

Marek SITARZ, Andrzej HEŁKA, Adam MAŃKA

## PREDYKCJA WŁASNOŚCI EKSPLOATACYJNYCH KOMPOZYTOWYCH WSTAWEK HAMULCOWYCH ZA POMOCĄ SIECI NEURONOWYCH

**Streszczenie.** W pracy przedstawiono zastosowanie sztucznych sieci neuronowych do opisu zależności współczynnika tarcia w układzie wstawka - koło od różnych parametrów eksploatacyjnych. Dzięki wykorzystaniu ich w modelu symulującym hamowanie pojazdów szynowych wyposażonych w kompozytowe wstawki hamulcowe możliwe było przewidywanie drogi hamowania pojazdu jako podstawowego parametru eksploatacyjnego.

## PREDICTION OF EXPLOITATION PROPERTIES OF A PLASTIC BRAKE SHOES FROM NEURAL NETWORK

**Summary.** The article describes the trail of artificial neural networks use for the relation description of the friction factor in the system of brake shoe – wheel from the different exploitation parameters. Because of the use of them in the model simulating the braking of railway vehicles with plastic brake shoe the prediction of the braking track as the basic exploitation parameter was possible.

### 1. WSTĘP

Głównym parametrem decydującym o drodze hamowania pojazdu, a tym samym o bezpieczeństwie ruchu, jest zależność współczynnika tarcia w parze cierniej wstawka - koło od warunków współpracy tych elementów. Zależność ta decyduje m.in. o możliwości zastosowania wstawek kompozytowych zamiast żeliwnych.

Ocena przydatności kompozytowych wstawek hamulcowych do zastosowania w pojazdach szynowych wymaga przeprowadzenia długotrwałych i kosztownych badań laboratoryjnych, stanowiskowych, a zwłaszcza eksploatacyjnych. W niniejszej pracy do tej oceny zaproponowano system symulacji komputerowej, który na podstawie wyników badań stanowiskowych pozwala na symulację drogi hamowania pojazdu w eksploatacji. System ten pozwoli na przyspieszenie i obniżenie kosztów oceny przydatności eksploatacyjnej wstawek np. poprzez wyeliminowanie materiałów o niekorzystnych właściwościach bez konieczności wykonywania kosztownych badań eksploatacyjnych. Wykorzystuje on sztuczne sieci neuronowe do modelowania zależności współczynnika tarcia w układzie wstawka - koło od parametrów eksploatacyjnych. Zastosowanie tych sieci umożliwi uniknięcie definiowania nieznannej struktury modelu matematycznego. Połączenie tego modelu z modelem dynamicznym pojazdu umożliwi przewidywanie zachowania się pojazdów wyposażonych we wstawki kompozytowe. System ten pozwala przewidzieć m.in. drogi hamowania pojazdów wyposażonych we wstawki kompozytowe dla warunków, które nie były przewidziane w trakcie badań stanowiskowych.

## 2. MODEL NEURONOWY WSPÓŁCZYNNIKA TARCIA

Wiele ośrodków prowadzi badania symulacyjne pozwalające przewidzieć zachowanie się pociągu podczas hamowania z zastosowaniem różnych konstrukcji i materiałów wstawek hamulcowych. Jednakże proponowany model opisujący własności trybologiczne materiałów ciernych używanych na wstawki hamulcowe nadal jest bardzo uproszczony i nie uwzględnia wielu czynników. Ponieważ określenie drogi hamowania będącej podstawowym parametrem eksploatacyjnym wymaga dokładnego opisu współczynnika tarcia.

Najbardziej znanym i rozpowszechnionym od lat wzorem na współczynnik tarcia jest wzór Karwackiego [1]:


$$\mu = x_0 \cdot \frac{x_1 \cdot N + x_2}{x_3 \cdot N + x_4} \cdot \frac{v + 100}{5v + 100} \quad (1)$$

Powołuje się na niego wielu autorów [2, 3]. Wymaga on jednak ustalenia wartości parametrów liczbowych  $x_0 - x_4$ , zależnych od rodzaju materiału. Wzór ten uzależnia wartość współczynnika tarcia tylko od nacisków i prędkości. Autor pracy [3] podaje wzory z ustalonymi wartościami tych parametrów dla żeliwa jak i dla kompozytu. Dla tradycyjnych wstawek żeliwnych przedstawia on zależność:

$$\mu = 0,6 \cdot \frac{16N + 100}{80N + 100} \cdot \frac{v + 100}{5v + 150} \quad (2)$$

Jednakże w rzeczywistości współczynnik tarcia zależy od wielu parametrów eksploatacyjnych nie tylko nacisków i prędkości. Na podstawie analizy specjalnej literatury i wyniki badań stanowiskowych stwierdzono, że współczynnik tarcia zależy od wielu czynników, a ich matematyczna postać jest nieznaną. Dlatego też w niniejszej pracy zaproponowano wykorzystanie sztucznych sieci neuronowych do opisu zależności współczynnika tarcia w układzie koło - klocek m. in. z uwagi na złożony charakter tej zależności. Sieci neuronowe pozwalają na opis skomplikowanych zależności o nieznaną postać matematyczną [4]. W pracy tej stanowią one element systemu, który na podstawie wyników badań stanowiskowych pozwala przewidzieć własności trakcyjne różnych pojazdów wyposażonych we wstawki kompozytowe. W szczególności uwzględniono zastosowanie tego systemu do symulacji hamowania pojazdów z klockami wykonanymi z nowego kompozytowego materiału ciernego. Sztuczna sieć neuronowa stanowi matematyczny model systemu nerwowego. Jest on zbudowany ze sztucznych neuronów, które są jednostkami przetwarzającymi informacje. Zwykle możliwości pojedynczego neuronu są zbyt skromne do rozwiązywania skomplikowanych problemów. W takich przypadkach konieczna jest współpraca wielu neuronów tworzących strukturę zwaną siecią. W ramach sieci neurony mogą być grupowane w warstwy albo kaskadę. Prawidłowe działanie sieci neuronowej wymaga przeprowadzenia procesu uczenia. W jego wyniku następuje dobór współczynników wagowych sieci. W pracy zastosowano algorytm uczenia pod nadzorem, który polega na prezentowaniu jej par uczących, tzn. wzorcowych wektorów wejściowych oraz odpowiadających im wektorów wyjściowych tworzących ciąg uczący. Taki typ uczenia sieci jest szczególnie przydatny przy modelowaniu zjawisk w oparciu o posiadane wyniki badań. Nauczona sieć neuronowa pozwala na określanie wielkości wyjściowych przy znajomości danych wejściowych (rys. 1). Może więc pełnić rolę modelu matematycznego [5]. Proces uczenia sieci zazwyczaj kończy się z chwilą zmniejszenia się błędu do zadanej wartości. Błąd ten wyznaczono w pracy jako: sumaryczny błąd kwadratowy (SSE – ang. Sum Square Error)

oraz średni błąd kwadratowy (MSE – ang. Mean Square Error). Wartość tę ustala się doświadczalnie. Zbyt duży błąd powoduje niedokładne działanie sieci, natomiast przyjęcie zbyt małej jego wartości może prowadzić do nadmiernego wzrostu czasu uczenia. Poza tym osiągnięcie bardzo małej wartości błędu dla danych wykorzystanych podczas nauki nie zape -



Rys. 1. System przetwarzania danych wykorzystujący sieć neuronową

Fig. 1. System of the data processing with use neural network

wnia poprawnego działania sieci dla innych, nawet zbliżonych danych. Może wtedy występować tzw. uczenie się na pamięć, prowadzące do utraty zdolności sieci do uogólniania, która jest bardzo istotna, zwłaszcza przy wykorzystaniu sieci jako modelu matematycznego. Z tego względu dane służące do uczenia sieci dzieli się zwykle na dwie grupy, tzw. zestaw uczący i testowy. Pierwszy z nich służy do nauki sieci, a drugi do testowania jej zdolności do uogólniania. Zakończenie procesu uczenia powinno nastąpić z chwilą zauważenia wzrostu błędu zestawu testowego [5]. W pracy sieci neuronowe symulowane są za pomocą profesjonalnego programu - Stuttgart Neural Network Simulator (SNNS v. 4.2), opracowanego przez Uniwersytety w Stuttgarcie i Tübingen. Wyboru dokonano ze względu na bardzo szerokie możliwości programu, obejmujące prawie 40 metod uczenia sieci różnych typów. Ponadto program jest szybki w działaniu, dzięki czemu uzyskiwane czasy uczenia sieci wahały się od kilku do kilkunastu minut.

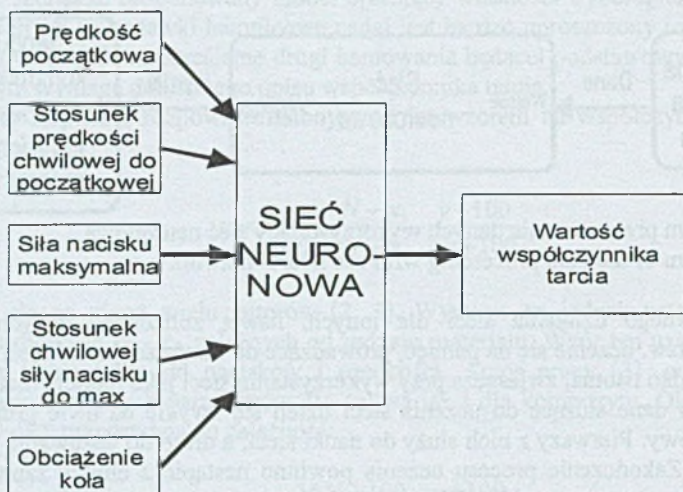
W pracy połączono proces uczenia z doбором struktury sieci. Umożliwiło to zastosowanie algorytmu kaskadowej korelacji Fahlmana (CC). W wyniku jego zastosowania otrzymano sieci, w których połączenia neuronów tworzyły kaskadę. Każdy neuron wyjściowy był połączony ze wszystkimi neuronami ukrytymi i z wejściami sieci. Algorytm korelacji kaskadowej dobierał wielkość sieci automatycznie na podstawie obserwacji wyników procesu uczenia. Proces uczenia rozpoczynało na sieci o minimalnych rozmiarach, składającej się tylko z węzłów wejściowych i neuronów wyjściowych. Bezpośrednie połączenia wagowe pomiędzy wejściem i wyjściem sieci były uczone tak, by zminimalizować wartość błędu. Do nauki sieci kaskadowych zastosowano algorytm RPROP. Po osiągnięciu minimum funkcji celu dla danej struktury sieci algorytm CC analizował wielkość błędu generowanego przez sieć. Jeżeli minimalny błąd dla danej struktury był większy od zakładanego, to powiększano strukturę o neuron ukryty.

Ciągi uczące i testujące zbudowano wykorzystując wyniki badań stanowiskowych przeprowadzonych na homologowanym przez ERRI stanowisku badawczym na Uniwersytecie Technicznym w Żylinie, zgodnie z programem badawczym określonym przez kartę UIC 541-1 [6]. W trakcie tych badań wyznaczono współczynnik tarcia dla wstawek wykonanych z nowego materiału kompozytowego typu FR502 produkcji firmy Frenoplast. Wartość tego współczynnika stanowiła parametr wyjściowy sieci. Parametry wejściowe opisywały proces hamowania oraz pojazd. Po wykonaniu badań wstępnych dla różnych zestawów tych parametrów przyjęto:

- prędkość początkowa hamowania [km/h];
- stosunek prędkości chwilowej do początkowej;
- maksymalna siła nacisku wstawek na koło [N];

- stosunek chwilowej siły nacisku do maksymalnej;
- masa pojazdu przypadająca na koło [t].

Przyjęte parametry wejściowe i wyjściowe neuronowego modelu współczynnika tarcia przedstawiono na rys. 2.



Rys. 2. Schemat neuronowego modelu współczynnika tarcia między klockiem kompozytowym a kołem

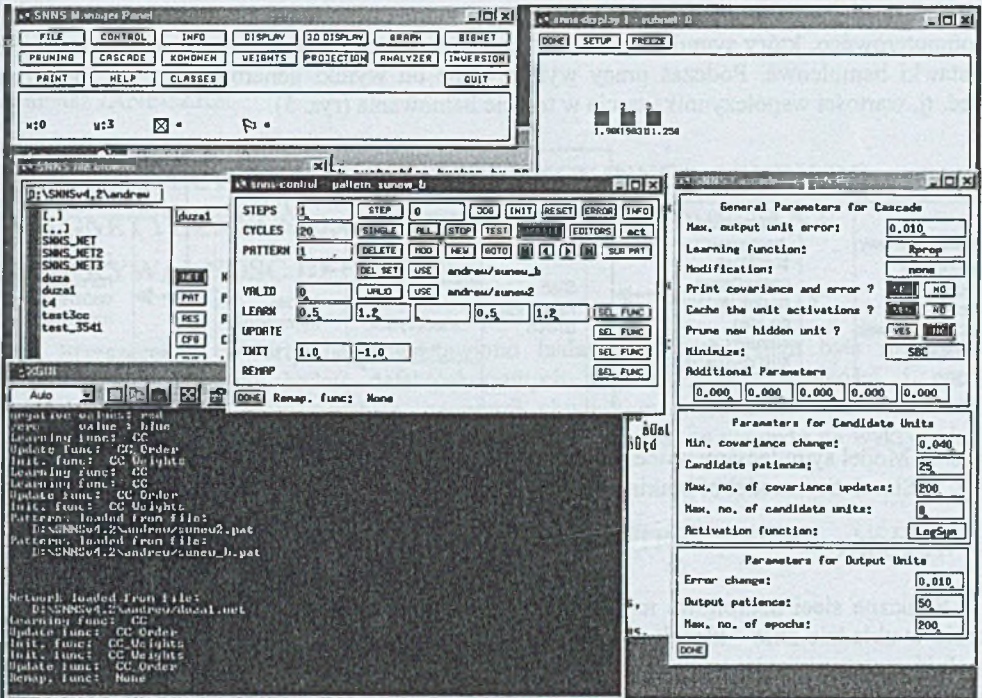
Fig. 2. Scheme of neural model of friction coefficient between plastic brake shoe and wheel

Uwzględniono dwa przypadki: jedna albo dwie sieci: osobno dla hamowań na sucho i na mokro. W wyniku wstępnego doboru sieci stwierdzono, że znacznie lepszą korelację wykazywały wyniki uzyskiwane przy zastosowaniu dwóch osobnych sieci. Dlatego przyjęto, że model będą stanowiły dwie sieci neuronowe: jedna dla warunków na sucho, druga dla warunków na mokro. Zostały więc utworzone osobno ciągi uczące i testujące dla różnych warunków. Zgromadzona ilość danych badawczych pozwoliła na utworzenie ciągu uczącego dla warunków na sucho o długości 4859 przykładów i testującego, obejmującego 480 wzorców oraz dla warunków na mokro o długości 5199 przykładów i testującego, obejmującego 510 wzorców. Zestawy testujące zawierały przykłady nie występujące w ciągu uczącym. Zgodnie z wymaganiami programu SNNS użytego do budowy i uczenia sieci neuronowych konieczne jest, aby wielkości wyjściowe były z zakresu od 0 do 1. W przypadku współczynnika tarcia wymóg ten jest spełniony, dlatego nie było konieczne wprowadzanie modyfikacji. Jak już wspomniano, strukturę sieci dobrano przy wykorzystaniu algorytmu kaskadowej korelacji Fahlmana (CC). Program SNNS po ustawieniu założonych parametrów automatycznie dobierał strukturę sieci w trakcie uczenia w celu minimalizacji wartości błędów SSE i MSE (rys. 3). Własności przykładowych sieci neuronowych otrzymanych w wyniku procesu uczenia zestawiono w tab. 1. Z uwagi na niewielkie błędy i wysoką korelację wyników generowanych przez te sieci z danymi pomiarowymi wybrano je do zastosowania w modelu hamowania pojazdów szynowych.

Tabela 1

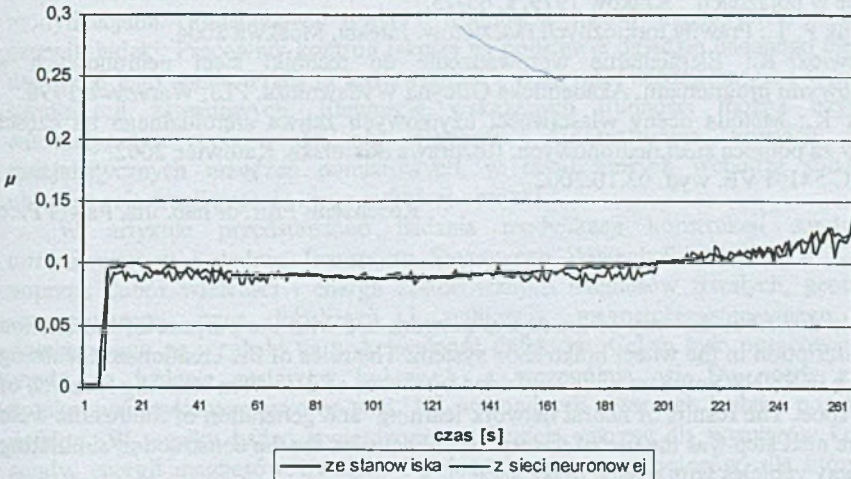
Własności wybranych sieci

Warunki hamowania	Nazwa sieci	Liczba ukrytych neuronów	Błąd MSE	Błąd SSE	Współczynnik korelacji testu
Na sucho	6ksu01.net	20	0,00019	0,90558	0,92
Na mokro	6kmb13.net	20	0,00023	1,1965	0,89



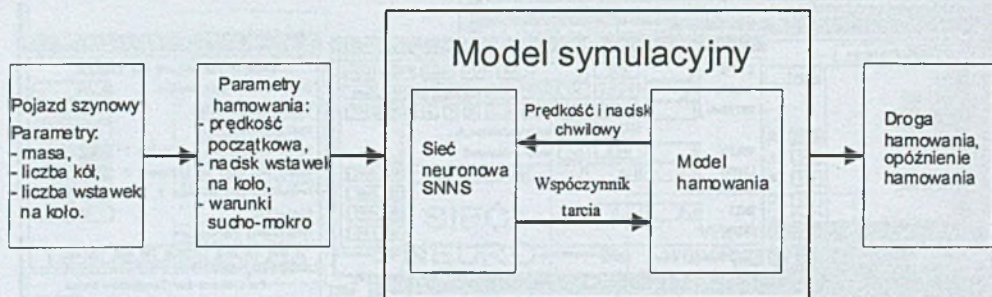
Rys. 3. Program SNNS w trakcie uczenia  
 Fig. 3. Software SNNS in learning mode

Na rysunku 4 zestawiono przykładowy przebieg współczynnika tarcia w funkcji prędkości wygenerowany przez model neuronowy w porównaniu z rzeczywistym zarejestrowanym na stanowisku bezwładnościowym. Z tego zestawienia wynika, że wartości generowane przez model neuronowy są zbliżone do uzyskiwanych w badaniach stanowiskowych.



Rys. 4. Hamowanie nr 31: 100 [km/h], 12 [kN], 2,5 [t], współczynnik korelacji 95%  
 Fig. 4. Braking no. 31: 100 [km/h], 12 [kN], 2,5 [t], correlation coefficient 95%

Opisany model neuronowy został wykorzystany do zbudowania modelu - programu komputerowego, który symuluje proces hamowania pojazdu wyposażonego w kompozytowe wstawki hamulcowe. Podczas pracy wykorzystuje on wyniki generowane przez nauczoną sieć, tj. wartości współczynnika tarcia w trakcie hamowania (rys. 5).



Rys. 5. Model symulacyjny procesu hamowania

Fig. 5. Simulation model of braking process

### 3. WNIOSKI

Sztuczne sieci neuronowe mogą być wykorzystane do opisu zależności współczynnika tarcia w układzie koło - kłoczek od różnych czynników eksploatacyjnych. Dzięki temu mogą znaleźć zastosowanie w modelu symulującym hamowanie pojazdów szynowych wyposażonych w kompozytowe klocki hamulcowe, który pozwala na ocenę ich własności eksploatacyjnych w oparciu o wyniki badań stanowiskowych.

### Literatura

1. Kazarinow W. M., Inoziemce W. W.G., Jasiencow W. F.: Teoreticheskiye osnovy projektirovanja w eksploatacji awtotormozow. Transport 1968.
2. Dzuła S.: Graniczna wartość procentu ciężaru hamującego a intensywność hamowania dla pojazdów szynowych z hamulcami jednostopniowymi. III Krajowa Konferencja „Hamulce w pojazdach”. Kraków 1979, s. 65-75.
3. Grebienjuk P. T.: Prawiła tormoznych rasczietow. Intekst, Moskwa 2004.
4. Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza, PLJ, Warszawa 1998.
5. Witaszek K.: Metoda oceny właściwości użytkowych żeliwa sferoidalnego na części pojazdów za pomocą sieci neuronowych. Rozprawa doktorska, Katowice 2002.
6. Karta UIC 541-4 VE. wyd. 03.10.2002.

Recenzent: Prof. dr hab. inż. Paweł Piec

### Abstract

This article describes the way of the neural network use with the purpose of the friction coefficient description in the wheel brake shoe system. The rules of the creation and learning neural network in SNNS Software were explained by means of data from standing research of plastic brake shoe. The results of neural network learning and generation of the results were presented. The next step was the use of trained neural network for the construction simulating breaking railway vehicles with plastic brake shoe.