



## Zastosowanie sztucznych sieci neuronowych do modelowania zużycia przy tarciiu granicznym

BOLESŁAW GIEMZA, KRZYSZTOF GOCMAN,  
TADEUSZ KAŁDOŃSKI

Wojskowa Akademia Techniczna, Wydział Mechaniczny,  
Instytut Pojazdów Mechanicznych i Transportu,  
00-908 Warszawa, ul. S. Kaliskiego 2

**Streszczenie.** W artykule przedstawiono wybrane wyniki badań wpływu obciążenia i prędkości obrotowej na zużycie badanego węzła tarcia — kulek testowych aparatu czterokulowego. Dokonano analizy wyników badań oraz zamodelowano zużycie testowego węzła tribologicznego za pomocą sztucznych sieci neuronowych (SSN). Zastosowano różne rodzaje SSN i algorytmy uczące w celu uzyskania jak najlepszej generalizacji i jakości uzyskanego modelu.

**Słowa kluczowe:** tarcie graniczne, smarność, sztuczne sieci neuronowe, SNN, aparat czterokulowy  
**Symbole UKD:** 531.43

### 1. Wykaz symboli i oznaczeń, definicje

- $\Theta$  — temperatura otoczenia [ $^{\circ}\text{C}$ ],  
 $v$  — wilgotność względna powietrza [%],  
 $d_{si}$  — średnica skazy [mm],  
 $d_{s\acute{s}}$  — średnia średnic skaz [mm],  
 $G_{oz}$  — graniczne obciążenie zużycia [MPa],  
GRNN — sieć realizująca regresję uogólnioną,  
 $I_h$  — wskaźnik zużycia pod obciążeniem [daN],  
 $L_t$  — praca tarcia [kJ],  
MLP — perceptron wielowarstwowy,  
 $n$  — prędkość obrotowa wrzeciona [obr/min],

$N_u$	— liczba próbek uczących SSN
$N_w$	— liczba wag SSN
$P$	— obciążenie węzła tarcia [N],
$p_a$	— ciśnienie atmosferyczne [hPa],
$P_t$	— obciążenie zacierające [daN],
$P_z$	— obciążenie zespawania [daN],
RBF	— sieć o radialnych funkcjach bazowych,
SSN	— sztuczna sieć neuronowa,
$t$	— czas [s],
$T$	— temperatura środka smarnego w węźle tarcia [°C].

**Błąd uczący, błąd walidacyjny, błąd testowy** — pierwiastki sum kwadratów błędów poszczególnych przypadków wyznaczanych przez funkcję błędu sieci odpowiednio dla zbiorów uczącego, walidacyjnego i testowego [6].

**Jakość uczenia, jakość walidacyjna, jakość testowa** — dla sieci klasyfikujących jest to proporcja poprawnie zakwalifikowanych przypadków [6].

**Korelacja** — standardowy współczynnik korelacji R Persona dla wartości zadanej i wartości otrzymanej na wyjściu sieci [6].

**Średni błąd** — średnia wartość błędu rozumiana jako różnica pomiędzy wartością zadaną i wartością uzyskaną na wyjściu sieci [6].

## 2. Wstęp

Jednym z istotnych problemów współczesnej tribologii jest poszukiwanie modeli tarcia i zużycia uwzględniających wszystkie zjawiska zachodzące w węzłach tribologicznych. Mniej lub bardziej znane są mechanizmy poszczególnych rodzajów zużycia, jednak nie potrafimy precyzyjnie przewidywać zużycia określonego węzła tribologicznego. Wynika to częściowo z tego, że w rzeczywistych warunkach różne rodzaje i formy zużycia oddziałują na siebie, a ponadto znane mechanizmy zużycia są niestety niedoskonałe. Z punktu widzenia konstruktorów maszyn pożądane byłoby opracowanie metod prognozowania wartości zużycia różnych węzłów tribologicznych [3, 8, 9, 10]. W ostatnich latach powstało wiele modeli jednak nie odzwierciedlają one w pełni zjawisk zachodzących w węzłach tribologicznych, szczególnie w warunkach tarcia granicznego [3, 8, 9, 10]. Złożony i nieliniowy charakter zjawisk tarciovych wymusza poszukiwanie innych niż analityczne modeli pozwalających na przykład na predykcję wartości zużycia. Ze względu na swoje właściwości obiecującym narzędziem mogą stać się sztuczne sieci neuronowe. W odróżnieniu od istniejących obecnie modeli pozwalają one na analizę wieloparametrową zwłaszcza wobec występujących w takiej sytuacji trudności wykrywania tradycyjnymi metodami wpływu pojedynczych parametrów a zwłaszcza interakcji między nimi.

W niniejszym artykule podjęto próbę modelowania za pomocą SSN parametrów charakteryzujących zużycie badanego węzła tarcia (kulek w aparacie czterokulowym) w zależności od parametrów pracy węzła. Opracowano również, w oparciu o SSN, klasyfikator określający stan współpracujących powierzchni elementów testowych.

### 3. Metodyka badań

#### 3.1. Obiekt badań

Do przeprowadzonych testów wykorzystano olej smarowy ochronny otrzymywany z przeróbki ropy naftowej. Podstawowe właściwości oleju określone wg stosownych norm przedstawiono w tabeli 1.

TABELA 1

Właściwości fizyczno-chemiczne badanego oleju smarowego (PN-77/C-96080)

Własność	Nr normy	Wartość
lepkość kinematyczna, w temp. 40°C	PN-EN ISO 3104:2004	212 mm <sup>2</sup> /s
wskaźnik lepkości	PN-79/C-04013	96
temperatura zapłonu	PN-EN ISO 2719:2003	200°C
właściwości smarne, obciążenie zespawania	PN-76/C-04147	245 daN

Jako kulki testowe wykorzystano kulki łożyskowe ½” zgodne z PN-83/M-8452.

#### 3.2. Stanowisko badawcze


Badania były wykonywane na testerze tribologicznym T-02 (aparacie czterokulowym) (rys. 1 i 2). Maszyna ta służy do oceny własności smarnych olejów i smarów m.in. wg normy PN-76/C-04147, tzn. do określenia:

- wskaźnika zużycia pod obciążeniem  $I_h$  i obciążenia zespawania  $P_z$ ,
- obciążenia zacierającego  $P_t$ ,
- granicznego obciążenia zużycia  $G_{oz}$ .


Warunki współpracy elementów węzła tarcia aparatu czterokulowego są następujące:

- rodzaj styku: skoncentrowany punktowy, potrójny, utworzony przez powierzchnię czterech kulek o średnicy ½”,
- rodzaj ruchu: ślizgowy o stałych prędkościach ścinania odpowiadających 50 do 1500 obr/min górnej kulki,

- obciążenie styku: zmieniane od 0 do 7848 N (800 kG) — może narastać w sposób ciągły z prędkością 408,8 N/s,
- sposób smarowania: zanurzeniowy lub przez jednorazowe nakładanie próbki badanego środka smarowego przed rozpoczęciem testu.



Rys. 1. Schemat węzła tribologicznego: 1 — górna kulka; 2 — dolne kulki; 3 — wrzeciono; 4 — uchwyt kulek dolnych



Rys. 2. Widok ogólny testera T-02

Aparat czterokulowy T-02 jest wyposażony w mikroprocesorowy system sterowania i pomiarów [1]. Integralną częścią systemu pomiarowego są czujniki:

- tensometryczny czujnik siły (do wyznaczania momentu tarcia),
- czujnik termoelektryczny do pomiaru temperatury węzła tarcia,
- czujnik impulsów do pomiaru prędkości obrotowej.

### 3.3. Przebieg badań

Badania na aparacie czterokulowym zostały przeprowadzone według własnej metodyki w oparciu o metodę wyznaczania granicznego obciążenia zużycia  $G_{oz}$ . Realizowano 60-sekundowe przebiegi czasowe przy stałym obciążeniu w zakresie 500-2500 N i prędkości obrotowej wrzeciona 500-1500 obr/min.

W czasie pomiarów rejestrowano następujące wielkości:

- opory ruchu (moment tarcia)  $M_t$  [Nm],
- temperaturę środka smarowego w węźle tribologicznym  $T$  [°C],
- temperaturę otoczenia  $\Theta$  [°C],
- ciśnienie atmosferyczne  $p_a$  [hPa],
- wilgotność względną powietrza  $v$  [%].

Każdorazowo określano zużycie elementów węzła tribologicznego poprzez pomiar średnic skaz zużycia kulek  $d_{si}$ . Średnicę skaz mierzone na dolnych kulkach wzdłuż i w poprzek śladów zużycia. Na podstawie zmierzonych wartości wyliczano wartość średnią  $d_{ss}$  zgodnie z (1):

$$d_{ss} = \frac{1}{6} \sum_{i=1}^6 d_{si}. \quad (1)$$


Obliczono również pracę tarcia  $L_t$  na podstawie zmierzonego oporu ruchu (momentu tarcia)  $M_t$  zgodnie z (2):

$$L_t = \frac{\pi \cdot n}{30} \int_{t_0}^{t_k} M_t dt. \quad (2)$$

#### 4. Wyniki badań

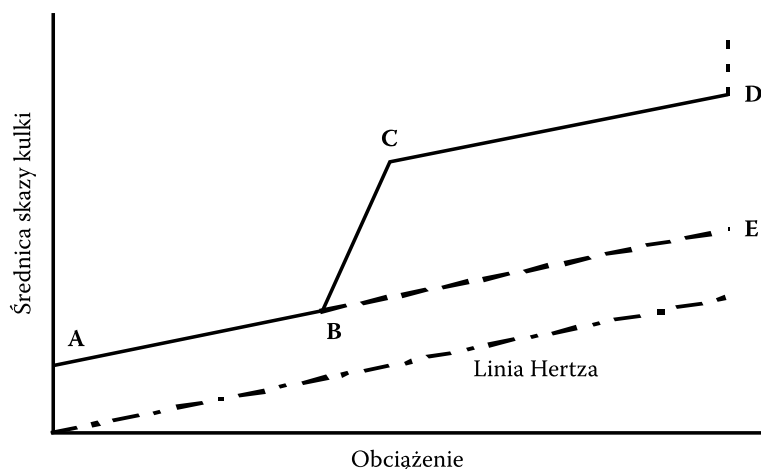
Wyniki badań średnic skaz zużycia kulek testowych przedstawiono na rysunku 3.

Uzyskane przebiegi zużycia kulek testowych nie odbiegają od opisanych w literaturze [3, 9] mechanizmów zużywania na aparacie czterokulowym.




Rys. 3. Średnie średnic skaz  $d_{ss}$  kulek testowych w funkcji obciążenia  $P$  dla różnych prędkości obrotowych wrzeciona  $n$

Zużycie kulek wzrasta wraz z obciążeniem oraz prędkością obrotową wrzeciona. Przedziałami są to zależności zbliżone do liniowych, przy czym charakterystyczne jest występowanie granicznego obciążenia, przy którym następuje (dla danej prędkości obrotowej) gwałtowny wzrost wartości średnic skaz kulek — zacieranie wężła tarcia (rys. 3, 4).



Rys. 4. Modelowy przebieg zużycia kulek w funkcji obciążenia: ABE — linia kompensacyjna; B — największe obciążenie niezacierające; BC — początek zacierania; C — obciążenie zacierania; CD — intensywne zużywanie; D — zespanianie [3]

Na rysunku 5 przedstawiono przykładowe fotografie średnic skaz zarejestrowanych na mikroskopie optycznym w jasnym polu. Zmiana charakteru zużycia się badanego wężła tarcia skutkuje oprócz zwiększenia śladu skazy zmianą stanu powierzchni współpracujących elementów.



Rys. 5. Ślady zużycia — skazy — kulek testowych dla  $n = 1250$  obr/min: a)  $P = 500$  N; b)  $P = 1000$  N; c)  $P = 2000$  N

Interesującym faktem jest to, że dla najmniejszego zadawanego obciążenia (500 N) wraz ze wzrostem prędkości obrotowej zaobserwować można nawet nieznaczne zmniejszenie zużycia kulek. Fakt ten można wytłumaczyć analizując wykresy momentów tarcia w funkcji czasu (rys. 5). Dla zadanych prędkości obrotowych obciążenie 500 N jest zbyt małe by spowodować trwałe przerwanie warstwy granicznej, w skojarzeniu natomiast wzrost prędkości obrotowej powoduje łatwiejsze występowanie efektów hydrodynamicznych — tworzenie bardziej trwałego, bo o większej grubości klina smarnego mogącego przenieść większe obciążenie.


Wyniki obliczeń pracy tarcia  $L_t$  oraz zarejestrowane wartości maksymalnego momentu tarcia  $M_{t,max}$  i przyrostu temperatury środka smarnego  $\Delta T$  przedstawiono w tabeli 2.

TABELA 2

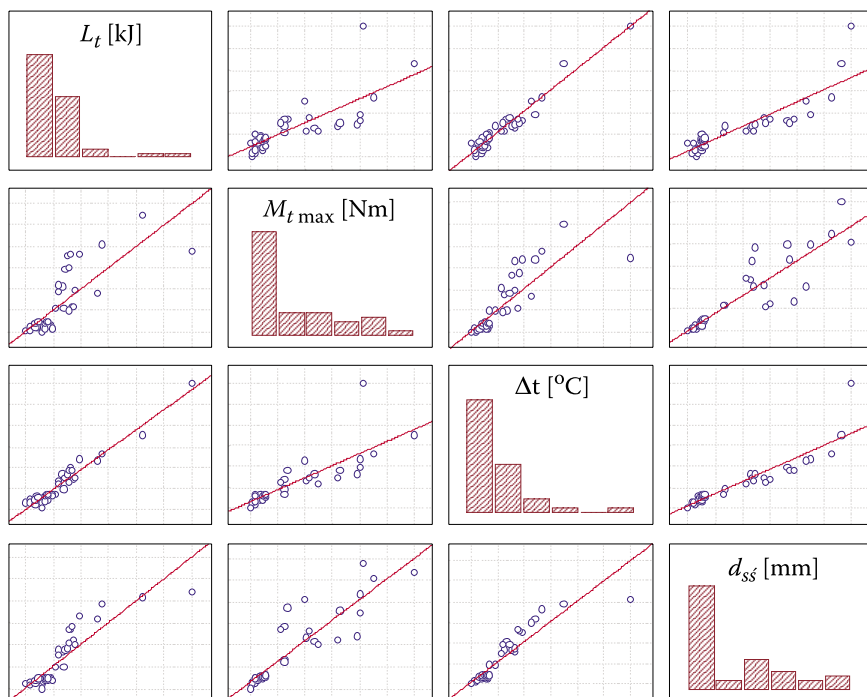
Wartość pracy tarcia  $L_t$ , maksymalnego momentu tarcia  $M_{t,max}$  oraz przyrostu temperatury oleju smarowego  $\Delta T$  badanego węzła tribologicznego

P [N]	n [obr/min]														
	500			750			1000			1250			1500		
	$\Delta T$ [°C]	$L_t$ [kJ]	$M_{t,max}$ [Nm]	$\Delta T$ [°C]	$L_t$ [kJ]	$M_{t,max}$ [Nm]	$\Delta T$ [°C]	$L_t$ [kJ]	$M_{t,max}$ [Nm]	$\Delta T$ [°C]	$L_t$ [kJ]	$M_{t,max}$ [Nm]	$\Delta T$ [°C]	$L_t$ [kJ]	$M_{t,max}$ [Nm]
500	1,3	1,17	0,38	1,3	1,80	0,39	1,1	2,34	0,55	1,6	3,18	0,42	0,5	3,20	0,34
700	–			–			–			1,9	3,59	0,54	3,0	4,50	0,54
800	–			–			2,6	3,34	0,57	2,2	3,94	0,70	2,7	4,55	0,54
900	–			–			2,9	3,73	0,65	3,2	4,94	1,58	5,5	6,44	1,49
1000	2,0	1,64	0,55	3,0	2,48	0,55	3,0	3,77	0,69	4,3	5,81	1,58	6,1	6,95	1,63
1100	2,2	2,32	0,79	2,7	3,53	0,79	3,2	4,22	0,71	–			–		
1200	2,3	2,35	0,79	3,0	3,75	0,82	3,2	4,11	0,71	–			–		
1300	2,3	2,62	0,87	3,0	3,92	0,88	6,4	7,16	2,54	–			–		
1400	2,4	2,72	0,90	3,2	3,93	0,87	–			–			–		
1500	7,2	5,66	2,75	5,7	5,21	2,46	7,9	6,52	3,73	7,9	6,90	1,71	9,9	10,04	2,42
2000	6,6	6,00	3,65	8,5	6,68	4,48	10,4	7,84	4,49	11,4	10,57	5,00	25,5	21,62	4,62
2500	7,3	6,17	4,35	–			15,0	15,70	6,53	–			–		

Podane w tabeli 2 wartości obrazują pośrednio proces tarcia badanego węzła. Na rysunku 6 pokazano zależności pomiędzy badanymi parametrami. Widać wyraźnie, że wzrost zużycia kulek testowych wiąże się bezpośrednio z wysokimi oporami ruchu ( $M_{t,max}$  i  $L_t$ ) oraz większym przyrostem temperatury  $\Delta T$ .



Rys. 6. Przykładowy przebieg zmian momentu tarcia  $M_t$  w funkcji czasu ( $n = 1250$  obr/min)



Rys. 7. Wykres macierzowy rozrzutu badanych parametrów



## 5. Model neuronowy

Na podstawie uzyskanych wyników podjęto próbę modelowania zużycia węzła tarcia za pomocą SSN. Są one narzędziem opracowanym z wykorzystaniem wiedzy na temat budowy i funkcjonowania neuronowych sieci biologicznych, których głównym zadaniem jest przetwarzanie i analiza informacji. Jako narzędzie budowy i analizy modeli wykorzystano pakiet STATISTICA Neural Networks 6.0 PL.

Strukturę SSN stanowi zespół połączonych ze sobą neuronów, które są elementami przetwarzającymi zbiór sygnałów wejściowych w sygnał wyjściowy. Budowa modelu neuronowego wymaga przeprowadzenia procesu uczenia, w trakcie którego następuje dobór wartości wag i parametrów sieci zgodnie z przyjętym kryterium minimalizacji błędu popełnianego przez sieć. O jakości sieci decyduje jej zdolność do generalizacji tzn. zdolność do prawidłowego przewidywania — odtwarzania z danego zakresu danych z możliwie małym (akceptowalnym) błędem [4, 5, 7].

W trakcie budowy SSN bardzo istotna jest podstawowa znajomość modelowanego procesu w celu uniknięcia tworzenia fałszywych zależności, nie mających fizycznego uzasadnienia [2].

### 5.1. Metodyka budowy sieci neuronowej

Dane uwzględnione w procesie modelowania zostały podzielone na trzy grupy: uczące, walidacyjne i testujące. Zbiór uczący składał się z wektorów biorących udział w modyfikowaniu wartości wag połączeń neuronów sieci. Po prezentacji każdej epoki nastąpiło obliczenie błędu uczenia sieci. Następnie na wejście podawane były sygnały wektorów należących do zbioru walidacyjnego i obliczano błąd walidacji. Po zakończeniu procesu uczenia model poddawany był testowaniu w celu określenia jego zdolności do generalizacji. Należy mieć na uwadze, że dane wykorzystane do testowania sieci nie były wcześniej przez nią „widziane” i nie brały udziału w uczeniu sieci.

W opracowanych modelach neuronowych jako sygnały wejściowe przyjęto:

- obciążenie węzła tarcia  $P$ ,
- prędkość obrotową wrzeciona  $n$ .

Ze względu na ograniczoną liczbę danych pomiarowych oraz niepełne odwzorowanie obszaru zmian parametrów otoczenia ( $\Theta, p_a, v$ ) pominięto je w modelowaniu zużycia.

Zdolność do generalizacji SSN jest miarą jej jakości. Dysponując ograniczonym zbiorem danych pomiarowych użytkownik jest zmuszony do dobrania takiej architektury SSN aby spełniała ona określone warunki tzn. liczba wag występujących w sieci (połączeń pomiędzy neuronami) powinna być kilkakrotnie mniejsza od liczby próbek uczących [5]. Dla przedstawionego problemu autorzy

starali się, aby całkowita liczba wag  $N_w$  była mniejsza co najmniej 3-4 razy od liczby próbek uczących  $N_u$ .

## 5.2. Neuronowy model zużycia

Za sygnały wyjściowe — odpowiedź SSN przyjęto dla modelu zużycia:

- średnicę skaz kulek  $d_{ss}$  — jako miarę wielkości zużycia elementów testowych,
- pracę tarcia  $L_t$  — jako miarę oporów ruchu w procesie zużywania.

Zbudowano SSN o dwóch rodzajach architektury:

- z dwoma wyjściami (razem dla  $d_{ss}$  i  $L_t$ ),
- z pojedynczym wyjściem (osobno dla  $d_{ss}$  i  $L_t$ ).

W poszukiwaniu najbardziej odpowiedniej sieci testowano następujące ich rodzaje:

- sieci liniowe,
- sieci wielowarstwowe perceptronowe (MLP),
- sieci radialne (RBF),
- sieci realizujące regresję uogólnioną (GRNN).

Przeprowadzono analizę wielu modeli, zwracając uwagę na zachowanie różnorodności sieci, metody ich uczenia oraz inne parametry takie jak szybkość uczenia, liczba epok, liczbę neuronów w warstwach itd. W wyniku tego otrzymano zbiór wielu różnych modeli, które lepiej lub gorzej oddawały charakter występujących procesów. Zdecydowanie najlepsze wyniki uzyskano dla sieci wielowarstwowych perceptronowych (MLP). Wartość błędu testowego uzyskanego przez te sieci była poniżej 5%. Dla sieci radialnych (RBF) i sieci realizujących regresję uogólnioną (GRNN) przekraczała ona 15%. Ostatecznego modelu poszukiwano więc tylko wśród sieci MLP. Podsumowanie najlepszych testowanych sieci przedstawiono w tabelach 3, 4 i 5.

TABELA 3

Podsumowanie testowanych modeli zużycia (razem dla  $d_{ss}$  i  $L_t$ )

Nr SSN	typ	błąd ucz.	błąd walid.	błąd test.	korelacja		średni błąd	
					$d$	$L$	$d$	$L$
12	MLP 2:2-3-2:2	0,056	0,073	0,093	0,961	0,977	-0,004	-0,003
20	MLP 2:2-4-2:2	0,044	0,047	—	0,979	0,987	-0,002	-0,014
8	MLP 2:2-2-1-2:2	0,117	0,025	0,042	0,910	0,857	-0,109	-0,231
15	MLP 2:2-2-1-2:2	0,062	0,029	0,093	0,961	0,970	0,018	-0,001
9	MLP 2:2-1-3-2:2	0,107	0,024	0,071	0,922	0,891	-0,056	-0,606

TABELA 4

Podsumowanie testowanych modeli zużycia (dla  $d_{ss}$ )

Nr SSN	typ	błąd ucz.	błąd walid.	błąd test.	korelacja	średni błąd
11	MLP 2:2-2-1:1	0,085	0,037	0,035	0,946	-0,0001
12	MLP 2:2-4-1:1	0,084	0,037	0,013	0,947	0,003
13	MLP 2:2-4-1:1	0,113	0,034	0,078	0,939	0,011
14	MLP 2:2-4-1:1	0,105	0,031	0,040	0,949	0,017
15	MLP 2:2-4-1:1	0,071	0,027	0,008	0,963	0,015

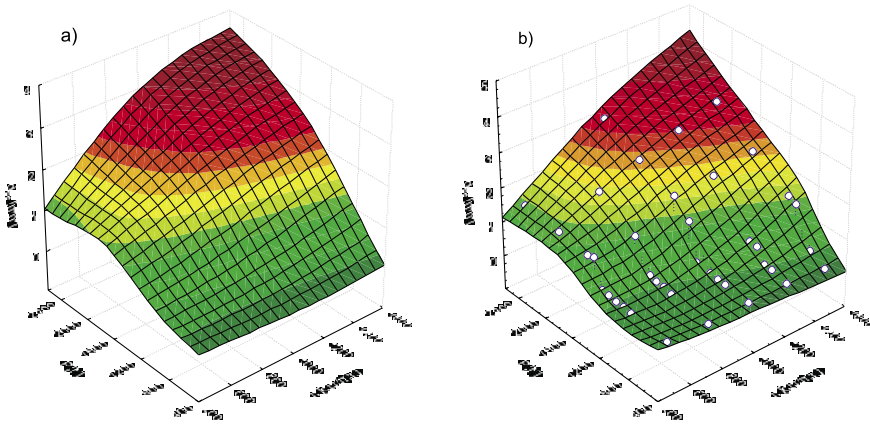
TABELA 5

Podsumowanie testowanych modeli zużycia (dla  $L_i$ )

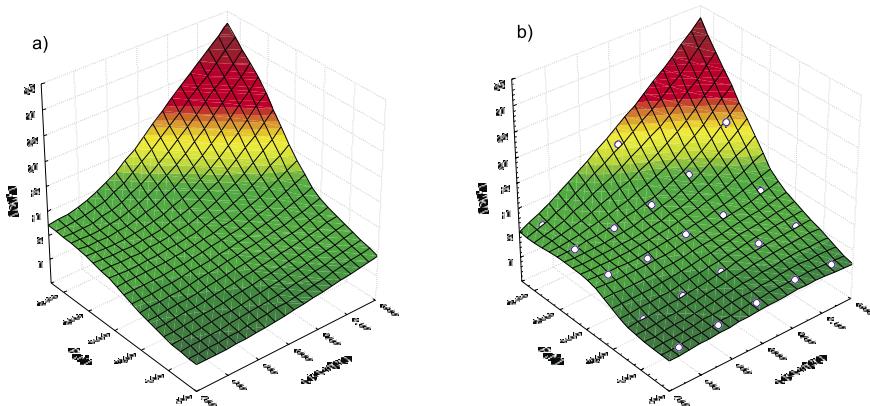
Nr SSN	typ	błąd ucz.	błąd walid.	błąd test.	korelacja	średni błąd
8	MLP 2:2-2-1:1	0,031	0,026	0,042	0,977	-0,058
22	MLP 2:2-1-1:1	0,077	0,021	0,073	0,893	-0,404
24	MLP 2:2-3-1:1	0,031	0,016	0,026	0,979	-0,001
26	MLP 2:2-3-2-1:1	0,024	0,012	0,042	0,985	-0,013
30	MLP 2:2-3-3-1:1	0,027	0,011	0,025	0,984	0,034

Na rysunkach 8 i 9 przedstawiono porównanie wykresu odpowiedzi modelu sieci neuronowej z wykresem powierzchniowym opartym o uzyskane wyniki badań. Bardzo zbliżony charakter powierzchni odpowiedzi pokrywający cały obszar zmiennych parametrów  $P$  i  $n$  potwierdza wyniki przedstawione w tabelach 3, 4 i 5. Sieci neuronowe (w tym przypadku typu MLP) pozwalają uzyskać bardzo dobry wynik w sposób ciągły, również z możliwością dobrej aproksymacji w pobliżu zakresu badawczego.

Modele SSN o dwóch wyjściach w porównaniu z modelami o jednym wyjściu z założenia są bardziej skomplikowane (większa ilość neuronów — większa liczba wag  $N_w$ ). Pomimo dodawania drugiej warstwy ukrytej nie uzyskuje się dużej poprawy w generalizacji sieci (wartości błędów walidacyjnych i testowych — tabela 3). Wprowadzenie dodatkowych neuronów skutkuje również zwiększeniem średniego błędu odpowiedzi sieci, przy czym korelacja nie zawsze ulega poprawie. Zwiększenie zbioru danych uczących kosztem zbioru testowego (sieć nr 20 — tabela 3) zmniejszyło błąd sieci, przy wzroście korelacji, jednakże stawia to pod znakiem zapytania zdolność do generalizacji (ocenianą w tym przypadku tylko



Rys. 8. Zależność  $d_{SS}$  w funkcji  $n$  i  $P$  dla sieci nr 15 (tab. 4): a) odpowiedź sieci; b) wyniki badań



Rys. 9. Zależność  $L_t$  w funkcji  $n$  i  $P$  dla sieci nr 30 (tab. 5): a) odpowiedź sieci; b) wyniki badań

na podstawie danych walidacyjnych). Reasumując modele sieci o pojedynczym wyjściu ( $d_{SS}$  i  $L_t$ ) charakteryzują się prostszą budową oraz lepszym dopasowaniem — zdolnością do generalizacji, w porównaniu z modelami o dwóch wyjściach. Należy jednak zaznaczyć, że uzyskane wyniki modeli SSN z dobrą dokładnością przewidują zadane parametry.

Różnice pomiędzy poszczególnymi modelami o podobnej (lub wręcz identycznej) strukturze wynika z losowego doboru grup danych uczących, walidacyjnych i testowych. Dodatkowym sprawdzianem modelu SSN jest oczywiście wiedza użytkownika o badanych procesach oraz porównanie odpowiedzi sieci (użytkownika lub definiowanego arkusza w postaci tabel lub wykresów) z danymi pomiarowymi.

### 5.3. Klasyfikator stanu współpracujących powierzchni

Na podstawie danych literaturowych [3], [9] dokonano podziału wyników badań ze względu na zmierzone zużycie kulek testowych. Zgodnie z rysunkami 3 i 4 dla danej prędkości obrotowej w obszarze małych obciążeń (poniżej największego obciążenia niezacierającego) zapewnione jest smarownie współpracujących powierzchni elementów — zużycie kulek testowych jest stosunkowo niewielkie (rys. 5a). Obciążenie badanego węzła powyżej największego obciążenia niezacierającego (pkt. B na rysunku 4) powoduje większe niszczenie warstwy wierzchniej — zacieranie współpracujących elementów, któremu towarzyszy zwiększony opór ruchu (wzrost wartości  $M_t$ ) oraz gwałtowny wzrost wartości  $d_{ss}$  (rys. 5 b i c).

Wyróżniono dwa stany badanych powierzchni kulek testowych:

1. stan „smarowanie” — nie nastąpiło gwałtowne przerwanie warstwy granicznej, małe wartości  $d_{ss}$ , zakres obciążeń AB na rysunku 4;
2. stan „zatarcie” — nastąpiło trwałe przerwanie warstwy granicznej, duże wartości  $d_{ss}$ , zakres obciążeń powyżej pkt. B na rysunku 4.

W procesie budowy klasyfikatora SSN jako klasy przyjęto tak zdefiniowane parametry „smarowanie” i „zatarcie”, mogące przyjmować wartości 0 lub 1. Wartość „1” oznaczała przynależność danego przypadku do określonej klasy. Zaprojektowane modele klasyfikujące stan powierzchni współpracujących elementów — zużycie kulek — scharakteryzowano w tabeli 6.

TABELA 6

Podsumowanie testowanych modeli klasyfikacyjnych

Nr	Rodzaj	Jakość			Błąd			Ilość poprawnych klasyfikacji [%]	
		ucz.	wal.	test.	ucz.	wal.	test.	„smarowanie”	„zatarcie”
21	Liniowa 2:2-2:2	0,86	1,00	1,00	0,34	0,31	0,24	100	78
22	Liniowa 1:1-2:2	0,80	1,00	1,00	0,39	0,30	0,29	92	72
32	MLP 2:2-2-2:2	1,00	1,00	1,00	0,12	0,13	0,20	94	100
28	MLP 2:2-3-2:2	1,00	1,00	1,00	0,01	$2 \cdot 10^{-6}$	$2 \cdot 10^{-8}$	100	100
29	MLP 2:2-4-2:2	1,00	1,00	1,00	$1 \cdot 10^{-4}$	$1 \cdot 10^{-9}$	0	100	100
30	MLP 2:2-5-2:2	1,00	1,00	1,00	$2 \cdot 10^{-4}$	0	0	100	100
43	RBF 2:2-3-2:2	0,80	1,00	1,00	0,36	0,25	0,36	88	78
42	RBF 2:2-5-2:2	0,91	1,00	1,00	0,32	0,32	0,23	96	89
24	RBF 2:2-8-2:2	0,97	1,00	1,00	0,30	0,26	0,17	100	100

Uzyskane modele klasyfikacyjne charakteryzują się dobrą i bardzo dobrą jakością. Jakość sieci na poziomie 100% dla sieci typu MLP gwarantuje idealne przyporządkowanie danego przypadku do swojej klasy (stanu powierzchni). Dla pozostałych typów błąd poprawnego przyporządkowania jest większy, ale na akceptowalnym poziomie. Interesującym jest, że na podstawie jednego parametru — obciążenia  $P$  (sieć 22) — sieć liniowa była w stanie z dużą dokładnością zaklasyfikować zaprezentowane przypadki.

W przypadku sieci MLP zwiększenie ilości neuronów powoduje ewidentne zmniejszenie błędu sieci, co jest również widoczne dla sieci RBF, choć w dużo mniejszym stopniu. Dla sieci RBF uzyskuje się również poprawę dokładności klasyfikacji.

## 6. Wnioski

Przeprowadzone badania wskazują na możliwość stosowania sieci neuronowych jako modeli predykcyjnych oraz klasyfikacyjnych w procesach tribologicznych. Badania wykazały lepsze właściwości w modelowaniu miary zużycia i pracy tarcia przy zastosowaniu perceptronu wielowarstwowego w stosunku do innych testowanych sieci. Wyznaczone modele perceptronowe o stosunkowo prostych strukturach sieci dokonują predykcji zużycia i klasyfikacji z dobrą dokładnością. W przypadku sieci MLP dla danych testowych uzyskano błąd poniżej 5%, co w badaniach tribologicznych można uznać za bardzo dobry wynik.

Ze względu na ograniczoną licznosc zbioru przypadków pomiarowych ograniczono się tylko do sieci o dwóch wejściach i maksymalnie dwóch wyjściach.

Uzyskanie modelu dającego pełniejszy obraz zachodzących procesów wymaga przeprowadzenia kolejnych badań i zagęszczenia punktów pomiarowych szczególnie w obszarach, gdzie zależności między parametrami są nieliniowe.

*Artykuł wpłynął do redakcji 23.11.2005 r. Zweryfikowaną wersję po recenzji otrzymano w marcu 2006 r.*

### LITERATURA

- [1] *Instrukcja obsługi T-02 — Aparat czterokulowy*, Instytut Technologii Eksploatacji, Radom 1998.
- [2] M. TRZOS, *Modele neuronowe do prognozowania właściwości przeciwzużyciowych olejów smarnych*, Tribologia nr 4, 2004, 273-283.
- [3] M. HEBDA, A. WACHAL, *Trybologia*, Wydawnictwa Naukowo-Techniczne, Warszawa 1980.
- [4] R. TADEUSIEWICZ, P. LULA, P. WÓJTOWICZ, *Sieci neuronowe*, materiał kursowy StatSoft Polska, Kraków 2003.
- [5] S. OSOWSKI, *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [6] *Statistica Neural Networks PL. Przewodnik problemowy*, StatSoft Polska Sp. z o.o., 2001.

- 
- [7] *Statistica. Sieci Neuronowe* ([www.statsoft.pl/stat\\_nn.html](http://www.statsoft.pl/stat_nn.html)).
- [8] M. SZCZEREK, M. WIŚNIEWSKI, *Tribologia i tribotechnika*, Wydawnictwo Instytutu Technologii Eksploatacji, Radom 2000.
- [9] T. KAŁDOŃSKI, *Tribologia i płyny eksploatacyjne. Cz. I. Wybrane problemy tribologii*, Warszawa 1995.
- [10] T. KAŁDOŃSKI, *Zużywanie ściernie w systemach tribologicznych*, praca habilitacyjna, WAT Warszawa, 1996.

B. GIEMZA, K. GOCMAN, T. KAŁDOŃSKI

**Application of artificial neural networks to model wear process of a tribological couple under boundary friction**

**Abstract.** The results of initial investigations of influence of load and rotational speed on wear of a friction couple-tested ball of four-ball machine are presented. The investigation results were analysed and a model of wear of the tested tribological couple was built on basis of artificial neural networks (ANNs). Different kinds of ANNs and training algorithms were applied to obtain the best generalisation and quality of the built model.

**Keywords:** boundary friction, lubricity, artificial neural networks (ANNs), four-ball machine

**Universal Decimal Classification:** 531.43

