

dr hab. inż. Maciej TABASZEWSKI¹

Institute of Applied Mechanics
Poznan University of Technology
ul. Jana Pawła II 24, 60-965 Poznań, Poland
e-mail: maciej.tabaszewski@put.poznan.pl

dr inż. Bartosz FIRLIK²

Department of Rail Vehicles
Poznan University of Technology
ul. Piotrowo 3, 60-965 Poznań, Poland
e-mail: bartosz.firlik@put.poznan.pl

Ocena stanu torowiska z wykorzystaniem metody GRA³

Słowa kluczowe: tor, utrzymanie, monitorowanie, tramwaj, GRA

Streszczenie: Praca dotyczy opracowanej metodyki do oceny stanu technicznego toru tramwajowego. Dzięki zgromadzonym danym z wielokrotnych przejazdów tramwaju wyposażonego w pokładowy system rejestracji drgań, udało się stworzyć profile przejazdów przez odcinki torów w różnym stanie technicznym. W celu identyfikacji stanu toru zaproponowano algorytm oparty na metodzie modelowania szarych systemów oraz badanie podobieństwa pomiędzy uzyskanymi profilami przejazdów. Zaproponowano także nową miarę podobieństwa nie stosowaną do tej pory w zagadnieniach modelowania szarych systemów. Uzyskane wyniki potwierdzają aplikacyjność zaproponowanej metodyki.

1. Wprowadzenie

Realizacja dotychczasowych prac badawczych dotyczących rejestracji przyspieszeń drgań tramwajów w warunkach eksploatacyjnych za pomocą systemów pokładowych i bezprzewodowej transmisji danych umożliwia podjęcie próby oceny stanu torowiska w oparciu o analizę odpowiedzi dynamicznej pojazdu [5÷7]. Zagadnienie to jest bardzo ważne z punktu widzenia utrzymania infrastruktury, gdyż pozwala na bieżącą ocenę jej stanu technicznego w warunkach normalnej eksploatacji. Systemy takie sprawdzają się zwłaszcza w sieciach kolejowych, w których warunki jazdy są stałe, powtarzalne i pozbawione istotnych zakłóceń czy też zmian wynikających ze sposobu jazdy [np. 1; 3; 12]. W warunkach miejskich nie jest to jednak zadanie trywialne co wynika z istotnego rozrzutu otrzymywanych

1

Full Authors' data including scientific title and affiliation, with postal and e-mail address.

2

Full Authors' data including scientific title and affiliation, with postal and e-mail address.

3

Title, abstract and key words in Polish and in English language version. For foreigners Polish language version if available.

danych nawet z tego samego typu pojazdu i tego samego odcinka pomiarowego. Rozrzut ten wynika z faktu poruszania się pojazdu z różnymi prędkościami w obrębie tego samego sprawdzanego odcinka toru, zmiennego obciążenia (liczby pasażerów), sposobu prowadzenia pojazdu przez motorniczych (gwałtowne lub łagodne przyspieszanie i hamowanie), warunków pogodowych, natężenia ruchu w różnych godzinach i dniach, stanu technicznego pojazdu itp. Do tego należy uwzględnić niepewność pomiaru samego systemu monitorowania. Wszystkie te czynniki powodują, że dla lekkich pojazdów szynowych nie ma łatwego przełożenia pomiędzy stanem toru a uzyskiwanym poziomem przyspieszeń drgań mierzonych w pojeździe.


Aby wyeliminować część z tych czynników i móc zaproponować metodykę oceny stanu toru, postanowiono wybrać, w pierwszym etapie, dane dotyczące przejazdów z różnych odcinków torów (w różnych częściach miasta) jednego typu, tzn. z szyną tramwajową 60R2 z pominięciem rozwiązań bazujących na szynie kolejowej (głównie 49E1). Dodatkowo postanowiono uwzględnić rejestracje dotyczące różnych prędkości przejazdu tramwaju przez dany odcinek toru, tworząc razem pewien profil charakterystyczny dla danego stanu toru (zależność wartości skutecznej przyspieszeń od prędkości maksymalnej dla danego przejazdu tramwaju). Dla każdego z przejazdów wzięto pod uwagę prędkość maksymalną zakładając, że właśnie w takich warunkach najsilniej objawi się informacja o stanie technicznym toru. Innym czynnikiem, którego wpływ wyeliminowano był stan techniczny samego pojazdu. Rozważane dane pochodziły z pojazdu nowego, co jednak nie ogranicza zastosowania zaproponowanej metodyki. W praktyce zawsze da się ten czynnik wyeliminować instalując system pomiaru drgań na pojeździe nowym lub poddanym naprawie głównej.

Do analiz wykorzystano dane zebrane z przeszło dwumiesięcznej eksploatacji nowoczesnego tramwaju niskopodłogowego w normalnym ruchu liniowym z pasażerami. W ocenie stanu wykorzystano informacje dotyczące wartości skutecznej przyspieszeń drgań, wyznaczonej z 1s. okna czasowego w paśmie od 0 do 100 Hz, rejestrowanej na nadwoziu pojazdu w miejscu nad pierwszym wózkiem. Jest to więc pewna miara komfortu jazdy (nie istnieją obecnie w Polsce oficjalne akty prawne w tym zakresie, dedykowane dla lekkich pojazdów szynowych typu tramwaj). Wartość skuteczną przyspieszeń drgań wybrano po wykonaniu analizy porównawczej różnych statystycznych miar oceny [7].

Ocena rzeczywistego stanu technicznego badanych odcinków toru uzyskana była na podstawie niezależnych informacji uzyskanych od służb utrzymania, wspomaganym dodatkowo niezależnymi pomiarami geometrii toru. Ostatecznie wzięto pod uwagę dane zamieszczone w tabeli 1 i przedstawione na rysunku 1. Zaproponowana skala oceny stanu technicznego jest celowo zbieżna z tą przyjętą w MPK Poznań.

Tab. 1. Dane uwzględnione w badaniach

Stan techniczny	Liczba odcinków toru	Łączna liczba pomiarów odpowiedzi dynamicznej pojazdu
Dobry	8	1086
Zadowalający	2	278
Zły	3	103
Krytyczny	2	240



Rys.1. Profile przejazdów różnych odcinków torów w różnym stanie technicznym

Jak wynika z analizy rysunku 1, dane dotyczące różnych stanów technicznych toru silnie przeplatają się ze sobą i są silnie zależne od prędkości maksymalnej danego przejazdu. Ponadto dostępny zakres prędkości dla określonych danych może być różny co wynika z faktu, że odcinki o różnym stanie technicznym rozlokowane są w innym „środowisku” miejskim. Niekiedy mogą to być odcinki, które tramwaj przebywa bez zatrzymywania się a niekiedy konieczne jest hamowanie i przyspieszanie. Stąd należy się liczyć także z różną rozpiętością wartości maksymalnych prędkości. Dostępne dane różnią się także liczebnością (różna liczba przejazdów przez określony fragment toru) co należy uwzględnić w proponowanej metodyce.

O ile dość łatwo dałoby się określić stany dobry i krytyczny na podstawie średniej czy maksymalnej wartości skutecznej przyspieszeń drgań, o tyle pozostałe stany pośrednie ze względu na duży rozrzut pomiarów, nie są już łatwo rozróżnialne (patrz tabela 2 kolumny 1 i 2). Inną prostą możliwością byłoby stworzenie modelu regresji liniowej profilu przejazdów dla każdego ze stanów toru i ocena odpowiednio wyrazu wolnego lub współczynnika kierunkowego prostej. Niestety współczynnik kierunkowy nie niesie informacji o stanie, a informacja zawarta w wyrazie wolnym nie pozwala na rozróżnienie stanu dobrego od zadowolającego. Odpowiednie dane zawarto w tabeli 2.

Tab. 2. Proste parametry statystyczne opisujące zgromadzone dane

Stan techniczny toru	Wartość średnia RMS przyspieszeń drgań [m/s ²]	Wartość maksymalna RMS przyspieszeń drgań [m/s ²]	Współczynnik kierunkowy prostej regresji opisującej profil przejazdów	Wyraz wolny w prostej regresji opisującej profil przejazdów
Dobry	0,224	0,386	0,0024	0,0918

Zadowolający	0,184	0,385	0,0034	0,0632
Zły	0,250	0,341	0,0029	0,1408
Krytyczny	0,375	0,537	0,0030	0,2330

Ponieważ zastosowanie wspomnianych wcześniej prostych metod nie jest skuteczne w jednoznacznym określeniu stanu toru postanowiono sięgnąć po metody oparte na podobieństwie określonych danych do wzorca. Wzorzec zbudowany zostanie w oparciu o profil przejazdów dla odcinka w dobrym stanie technicznym. Ideę metody będzie stanowił porównywanie uzyskanego profilu przejazdów z wcześniej zbudowanym wzorcem. W warunkach rzeczywistych na zgromadzenie określonych danych z określonego, kontrolowanego odcinka toru będzie potrzebny czas zaledwie kilku dni ze względu na wielokrotne przejazdy pojazdu tą samą trasą. Jest to czas relatywnie krótki w stosunku do potrzeb.

Ponieważ jak wykazano, dane mogą charakteryzować się dużym rozrzutem postanowiono sięgnąć po narzędzia z zakresu modelowania szarych systemów, które można stosować nie tylko wtedy gdy dostępnych danych jest niewiele, lecz także wtedy gdy dane są niepewne. Istnieje tutaj możliwość wykorzystania szarych modeli GM w celu zamodelowania określonego profilu. Konieczne jest również zdefiniowanie miary podobieństwa poszczególnych profili przejazdów. Tutaj także można odwołać się do metod z zakresu modelowania szarych systemów (GRA).

2. Opis metodyki określania stanu technicznego toru

Zasadnicza część działań opierać się będzie o metody związane z modelowaniem szarych systemów, stąd warto przedstawić w tym miejscu pewne podstawy tej teorii. Teoria szarych systemów zaproponowana przez prof. J-L. Deng'a ma wiele różnych obszarów badawczych i zastosowań [4]. Jednym z nich jest badanie podobieństwa pomiędzy sekwencjami danych (GRA) [10]. Badanie podobieństwa danych w różnych zbiorach ma w omawianej metodyce duże znaczenie gdyż pozwala na porównanie danego profilu przejazdów i wzorca dla stanu dobrego. Określona miara podobieństwa w dziedzinie maksymalnej prędkości przejazdu może następnie zostać łatwo sparametryzowana dając jedną liczbę informującą o stopniu zgodności z wzorcem, a więc i o stanie technicznym toru.

W tym celu należy zdefiniować miary podobieństwa profili przejazdów. W literaturze dotyczącej GRA istnieje wiele miar określających relację podobieństwa pomiędzy danymi. Przykładem może być uogólniony model GRA, który służy do analizy relacji pomiędzy sekwencjami oraz miary bazujące na odległości i podobieństwie. Szczegółowy przegląd metod można znaleźć np. w [10]. Pewne inne miary zaproponowano w [13].


Istotną rolę w opisywanym podejściu stanowi modelowanie szarych systemów GM w odniesieniu do zbioru danych. Taki zbiór, w wyniku określonych operacji, można potraktować jako szereg co pozwala na jego zamodelowanie szarym modelem np. GM(1,1) [4; 8; 11; 14; 16; 17]. Daje to możliwość modelowej reprezentacji pierwotnych danych, które charakteryzują się dużą niepewnością i dyspersją. Jedną z cech wspomnianego modelu jest wygładzenie lokalnych fluktuacji (odchyleń) szeregu poprzez zastosowanie operacji AGO

(Accumulated Generating Operation) co pozwala na zastąpienie pierwotnych danych danymi modelowymi, w dużej mierze wygładzonymi.

Na rysunku 2 przedstawiono schemat blokowy, ilustrujący algorytm modelowania profili przejazdów, wyznaczania miar podobieństwa i określania stanu technicznego toru.

Założmy, że mamy kolejne realizacje profili przejazdów z danego odcinka toru. Niech $X_i(k)$, $X_j(k)$, $i=1,2, \dots, n$, $j = 1,2, \dots, m$ oznaczają wektory, których elementami są pomiary wartości miary komfortu przejazdu dla realizacji profili przejazdów i i j . Przed zastąpieniem pierwotnych danych przez modelowe uzyskane za pomocą modeli GM(1,1) należy usunąć przypadki, w których dokładnie tej samej wartości prędkości odpowiadają różne wartości skuteczne przyspieszeń drgań. Konieczność taka wynika z faktu, że modele GM(1,1) opisują szereg. Mimo iż wartości prędkości są określane z dokładnością do 0,01 km/h sytuacja, w której dla dokładnie tej samej prędkości otrzymujemy różne odczyty wartości przyspieszeń, jest dość częsta i należy ją uwzględnić.

W kolejnym kroku algorytmu, pierwotne dane zastępowane są wynikami interpolacji liniowej. Wynika to z faktu, że podstawowy model GM(1,1) wymaga stałego odstępu pomiędzy danymi jak i z tego, że porównywane wektory X_i oraz X_j muszą mieć tę samą liczbę elementów. Jest to warunek obliczenia miary podobieństwa obu profili. W tym celu konieczne może być także wycięcie fragmentu danych tak aby obejmowały one ten sam zakres prędkości maksymalnej w obu porównywalnych profilach przejazdów – badanego i wzorca.



Rys.2. Algorytm wyznaczania stanu technicznego toru na zasadzie badania podobieństwa modelowych profili przejazdów: rozpoznawanego i odniesienia

W celu zamodelowania tak powstałego szeregu konieczne jest zastosowanie operacji AGO, którą dla wektora X_i można zapisać jako [8]:

$$X^{(1)}_i(k) = \sum_{r=1}^k x_i(r). \quad (1)$$

Wspomniany wcześniej model GM(1,1) uzyskuje się z ogólnego opisu szarego systemu w postaci równania różniczkowego (2). W ogólności dla przypadku, gdy rozpatrujemy równanie rzędu p z wymuszeniami rzędu m GM(p,m) otrzymamy [2]:

$$\sum_{l=0}^p a_l \frac{d^{p-l} X_i^{(1)}}{dt^{p-l}} = \sum_{i=1}^{m-1} b_i X_{i+1}^{(1)}, \quad (2)$$

gdzie: X_1 jest wektorem pierwotnych obserwacji $x_1(r)$, $X_1^{(1)}$ jest wektorem zmiennych stanu system uzyskanym na podstawie wektora pierwotnych obserwacji po zastosowaniu operacji AGO zgodnie z wzorem (1), X_{i+1} jest wektorem wejściowym, a_l , b_h są stałymi współczynnikami.

Model GM(1,1) dotyczący danego zbioru danych X można zapisać jak niżej:

$$\frac{dX^{(1)}(t)}{dt} + aX^{(1)}(t) = b \quad (3)$$

Rozwiązanie równania (3) z jednostkowym krokiem k może być przedstawione jako [8]:

$$\hat{x}^{(1)}(k+1) = [x^{(0)}(1) - b/a] \exp(-ak) + b/a \quad (4)$$

gdzie $\hat{x}^{(1)}$ jest prognozowaną wartością elementu szeregu skumulowanego. Stosując różnice skończone oraz wyrażając równanie (3) jako szereg równań dotyczących dyskretnych wartości, otrzymujemy następujące przybliżenie [8]:

$$x^{(1)}(k+1) - x^{(1)}(k) = -\frac{a}{2} [x^{(1)}(k) + x^{(1)}(k+1)] + b \quad (5)$$

Parametry modelu są obliczone w oparciu o równanie (5) z użyciem metody najmniejszych kwadratów [16]:

$$\begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{Y} \quad (6)$$

gdzie:

$$z(k) = -\frac{1}{2} (x^{(1)}(k+1) + x^{(1)}(k)),$$

$$\mathbf{Y} = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \dots \\ x^{(0)}(n) \end{bmatrix}, \quad \mathbf{Z} = \begin{bmatrix} z(1) & 1 \\ z(2) & 1 \\ \dots & \dots \\ z(n-1) & 1 \end{bmatrix}$$

Parametry modelu GM(1,1) mogą być szacowane na podstawie wszystkich dostępnych rejestracji lub ich części (rolling window method) [15]. Szacowanie parametrów na podstawie wszystkich danych może spowodować, że model będzie zbyt uśredniał i nie wychwyci pewnych zmian jego trendu. Stosowanie okna o niewielkiej długości powoduje, że model adaptuje się do zmian w trendzie i je odzwierciedla. Model można stosować wtedy

gdy danych jest niewiele, stąd też można posługiwać się wąskimi oknami. W pracy przyjęto arbitralnie okno o długości 80 pomiarów, co przy kroku interpolacji dającym profil przejazdu złożonym z 360 punktów wydaje się być wartością kompromisową pomiędzy dobrym uśrednieniem danych jak i możliwością adaptacji modelu do danych. W każdym kroku budowy modelu okno przesuwano o jeden pomiar i szacowano modelowe, wygładzone wartości. W przypadku gdy liczba dostępnych danych wybranych do oszacowania parametrów modelu była mniejsza niż długość okna, okno było skracane. Teoretycznie okno można skrócić zaledwie do czterech pomiarów, które są niezbędne do oszacowania parametrów modelu GM(1,1). Ostatnie cztery wartości modelowe wyznaczone są na podstawie prognoz z wykorzystaniem wspomnianego modelu i ostatnio oszacowanych parametrów.

W kolejnym kroku dokonywane jest obliczenie podobieństwa modelowanych profili przejazdu. Przy stałym kroku interpolacji k można zdefiniować macierz zmian wzajemnego i własnego podobieństwa [13]:

$$\Sigma_k = \begin{bmatrix} \sigma_{11}(k) & \dots & \sigma_{1m}(k) \\ \dots & \dots & \dots \\ \dots & \sigma_{jj}(k) & \sigma_{jm}(k) \\ \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \sigma_{mm}(k) \end{bmatrix} \quad (7)$$

gdzie: $\sigma_{ij}(k)$ oznacza miarę podobieństwa dla profili przejazdu i i j dla danego kroku k , odpowiadającego danej prędkości maksymalnej. Tutaj najbardziej interesujące są miary wzajemne: $\sigma_{21}(k)$, $\sigma_{31}(k)$, $\sigma_{41}(k)$, które dotyczą porównań profili przejazdów związanymi z poszczególnymi stanami technicznymi toru (zadawalający, zły i krytyczny) oraz profilu wzorcowemu (odnoszącemu się do stanu dobrego toru).

Zaproponowana definicja miary podobieństwa profili może być wyrażona jako:

$$\sigma_{ij} = \frac{\alpha A_{ij} + \beta B_{ij} + \gamma C_{ij}}{\alpha + \beta + \gamma} \quad (8)$$

gdzie:

$$A_{ij} = \begin{cases} \frac{\hat{x}_i^{(0)} \hat{x}_j^{(0)}}{\max(\hat{x}_i^{(0)}) \cdot \max(\hat{x}_j^{(0)})} & \text{for } \hat{x}_i^{(0)} \neq \hat{x}_j^{(0)} \\ 1 & \text{for } \hat{x}_i^{(0)} = \hat{x}_j^{(0)} \end{cases},$$

$$B_{ij} = \begin{cases} \frac{\max(\Delta_{ij}) - \Delta_{1ij}}{\max(\Delta_{ij}) - \min(\Delta_{ij})} & \text{for } \max(\Delta_{ij}) \neq \min(\Delta_{ij}) \\ 1 & \text{for } \max(\Delta_{ij}) = \min(\Delta_{ij}) \end{cases},$$

$$C_{ij} = \begin{cases} \frac{\max(\Delta_{ij}) - \Delta_{ij}}{\max(\Delta_{ij}) - \min(\Delta_{ij})} & \text{for } \max(\Delta_{ij}) \neq \min(\Delta_{ij}) \\ 1 & \text{for } \max(\Delta_{ij}) = \min(\Delta_{ij}) \end{cases},$$

$$\Delta_{1ij} = |\hat{x}_{1i}^{(0)} - \hat{x}_{1j}^{(0)}|, \Delta_{ij} = |\hat{x}_i^{(0)} - \hat{x}_j^{(0)}|$$

$\hat{x}^{(0)}$ - wektor wartości szeregu po wygładzeniu modelem GM(1,1), $\hat{x}_1^{(0)}$ - pierwsza wartość szeregu, A –składnik charakteryzujący podobieństwo „kształtów” porównywanych przebiegów, B – składnik uwzględniający różne wartości profilu dla najmniejszej prędkości, C – składnik charakteryzujący różnice w wartościach, α, β, γ - współczynniki wpływu poszczególnych składników (wagi uwzględniające poszczególne cechy).


Wszystkie składniki we wzorze (8) nie przekraczają wartości 1.0 i stanowią cząstkowe miary podobieństwa w kategoriach poszczególnych cech. Poprzez współczynniki wagowe można nadawać poszczególnym cechom różne znaczenie. Składnik C jest stosowaną w literaturze dotyczącej GRA miarą podobieństwa np. [9], natomiast B jest adaptacją tej miary dla pierwszej wartości szeregu.

Zastosowanie modelu adaptacyjnego typu GM(1,1) jest w zaproponowanej metodyce o tyle ważne, że pozwala na uchwycenie cech podobieństwa związanymi z „lokalnymi” zmianami wartości porównywanych profili przejazdów. W przypadku np. regresji liniowej modelującej te profile, informacje te zostały by stracone. Należy wspomnieć, że zaproponowana miara podobieństwa jest uniwersalna i może służyć do porównania różnych zbiorów danych dotyczących nie tylko poruszanego problemu.

Ostatecznie otrzymane wartości podobieństwa można łatwo sparametryzować poprzez obliczenie wartości średniej czy maksymalnej i na tej podstawie podejmować decyzje eksploatacyjne lub też decyzje o dodatkowych kontrolach danego odcinka toru.

3. Wyniki

Przedstawioną metodę zastosowano do zebranych danych, przedstawionych na rysunku 1. Profile przejazdów interpolowane i wygładzone za pomocą modelu GM(1,1) z oknem 80 punktów przedstawiono na rysunku 3. Jak wynika z rysunku, uwidocznił się tutaj charakter zmian wartości skutecznej przyspieszeń od prędkości. Uzyskane wygładzone profile stanowiły wejście do procedury obliczania podobieństwa $\sigma_{21}(k), \sigma_{31}(k), \sigma_{41}(k)$, gdzie indeks 1 odnosi się do profilu przejazdów dla stanu technicznego toru określanego jako dobry. Średnie wartości miary podobieństwa dla różnych przyjętych wag zestawiono tabeli 2.



Rys.3. Wynik zastosowania modelu GM(1,1) z przesuwным oknem

Tab.3. Przykładowe wyniki średniej miary podobieństwa dla danych z rysunku 1 i różnych wag

Podobieństwo	$\alpha=1,$ $\beta=1, \gamma=1$	$\alpha=2,$ $\beta=1, \gamma=1$	$\alpha=1,$ $\beta=2, \gamma=1$	$\alpha=1,$ $\beta=1, \gamma=2$	$\alpha=0,$ $\beta=0, \gamma=1$
Stan zadowolający – dobry	0,538	0,539	0,489	0,586	0,731
Stan zły – dobry	0,483	0,507	0,471	0,526	0,654
Stan krytyczny - dobry	0,448	0,478	0,413	0,453	0,469

Jak wynika z tabeli 3, we wszystkich przedstawionych przypadkach stany techniczne torów stają się rozróżnialne (inaczej niż wynika to z tabeli 1). Mniejsza liczba oznacza mniejsze podobieństwo danego profilu przejazdów do profilu odpowiadającego stanowi dobremu torowiska. Najbardziej podobne do wzorca określonego na odcinkach toru w dobrym stanie technicznym były profile uzyskane z przejazdów po odcinkach w stanie zadowolającym. Mniejszą miarą podobieństwa cechowały się dane związane przejazdami po torach w złym stanie technicznym, a najmniejszą, w stanie krytycznym.

W przypadku większej wagi dotyczącej odległości wszystkich wartości profilu od profilu wzorcowego, rozróżnialność staje się szczególnie wyraźna, stąd wniosek, że w uzyskanych profilach ta cecha staje się najważniejsza. Jak wynika z analiz, sama ta cecha (a więc w praktyce miara GRA stosowana powszechnie) także wystarcza do jednoznacznego rozróżnienia stanów a nawet w tym przypadku zapewnia większą rozróżnialność stanów, jednak wydaje się, że zdefiniowana bardziej elastyczna miara może mieć szersze zastosowanie także do innych danych.

Dzięki zastosowanej metodyce daje się jednoznacznie rozróżnić stany techniczne torów w warunkach eksploatacyjnych co ma bardzo istotne znaczenie z praktycznego punktu widzenia.

3. Wnioski

Problem oceny stanu technicznego toru w warunkach eksploatacyjnych nie jest trywialny ze względu na szereg czynników wpływających na wyniki pomiarów, które trudno uwzględnić bezpośrednio w modelach. Idea rejestracji przyspieszeń drgań przez system pokładowy zamontowany w tramwaju (przy złożeniu jego sprawności technicznej) i tworzenia profili przejazdów przez dany diagnozowany odcinek toru pozwala na klasyfikację stanu toru technicznego. Jednak ze względu na duży rozrzut danych pomiarowych może być to utrudnione. Jak wykazano klasyfikacja ta może opierać się na modelowaniu takiego profilu a następnie badaniu podobieństwa danego profilu i profilu wzorcowego. Dobrą podstawę do tego typu działań daje teoria szarych systemów, która z założenia pozwala modelować dane niepewne, a więc obciążone także dużym rozrzutem. Wykorzystanie metodologii GRA w tym przypadku daje jednoznaczne wyniki i pozwala na rozróżnienie stanów technicznych toru poprzez prostą parametryzację miar podobieństwa wzajemnych modelowych profili przejazdów. Zaproponowana metodyka pozwala na relatywnie szybkie uzyskanie diagnozy. Ze względu na wielokrotność przejazdu danego pojazdu po danym odcinku toru zgromadzenie potrzebnych danych i stworzenie profilu przejazdów nie jest sprawą trudną. Stanowi to o praktyczności zastosowanej metodyki.

Zaproponowana w pracy miara podobieństwa cechuje się dużą elastycznością i może być zastosowana w różnych problemach. Ujmuje ona różne aspekty podobieństwa szeregów. W przypadku rozpatrywanych danych daje bardzo dobre wyniki, choć w tym przypadku zastosowanie prostszej metody GRA także spełnia swoje zadanie.

Acknowledgement: *Artykuł powstał w związku z realizacją projektu POIG.01.01.02-00-013/08: „MONITOROWANIE TECHNICZNEGO STANU KONSTRUKCJI I OCENA JEJ ŻYWOTNOŚCI (MONIT)”, Program Operacyjny Innowacyjna Gospodarka Oś priorytetowa 1: Badania i rozwój nowoczesnych technologii, Działanie 1.1: Wsparcie badań naukowych dla budowy gospodarki opartej na wiedzy.*

Bibliografia ⁴

1. Barbera A N, Corradi R, Barilaro P, Li Z, Wacrenier P L. A Track Quality Monitoring System Designed to be Installed on Vehicles in Normal Operation. Proceedings of the First International Conference on Railway Technology: Research, Development and Maintenance 2012; Paper 43.
2. Chen H W, Chang Ni-Bin. Prediction analysis of solid waste generation based on grey fuzzy dynamic modelling. Resources, Conservation and Recycling 2000; 29: 1-18.
3. Chen J, Roberts C, Weston P. Fault detection and diagnosis for railway track circuits using neuro-fuzzy systems. Control Engineering Practice 2008; 16(5): 585-596.

⁴

References in alphabetical order and with required format as presented on the list above.

4. Deng J L. Introduction to grey system theory. *The Journal of Grey System* 1989; 1(1): 1-24.
5. Firlik B, Czechyra B, Chudzikiewicz A. Condition Monitoring System for Light Rail Vehicle and Track. *Key Engineering Materials* 2012; 518: 66-75.
6. Firlik B, Tabaszewski M. Dynamical Problems in Condition Monitoring of a Light Rail Vehicle. *Proceedings of 13th Mini Conference on Vehicle System Dynamics, Identification and Anomalies – VSDIA 2012*; 293-301.
7. Firlik B, Tabaszewski M, Sowiński B. Vibration-based symptoms in condition monitoring of a light rail vehicle. *Key Engineering Materials* 2012; 518: 409-417.
8. Kayacan E, Ulutas B, Kaynak O. Grey system theory-based models in time series Prediction. *Expert Systems with Applications* 2010; 37: 1784-1789.
9. Lin S L, Wu S J. Is grey relational analysis superior to the conventional techniques in predicting financial crisis?. *Expert Systems with Applications* 2011; 38: 5119-5124.
10. Liu S F, Yang Y Y, Xie N M. A summary on the research of GRA models. *Grey Systems: Theory and Application* 2013; 3(1): 7-15.
11. Luo M, Kuhnell B T. Forecasting machine condition using grey-system theory. *Bulletin of MCCM, Monash Univ. Australia* 1990; 2(1).
12. Parkinson H, Iwincki S. An Intelligent Track Monitoring System. *AIC conference on Infrastructure Management, London, February 1999*.
13. Tabaszewski M, Cempel C. Similarity measures for diagnostic symptom evolution. *Grey Systems: Theory and Application* 2016; 6: 51-63.
14. Wang T C, Liou M C, Hung H H. Application of grey theory on forecasting the exchange rate between TWD and USD. *International Conference on Business and Information, Academy of Taiwan Information System Research and Hong Kong Baptist University, July 2005*.
15. Yao A W L, Chi S C. Analysis and design of a Taguchi–Grey based electricity demand predictor for energy management systems. *Energy Conversion and Management* 2004; 45: 1205–1217.
16. Zhang H, Li Z, Chen Z. Application of grey modelling method to fitting and forecasting wear trend of marine diesel engines. *Tribology International* 2003; 36: 753-756.
17. Zhang L, Wang Z, Zhao S. Short-term fault prediction of mechanical rotating parts on the basis of fuzzy-grey optimizing method. *Mechanical Systems and Signal Processing* 2007; 21: 856-865.