

Kazimierz WITASZEK, Mirosław WITASZEK

## ZASTOSOWANIE SIECI NEURONOWYCH DO OCENY ZUŻYCIA ELEMENTÓW POJAZDÓW

**Streszczenie.** W ramach pracy przeprowadzono badania modeli zużycia elementów pojazdów wykonanych z żeliwa sferoidalnego. Do budowy tych modeli wykorzystano sztuczne sieci neuronowe. Poprawność działania sieci oceniano za pomocą tzw. błędu zestawu testującego. W pracy dobrano strukturę i metodę uczenia sieci neuronowych zapewniające wymaganą dokładność działania modelu zużycia.

## USE OF NEURAL NETWORKS AS A TOOL FOR WEAR ASSESSMENT OF VEHICLE ELEMENTS

**Summary.** In this work research of wear models of spheroidal graphite cast iron vehicles' elements have been carried out. Artificial neural networks were used as these models. Models' quality has been assessed with the aid of test's set error. In this work a structure and training method that ensures required accuracy have been selected.

### 1. WPROWADZENIE


Liczne elementy pojazdów pracują w warunkach tarcia wchodząc w skład systemów trybomechanicznych, w których zachodzą procesy zużycia [1-3]. Decydują one o trwałości i niezawodności elementów. Procesy zużycia mają skomplikowany charakter, gdyż obejmują różnorodne zjawiska fizyczne i chemiczne, często działające jednocześnie i wywierające wpływ na siebie nawzajem.

Zużycie jest zależne od wielu czynników [3-5], które obejmują dwie grupy: parametry materiałowe i eksploatacyjne [6, 7]. Parametry eksploatacyjne określają warunki współpracy elementów, jak np. obciążenie, ruch względny, czas trwania współpracy czy smarowanie. Czynniki materiałowe charakteryzują skład chemiczny, strukturę i właściwości mechaniczne materiałów elementów pary ciernej. Przy modelowaniu zużycia zachodzi konieczność wyboru najistotniejszych parametrów. Stanowią one wielkości wejściowe modelu.

## 2. BADANIA WŁASNE

W pracy zastosowano sieci neuronowe w charakterze modelu opisującego zużycie elementów wykonanych z żeliwa sferoidalnego. Materiał ten jest szeroko stosowany w budowie pojazdów samochodowych. Doboru wielkości wejściowych i wyjściowych modelu dokonano na podstawie literatury [6-9]. Jako czynniki eksploatacyjne dobrano: nacisk, prędkość względną, współczynnik tarcia i temperaturę jednego z elementów w pobliżu węzła tarcia. Jako parametry materiałowe przyjęto: mikrotwardość osnowy, udział powierzchniowy grafitu i ilość wydzieleni grafitu na  $\text{mm}^2$ .

Jako wielkość wyjściową modelu przyjęto intensywność zużycia, gdyż do chwili obecnej jest ona najpopularniejszą miarą zużycia, stosowaną w licznych pracach. Spośród wielu rodzajów intensywności zużycia wybrano liniową intensywność zużycia, ponieważ zwykle o trwałości części pojazdów, jak np. krzywki wałków rozrządu, popychacze, pierścienie czy tuleje cylindrowe, decydują wymiary liniowe ulegające zmianom wskutek zużycia. Przyjęte parametry wejściowe i wyjściowe neuronowego modelu zużycia przedstawiono na rys. 1.



Rys. 1. Wielkości wejściowe i wyjściowe neuronowych modeli zużycia

Fig. 1. Input and output signals of neural wear models

Poprzez wybór parametrów wejściowych i wyjściowych sieci zostały jednoznacznie zdefiniowane rozmiary warstwy wejściowej i wyjściowej sieci neuronowych. Warstwa wejściowa składała się z siedmiu neuronów, natomiast wyjściową stanowił jeden neuron. W ramach doboru struktury możliwe były więc zmiany liczby i wielkości warstw ukrytych oraz modeli tworzących je neuronów.

Do przeprowadzenia procesu uczenia sieci mającej stanowić model zużycia niezbędne było przygotowanie danych stanowiących ciąg uczący i zestaw testowy. Dane te uzyskano na podstawie wstępnie opracowanych wyników laboratoryjnych badań zużycia próbek z żeliwa sferoidalnego gatunku EN-GJS-900-2. Próbkę poddano hartowaniu i odpuszczaniu uzyskując twardości 37 – 52 HRC. Badania przeprowadzono na testerze trybologicznym typu T-01M pracującym w układzie trzpień – tarcza. Metodologię badań szerzej opisano w pracy [10].

Przygotowane zestawy danych uczących obejmowały od 300 do 500 kompletów wielkości wejściowych sieci oraz odpowiadających im wyników badań zużycia. Zestawy testujące zawierały kilkadziesiąt przykładów nie występujących w ciągu uczącym.

Do symulacji sieci neuronowych wykorzystano dwa programy: Stuttgart Neural Network Simulator (SNNS v4.2) oraz Qnet 2000. Za ich pomocą zbudowano i nauczono szereg sieci neuronowych o różnych strukturach.

W tabeli 1 przedstawiono wyniki testów sieci neuronowych o różnych strukturach. Z tabeli tej wynika, że struktura sieci wywiera wpływ na wartość generowanego przez sieć błędu. Błąd sieci o jednej warstwie ukrytej był najczęściej większy od błędów sieci o bardziej rozbudowanych strukturach. Ponadto błąd testu sieci modelującej jednocześnie zużycie przy tarcu na sucho i w obecności środka smarnego był wyższy niż w przypadku zastosowania osobnych sieci do modelowania zużycia przy obu tych rodzajach tarcia.

Wśród sieci o dwóch warstwach ukrytych najmniejszymi błędami charakteryzowała się sieć o strukturze 7-7-3-1 (rys. 2). Dla sieci o trzech warstwach ukrytych zaobserwowane błędy były większe. Do dalszych badań wybrano więc wspomnianą sieć o strukturze 7-7-3-1. W trakcie tych badań zmieniano funkcje aktywacji neuronów oraz metody uczenia sieci. Rezultaty testów tych sieci zestawiono w tabeli 2. Wskazują one na niewielki wpływ przyjętych metod uczenia na ostateczne wartości błędów. Zastosowanie metod heurystycznych Quickprop i RPROP jednak znacząco skróciło czas procesu uczenia wyrażony liczbą cykli uczących. Większy wpływ na wartość końcowego błędu sieci wywiera zastosowana funkcja aktywacji neuronów. Najmniejszy błąd zaobserwowano dla funkcji sigmoidalnej.

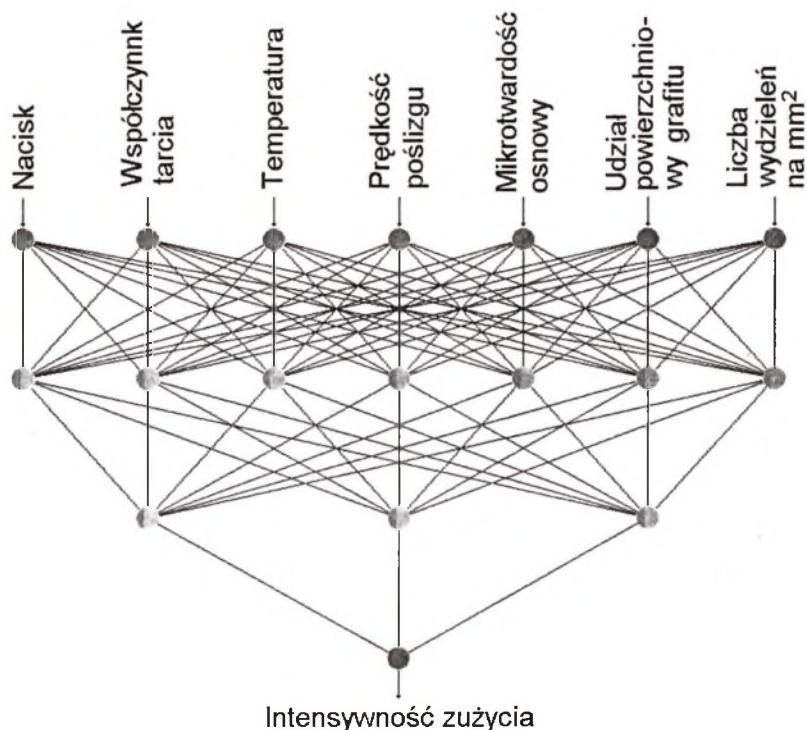
Do modelowania zużycia żeliwa sferoidalnego wykorzystano ostatecznie dwie sieci o strukturze 7-7-3-1 i sigmoidalnej funkcji aktywacji neuronów. Umożliwiły one określanie zużycia żeliwa sferoidalnego zgodnie z zadanymi parametrami eksploatacyjnymi i materiałowymi. Pierwsza z nich przy tarcu na sucho, a druga w warunkach styku smarowanego.

Tabela 1

## Wyniki testu sieci neuronowych o różnych strukturach

Lp.	Struktura	Metoda uczenia (*)	Długość ciągu uczącego (sucho / olej)	Długość ciągu testującego (sucho / olej)	Błąd dla zestawu testującego (RMS)		
					tarcie suche	styk smarowany	oba przypadki
1	7-10-1	LRBMA	390 / 320	98 / 82	0,04636	0,04996	0,06918
2	7-3-6-1	LRBMA	390 / 320	98 / 82	0,05042	0,04897	0,06203
3	7-3-7-1	LRBMA	390 / 320	98 / 82	0,04809	0,05426	0,07108
4	7-4-2-1	LRBMA	390 / 320	98 / 82	0,04193	0,05228	0,06681
5	7-4-4-1	LRBMA	390 / 320	98 / 82	0,04196	0,05198	0,10302
6	7-5-4-1	LRBMA	390 / 320	98 / 82	0,03879	0,05051	0,05881
7	7-5-5-1	LRBMA	390 / 320	98 / 82	0,03988	0,03617	0,05652
8	7-6-3-1	LRBMA	390 / 320	98 / 82	0,03846	0,04255	0,05793
9	7-6-4-1	LRBMA	390 / 320	98 / 82	0,04082	0,05029	0,07377
10	7-7-3-1	LRBMA	390 / 320	98 / 82	0,03432	0,03559	0,05017
11	7-7-4-1	LRBMA	390 / 320	98 / 82	0,03529	0,03785	0,05270
12	7-7-5-1	LRBMA	390 / 320	98 / 82	0,03601	0,03492	0,05802
13	7-10-6-1	LRBMA	390 / 320	98 / 82	0,04201	0,03925	0,05582
14	7-4-4-2-1	LRBMA	390 / 320	98 / 82	0,04196	0,04285	0,05448
15	7-5-4-2-1	LRBMA	390 / 320	98 / 82	0,04353	0,04516	0,06377

(\*) – LRBMA – Backpropagation with momentum and adaptive learn rate control – wsteczna propagacja błędu z momentem i adaptacyjnym doborem współczynnika uczenia



Rys. 2. Struktura sieci użytych do prognozowania zużycia żeliwa sferoidalnego  
 Fig. 2. The structure of networks used for forecasting of spheroidal cast iron wear


Tabela 2

Wyniki testu sieci neuronowych o strukturze 7-7-3-1


Lp.	Struktura	Metoda uczenia <sup>(*)</sup>	Funkcja aktywacji neuronów sieci <sup>(**)</sup>	Ilość cykli uczących	Błąd dla zestawu testującego		
					tarcie suche	styk smarowany	oba przypadki
1	7-7-3-1	LRBMA	Tanh	50 000	0,04103	0,03578	0,05933
2	7-7-3-1	LRBMA	Sech	50 000	0,04462	0,04571	0,05777
3	7-7-3-1	LRBMA	Gauss	50 000	0,04189	0,04724	0,06648
4	7-7-3-1	LRBMA	Sigmoida	50 000	0,03432	0,03559	0,05017
5	7-7-3-1	RROP	Sigmoida	45	0,03383	0,03501	0,05525
6	7-7-3-1	Quickprop	Sigmoida	350	0,03498	0,03611	0,05243

(\*\*) – Tanh – tangens hiperboliczny, Sech – sekans hiperboliczny, Gauss – funkcja Gaussa

Aby zbadać wpływ poszczególnych czynników wejściowych sieci na intensywność zużycia, dokonano tzw. analizy wrażliwościowej danych uczących [11]. W jej wyniku dla poszczególnych wielkości wejściowych otrzymano tzw. współczynniki ważności, które określają, w jakim stopniu wielkości te wpływają na wielkość wyjściową (rys. 3 i 4).



Rys. 3. Współczynniki ważności czynników wejściowych sieci przy tarcii suchym  
 Fig. 3. Importance coefficients of input factors by dry friction



Rys. 4. Współczynniki ważności czynników wejściowych sieci przy tarcii ze smarowaniem  
 Fig. 4. Importance coefficients of input factors by lubricated friction

### 3. UWAGI KOŃCOWE

Badania modelowe przeprowadzone w pracy wskazują na to, że sztuczne sieci neuronowe mogą być wykorzystane do modelowania zużycia elementów pojazdów. Większą dokładność modeli otrzymano dla dwóch sieci, z których jedna służy do określania intensywności zużycia przy tarcia na sucho a druga – w obecności środka smarnego, niż w przypadku jednej sieci dla obu tych rodzajów tarcia. Stwierdzono również znaczny wpływ struktury sieci i funkcji przejścia neuronów na błąd testu. Najniższy błąd otrzymano dla sieci o strukturze 7-7-3-1, której neurony mają sigmoidalną funkcję przejścia. Zastosowanie różnych metod uczenia tej sieci wywierało istotny wpływ na długość procesu uczenia bez wyraźnego wpływu na błąd testu.

Współczynniki ważności czynników wejściowych sieci wskazują, że nacisk wywiera największy wpływ na intensywność zużycia elementów z żeliwa sferoidalnego zarówno przy tarcia na sucho, jak i w obecności środka smarnego. Kolejność pozostałych czynników była zależna od obecności środka smarnego. Na przykład w przypadku tarcia na sucho drugi co do ważności jest wpływ mikrotwardości osnowy, a dla tarcia ze smarowaniem – udział powierzchniowy grafitu. Taki rezultat jest zgodny z oczekiwaniami, gdyż przy tarcia na sucho dochodzi do znacznej ilości kontaktów metalicznych współpracujących powierzchni i twardość materiału osnowy w większym stopniu decyduje o oddzielaniu się materiału w formie produktów zużycia niż występuje to dla tarcia w obecności środka smarnego. Środek smarny oddziela współpracujące powierzchnie przeciwdziałając kontaktom metalicznym. Obecność grafitu w środku smarnym dodatkowo utrudnia stykanie się metalicznych wierzchołków nierówności powierzchni. Podobnie ilość wydzielenń grafitu na jednostkę powierzchni wywiera silniejszy wpływ na zużycie przy tarcia na sucho niż w oleju. Wiąże się to z osłabieniem materiału warstwy wierzchniej, który przy tarcia na sucho przenosi większe siły styczne. Może to intensyfikować zmęczenie stykowe.

Wpływ temperatury elementów pary cieiernej na ich zużycie jest większy w przypadku tarcia ze smarowaniem olejem niż na sucho. Wynika to ze spadku lepkości oleju powodującego pogorszenie się jakości smarowania, co zwiększało zużycie. Prędkość ruchu względnego wywiera w podobnym stopniu wpływ na zużycie przy tarcia na sucho i w obecności środka smarnego.

### Literatura

1. DIN 50 320. Verschleiß. Begriffe, Systemanalyse von Verschleißvorgängen, Gliederung des Verschleißgebietes.
2. Czichos H.: Tribology a system aproach to the science and technology of friction, lubrication and wear. Elsevier Amsterdam – Oxford – New York 1978.
3. Tribologia i tribotechnika. Praca zbiorowa pod redakcją M. Szczerka i M. Wiśniewskiego. Wydawnictwo Instytutu Technologii Eksploatacji, Radom 2000.
4. Wybrane zagadnienia zużywania się materiałów w ślizgowych węzłach tarcia. Praca zbiorowa pod redakcją W. Zwierzyckiego. PWN, Warszawa – Poznań 1990.
5. Gierk A.: Zużycie ściernych metalowych elementów roboczych. Politechnika Śląska skrypt nr 1752, Gliwice 1993.
6. Stanik Z.: Analiza przyczyn nadmiernego zużycia krzywek wałków rozrządu. Praca doktorska. Instytut Transportu Politechniki Śląskiej, Katowice 2002.
7. Witaszek M.: Ocena zużycia kół kolejowych. Praca doktorska. Instytut Transportu Politechniki Śląskiej, Katowice 1999.

8. Seetharamu S., Sampathkumaran P., Kumar R.K., Narasimha Murthy K., Martin Jebraj P.: Abrasion and erosion resistance of permanent moulded austempered ductile iron. *Wear*, 167 (1993), s. 1-8.
9. Dai W.S., Chen L.H., Lui T.S.: A study on SiO<sub>2</sub> particle erosion of flake graphite and spheroidal graphite cast irons. *Wear*, 239 (2000), s. 143-152.
10. Witaszek K.: Metodyka badania zużycia żeliwa sferoidalnego na stanowisku T-01M. Międzynarodowa Studencka Sesja Naukowa: Materiały i Technologie XXI wieku, Katowice 10.05.2001.
11. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne, Warszawa 1996.

Recenzent: Dr hab. inż. Edmund TASAK, prof. AGH

### Abstract

This article describes modelling of wear of vehicles' elements with the aid of artificial neural networks. Input and output parameters of models were selected on the basis of literature. Different nets were used as wear models. The best modelling accuracy was observed for two networks type 7-7-3-1: first for dry friction and second for lubricated contact. These nets enabled analysis of influence of input parameters on wear rate. Contact pressure, caused by load, has been found as the most important factor both by dry and lubricated conditions.

*Praca wykonana w ramach badań własnych BW-465/RM10-1/2002.*