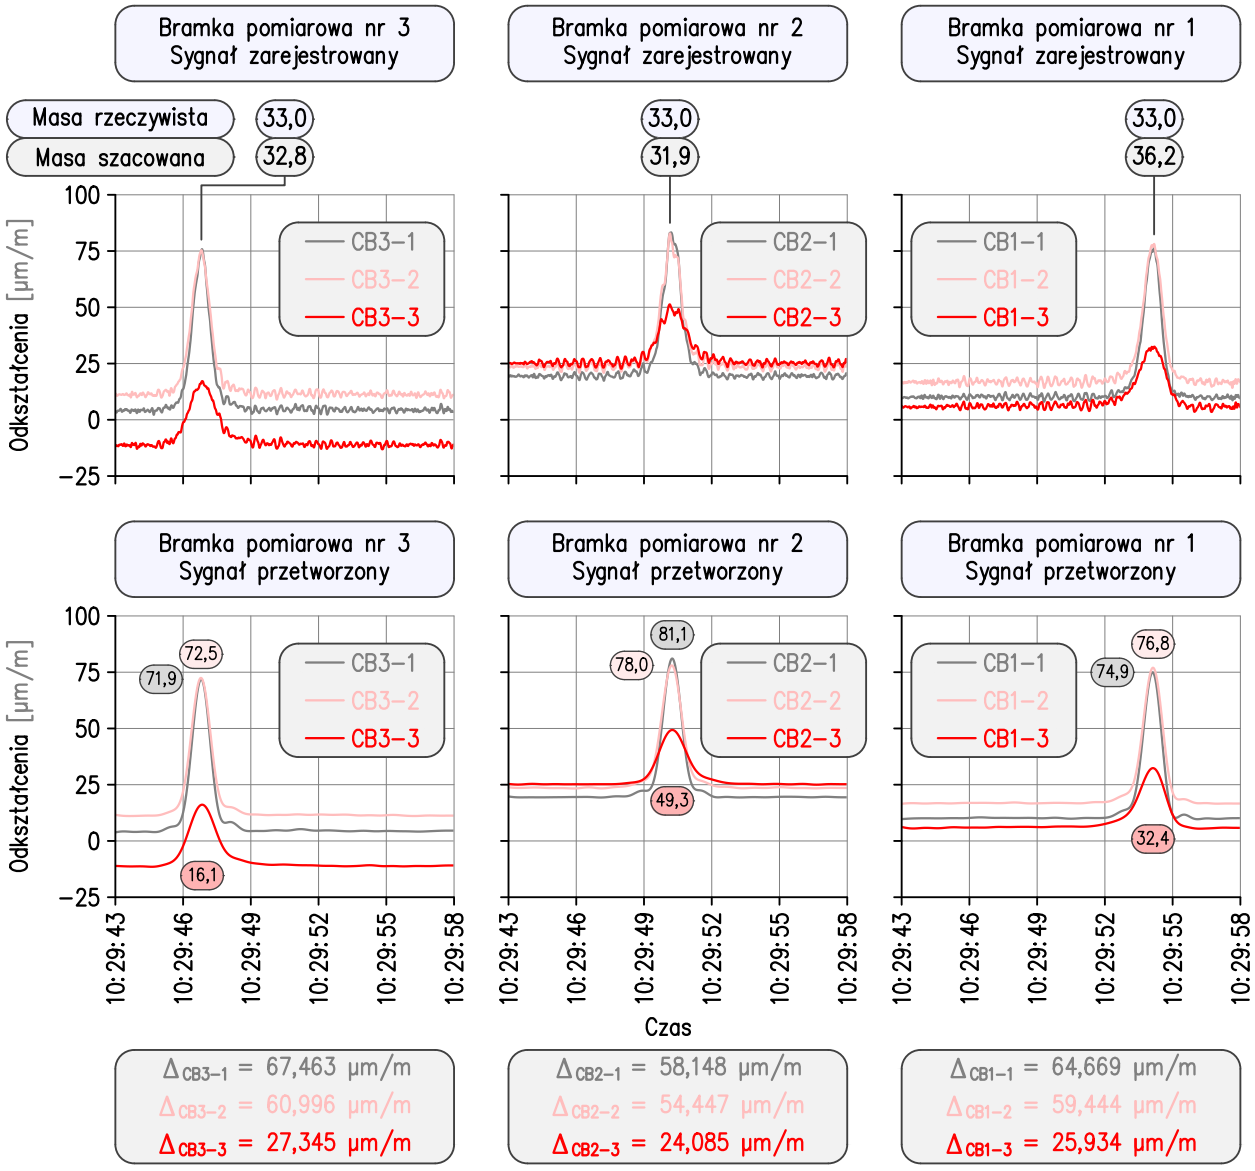

Rysunek 5.8. Szacowana masa pojazdu czteroosiowego poruszającego się lewym pasem ruchu

Przedstawione przebiegi potwierdzają poprawność działania opracowanego algorytmu. Szacowane masy są porównywalne dla każdej bramki, a ich dodatkowe uśrednienie poprawia końcową wartość predykcji. Dla zamieszczonych przykładów oszacowana masa była równa 34,1 t oraz 33,6 t odpowiednio dla przejazdu prawym oraz lewym pasem ruchu. Rzeczywista masa pojazdu wynosiła natomiast 33,0 t.

Zmiana położenia pojazdu na szerokości jezdni wpływa także na wartości przyrostów odkształceń rejestrowanych w poszczególnych punktach pomiarowych. Zastosowanie trzech czujników na poprzecznicy umożliwia jednak uwzględnienie tych zmian w procesie predykcji masy całkowitej. Model sieci neuronowej nie skupia się bowiem na pojedynczej wartości odkształcenia, lecz analizuje wzajemne relacje pomiędzy wszystkimi trzema punktami pomiarowymi. Dzięki temu zachowana zostaje zdolność do poprawnej identyfikacji masy pojazdu niezależnie od jego położenia na szerokości jezdni.

Szczegółowe wyniki uzyskane dla pojedynczych przejazdów przedstawiono w Tabeli 5.3. W obecnych oraz przyszłych analizach wykorzystanych zostało pięć metryk, mających na celu ocenę jakości uzyskiwanych predykcji. Obejmowały one współczynnik zgodności ACC (*ang. Accuracy Coefficient*), definiowany jako stosunek masy szacowanej do rzeczywistej, a ponadto średni błąd procentowy MPE (*ang. Mean Percentage Error*), średni bezwzględny błąd procentowy MAPE (*ang. Mean Absolute Percentage Error*), średni błąd ME (*ang. Mean Error*) oraz średni błąd bezwzględny MAE (*ang. Mean Absolute Error*).

Tabela 5.3. Szacowane masy oraz metryki jakości predykcji dla pojedynczych przejazdów

Szacowane masy oraz metryki jakości predykcji dla pojedynczych przejazdów										
Pojazd	**Pas**	**Szacowane masy pojazdów**				**Metryki jakości predykcji**				
		Br. 1	**Br. 2**	**Br. 3**	**Śr.**	**ACC**	**MPE**	**MAPE**	**ME**	**MAE**
		[t]	[t]	[t]	[t]	[-]	[%]	[%]	[t]	[t]
6-osiowy [**41,4 t**]	Prawy	37,1	37,4	37,2	37,2	0,90	10,13	10,13	−4,2	4,2
	Lewy	39,9	41,3	41,5	40,9	0,99	1,35	1,35	−0,6	0,6
5-osiowy [**40,6 t**]	Prawy	39,8	39,9	39,2	39,6	0,98	2,38	2,38	−1,0	1,0
	Lewy	43,2	39,6	42,2	41,7	1,03	−2,63	2,63	1,1	1,1
5-osiowy [**41,5 t**]	Prawy	39,4	40,1	39,8	39,8	0,96	4,22	4,22	−1,8	1,8
	Lewy	42,7	41,7	42,9	42,4	1,02	−2,21	2,21	0,9	0,9
4-osiowy [**33,0 t**]	Prawy	34,4	34,2	33,7	34,1	1,03	−3,10	3,10	1,0	1,0
	Lewy	36,2	31,9	32,8	33,6	1,02	−1,70	1,70	0,6	0,6
4-osiowy [**32,2 t**]	Prawy	33,2	33,1	32,4	32,9	1,02	−2,34	2,34	0,8	0,8
	Lewy	34,0	32,1	32,7	32,9	1,02	−2,39	2,39	0,8	0,8
4-osiowy [**32,7 t**]	Prawy	34,4	33,8	33,4	33,9	1,04	−3,52	3,52	1,2	1,2
	Lewy	34,3	34,1	32,5	33,6	1,03	−2,81	2,81	0,9	0,9
3-osiowy [**28,7 t**]	Prawy	31,9	30,9	30,8	31,2	1,09	−8,78	8,78	2,5	2,5
	Lewy	33,4	34,8	31,7	33,3	1,16	−16,14	16,14	4,6	4,6
3-osiowy [**27,8 t**]	Prawy	30,2	29,5	30,1	29,9	1,08	−7,81	7,81	2,2	2,2
	Lewy	27,7	28,4	31,4	29,2	1,05	−5,19	5,19	1,4	1,4
3-osiowy [**28,8 t**]	Prawy	30,3	30,7	30,7	30,6	1,06	−6,25	6,25	1,8	1,8
	Lewy	28,8	29,1	28,4	28,8	1,00	0,06	0,06	0,0	0,0
					Średnia:	1,03	−2,60	4,61	0,7	1,5
					Odchylenie standardowe:	0,06	5,57	3,95	1,8	1,2

5.6.2 Przejazdy w kolumnach

Oprócz przejazdów pojedynczych zrealizowano również scenariusze obejmujące ruch kilku pojazdów poruszających się w kolumnie. W tym celu wykorzystane zostały trzy grupy o zbliżonych parametrach geometrycznych. Dla każdej z nich przewidziano wariant obejmujący dwa oraz trzy pojazdy, a analizie poddano ruch odbywający się oboma pasami ruchu niezależnie. Pierwsza kolumna składała się z pojazdów pięcioosiowych oraz jednego pojazdu sześcioosiowego, natomiast dwie kolejne obejmowały odpowiednio pojazdy czteroosiowe oraz trójosiowe. Łącznie wykonanych zostało dwanaście dodatkowych przypadków, a przykładowe zmiany odkształceń dla dwóch z nich, zarejestrowane w drugiej bramce pomiarowej, przedstawiono na Rysunku 5.9. Szczegółowe wyniki zamieszczono natomiast w Tabeli 5.4.

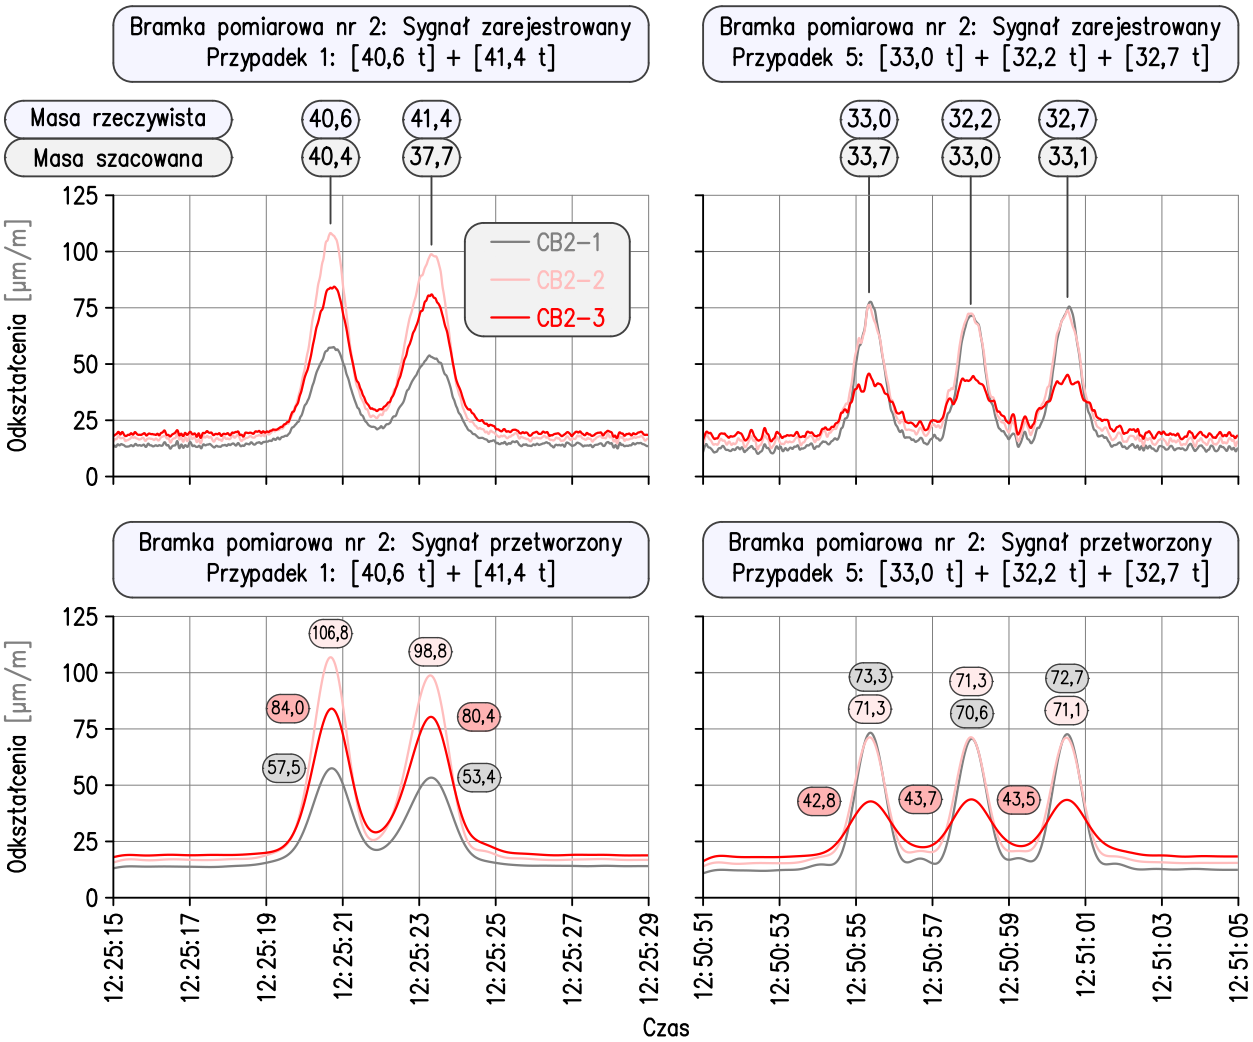

Rysunek 5.9. Szacowane masy pojazdów dla przykładowych przejazdów w kolumnach

Z przeprowadzonych dwunastu przejazdów wybrano sześć reprezentatywnych, odzwierciedlających ogólny trend uzyskanych predykcji. Obejmowały one wszystkie analizowane grupy oraz warianty składające się z dwóch i trzech pojazdów poruszających się odpowiednio prawym oraz lewym pasem. Dla

wszystkich przypadków osiągnięto zbliżone wartości analizowanych metryk, potwierdzając możliwość skutecznej identyfikacji mas pojazdów również w przypadku przejazdów realizowanych w kolumnach.

Tabela 5.4. Szacowane masy oraz metryki jakości predykcji dla przejazdów pojazdów w kolumnach

Szacowane masy oraz metryki jakości predykcji dla przejazdów pojazdów w kolumnach

Pojazd	Pas	Szacowane masy pojazdów				Metryki jakości predykcji				
		Br. 1	Br. 2	Br. 3	Śr.	ACC	MPE	MAPE	ME	MAE
		[t]	[t]	[t]	[t]	[-]	[%]	[%]	[t]	[t]
Przypadek 1: 5-osiowy [**40,6 t**] + 6-osiowy [**41,4 t**]										
40,6 t	Prawy	40,4	40,7	40,1	40,4	1,00	0,49	0,49	−0,2	0,2
41,4 t	Prawy	37,2	37,9	38,1	37,7	0,91	8,95	8,95	−3,7	3,7
					Średnia:	0,95	−4,72	4,72	−2,0	2,0
Przypadek 2: 4-osiowy [**33,0 t**] + 4-osiowy [**32,2 t**]										
33,0 t	Prawy	34,2	34,5	33,6	34,1	1,03	−3,21	3,21	1,1	1,1
32,2 t	Prawy	32,4	33,3	32,7	32,8	1,02	−1,99	1,99	0,6	0,6
					Średnia:	1,03	−2,60	2,60	0,9	0,9
Przypadek 3: 3-osiowy [**28,7 t**] + 3-osiowy [**27,8 t**]										
28,7 t	Prawy	31,3	31,0	31,3	31,2	1,09	−8,71	8,71	2,5	2,5
27,8 t	Prawy	27,6	28,1	28,6	28,1	1,01	−1,23	1,23	0,3	0,3
					Średnia:	1,05	−4,97	4,97	1,4	1,4
Przypadek 4: 5-osiowy [**40,6 t**] + 6-osiowy [**41,4 t**] + 5-osiowy [**41,5 t**]										
40,6 t	Lewy	44,3	39,9	41,2	41,8	1,03	−2,96	2,96	1,2	1,2
41,4 t	Lewy	42,2	41,1	41,7	41,7	1,01	−0,55	0,55	0,2	0,2
41,5 t	Lewy	39,5	42,9	42,6	41,7	1,00	−0,35	0,35	0,1	0,1
					Średnia:	1,01	−1,29	1,29	0,5	0,5
Przypadek 5: 4-osiowy [**33,0 t**] + 4-osiowy [**32,2 t**] + 4-osiowy [**32,7 t**]										
33,0 t	Lewy	36,8	31,9	32,5	33,7	1,02	−2,10	2,10	0,7	0,7
32,2 t	Lewy	34,5	31,2	33,4	33,0	1,03	−2,72	2,72	0,9	0,9
32,7 t	Lewy	32,4	31,5	35,3	33,1	1,01	−1,06	1,06	0,3	0,3
					Średnia:	1,02	−1,96	1,96	0,6	0,6
Przypadek 6: 3-osiowy [**28,7 t**] + 3-osiowy [**27,8 t**] + 3-osiowy [**28,8 t**]										
28,7 t	Lewy	32,2	30,5	28,9	30,5	1,06	−6,41	6,41	1,8	1,8
27,8 t	Lewy	27,4	26,5	30,4	28,1	1,01	−1,23	1,23	0,3	0,3
28,8 t	Lewy	27,0	27,3	31,7	28,7	1,00	0,39	0,39	−0,1	0,1
					Średnia:	1,02	−2,41	2,68	0,7	0,8

5.6.3 Przejazdy losowe

Kontynuując ocenę skuteczności opracowanego systemu, przeanalizowano również bardziej złożone scenariusze ruchu. Obejmowały one jednoczesne przejazdy wszystkich dziewięciu pojazdów bez narzucania prędkości oraz odległości pomiędzy nimi. W pierwszej kolejności zrealizowano przejazdy każdym z pasów oddzielnie, a następnie rozważono scenariusze obejmujące jednoczesne wykorzystanie obu pasów ruchu. Kolejność pojazdów oraz ich położenie na poszczególnych pasach dobierano losowo.

Przykładowe wyniki uzyskane dla przejazdu prawym pasem ruchu przedstawiono na Rysunku 5.10. Zamieszczono na nim odkształcenia zarejestrowane w drugiej bramce pomiarowej wraz z przebiegami po filtracji oraz wartościami mas rzeczywistych i szacowanych przez model sieci neuronowej.

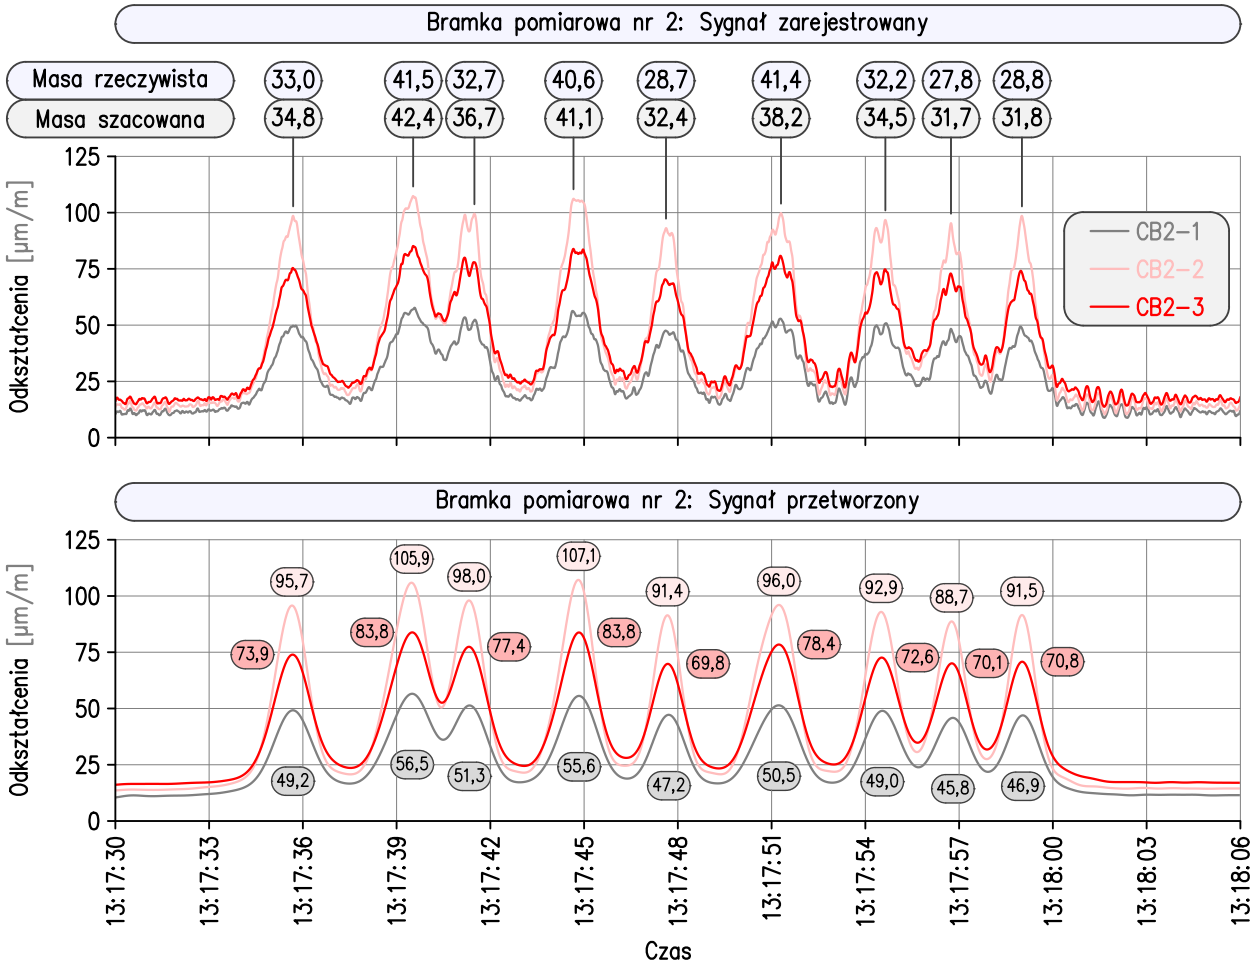

Rysunek 5.10. Szacowane masy pojazdów dla przejazdu losowego prawym pasem ruchu

W Tabeli 5.5 przedstawione zostały szczegółowe wyniki uzyskane dla wszystkich dziewięciu pojazdów poruszających się prawym pasem ruchu. Zestawiono w niej wartości mas szacunkowych każdego pojazdu zarejestrowane niezależnie na każdej bramce pomiarowej oraz odpowiadające im metryki jakości predykcji. System osiągnął średni błąd procentowy MPE na poziomie –6,43 % oraz błąd MAPE równy 8,15 %. Średni błąd ME wyniósł 1,9 t, natomiast średni błąd bezwzględny MAE osiągnął wartość 2,6 t.

Tabela 5.5. Szacowane masy oraz metryki jakości predykcji dla przejazdu losowego prawym pasem ruchu

Szacowane masy oraz metryki jakości predykcji dla przejazdu losowego prawym pasem ruchu

Pojazd	Pas	Szacowane masy pojazdów				Metryki jakości predykcji				
		Br. 1	Br. 2	Br. 3	Śr.	ACC	MPE	MAPE	ME	MAE
		[t]	[t]	[t]	[t]	[-]	[%]	[%]	[t]	[t]
4-osiowy [**33,0 t**]	Prawy	35,5	35,1	33,9	34,8	1,05	−5,43	5,43	1,8	1,8
5-osiowy [**41,5 t**]	Prawy	43,1	42,5	41,5	42,4	1,02	−2,04	2,04	0,8	0,8
4-osiowy [**32,7 t**]	Prawy	36,1	37,6	36,5	36,7	1,12	−12,27	12,27	4,0	4,0
5-osiowy [**40,6 t**]	Prawy	41,2	41,5	40,6	41,1	1,01	−1,23	1,23	0,5	0,5
3-osiowy [**28,7 t**]	Prawy	32,2	32,8	32,1	32,4	1,13	−12,78	12,78	3,7	3,7
6-osiowy [**41,4 t**]	Prawy	37,9	38,6	38,2	38,2	0,92	7,74	7,74	−3,2	3,2
4-osiowy [**32,2 t**]	Prawy	34,7	34,8	33,9	34,5	1,07	−7,17	7,17	2,3	2,3
3-osiowy [**27,8 t**]	Prawy	31,0	32,5	31,6	31,7	1,14	−14,19	14,19	3,9	3,9
3-osiowy [**28,8 t**]	Prawy	30,7	33,0	31,7	31,8	1,11	−10,49	10,49	3,0	3,0
				Średnia:		1,06	−6,43	8,15	1,9	2,6
				Odchylenie standardowe:		0,07	7,07	4,67	2,3	1,3

Uzyskane wyniki potwierdzają możliwość skutecznej identyfikacji mas pojazdów również dla bardziej złożonych scenariuszy ruchu. W większości przypadków uzyskano błędy predykcji nieprzekraczające 10 %, natomiast nieco większe wartości obserwowano dla części pojazdów poruszających się w niewielkich odstępach czasowych. Zachowanie takie można wiązać z efektem nakładających się sygnałów odkształceń i wynikającej z tego superpozycji wpływu pojazdów znajdujących się w najbliższym sąsiedztwie bramki pomiarowej. Szczególnie zauważalne jest to pomiędzy drugim i trzecim pojazdem, a także w końcowej fazie przejazdu. W obszarach tych nie ma wyraźnego powrotu sygnału do poziomu bazowego pomiędzy kolejnymi przejazdami, co może nieznacznie wpływać na jakość uzyskiwanych pre-

dykcji. Pomimo tego, średnia wartość błędu MAPE dla całego przypadku wyniosła 8,15 %, potwierdzając tym samym skuteczność opracowanego modelu również w bardziej złożonych warunkach ruchu.

W kolejnym kroku przeanalizowano scenariusze obejmujące jednoczesny ruch pojazdów po obu pasach ruchu. W porównaniu do przedstawionego wcześniej przypadku prowadziło to do większej złożoności rejestrowanych odkształceń, wynikającej głównie z różnego położenia pojazdów na szerokości jezdni. Przykładowe wyniki uzyskane dla jednego z przejazdów przedstawiono na Rysunku 5.11. Zaprezentowano na nim odkształcenia zarejestrowane w drugiej bramce pomiarowej wraz z przebiegami po filtracji oraz wartościami mas rzeczywistych i oszacowanych. W analizowanym przypadku położenie pojazdów na pasach ruchu, odległości pomiędzy nimi oraz prędkości przejazdu dobierane były losowo.

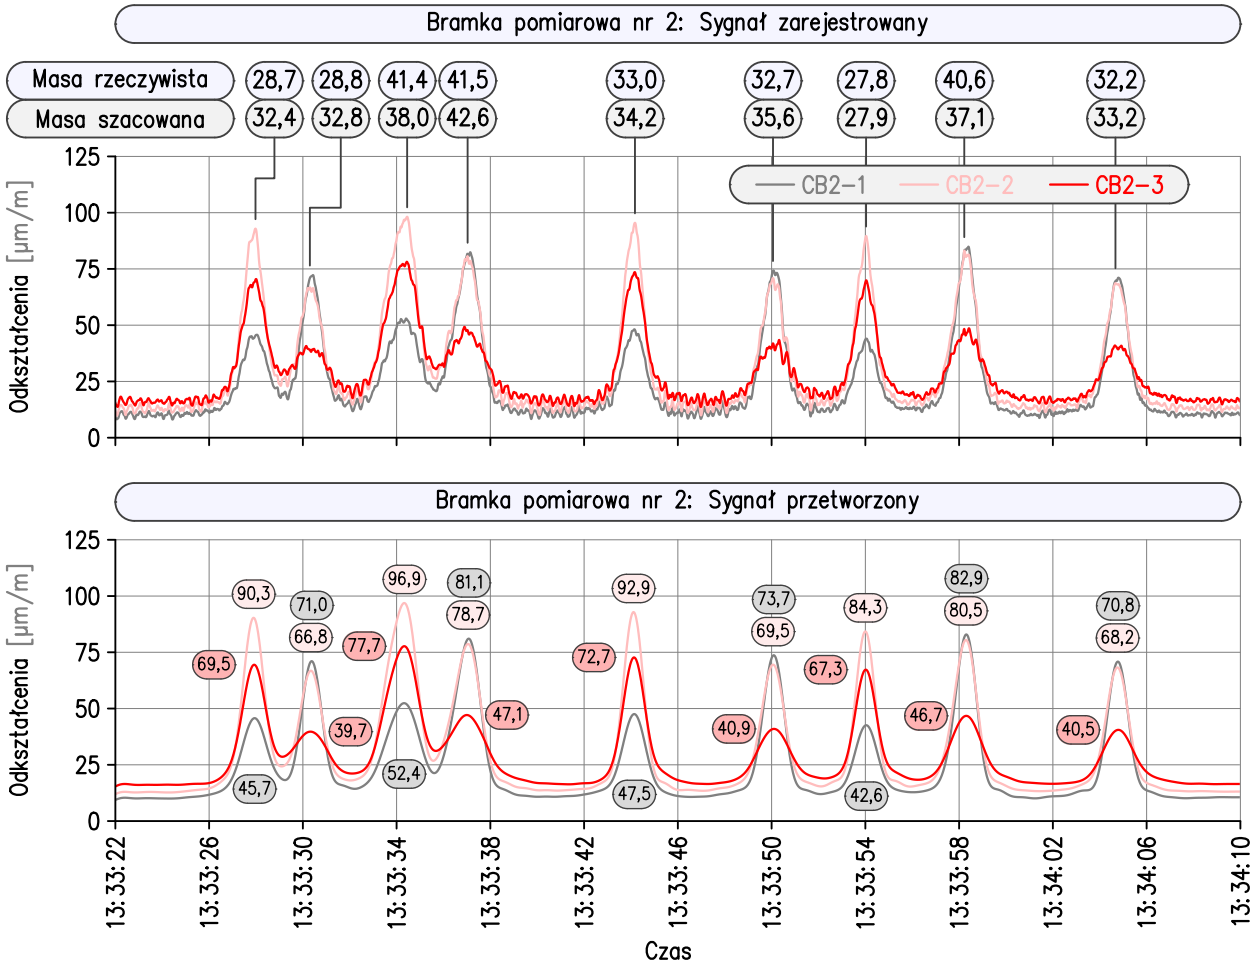

Rysunek 5.11. Szacowane masy pojazdów dla przejazdu losowego dwoma pasami ruchu

Zauważalne jest również, że w analizowanym przypadku odstępy czasowe pomiędzy kolejnymi pojazdami były większe niż dla wcześniej przedstawionego przejazdu. Przekładało się to na lepszą separację pomiarów oraz ograniczenie wzajemnego wpływu sąsiednich pojazdów. Dla części z nich sygnał powracał do poziomu bazowego jeszcze przed pojawieniem się odkształceń od kolejnego pojazdu, dzięki czemu mogły być one analizowane jako niezależne przypadki obciążeniowe. Przykładem może być po-

jazd o masie całkowitej 27,8 t, dla którego odstęp czasowy względem sąsiednich przejazdów wynosił około 4 s. Przy prędkości przejazdu równej około 40 km/h odpowiada to odległości ponad 40 m, przekraczając tym samym strefę oddziaływania pojedynczej bramki pomiarowej. W rezultacie odpowiedzi obu pojazdów były od siebie wyraźnie odseparowane, co sprzyjało poprawnej identyfikacji ich mas.

Szczegółowe wyniki analizowanego przejazdu przedstawiono w Tablicy 5.6. Osiągnięto średnią wartość MPE na poziomie –3,21 % oraz MAPE równą 6,97 %. Błędy ME oraz MAE osiągnęły z kolei średnie wartości wynoszące odpowiednio 0,8 t oraz 2,3 t. Nieznacznie zmniejszoną jakość predykcji zaobserwowano natomiast w początkowej fazie przejazdu. Zachowanie takie można wiązać z częściowym nakładaniem się wpływów sąsiednich pojazdów, znajdujących się w obrębie analizowanej bramki.

Tabela 5.6. Szacowane masy oraz metryki jakości predykcji dla przejazdu losowego dwoma pasami ruchu

Szacowane masy oraz metryki jakości predykcji dla przejazdu losowego dwoma pasami ruchu

Pojazd	Pas	Szacowane masy pojazdów				Metryki jakości predykcji				
		Br. 1	Br. 2	Br. 3	Śr.	ACC	MPE	MAPE	ME	MAE
		[t]	[t]	[t]	[t]	[-]	[%]	[%]	[t]	[t]
3-osiowy [**28,7 t**]	Prawy	33,3	32,4	31,5	32,4	1,1	–12,89	12,89	3,7	3,7
3-osiowy [**28,8 t**]	Lewy	33,0	33,2	32,3	32,8	1,14	–14,08	14,08	4,1	4,1
6-osiowy [**41,4 t**]	Prawy	36,0	39,3	38,7	38,0	0,92	8,30	8,30	–3,4	3,4
5-osiowy [**41,5 t**]	Lewy	37,6	44,4	45,7	42,6	1,03	–2,52	2,52	1,0	1,0
4-osiowy [**33,0 t**]	Prawy	34,7	34,1	33,9	34,2	1,04	–3,61	3,61	1,2	1,2
4-osiowy [**32,7 t**]	Lewy	39,6	34,2	33,1	35,6	1,09	–8,90	8,90	2,9	2,9
3-osiowy [**27,8 t**]	Prawy	29,3	27,5	27,0	27,9	1,01	–0,62	0,62	0,2	0,2
5-osiowy [**40,6 t**]	Lewy	39,3	37,3	34,7	37,1	0,91	8,62	8,62	–3,5	3,5
4-osiowy [**32,2 t**]	Lewy	34,1	32,7	32,8	33,2	1,03	–3,23	3,23	1,0	1,0
				Średnia:		1,03	–3,21	6,98	0,8	2,3
				Odchylenie standardowe:		0,08	8,10	4,73	2,8	1,5

5.6.4 Analiza wpływu prędkości i dodatkowego wzbudzenia dynamicznego

Kolejnym etapem badań była analiza wpływu prędkości oraz dodatkowych efektów dynamicznych na jakość predykcji masy całkowitej pojazdu. Przedstawione w poprzednich etapach pracy założenie, że prędkość przejazdu nie wpływa znacząco na rejestrowane odkształcenia, wynikało głównie z otrzymanej wartości współczynnika przewyższenia dynamicznego bliskiej jedności oraz analizy różnicy odkształceń pomiędzy stanami obciążonym i nieobciążonym. W celu weryfikacji tych czynników przeprowadzono serię przejazdów z wykorzystaniem trzech pojazdów czteroosiowych o masach 33,0 t, 32,2 t oraz 32,7 t. Dla każdego pojazdu zrealizowano po dwa przejazdy lewym oraz prawym pasem ruchu, przy prędkościach w zakresie od 10 km/h do 90 km/h. Na Rysunku 5.12 przedstawiono przykładowe zmiany odkształceń w drugiej bramce pomiarowej dla pojazdu o masie 33,0 t, poruszającego się lewym pasem ruchu z prędkościami 10 km/h oraz 70 km/h, a także z losową, nienarzuconą wcześniej prędkością. Dla każdego z tych przejazdów przetwarzanie sygnału oraz predykcja masy całkowitej realizowane były niezależnie.

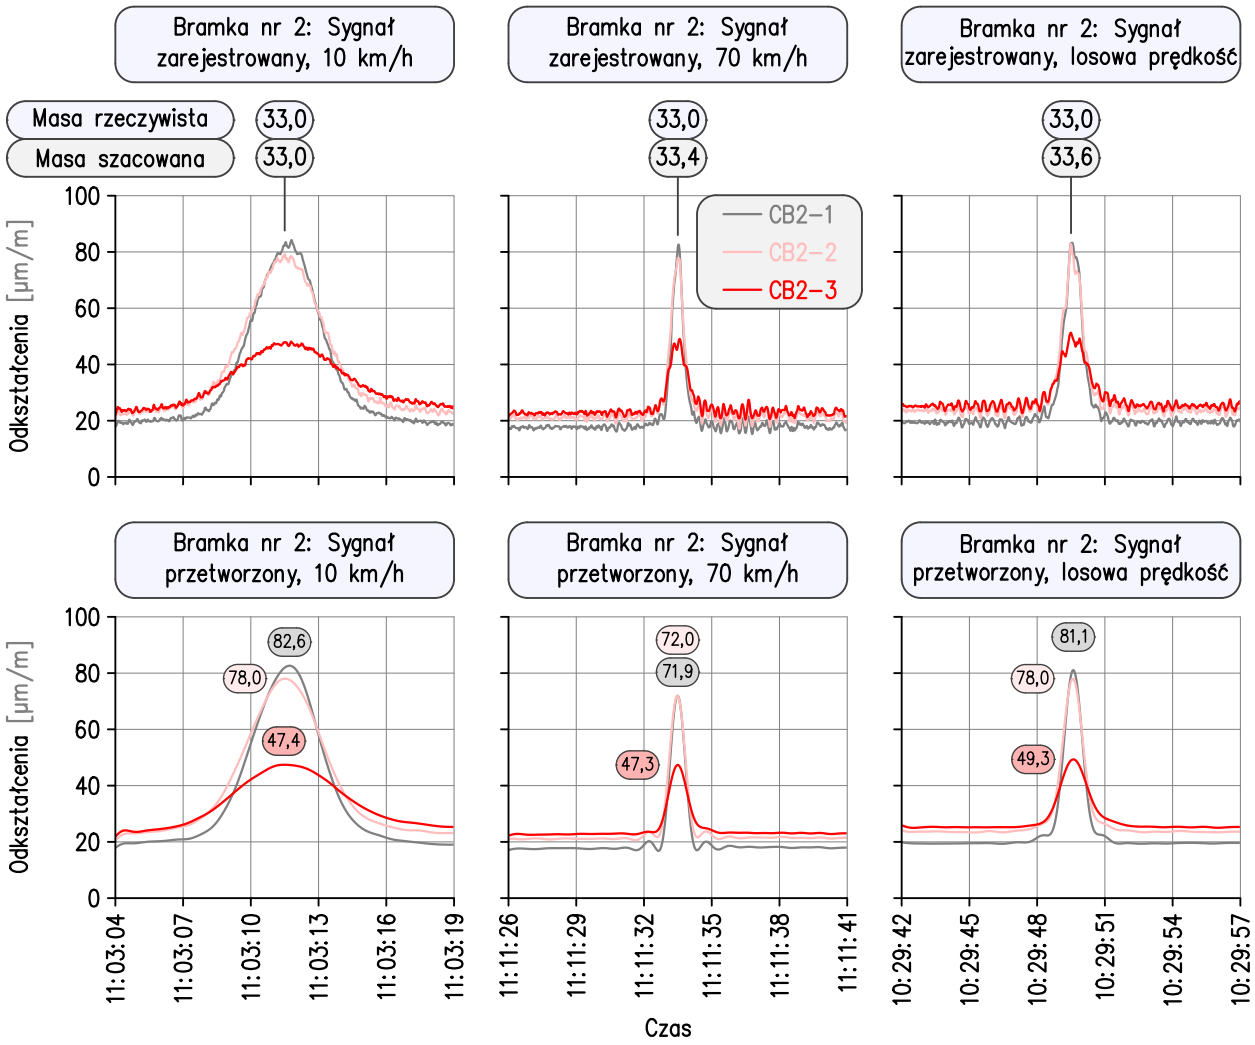

Rysunek 5.12. Szacowane masy pojazdu dla przejazdów lewym pasem ruchu z różnymi prędkościami

Następnie w celu analizy wpływu dodatkowych efektów dynamicznych zrealizowane zostały przejazdy z prędkością 30 km/h przez sztuczną przeszkodę w postaci progu. Ponieważ został on umieszczony w $1/4$ rozpiętości przęsła, na Rysunku 5.13 przedstawiono zmiany odkształceń zarejestrowane w pierwszej bramce pomiarowej. Obejmują one przejazd prawym pasem ruchu pojazdem o masie całkowitej 32,7 t, uwzględniając dodatkowe wymuszenie dynamiczne oraz różne prędkości przejazdu w tym 30 km/h oraz 50 km/h, a także prędkość losową, nienarzuconą przed rozpoczęciem badań.

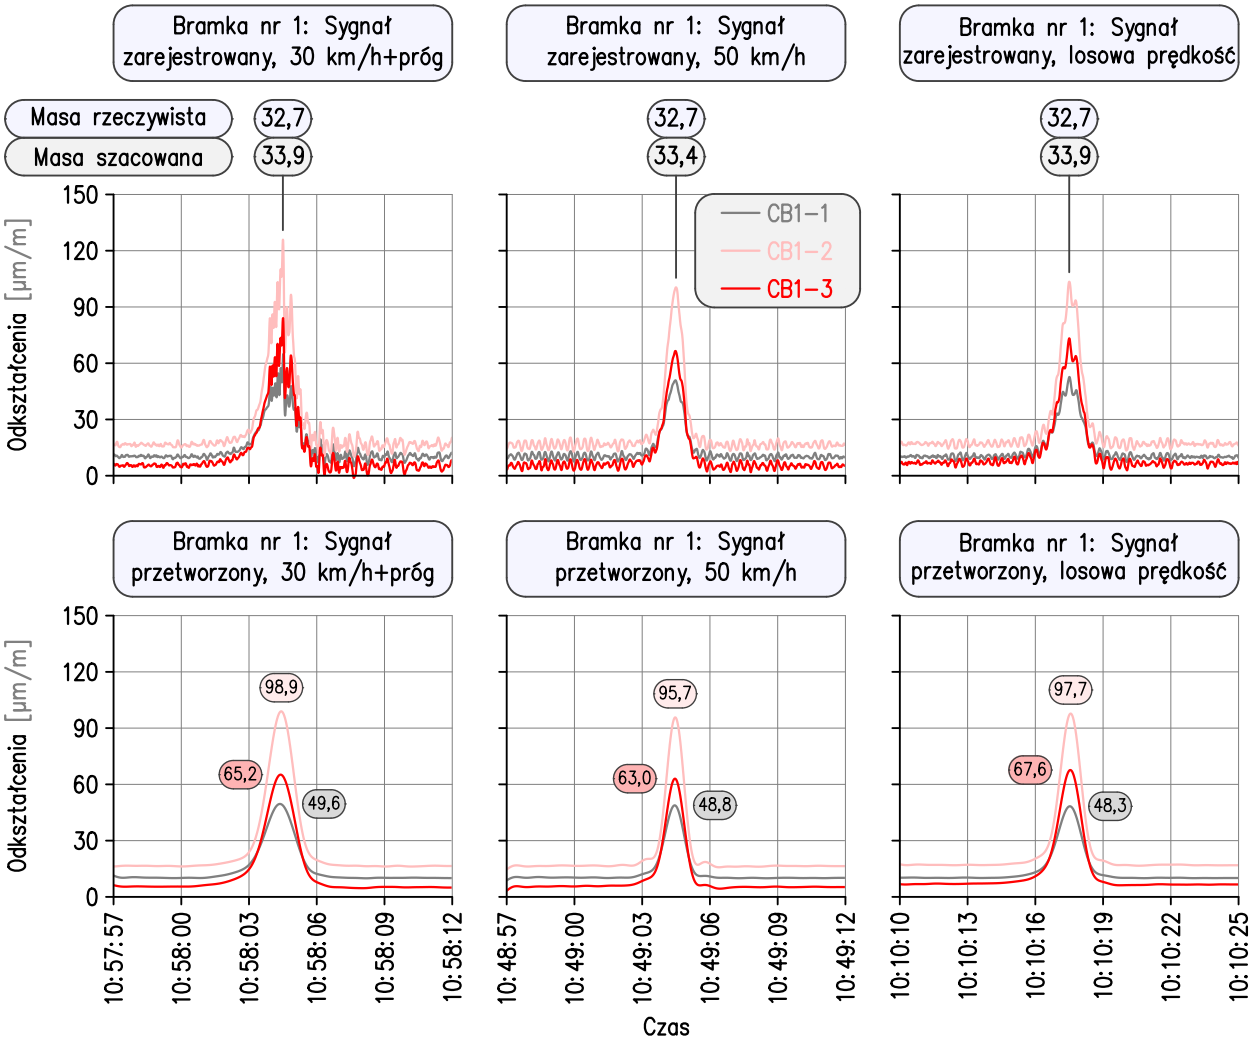

Rysunek 5.13. Szacowane masy pojazdu dla przejazdów prawym pasem ruchu z różnymi prędkościami oraz dodatkowym wymuszeniem dynamicznym

Analiza wyników uzyskanych dla przejazdu przez próg potwierdza skuteczność zastosowanej metody przetwarzania sygnału. W trakcie tej próby występowały dodatkowe wzbudzenia dynamiczne, powodujące lokalny wzrost wartości odkształceń. Po zastosowaniu filtracji wpływ ten został jednak w znacznym stopniu zniwelowany, a uzyskane wartości odkształceń pozostały zbliżone do obserwowanych dla pozostałych przejazdów. Wskazuje to na skuteczne ograniczenie składowych związanych z oddziaływaniami dynamicznymi przy jednoczesnym zachowaniu informacji istotnych z punktu widzenia procesu

identyfikacji mas pojazdów. Potwierdza to także odporność opracowanego rozwiązania na lokalne zakłócenia występujące podczas przejazdu. Szczegółowe wyniki zostały zamieszczone w Tabeli 5.7.

Tabela 5.7. Szacowane masy oraz metryki jakości predykcji w zależności od prędkości oraz przy dodatkowym wzbudzeniu dynamicznym

Szacowane masy oraz metryki jakości predykcji w zależności od prędkości oraz przy dodatkowym wzbudzeniu dynamicznym

Prędkość	Pas	Szacowane masy pojazdów				Metryki jakości predykcji				
		Br. 1	Br. 2	Br. 3	Śr.	ACC	MPE	MAPE	ME	MAE
[km/h]		[t]	[t]	[t]	[t]	[-]	[%]	[%]	[t]	[t]
Przypadek 1.1: Pojazd czteroosiowy [**33,0 t**], poruszający się prawym pasem ruchu										
10	Prawy	33,7	33,4	35,1	34,1	1,03	–3,11	3,11	1,0	1,0
70	Prawy	30,1	31,0	30,7	30,6	0,93	7,39	7,39	–2,4	2,4
	Prawy	**34,4**	**34,2**	**33,7**	**34,1**	**1,03**	**-3,10**	**3,10**	**1,0**	**1,0**
Przypadek 1.2: Pojazd czteroosiowy [**33,0 t**], poruszający się lewym pasem ruchu										
10	Lewy	31,9	34,1	33,0	33,0	1,00	0,12	0,12	0,0	0,0
70	Lewy	35,6	33,6	30,9	33,4	1,01	–0,99	0,99	0,3	0,3
	Lewy	**36,2**	**31,9**	**32,8**	**33,6**	**1,02**	**-1,70**	**1,70**	**0,6**	**0,6**
Przypadek 2.1: Pojazd czteroosiowy [**32,2 t**], poruszający się prawym pasem ruchu										
30	Prawy	33,0	33,1	32,8	33,0	1,03	–2,51	2,51	0,8	0,8
90	Prawy	28,5	29,4	30,3	29,4	0,91	8,58	8,58	–2,8	2,8
	Prawy	**33,2**	**33,1**	**32,4**	**32,9**	**1,02**	**-2,34**	**2,34**	**0,8**	**0,8**
Przypadek 2.2: Pojazd czteroosiowy [**32,2 t**], poruszający się lewym pasem ruchu										
30	Lewy	33,0	32,9	31,8	32,6	1,01	–1,27	1,27	0,4	0,4
90	Lewy	34,0	31,0	31,5	32,2	1,00	–0,02	0,02	0,0	0,0
	Lewy	**34,0**	**32,1**	**32,7**	**32,9**	**1,02**	**-2,39**	**2,39**	**0,8**	**0,8**
Przypadek 3.1: Pojazd czteroosiowy [**32,7 t**], poruszający się prawym pasem ruchu										
30+próg	Prawy	34,3	33,8	33,7	33,9	1,04	–3,71	3,71	1,2	1,2
50	Prawy	33,3	33,0	33,9	33,4	1,02	–2,08	2,08	0,7	0,7
	Prawy	**34,4**	**33,8**	**33,4**	**33,9**	**1,04**	**-3,52**	**3,520**	**1,2**	**1,2**
Przypadek 3.2: Pojazd czteroosiowy [**32,7 t**], poruszający się lewym pasem ruchu										
30+próg	Lewy	34,2	34,1	33,0	33,8	1,03	–3,20	3,20	1,0	1,0
50	Lewy	32,4	31,5	31,7	31,9	0,97	2,61	2,61	–0,9	0,9
	Lewy	**34,3**	**34,1**	**32,5**	**33,6**	**1,03**	**-2,81**	**2,81**	**0,9**	**0,9**
				Średnia:		1,01	–0,78	2,86	0,3	0,9
				Odchylenie standardowe:		0,04	3,56	2,15	1,2	0,7

Łącznie zrealizowanych zostało dwanaście dodatkowych przejazdów, po cztery dla każdego z trzech wykorzystanych pojazdów. Wyróżniono przy tym przejazdy referencyjne, dla których prędkość nie była narzucona przed rozpoczęciem badań. Dla wszystkich przypadków uzyskano zbliżone wartości metryk jakości predykcji, niezależnie od prędkości oraz występowania dodatkowego wzbudzenia dynamicznego. Średnia wartość błędu MPE wyniosła –0,79 %, natomiast błędu MAPE 2,87 %. Z kolei błąd ME osiągnął wartość 0,3 t, a średni błąd bezwzględny MAE 0,9 t. Nie zaobserwowano jednoznacznej zależności pomiędzy prędkością przejazdu lub dodatkowym wzbudzeniem dynamicznym, a jakością predykcji masy całkowitej pojazdów. Potwierdza to skuteczność zastosowanej metody przetwarzania sygnału oraz ograniczony wpływ oddziaływań dynamicznych. Uzyskane wyniki stanowią również potwierdzenie poprawności przeprowadzonej identyfikacji modelu numerycznego, w której uwzględniono wyłącznie obciążenia statyczne. Oznacza to, że przyjęte założenia były uzasadnione, a pominięcie badań dynamicznych na etapie identyfikacji modelu MES nie prowadziło do pogorszenia jakości uzyskiwanych predykcji.

5.6.5 Podsumowanie wyników

Otrzymane rezultaty potwierdzają skuteczność wykorzystania opracowanego rozwiązania do identyfikacji masy całkowitej pojazdów w rzeczywistych warunkach eksploatacyjnych. W szczególności potwierdzona została zdolność systemu do poprawnej identyfikacji masy pojazdów poruszających się po obu pasach ruchu, w różnych konfiguracjach wzajemnego położenia oraz przy zróżnicowanych odstępach czasowych. Analizowane przypadki obejmowały zarówno przejazdy pojedyncze, grupowe oraz losowe, jak również scenariusze uwzględniające różne prędkości i dodatkowe wzbudzenia dynamiczne. Pomimo znacznego zróżnicowania warunków ruchu, we wszystkich analizowanych wariantach uzyskano poprawną predykcję masy pojazdów, nie obserwując istotnego wpływu prędkości przejazdu oraz dodatkowych oddziaływań dynamicznych na jakość uzyskiwanych wyników.

Analizowane przypadki losowe stanowiły ponadto scenariusze opracowane specjalnie na potrzeby oceny wdrożonego rozwiązania. Podczas ponad rocznej eksploatacji systemu nie zaobserwowano sytuacji obejmujących jednoczesną obecność większej liczby pojazdów w obszarze oddziaływania pojedynczej bramki pomiarowej. Oznacza to, że rzeczywiste warunki są zazwyczaj mniej wymagające niż przedstawione przypadki testowe i w większości ograniczają się do identyfikacji pojedynczego pojazdu.

Istotnym elementem uzyskiwanych wyników było również wykorzystanie trzech niezależnych bramek pomiarowych. Dzięki temu wyznaczono odrębne oszacowania masy całkowitej pojazdu, określając wartość końcową jako średnią wszystkich trzech pomiarów. Zwiększona została zatem odporność systemu na ewentualne zakłócenia lokalne oraz wpływ czynników zewnętrznych czy błędów predykcji.

5.7 Podsumowanie

Przedstawiony proces ważenia pojazdów w ruchu stanowił końcowy element wdrożonej koncepcji cyfrowego bliźniaka. Jego kluczowym komponentem był zidentyfikowany model MES, na podstawie którego wygenerowano syntetyczny zbiór danych treningowych. Obejmował on szeroki zakres scenariuszy obciążeń, uwzględniając różne rodzaje pojazdów, ich masy oraz położenie na obiekcie. Podejście to pozwoliło na przygotowanie reprezentatywnego zbioru danych bez konieczności realizowania rozbudowanych oraz kosztownych badań eksperymentalnych.

Opracowane rozwiązanie obejmowało dwa podstawowe obszary. Pierwszy z nich związany był z przetwarzaniem danych rejestrowanych przez system monitoringu SHM, natomiast drugi obejmował proces uczenia oraz wykorzystania modeli sieci neuronowych. Zarejestrowane odkształcenia poddawano w pierwszej kolejności filtracji z wykorzystaniem filtru Butterwortha, ograniczając wpływ zakłóceń oraz ewentualnych składowych dynamicznych niezwiązanych bezpośrednio z identyfikowanym obciążeniem. Następnie z wykorzystaniem średniej kroczącej wyznaczano wartości odkształceń odpowiadające stanowi obciążonemu i nieobciążonemu. Ich różnica opisywała efekt wywoływany przejazdem i stanowiła dane wejściowe modeli predykcyjnych. Dla każdej bramki szacowano masę niezależnie, a wynik końcowy wyznaczano poprzez uśrednienie predykcji uzyskanych we wszystkich trzech przekrojach.

Przeprowadzona walidacja wykazała wysoką skuteczność wdrożonego rozwiązania. Analizom poddano zarówno przejazdy pojedynczych pojazdów, jak również bardziej złożone scenariusze ruchu, obejmujące jednoczesną obecność na moście wielu obciążeń. Szczególną uwagę poświęcono przy tym scenariuszom losowym, w którym pojazdy mogły poruszać się w dowolnej kombinacji, uwzględniając różne odległości między nimi, położenie i kolejność przejazdów. Badania te miały za zadanie symulować możliwie jak najbardziej złożony scenariusz ruchu, obejmujący jednoczesne oddziaływanie wielu pojazdów oraz dużą zmienność parametrów. Wdrożony algorytm wykazał przy tym dobrą jakość predykcji, osiągając średni błąd MAPE oszacowania masy na poziomie około 7 – 8 %. Dodatkowe badania potwierdziły ponadto brak istotnej zależności pomiędzy prędkością przejazdu oraz dodatkowymi wzbudzeniami dynamicznymi, a jakością predykcji masy całkowitej pojazdów. Uzyskane wyniki wykazały, że opracowany algorytm zachowuje wysoką skuteczność również w warunkach odbiegających od założeń quasi-kontrolowanych, które są charakterystyczne dla większości badań przedstawianych w literaturze.

Wdrożone rozwiązanie potwierdza, że integracja danych pomiarowych, zidentyfikowanego modelu numerycznego oraz metod uczenia maszynowego pozwoliła na skuteczną identyfikację obciążeń eksploatacyjnych. Opracowany algorytm dostarcza zatem informacji o rzeczywistych obciążeniach działających na konstrukcję i daje możliwość przeprowadzania dalszych analiz.

6 | Podsumowanie

W niniejszej rozprawie przedstawiony został schemat procesu budowy cyfrowego bliźniaka obiektu mostowego, bazującego na warstwie informacyjnej i sprzężeniu rzeczywistej konstrukcji z jej wirtualnym odpowiednikiem. Opracowana metodyka została zwalidowana na przykładzie mostu łukowego o znacznej rozpiętości, integrując w jednym systemie dane pomiarowe, model numeryczny MES oraz algorytmy uczenia maszynowego. Głównym osiągnięciem pracy jest opracowanie i wdrożenie systemu ważenia pojazdów w ruchu, który pozwala na identyfikację rzeczywistych obciążeń eksploatacyjnych i może być wykorzystany w toku dalszych prac i analiz. Przeprowadzone badania umożliwiły realizację wszystkich założonych celów oraz weryfikację sformułowanej tezy.

Zastosowanie zwalidowanej metodyki budowy cyfrowego bliźniaka integrującej dane pomiarowe, modele numeryczne i algorytmy uczenia maszynowego umożliwia identyfikację rzeczywistych obciążeń eksploatacyjnych na podstawie danych rejestrowanych przez system monitoringu

Opisany w pracy schemat (Rysunek 6.1) podzielić można na trzy zasadnicze grupy obejmujące część rzeczywistą, wirtualną oraz analityczną wdrożonego modelu. Przeprowadzone prace nie są zatem odrębnymi elementami, ale ich połączenie i zintegrowanie tworzy finalne odwzorowanie, określane mianem cyfrowego bliźniaka. Przedstawiona idea polega na powiązaniu modelu rzeczywistego i wirtualnego w taki sposób, aby oba odwzorowania wpływały na siebie nawzajem. Proces tworzenia cyfrowego bliźniaka rozpoczęto już na etapie budowy obiektu, wykorzystując dokumentację projektową do stworzenia modelu numerycznego MES. Wykorzystano go do przeprowadzenia wstępnych analiz, na podstawie których określono poziom wrażliwości poszczególnych elementów konstrukcyjnych oraz odpowiadające im linie wpływu odkształceń. Uzyskane wyniki pozwoliły na dobranie takiej lokalizacji punktów pomiarowych, która zapewniła możliwie największą ilość informacji, przy jednoczesnym ograniczeniu liczby czujników. Potwierdzono tym samym, że wykorzystanie cech charakterystycznych konstrukcji stanowi jeden z fundamentów projektowania systemów SHM oraz modeli cyfrowych bliźniaków.

Stworzony pierwotnie model MES stanowił początkowe odwzorowanie konstrukcji, jednak ze względu na przyjęte uproszczenia oraz niepewności nie odzwierciedlał w pełni rzeczywistej pracy obiektu. Z tego względu niezbędne było pozyskanie danych eksperymentalnych, umożliwiających jego późniejszą identyfikację. Posłużyły do tego badania pod próbnym obciążeniem, podczas których analizowane

były różne schematy obciążeń oraz scenariusze ruchu. Fizyczny obiekt mostowy oraz przeprowadzone badania eksperymentalne stanowiły część rzeczywistą opisanej koncepcji cyfrowego bliźniaka.

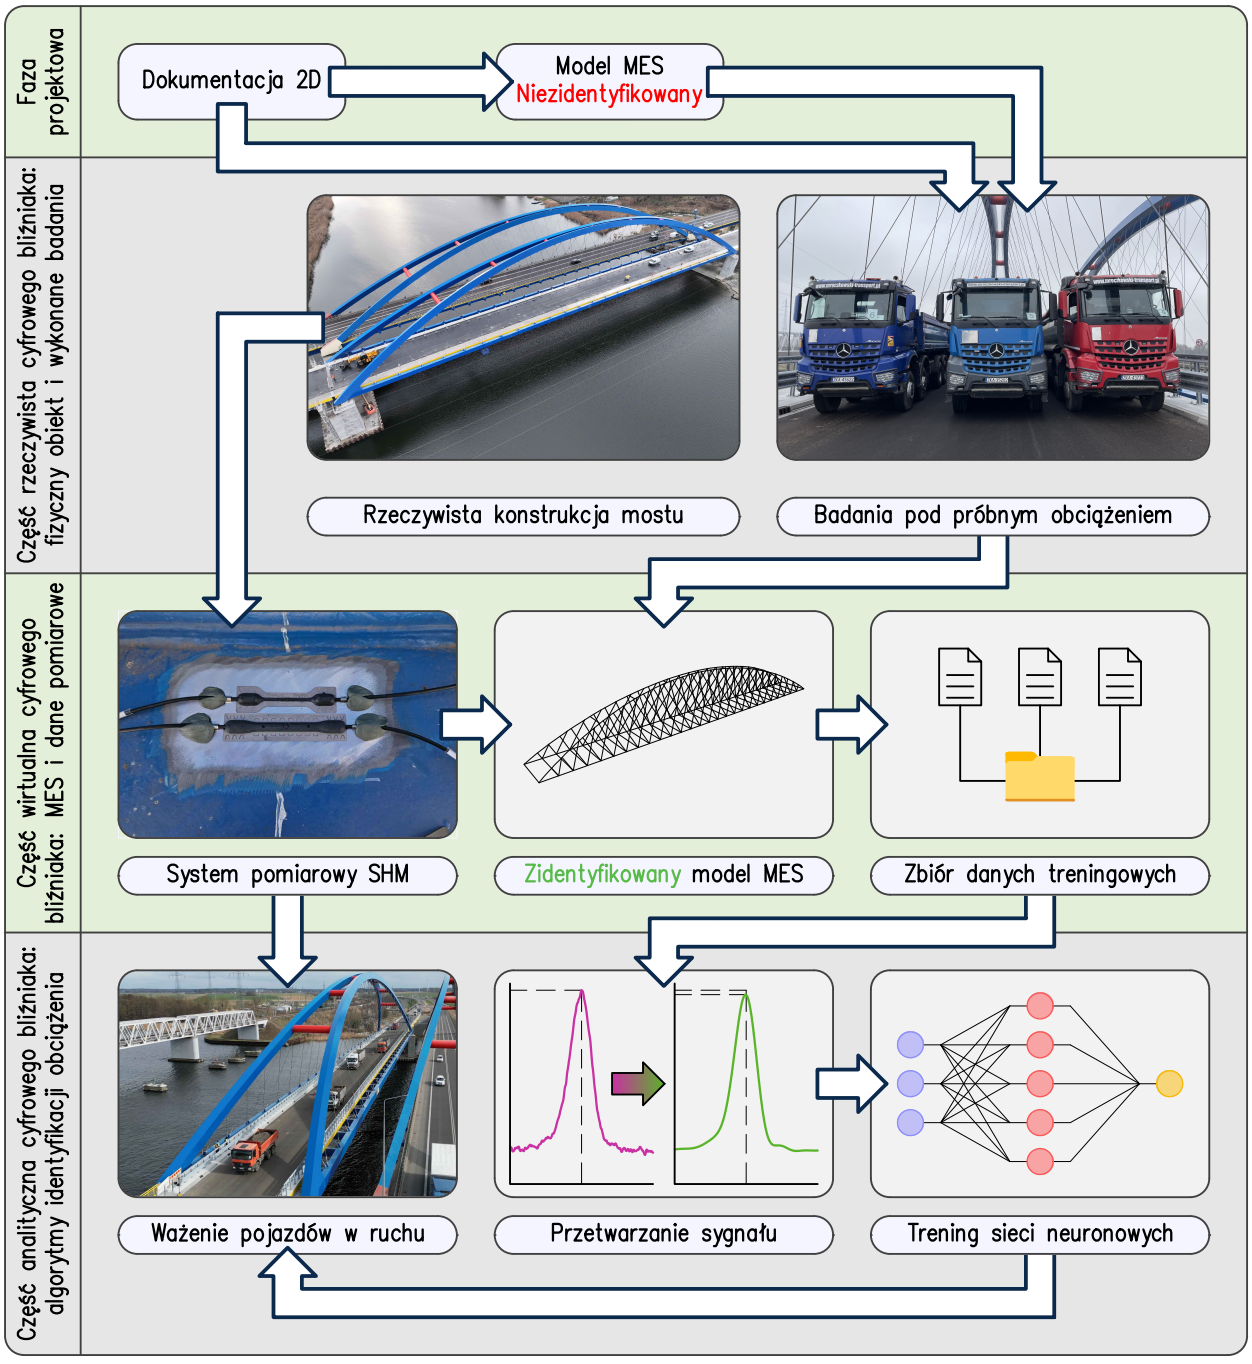

Rysunek 6.1. Schemat wdrożonej koncepcji cyfrowego bliźniaka

Pierwszym etapem wirtualnej części były natomiast dane pozyskane z zainstalowanego systemu SHM, który umożliwił ciągłą rejestrację odpowiedzi konstrukcji. Porównanie danych pomiarowych z wartościami symulowanymi pozwoliło na korektę podstawowych cech materiałowych w modelu MES. Przyjęto zatem parametr zastępczy modułu sprężystości, zapewniający zgodność rejestrowanych odkształceń z wartościami wyznaczonymi numerycznie.

Zidentyfikowany model MES stanowił następnie podstawę do wygenerowania syntetycznego zbioru danych treningowych. Obejmował on szeroki zakres scenariuszy obciążeń, uwzględniając różne typy pojazdów, masy i położenie na obiekcie. Dzięki temu możliwe było wykorzystanie danych w części analitycznej cyfrowego bliźniaka bez konieczności przeprowadzania bardziej złożonych badań doświadczalnych. Pierwszym etapem tej części koncepcji był algorytm filtrujący, który pozwolił na ograniczenie wpływu potencjalnych zaburzeń i efektów dynamicznych. Następnie wykorzystując podejście optymalizacyjne dobrano architekturę sieci neuronowych, wykorzystywanych do predykcji masy całkowitej pojazdów. Przeprowadzone analizy wykazały, że dane wygenerowane przy wykorzystaniu zidentyfikowanego modelu MES mogą stanowić skuteczną podstawę treningu modeli regresyjnych. Opracowane rozwiązanie zostało zwalidowane dla możliwie szerokiego scenariusza obciążeń, symulując tym samym złożone warunki ruchu drogowego.

Przeprowadzone badania potwierdziły możliwość wykorzystania danych pomiarowych, modeli numerycznych oraz metod uczenia maszynowego w ramach jednej warstwy informacyjnej cyfrowego bliźniaka. Opracowana metodyka umożliwia nie tylko odwzorowanie rzeczywistego zachowania konstrukcji, ale również interpretację rejestrowanej odpowiedzi w kontekście oddziaływań eksploatacyjnych. Tym samym potwierdzono sformułowaną w pracy tezę badawczą oraz wykazano możliwość wykorzystania cyfrowego bliźniaka do identyfikacji rzeczywistych obciążeń działających na obiekt mostowy.

Przedstawione wyniki otwierają jednocześnie kierunki dalszych badań. W szczególności zasadne wydaje się rozszerzenie warstwy informacyjnej cyfrowego bliźniaka o modele samouczące się, umożliwiające bieżącą aktualizację parametrów modelu MES na podstawie długoterminowych danych pomiarowych. Takie podejście może stanowić kolejny krok w kierunku autonomicznych cyfrowych bliźniaków zdolnych do samodzielnej interpretacji stanu konstrukcji. Naturalnym kierunkiem rozwoju przedstawionej koncepcji jest również połączenie opracowanej warstwy informacyjnej z modelem BIM oraz środowiskiem wizualizacyjnym. W takim ujęciu cyfrowy bliźniak mógłby pełnić nie tylko funkcję analityczną, ale również zapewnić lepszą integrację modelu z użytkownikiem.

Bibliografia

Artykuły naukowe

[1] Ahmad H. i Matsumoto Y. "Model updating of a single span prestressed concrete bridge using surrogate model and Particle Swam Optimization" (2025), s. 761–767. DOI: 10.2749/tokyo.2025.0761.

[2] Aktan E., Bartoli I., Glišić B. i Rainieri C. "Lessons from Bridge Structural Health Monitoring (SHM) and Their Implications for the Development of Cyber-Physical Systems". *Infrastructures* 9(2), 30 (2024). DOI: 10.3390/infrastructures9020030.

[3] Alamandala S., Sai Prasad R., Pancharathi R. K., Pavan V. i Kishore P. "Study on bridge weigh in motion (BWIM) system for measuring the vehicle parameters based on strain measurement using FBG sensors". *Optical Fiber Technology* 61, 102440 (2021). DOI: 10.1016/j.yofte.2020.102440.

[4] Al-Ali A., Beheiry S., Alnabulsi A., Obaid S., Mansoor N., Odeh N. i Mostafa A. "An IoT-Based Road Bridge Health Monitoring and Warning System". *Sensors* 24(2), 469 (2024). DOI: 10.3390/s24020469.

[5] Aloisio A., Pasca D. P., Battista L. D., Rosso M. M., Cucuzza R., Marano G. C. i Alaggio R. "Indirect assessment of concrete resistance from FE model updating and Young's modulus estimation of a multi-span PSC viaduct: Experimental tests and validation". *Structures* 37 (2022), s. 686–697. DOI: 10.1016/j.istruc.2022.01.045.

[6] An X., Meng X., Hu L., Xie Y., Zhang F. i Pan S. "GNSS integrated displacement and attitude determination for structural health monitoring of long-span bridges". *Satellite Navigation* 6, 19 (2025). DOI: 10.1186/s43020-025-00174-9.

[7] Anastasopoulos D., Reynders E. P., François S., Roeck G. D., Lysebetten G. V., Itterbeeck P. V. i Huybrechts N. "Vibration-based monitoring of an FRP footbridge with embedded fiber-Bragg gratings: Influence of temperature vs. damage". *Composite Structures* 287, 115295 (2022). DOI: 10.1016/j.compstruct.2022.115295.

[8] Ao W. K., Pavic A. i Brownjohn J. "Experimental-numerical Framework for Intelligent Finite Element Model Updating of a Full-scale Laboratory Footbridge Structure". *Journal of Vibration Engineering & Technologies* 14, 147 (2026). DOI: 10.1007/s42417-026-02402-1.

[9] Armijo A. i Zamora-Sánchez D. "Integration of Railway Bridge Structural Health Monitoring into the Internet of Things with a Digital Twin: A Case Study". *Sensors* 24(7), 2115 (2024). DOI: 10.3390/s24072115.

[10] Astroza R., Barrientos N., Li Y. i Flores E. S. "Calibration of a Large Nonlinear Finite Element Model of a Highway Bridge with Many Uncertain Parameters". *37th IMAC, A Conference and Exposition on Structural Dynamics*. (2019), s. 177–187. DOI: 10.1007/978-3-030-12075-7_20.

[11] Astroza R., Ebrahimian H. i Conte J. P. "Performance comparison of Kalman-based filters for nonlinear structural finite element model updating". *Journal of Sound and Vibration* 438 (2019), s. 520–542. DOI: 10.1016/j.jsv.2018.09.023.

[12] Avci O., Alkhamis K., Abdeljaber O., Alsharo A. i Hussein M. "Operational modal analysis and finite element model updating of a 230 m tall tower". *Structures* 37 (2022), s. 154–167. DOI: 10.1016/j.istruc.2021.12.078.

[13] Baisthakur S. i Chakraborty A. "Modified Hamiltonian Monte Carlo-based Bayesian finite element model updating of steel truss bridge". *Structural Control and Health Monitoring* 27(8), e2556 (2020). DOI: 10.1002/stc.2556.

[14] Barros B., Conde B., Cabaleiro M. i Riveiro B. "Deterministic and probabilistic-based model updating of aging steel bridges". *Structures* 54 (2023), s. 89–105. DOI: 10.1016/j.istruc.2023.05.020.

[15] Bartilson D. T., Jang J. i Smyth A. W. "Finite element model updating using objective-consistent sensitivity-based parameter clustering and Bayesian regularization". *Mechanical Systems and Signal Processing* 114 (2019), s. 328–345. DOI: 10.1016/j.ymssp.2018.05.024.

[16] Bertulessi M., Bignami D. F., Boschini I., Brunero M., Ferrairo M., Menduni G., Morosi J., Paganone E. J. i Zambrini F. "Monitoring Strategic Hydraulic Infrastructures by Brillouin Distributed Fiber Optic Sensors". *Water* 14(2), 188 (2022). DOI: 10.3390/w14020188.

[17] Birgin H. B., D'Alessandro A., Favaro M., Sangiorgi C., Laflamme S. i Ubertini F. "Field investigation of novel self-sensing asphalt pavement for weigh-in-motion sensing". *Smart Materials and Structures* 31, 085004 (2022). DOI: 10.1088/1361-665X/ac7922.

[18] Brzozowski K., Maczyński A., Ryguła A. i Kanior T. "A weigh-in-motion system with automatic data reliability estimation". *Measurement* 221, 113494 (2023). DOI: 10.1016/j.measurement.2023.113494.

[19] Cai K., Huang M., Wang C., Yang C., Ni Y. Q. i Li B. "A Combined Approach to Estimate Modal Parameters for Updating the Finite Element Model of a High-Rise Building". *Structural Control and Health Monitoring* 2024(1), 3650202 (2024). DOI: 10.1155/stc/3650202.

[20] Cai Q. L., Chen Z. W., Zhu S. i Mo L. Y. "On damage detection of beam structures using multiple types of influence lines". *Structures* 42 (2022), s. 449–465. DOI: 10.1016/j.istruc.2022.06.022.

[21] Chen H. P., Lu S. S., Wu W. B., Dai L. i Ceravolo R. "Fatigue damage assessment of a large rail-cum-road steel truss-arch bridge using structural health monitoring dynamic data". *Case Studies in Construction Materials* 21, e03772 (2024). DOI: 10.1016/j.cscm.2024.e03772.

[22] Cheng L., Cigada A., Zappa E., Gilbert M. i Lang Z.-Q. "Dynamic monitoring of a masonry arch rail bridge using a distributed fiber optic sensing system". *Journal of Civil Structural Health Monitoring* 14 (2024), s. 1075–1090. DOI: 10.1007/s13349-024-00774-0.

[23] Cheng X. X., Fan J. H. i Xiao Z. H. "Finite element model updating for the Tsing Ma Bridge tower based on surrogate models". *Journal of Low Frequency Noise, Vibration and Active Control* 41(2) (2022), s. 500–518. DOI: 10.1177/14613484211058999.

[24] Cigada A., Moschioni G., Vanali M. i Caprioli A. "The measurement network of the San Siro Meazza Stadium in Milan: Origin and implementation of a new data acquisition strategy for structural health monitoring". *Experimental Techniques* 34 (2010), s. 70–81. DOI: 10.1111/j.1747-1567.2009.00536.x.

[25] Colombani I. A. i Andrawes B. "Comparison of load rating of reinforced concrete slab bridge using analytical and field testing approaches". *Innovative Infrastructure Solutions* 7, 79 (2022). DOI: 10.1007/s41062-021-00677-9.

[26] Conde J., Munoz-Arcentales A., Romero M., Rojo J., Salvachúa J., Huecas G. i Alonso Á. "Applying digital twins for the management of information in turnaround event operations in commercial airports". *Advanced Engineering Informatics* 54, 101723 (2022). DOI: 10.1016/j.aei.2022.101723.

[27] De Angelis A. i Pecce M. R. "Model assessment of a bridge by load and dynamic tests". *Engineering Structures* 275, 115282 (2023). DOI: 10.1016/j.engstruct.2022.115282.

[28] Deb K. "An efficient constraint handling method for genetic algorithms". *Computer Methods in Applied Mechanics and Engineering* 186(2-4) (2000), s. 311–338. DOI: 10.1016/S0045-7825(99)00389-8.

[29] Deb K. i Deb D. "Analysing mutation schemes for real-parameter genetic algorithms". *International Journal of Artificial Intelligence and Soft Computing* 4(1) (2014), s. 1–28. DOI: 10.1504/IJAISC.2014.059280.

[30] Deng Y., Ju H. i Zhong G. "Data quality evaluation for bridge structural health monitoring based on deep learning and frequency-domain information". *Structural Health Monitoring* 22(5) (2023), s. 2925–2947. DOI: 10.1177/14759217221138724.

[31] Desjardins S. L. i Lau D. T. "Enhanced operational modal analysis and change point detection for vibration-based structural health monitoring of bridges". *Journal of Infrastructure Intelligence and Resilience* 3(4), 100121 (2024). DOI: 10.1016/j.iintel.2024.100121.

[32] Di Re P., Vangelisti I. i Lofrano E. "Influence of the Objective Function in the Dynamic Model Updating of Girder Bridge Structures". *Buildings* 15, 341 (2025). DOI: 10.3390/buildings15030341.

[33] Dong C., Bas S., Debees M., Alver N. i Catbas F. N. "Bridge Load Testing for Identifying Live Load Distribution, Load Rating, Serviceability and Dynamic Response". *Frontiers in Built Environment* 6, 46 (2020). DOI: 10.3389/fbuil.2020.00046.

[34] Fang C., Liu H. J., Lam H. F., Adeagbo M. O. i Peng H. Y. "Practical model updating of the Ting Kau Bridge through the MCMC-based Bayesian algorithm utilizing measured modal parameters". *Engineering Structures* 254, 113839 (2022). DOI: 10.1016/j.engstruct.2022.113839.

[35] Fanian F., Rafsanjani M. K. i Shokouhifar M. "Combined fuzzy-metaheuristic framework for bridge health monitoring using UAV-enabled rechargeable wireless sensor networks". *Applied Soft Computing* 167, 112429 (2024). DOI: 10.1016/j.asoc.2024.112429.

[36] Farhat M., Yassin M. H., Nahas M. i Bilal A. "Fiber Bragg Grating Sensors vs Strain Gauges for Static Bridge Monitoring System" (2024), s. 1–6. DOI: 10.1109/I2MTC60896.2024.10560727.

[37] Ferguson A. J., Hester D., Huseynov F., Kim C. W., Brownjohn J., Woods R. i Bull L. A. "On the normalisation and mapping of influence lines". *Mechanical Systems and Signal Processing* 237, 112883 (2025). DOI: 10.1016/j.ymssp.2025.112883.

[38] Gajda J., Sroka R., Burnos P. i Daniol M. "Weigh-in-Motion Site for Type Approval of Vehicle Mass Enforcement Systems in Poland". *Sensors* 23(22), 9290 (2023). DOI: 10.3390/s23229290.

[39] Gao Y., Li H., Xiong G. i Song H. "AIoT-informed digital twin communication for bridge maintenance". *Automation in Construction* 150, 104835 (2023). DOI: 10.1016/j.autcon.2023.104835.

[40] Ghahremani B., Enshaeian A. i Rizzo P. "Bridge Health Monitoring Using Strain Data and High--Fidelity Finite Element Analysis". *Sensors* 22(14), 5172 (2022). DOI: 10.3390/s22145172.

[41] Ghannadi P., Khatir S., Kourehli S. S., Nguyen A., Boutchicha D. i Wahab M. A. "Finite element model updating and damage identification using semi-rigidly connected frame element and optimization procedure: An experimental validation". *Structures* 50 (2023), s. 1173–1190. DOI: 10.1016/j.istruc.2023.02.008.

[42] Giagopoulos D., Arailopoulos A., Dertimanis V., Papadimitriou C., Chatzi E. i Grompanopoulos K. "Structural health monitoring and fatigue damage estimation using vibration measurements and finite element model updating". *Structural Health Monitoring* 18(4) (2019), s. 1189–1206. DOI: 10.1177/1475921718790188.

[43] Goble G., Moses F. i Pavia A. "Applications of a bridge measurement system". *Transportation Research Record* 579 (1976), s. 36–47.

[44] Goossens S., Pauw B. D., Geernaert T., Salmanpour M. S., Khodaei Z. S., Karachalios E., Saenz-Castillo D., Thienpont H. i Berghmans F. "Aerospace-grade surface mounted optical fibre strain sensor for structural health monitoring on composite structures evaluated against in--flight conditions". *Smart Materials and Structures* 28, 065008 (2019). DOI: 10.1088/1361-665X/ab1458.

[45] Grishyn K. "Deep neural network architecture for box girder bridge weigh-inmotion system". *Industrial Artificial Intelligence* 4, 4 (2026). DOI: 10.1007/s44244-026-00030-y.

[46] Guan Z. X., Yang D. H., Yi T. H., Li W. J. i Li C. "Bridge finite element model updating using stochastic vehicle-induced static response monitoring data". *Engineering Structures* 301, 117280 (2024). DOI: 10.1016/j.engstruct.2023.117280.

[47] Haider S. W., Singh R. R. i Wang H. "Impact of Surface Roughness, Speed, and Sensor Configuration on Weigh-in-Motion (WIM) System Accuracy". *International Journal of Pavement Research and Technology* 19 (2026), s. 1348–1361. DOI: 10.1007/s42947-025-00521-8.

[48] Hajializadeh D., Žnidarič A., Kalin J. i OBrien E. J. "Development and Testing of a Railway Bridge Weigh-in-Motion System". *Applied Sciences* 10(14), 4708 (2020). DOI: 10.3390/app10144708.

[49] He H., Zeng B., Zhou Y., Song Y., Zhang T., Su H. i Wang J. "Bridge Model Updating Based on Wavelet Neural Network and Wind-Driven Optimization". *Sensors* 23(22), 9185 (2023). DOI: 10.3390/s23229185.

[50] He L., Castoro C., Aloisio A., Zhang Z., Marano G. C., Gregori A., Deng C. i Briseghella B. "Dynamic assessment, FE modelling and parametric updating of a butterfly-arch stress-ribbon pedestrian bridge". *Structure and Infrastructure Engineering* 18(7) (2022), s. 1064–1075. DOI: 10.1080/15732479.2021.1995444.

[51] He W., Liu J., Song S. i Liu P. "A non-contact vehicle weighing approach based on bridge weigh--in-motion framework and computer vision techniques". *Measurement* 225, 113994 (2024). DOI: 10.1016/j.measurement.2023.113994.

[52] Hekič D., Kalin J., Žnidarič A., Češarek P. i Anžlin A. "Model Updating of Bridges Using Measured Influence Lines". *Applied Sciences* 15(8), 4514 (2025). DOI: 10.3390/app15084514.

[53] Hoda M. A., Mazzanti A., Shojaii J., Azam Y. E. i Linzell D. G. "Unsupervised machine learning for bridge SHM using FPGA: Proof of concept via full-scale experiments". *Measurement* 256(4), 118717 (2025). DOI: 10.1016/j.measurement.2025.118717.

[54] Hou S. i Wu G. "A low-cost IoT-based wireless sensor system for bridge displacement monitoring". *Smart Materials and Structures* 28(8), 085047 (2019). DOI: 10.1088/1361-665X/ab2a31.

[55] Hu D., Guo Y., Chen X. i Zhang C. "Cable Force Health Monitoring of Tongwamen Bridge Based on Fiber Bragg Grating". *Applied Sciences* 7(4), 384 (2017). DOI: 10.3390/app7040384.

[56] Ietka I., Moutinho C., Pereira S. i Cunha Á. "Structural Monitoring of a Large-Span Arch Bridge Using Customized Sensors". *Sensors* 23(13), 5971 (2023). DOI: 10.3390/s23135971.

[57] Innocenzi R. D., Nicoletti V., Arezzo D., Carbonari S., Gara F. i Dezi L. "A Good Practice for the Proof Testing of Cable-Stayed Bridges". *Applied Sciences* 12(7), 3547 (2022). DOI: 10.3390/app12073547.

[58] Jasiński M., Łaziński P. i Piotrowski D. "The Concept of Creating Digital Twins of Bridges Using Load Tests". *Sensors* 23(17), 7349 (2023). DOI: 10.3390/s23177349.

[59] Jian X., Xia Y., Sun S. i Sun L. "Integrating bridge influence surface and computer vision for bridge weigh-in-motion in complicated traffic scenarios". *Structural Control and Health Monitoring* 29(11) (2022), e3066. DOI: 10.1002/stc.3066.

[60] Jiang F., Ding Y., Song Y., Geng F. i Wang Z. "Digital Twin-driven framework for fatigue life prediction of steel bridges using a probabilistic multiscale model: Application to segmental orthotropic steel deck specimen". *Engineering Structures* 241, 112461 (2021). DOI: 10.1016/j.engstruct.2021.112461.

[61] Jiang T., Zhang Y., Wang L., Zhang L. i Song G. "Monitoring Fatigue Damage of Modular Bridge Expansion Joints Using Piezoceramic Transducers". *Sensors* 18(11), 3973 (2018). DOI: 10.3390/s18113973.

[62] Jo H. J., Park D. Y., Kim K. W. i Ahn T. J. "Real-time monitoring of concrete curing using fiber Bragg grating sensors: Strain and temperature measurement". *Sensors and Actuators: A. Physical* 362, 114650 (2023). DOI: 10.1016/j.sna.2023.114650.

[63] Kaur N., Goyal S., Anand K. i Sahu G. K. "A cost-effective approach for assessment of pre-stressing force in bridges using piezoelectric transducers". *Measurement* 168, 108324 (2021). DOI: 10.1016/j.measurement.2020.108324.

[64] Kennedy J. i Eberhart R. "Particle Swarm Optimization". 4 (1995), 1942–1948 vol.4. DOI: 10.1109/ICNN.1995.488968.

[65] Kim G., Shin J., Won J. i Park J. "Cloud-Based Internet-of-Things System for Long-Term Bridge Bearing Monitoring Using Computer Vision". *Applied Sciences* 15(3), 1622 (2025). DOI: 10.3390/app15031622.

[66] Kim S., Kim N., Park Y. S. i Jin S. S. "A Sequential Framework for Improving Identifiability of FE Model Updating Using Static and Dynamic Data". *Sensors* 19(23), 5099 (2019). DOI: 10.3390/s19235099.

[67] Lee Y., Jeon G., Byun N. i Yoon H. "Finite Element Model Updating for Identifying Structural Stiffness in Bridge Structures via Computer Vision and Deep Learning". *IEEE Sensors Journal* 25(12) (2025), s. 22080–22089. DOI: 10.1109/JSEN.2025.3563927.

[68] Lee Y., Lee J. H., Byun N. i Yoon H. "Vision-based geometric finite element model updating for cable suspension bridges". *Advanced Engineering Informatics* 68, 103714 (2025). DOI: 10.1016/j.aei.2025.103714.

[69] Li D. i Zhang J. "Finite element model updating through derivative-free optimization algorithm". *Mechanical Systems and Signal Processing* 185, 109726 (2023). DOI: 10.1016/j.ymssp.2022.109726.

[70] Li H., Zhao H., Shen Y., Zheng S. i Zhang R. "Structural Health Monitoring and Failure Analysis of Large-Scale Hydro-Steel Structures, Based on Multi-Sensor Information Fusion". *Water* 16(22), 3167 (2024). DOI: 10.3390/w16223167.

[71] Li Q., Ni P., Du X., Han Q., Xu K. i Bai Y. "Bayesian finite element model updating with a variational autoencoder and polynomial chaos expansion". *Engineering Structures* 316, 118606 (2024). DOI: 10.1016/j.engstruct.2024.118606.

[72] Li Q., He Y., Zhou K., Han X., He Y. i Shu Z. "Structural health monitoring for a 600 m high skyscraper". *The Structural Design of Tall and Special Buildings* 27(12), e1490 (2018). DOI: 10.1002/tal.1490.

[73] Li Y., Luo X. i Li Y. "Experimental Analysis of Static and Dynamic Performance for Continuous Warren Truss Steel Railway Bridge in Heavy Haul Railway". *Modelling and Simulation in Engineering* 2024 (2024), s. 3767759. DOI: 10.1155/2024/3767759.

[74] Liao W., Sun H., Wang Y. i Qing X. "An island-bridge packaging piezoelectric sensor for structural health monitoring in high-strain environments". *Journal of Intelligent Material Systems and Structures* 34(8) (2023), s. 891–908. DOI: 10.1177/1045389X221128580.

[75] Lin K., Xu Y. L., Lu X., Guan Z. i Li J. "Collapse prognosis of a long-span cable-stayed bridge based on shake table test and nonlinear model updating". *Earthquake Engineering and Structural Dynamics* 50(2) (2021), s. 455–474. DOI: 10.1002/eqe.3341.

[76] Lin S. W., Du Y. L., Yi T. H. i Yang D. H. "Influence lines-based model updating of suspension bridges considering boundary conditions". *Advances in Structural Engineering* 26(2) (2023), s. 316–328. DOI: 10.1177/13694332221126374.

[77] Liu J., Wei Y. i Chen B. "A hierarchical semantic segmentation framework for computer vision--based bridge damage detection". *Smart Structures and Systems* 31(4) (2023), s. 325–334. DOI: 10.48550/arXiv.2207.08878.

[78] Lu R. i Judd J. "Field-Deployable Fiber Optic Sensor System for Structural Health Monitoring of Steel Girder Highway Bridges". *Infrastructures* 7(2), 16 (2022). DOI: 10.3390/infrastructures7020016.

[79] Luo L., Song M., Li Y. i Sun L. "A hierarchical Bayesian model updating method for bridge structures by fusing multi-source information". *Structural Health Monitoring* 24(2) (2025), s. 1292–1310. DOI: 10.1177/14759217241253361.

[80] Luo L., Xia Y., Wang A., Lei X., Jian X. i Sun L. "Finite element model updating method for continuous girder bridges using monitoring responses and traffic videos". *Structural Control and Health Monitoring* 29(11), e3062 (2022). DOI: 10.1002/stc.3062.

[81] Lv Y., Wu J., Li J., Wang W., Wang T., Yuan Y. i Wang J. "Finite Element Model Updating of Large--Span-Cable-Stayed Bridge Based on Response Surface". *Buildings* 15(13), 2247 (2025). DOI: 10.3390/buildings15132247.

[82] Łaziński P., Jasiński M., Uściłowski M., Piotrowski D. i Ortyl Ł. "GPR in Damage Identification of Concrete Elements—A Case Study of Diagnostics in a Prestressed Bridge". *Remote Sensing* 17(1), 35 (2025). DOI: 10.3390/rs17010035.

[83] Mahmood Y., Xu L., Wang X., Quenette K., Yang X., Yasir N., Huang Y., Stork J. D. i Murphy T. J. "Embedded GFRP-packaged sensor system for real-time and high-precision vehicle load estimation in weigh-in-motion (WIM) applications". *Measurement Science and Technology* 37(9), 096004 (2026). DOI: 10.1088/1361-6501/ae4ac7.

[84] Malekghaini N., Ghahari F., Ebrahimian H., Bowers M., Ahlberg E. i Taciroglu E. "A Two-Step FE Model Updating Approach for System and Damage Identification of Prestressed Bridge Girders". *Buildings* 13(2), 420 (2023). DOI: 10.3390/buildings13020420.

[85] Malveiro J., Ribeiro D., Sousa C. i Calçada R. "Model updating of a dynamic model of a composite steel-concrete railway viaduct based on experimental tests". *Engineering Structures* 164 (2018), s. 40–52. DOI: 10.1016/j.engstruct.2018.02.057.

[86] Maroli J. M. "Generating discrete dynamical system equations from input–output data using neural network identification models". *Reliability Engineering and System Safety* 235, 109198 (2023). DOI: 10.1016/j.ress.2023.109198.

[87] Martini A., Tronci E. M., Feng M. Q. i Leung R. Y. "A computer vision-based method for bridge model updating using displacement influence lines". *Engineering Structures* 259, 114129 (2022). DOI: 10.1016/j.engstruct.2022.114129.

[88] Masciotta M. G., Barontini A., Chaves E., Mendes N., Brando G. i Lourenço P. B. "Modal-Based Multi-Criteria Optimization of Sensor Placement Techniques for Dynamic Monitoring of Bridges". *International Journal of Bridge Engineering, Management and Research* 2(2) (2025), 214250017–1:214250017. DOI: 10.70465/ber.v2i2.26.

[89] Mazzotti M., Mao Q., Bartoli I. i Livadiotis S. "A multiplicative regularized Gauss-Newton method with trust region Sequential Quadratic Programming for structural model updating". *Mechanical Systems and Signal Processing* 131 (2019), s. 417–433. DOI: 10.1016/j.ymssp.2019.05.062.

[90] Minardo A., Catalano E., Coscetta A., Zeni G., Maio C. D., Vassallo R., Picarelli L., Coviello R., Macchia G. i Zeni L. "Long-Term Monitoring of a Tunnel in a Landslide Prone Area by Brillouin--Based Distributed Optical Fiber Sensors". *Sensors* 21(21), 7032 (2021). DOI: 10.3390/s21217032.

[91] Moghadam A. "A novel speed-adaptive framework for structural load evaluation using nothing--on-road bridge weigh-in-motion". *Structures* 82, 110714 (2025). DOI: 10.1016/j.istruc.2025.110714.

[92] Moghadam A., AlHamaydeh M. i Sarlo R. "Dual-purpose procedure for bridge health monitoring and weigh-in-motion used for multiple-vehicle events". *Automation in Construction* 148, 104768 (2023). DOI: 10.1016/j.autcon.2023.104768.

[93] Moses F. "Weigh-in-Motion System Using Instrumented Bridges". *Transportation Engineering Journal of ASCE* 105(3) (1979). DOI: 10.1061/TPEJAN.0000783.

[94] Nguyen-Ngoc L., Nguyen-Huu Q., De Roeck G., Bui-Tien T. i Abdel-Wahab M. "Deep Neural Network and Evolved Optimization Algorithm for Damage Assessment in a Truss Bridge". *Mathematics* 12(15), 2300 (2024). DOI: 10.3390/math12152300.

[95] Ni Y., Ma Y., Lin H., Zhang H. i Zhuo Y. "Finite element model updating of existing bridge structures based on measured data and deep learning method". *Structures* 79, 109403 (2025). DOI: 10.1016/j.istruc.2025.109403.

[96] Oskoui E. A., Taylor T. i Ansari F. "Method and sensor for monitoring weight of trucks in motion based on bridge girder end rotations". *Structure and Infrastructure Engineering* 16(3) (2020), s. 481–494. DOI: 10.1080/15732479.2019.1668436.

[97] Pan H., Azimi M., Yan F. i Lin Z. "Time-Frequency-Based Data-Driven Structural Diagnosis and Damage Detection for Cable-Stayed Bridges". *Journal of Bridge Engineering* 23(6) (2018), s. 04018033. DOI: 10.1061/(ASCE)BE.1943-5592.0001199.

[98] Pan Q., Bao Y. i Li H. "Transfer learning-based data anomaly detection for structural health monitoring". *Structural Health Monitoring* 22(5) (2023), s. 3077–3091. DOI: 10.1177/14759217221142174.

[99] Park S., Chang M. i Yazdanpanah O. "A condition monitoring of steel box girder bridges based on consecutive system identification and model updating using a long-term monitoring database". *Structures* 80, 109779 (2025). DOI: 10.1016/j.istruc.2025.109779.

[100] Pashaie R., Shokrieh M. M., Vahedi M., Mirzaei A. H. i Akbari S. "A comparative study of residual stress measurement of laminated composites using FBG sensor, DIC technique, and strain gauge". *Optical and Quantium Electronics* 56, 1790 (2024). DOI: 10.1007/s11082-024-07676-x.

[101] Peng Z., Yu J., Meng X., Xie Y. i Xie Y. "Dynamic parameters identification of long-span suspension bridges using enhanced VMD-SVD techniques with GNSS data". *Measurement* 254, 117914 (2025). DOI: 10.1016/j.measurement.2025.117914.

[102] Piotrowski D., Jasiński M., Nowoświat A., Łaziński P., Chen Q., Yang T. i Pradelok S. "Measurement-informed calibration of FEM models for strain-based structural assessment using multi-sensor data". *Measurement* 280, 121856 (2026). DOI: 10.1016/j.measurement.2026.121856.

[103] Piotrowski D., Jasiński M., Nowoświat A., Łaziński P. i Pradelok S. "The Performance of an ML--Based Weigh-in-Motion System in the Context of a Network Arch Bridge Structural Specificity". *Sensors* 25(15), 4547 (2025). DOI: 10.3390/s25154547.

[104] Pirrò M. i Gentile C. "Detection and localization of anomalies in bridges using accelerometer data and sparse auto-encoders". *Developments in the Built Environment* 23, 100715 (2025). DOI: 10.1016/j.dibe.2025.100715.

[105] Prakash P., Dhakal A., Bruel P., Chalamalasetti S. R., Hogade N., Rattihalli G., Enriquez R. P. H., Bash C. i Milojicic D. "TwinVAR: Digital and Physical Twin Visualization with Virtual and Augmented Reality" (2024), s. 1–4. DOI: 10.1109/ISEMV63338.2024.00024.

[106] Qin S., Huang J., Li S., Zhou Y. i Wahab M. A. "Novel two-stage adaptive weight coefficients for Finite Element Model Updating of a cable stayed bridge via sensitivity analysis and Kriging model". *Mechanical Systems and Signal Processing* 231, 112674 (2025). DOI: 10.1016/j.ymssp.2025.112674.

[107] Qin S., Song R. i Li N. "Bayesian model updating for bridge engineering applications based on DREAMKZS algorithm and Kriging model". *Structures* 58, 105565 (2023). DOI: 10.1016/j.istruc.2023.105565.

[108] Qin S., Yuan Y., Han S. i Li S. "A Novel Multiobjective Function for Finite-Element Model Updating of a Long-Span Cable-Stayed Bridge Using In Situ Static and Dynamic Measurements". *Journal of Bridge Engineering* 28(1) (2023), s. 04022131. DOI: 10.1061/(ASCE)BE.1943-5592.0001974.

[109] Qu X., Ding X. i Xu Y. L. "Simultaneous monitoring of displacement and rotation of a long-span bridge based on innovative integration of GNSS and accelerometer measurements". *Engineering Structures* 338, 120518 (2025). DOI: 10.1016/j.engstruct.2025.120518.

[110] Rabi R. R. i Monti G. "Genetic Algorithm-Based Model Updating in a Real-Time Digital Twin for Steel Bridge Monitoring". *Applied Sciences* 15(8), 4074 (2025). DOI: 10.3390/app15084074.

[111] Rezaiee-Pajand M., Sarmadi H. i Entezami A. "A hybrid sensitivity function and Lanczos bidiagonalization-Tikhonov method for structural model updating: Application to a full-scale bridge structure". *Applied Mathematical Modelling* 89 (2021), s. 860–884. DOI: 10.1016/j.apm.2020.07.044.

[112] Richter B., Messerer D., Herbers M., Speck K., Laukner J., Gläser C., Jesse F. i Marx S. "Monitoring of a prestressed bridge girder with integrated distributed fiber optic sensors". *Procedia Structural Integrity* 64 (2024), s. 1208–1215. DOI: 10.1016/j.prostr.2024.09.168.

[113] Ritto T. i Rochinga F. "Digital twin, physics-based model, and machine learning applied to damage detection in structures". *Mechanical Systems and Signal Processing* 155, 107614 (2021). DOI: 10.1016/j.ymssp.2021.107614.

[114] Sacks R., Brilakis I., Pikas E., Xie H. S. i Girolami M. "Construction with digital twin information systems". *Data-Centric Engineering* 1, e14 (2020). DOI: 10.1017/dce.2020.16.

[115] Schnellenbach-Held M., Sprenger B. i Otoo M. "A Nonlinear Surrogate-Based Finite Element Model Updating Approach for Prestressed Concrete Bridges". *Structural Engineering International* 35(4) (2025), s. 649–661. DOI: 10.1080/10168664.2025.2487431.

[116] Sevieri G., Andeini M., Anna D. F. i Matthies H. G. "Concrete gravity dams model parameters updating using static measurements". *Engineering Structures* 196, 109231 (2019). DOI: 10.1016/j.engstruct.2019.05.072.

[117] Shengyi S., Yarnold M., Hurlebaus S. i Mander J. "Evaluation of a Load Cell-Based Bridge Weigh-in-Motion System". *Transportation Research Record: Journal of the Transportation Research Board* 2679(2) (2025), s. 535–549. DOI: 10.1177/03611981241263336.

[118] Song Y., Wu Q., Li J., Chen H. i Sun Y. "Static Bayesian finite element model updating driven by prior information with element displacement residual equation". *Applied Mathematical Modelling* 147, 116220 (2025). DOI: 10.1016/j.apm.2025.116220.

[119] Stawska S., Chmielewski J., Bacharz M., Bacharz K. i Nowak A. "Comparative Accuracy Analysis of TruckWeight Measurement Techniques". *Applied Sciences* 11(2), 745 (2021). DOI: 10.3390/app11020745.

[120] Svendsen B. T., Petersen Ø. W., Frøseth G. T. i Rønnquist A. "Improved finite element model updating of a full-scale steel bridge using sensitivity analysis". *Structure and Infrastructure Engineering* 19(3) (2023), s. 315–331. DOI: 10.1080/15732479.2021.1944227.

[121] Szinyéri B., Kővári B., Völgyi I., Kollár D. i Joó A. L. "A strain gauge-based Bridge Weigh-In-Motion system using deep learning". *Engineering Structures* 277, 115472 (2023). DOI: 10.1016/j.engstruct.2022.115472.

[122] Talebi A., Potenza F. i Gattulli V. "Interoperability between BIM and FEM for vibration-based model updating of a pedestrian bridge". *Structures* 53 (2023), s. 1092–1107. DOI: 10.1016/j.istruc.2023.04.115.

[123] Tao X., Liu H., Li J., Yu P. i Zhang J. "Research on the Rapid Testing Method of Influence Lines for Beam Bridges and Its Engineering Applications". *Buildings* 15(10), 1595 (2025). DOI: 10.3390/buildings15101595.

[124] Teng S., Chen X., Chen G. i Cheng L. "Structural damage detection based on transfer learning strategy using digital twins of bridges". *Mechanical Systems and Signal Processing* 191, 110160 (2023). DOI: 10.1016/j.ymssp.2023.110160.

[125] Tiprak K., Takeya K. i Sasaki E. "Probabilistic finite element model updating across multiple model classes and response domains using integrated NN - PSO framework: application to a PC girder bridge". *Structure and Infrastructure Engineering* (2025), s. 1–35. DOI: 10.1080/15732479.2025.2591822.

[126] Tonelli D., Luchetta M., Rossi F., Migliorino P. i Zonta D. "Structural Health Monitoring Based on Acoustic Emissions: Validation on a Prestressed Concrete Bridge Tested to Failure". *Sensors* 20(24), 7272 (2020), s. 1–20. DOI: 10.3390/s20247272.

[127] Tran M. Q., Sousa H. S., Matos J., Fernandes S., Nguyen Q. T. i Dang S. N. "Finite Element Model Updating for Composite Plate Structures Using Particle Swarm Optimization Algorithm". *Applied Sciences* 13(13), 7719 (2023). DOI: 10.3390/app13137719.

[128] Tran-Ngoc H., Khatir S., Le-Xuan T., G D. R., Bui-Tien T. i M A. W. "Finite element model udating of a multispan bridge with a hybrid metaheuristic search algorithm using experimental data from wireless triaxial sensors". *Engineering with Computers* 38 (2022), s. 1865–1883. DOI: 10.1007/s00366-021-01307-9.

[129] Wang H., Nagayama T., Kawakatsu T. i Takasu A. "A Data-Driven Approach for Bridge Weigh-in--Motion from Impact Acceleration Responses at Bridge Joints". *Structural Control and Health Monitoring* 2023(1) (2023), s. 2287978. DOI: 10.1155/2023/2287978.

[130] Wang W., He Y., Li F., Li J., Liu J. i Wu X. "Digital twin rehabilitation system based on self-balancing lower limb exoskeleton". *Technology and Health Care* 31(1) (2023), s. 103–115. DOI: 10.3233/THC-220087.

[131] Wang X., Wu W., Du Y., Cao J., Chen Q. i Xia Y. "Wireless IoT Monitoring System in Hong Kong–Zhuhai–Macao Bridge and Edge Computing for Anomaly Detection". *IEEE Internet of Things Journal* 11(3) (2024), s. 4763–4774. DOI: 10.1109/JIOT.2023.3300073.

[132] Wang X., Wang L., Wang H., Ning Y., Huang K. i Wang W. "Performance Evaluation of a Long-Span Cable-Stayed Bridge Using Non-Destructive Field Loading Tests". *Applied Sciences* 12(5), 2367 (2022). DOI: 10.3390/app12052367.

[133] Wang Y. i Bao Y. "Distributed acoustic sensing-based real-time monitoring of far-field cracks in reinforced concrete bridge decks". *Automation in Construction* 183, 106821 (2026). DOI: 10.1016/j.autcon.2026.106821.

[134] Wang Z. i Wang Y. "Bridge Weigh-In-Motion through Bidirectional Recurrent Neural Network with Long Short-Term Memory and Attention Mechanism". *Smart Structures and Systems* 27(2) (2021), s. 241–256. DOI: 10.12989/sss.2021.27.2.241.

[135] Wang Z., Hua S., Wang D., Xu W. i Yang S. "Design and verification of FBG strain gauge". *The Journal of Engineering* 2019(23) (2019), s. 8535–8538. DOI: 10.1049/joe.2018.9049.

[136] Wei J. Y., Zhang F. L., Xiang W. i Gong G. Q. "Optimal Sensor Placement Strategy Considering Bayesian Identification Uncertainty and State Change in Bridge Health Monitoring". *ASCE--ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering* 12(1) (2026). DOI: 10.1061/AJRUA6.RUENG-1729.

[137] Wu J., Yan Q., Huang S., Zou C., Zhong J. i Wang W. "Finite Element Model Updating in Bridge Structures Using Kriging Model and Latin Hypercube Sampling Method". *Advances in Civil Engineering* 2018 (2018), s. 8980756. DOI: 10.1155/2018/8980756.

[138] Xie Y., Meng X., Nguyen D. T., Xiang Z., Ye G. i Hu L. "A Discussion of Building a Smart SHM Platform for Long-Span Bridge Monitoring". *Sensors* 24(10), 3163 (2024). DOI: 10.3390/s24103163.

[139] Xu Y., Nikitas G., Zhang T., Han Q., Chryssanthopoulos M., Bhattacharya S. i Wang Y. "Support condition monitoring of offshore wind turbines using model updating techniques". *Structural Health Monitoring* 19(4) (2020), s. 1017–1031. DOI: 10.1177/1475921719875628.

[140] Yang X., Wang X., Podolsky J., Huang Y. i Lu P. "Addressing wander effect in vehicle weight monitoring: An advanced hybrid weigh-in-motion system integrating computer vision and in--pavement sensors". *Measurement* 234, 114870 (2024). DOI: 10.1016/j.measurement.2024.114870.

[141] Yang X., Liu M., Song H., Rao J. i Wu Y. "A novel packaging method for FBG temperature sensors based on ultrasonic-assisted soldering technology". *Sensors and Actuators: A. Physical* 373, 115381 (2024). DOI: 10.1016/j.sna.2024.115381.

[142] Yin T. "A Practical Bayesian Framework for Structural Model Updating and Prediction". *ASCE--ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering* 8(1) (2022), s. 04021073. DOI: 10.1061/AJRUA6.0001196.

[143] Yue Y., Wang J. J., Basheer P. M., Boland J. J. i Bai Y. "A Raman spectroscopy based optical fibre system for detecting carbonation profile of cementitious materials". *Sensors and Actuators B: Chemical* 257 (2018), s. 635–649. DOI: 10.1016/j.snb.2017.10.160.

[144] Zhang C., Chun Q. i Lin Y. "Optimal sensor placement and structural health monitoring methods of ancient bridges based on an improved genetic algorithm: Taking Lugou Bridge as an example". *Measurement* 241, 115680 (2025). DOI: 10.1016/j.measurement.2024.115680.

[145] Zhang L., Wang S., Deng L. i OBrien E. J. "A general solution to bridge weigh-in-motion equations based on maximum likelihood estimation". *Engineering Structures* 343, 121193 (2025). DOI: 10.1016/j.engstruct.2025.121193.

[146] Zhang L., Cheng X. i Wu G. "A bridge weigh-in-motion method of motorway bridges considering random traffic flow based on long-gauge fibre Bragg grating sensors". *Measurement* 186, 110081 (2021). DOI: 10.1016/j.measurement.2021.110081.

[147] Zhang Z. i Sun C. "Structural damage identification via physics-guided machine learning: a methodology integrating pattern recognition with finite element model updating". *Structural Health Monitoring* 20(4) (2021), s. 1675–1688. DOI: 10.1177/1475921720927488.

[148] Zhao D., He W., Deng L., Wu Y., Xie H. i Dai J. "Trajectory Tracking and Load Monitoring for Moving Vehicles on Bridge Based on Axle Position and Dual Camera Vision". *Remote Sensing* 13(23), 4868 (2021). DOI: 10.3390/rs13234868.

[149] Zhao H., Wu W., Xia Q. i Xia Y. "A Digital Twin Framework for Real-Time Monitoring and Full-Field Analysis of Bridges". *International Journal of Bridge Engineering* 2(3), 214250025 (2025), s. 1–19. DOI: 10.70465/ber.v2i3.34.

[150] Zheng X., Yi T. H., Yang D. H. i Li H. N. "Stiffness Estimation of Girder Bridges Using Influence Lines Identified from Vehicle-Induced Structural Responses". *Journal of Engineering Mechanics* 147(8) (2021), s. 04021042. DOI: 10.1061/(ASCE)EM.1943-7889.0001942.

[151] Zheng Y., Xu Y. i Gu Q. "Nonlinear model updating of a reinforced conrete pedestrian cable--stayed bridge". *Structural Control and Health Monitoring* 27(3) (2020), e2487. DOI: 10.1002/stc.2487.

[152] Zhou W., Yang H., Hao J., Zhai M., Cao H., Liu Z. i Wang K. "Finite Element Model Updating for a Continuous Beam-Arch Composite Bridge Based on the RSM and a Nutcracker Optimization Algorithm". *Sensors* 25(15), 4831 (2025). DOI: 10.3390/s25154831.

[153] Zhou Y., Pei Y., Zhou S., Zhao Y., Hu J. i Yi W. "Novel methodology for identifying the weight of moving vehicles on bridges using structural response pattern extraction and deep learning algorithms". *Measurement* 168, 108384 (2021). DOI: 10.1016/j.measurement.2020.108384.

[154] Zhu Y. F., Ren W. X. i Wang Y. F. "Structural health monitoring on Yangluo Yangtze River Bridge: Implementation and demonstration". *Advances in Structural Engineering* 25(7) (2022), s. 1431–1448. DOI: 10.1177/13694332211069508.

[155] Zhu Y., Wang Y., Gao C. i Xiong W. "A computer vision and dynamic strain fusion approach for urban bridge weighin-motion". *Communications Engineering* 4, 212 (2025). DOI: 10.1038/s44172-025-00544-w.

[156] Zhu Y. i Chen G. "Rayleigh scattering based, thermal-induced displacement measurement along a steel plate at high temperature". *Journal of Infrastructure Intelligence and Resilience* 1, 100002 (2022). DOI: 10.1016/j.iintel.2022.100002.

Standardy techniczne

[ST1] European co-operation for Accreditation. *EA-4/02 M: 2013 Wyznaczanie niepewności pomiaru przy wzorcowaniu. Evaluation of the Uncertainty of Measurement in Calibration*. EA. (2013).

[ST2] Hottinger Brüel & Kjaer GmbH. *CX22B-W, CX22B Data Recorder*. HBK. (2023).

[ST3] Hottinger Brüel & Kjaer GmbH. *FS62RSS Rugged Strain Sensor*. HBK. (2024).

[ST4] Hottinger Brüel & Kjaer GmbH. *FS62WSS Weldable Strain Sensor Aramid or Armor cable*. HBK. (2024).

[ST5] Hottinger Brüel & Kjaer GmbH. *FS62WSS, FS62WSR (BRD) Weldable Strain Sensor (Braided). Mounting Instructions*. HBK. (2022).

[ST6] Hottinger Brüel & Kjaer GmbH. *FS63RTS Rugged Temperature Sensor*. HBK. (2024).

[ST7] Hottinger Brüel & Kjaer GmbH. *FS63WTS Weldable Temperature Sensor*. HBK. (2024).

[ST8] Hottinger Brüel & Kjaer GmbH. *FS76ARM Armor Cable Sensor Array*. HBK. (2024).

[ST9] Hottinger Brüel & Kjaer GmbH. *MX840B Universal amplifier*. HBK. (2020).

[ST10] Hottinger Brüel & Kjaer GmbH. *MXFS BraggMETER Interrogator Module*. HBK. (2020).

[ST11] Hottinger Brüel & Kjaer GmbH. *MXFS QuantumX BraggMETER Module*. HBK. (2023).

[ST12] Instytut Badawczy Dróg i Mostów. *Krajowa Ocena Techniczna Nr IBDiM-KOT-2019/0432 wydanie 1. Cięgna linowe REDAELLI*. IBDiM. (2019).

[ST13] Peltron Towarzystwo Produkcyjno Handlowe. *Transformatorowe przetworniki przemieszczeń liniowych - Seria PLx*. Peltron.

[ST14] Peltron Towarzystwo Produkcyjno Handlowe. *Transformatorowe przetworniki przemieszczeń liniowych - Seria PSx*. Peltron.