

Dr hab. inż. Henryk CZARNECKI, prof. PCz
Instytut Marketingu
Politechnika Częstochowska

DOI: 10.17814/mechanik.2015.7.223

ANALIZA PROCESÓW TRIBOLOGICZNYCH Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

Streszczenie: Celem niniejszego opracowania jest analiza możliwości zastosowania sztucznych sieci neuronowych w badaniach i eksploatacji systemów tribologicznych. W tym celu wykorzystano symulator sieci neuronowych Neuronix wersja 2.3 z pakietu Sphinx. System ten umożliwia szybkie projektowanie, tworzenie i uruchamianie sieci umożliwiającej prognozowanie wyników zużycia powierzchni nagniatanej oscylacyjnie. Otrzymane wyniki porównano z danymi otrzymanymi z obliczeń wykonanych przy wykorzystaniu zależności z planowego eksperymentu i regresji wielokrotnej.

TRIBOLOGICAL PROCESSES ANALYSIS USING ARTIFICIAL NEURAL NETWORK

Abstract: The aim of this scientific description is analysis of using artificial neural network possibilities in research and exploitation of tribological systems. For this purpose was used neural network simulator Sphinx Neuronix ver. 2.3. This system enables fast design, creation and execution a network which allow to forecasting oscillating burnished surface wear. The results were compared with those obtained from calculations performed with the dependence of the planned experiment and multiple regression

*Słowa kluczowe: sieci neuronowe w badaniach tribologicznych
Keywords: neural networks in tribological researches*

1. WPROWADZENIE

Sieć neuronowa jest modelem matematycznym, składającym się z sieci węzłów obliczeniowych zwanych neuronami i ich połączeń. Jest to pewna technika obliczeniowo-statystyczna, należąca do dziedziny sztucznej inteligencji. Jej działanie symuluje działanie ludzkiego mózgu. Każdy neuron w mózgu jest połączony z około 10 tys. Innych, a podczas pracy mózgu pracują wszystkie neurony jednocześnie. Komputer natomiast składa się z osobnych obwodów logicznych, z których każdy łączy się tylko z sąsiadem. Działają one kolejno, a nie jednocześnie.

Patrząc na sieci neuronowe z punktu widzenia zasady funkcjonowania, zarówno mózg, jak i konwencjonalne komputery realizują podobne funkcje przetwarzania, gromadzenia i odzyskiwania informacji. Zasadniczą różnicą jest odmienny sposób przetwarzania informacji. Konwencjonalny komputer posiada jeden lub kilka złożonych procesorów

efektywnie działających szeregowo, zaś informacja jest pamiętana w specyficznie rozlokowanych komórkach pamięci operacyjnej [1-3, 10].

Matematycznie rzecz biorąc, dobrze skonstruowana sieć neuronowa jest w stanie „nauczyć się” aproksymować dowolną funkcję wielu zmiennych (istnieje na to dowód matematyczny). Ponieważ jest to aproksymacja, a nie interpolacja, to sieć jest w stanie uogólniać nabytą wiedzę na nieznaną jej, choć podobne problemy. Tę zdolność nazywa się generalizacją. Mówi się, że sieć neuronowa dobrze generalizuje, kiedy odpowiedzi udzielane przez nią dla zestawu danych testowych są prawidłowe lub mieszczą się w granicach ustalonego przez nas błędu. Oczywiście, dane testowe muszą pochodzić z tej samej populacji co dane wykorzystane do uczenia sieci, ale są różne od nich [7, 8, 10].

Istnieje kilka kierunków zastosowań sieci neuronowych. W predykcji wykorzystanie sieci polega na wytrenowaniu ich na pewnym zbiorze danych, aby potem za jej pomocą móc przewidywać określone dane wyjściowe. Mamy zatem do czynienia z czymś w rodzaju urządzenia prognozującego. Istotne jest to, że sieć nabiera zdolności do prognozowania wyłącznie na podstawie dostarczonych danych, nie podaje się jej natomiast żadnych wzorów lub teorii o związkach pomiędzy danymi a prognozowanymi wynikami. Można zatem sieci stosować w przypadkach, gdy nie znamy zależności pomiędzy przewidywanymi wynikami a znanymi danymi wejściowymi. Sieć neuronowa jest zdolna również rozpoznawać trend.

Sieć neuronowa może też być wykorzystana dla klasyfikacji i rozpoznawania. Ponadto potrafi po „pokazaniu” jej wystarczającej ilości informacji rozpoznawać w zbiorze danych występujące klasy danych i klasyfikować nowe wzorce według nauczonych wcześniej kategorii. Może to być np. rozpoznawanie pisma, cyfr, obrazów. Coraz bardziej obiecujące staje się wykorzystanie sieci do kojarzenia faktów wnioskowanych na podstawie wprowadzonych danych, dzięki zdolności sieci do uczenia, adaptacji i uogólniania doświadczeń.

Poza tym stosujemy ją do analizy danych, czyli do znalezienia związków występujących w wejściowym zbiorze danych.

Sieci neuronowe umożliwiają również filtrację sygnałów, czy też dzięki swojej niewrażliwości na zakłócenia znakomicie nadają się jako filtr stosowany np. w celu redukcji szumów w zbiorze danych. Mogą również dokonywać kompresji obrazów i dźwięków.

Z powodzeniem można je wykorzystać w optymalizacji. Sieci neuronowe znakomicie nadają się do poszukiwania rozwiązań optymalnych. Udowodniono już przydatność sieci nie tylko w optymalizacji statycznej i dynamicznej, ale również w zagadnieniach optymalizacji kombinatorycznej.

Ponadto sztuczne sieci neuronowe znajdują zastosowanie w rozwiązywaniu wielu innych problemów. Ze względu na swoją budowę – złożoną z wielu prostych procesorów – mogą być wykorzystane wszędzie tam, gdzie np. skomplikowaną procedurę obliczeniową można rozbić na elementy. W sytuacji gdy pewne procesy czy procedury mogą być realizowane równoległe, uzyskuje się znaczące przyspieszenie realizacji celu [2, 5, 9].

Sztuczne sieci neuronowe radzą sobie w sytuacjach, kiedy mamy do czynienia z danymi „rozmytymi” czy też obciążonymi dużymi błędami. Szczególną zaletą sieci neuronowych jest odkrywanie w zbiorze danych wzorców nawet wtedy, gdy są one niejasne i metody

statystyczne nie są w stanie ich zdefiniować. Ta zdolność sieci neuronowych ma duże znaczenie w określaniu decyzji, często wygrywając z doświadczonym personelem. Modele matematyczne zbudowane z wykorzystaniem sztucznych sieci neuronowych wykazują się dużą zdolnością adaptacyjną, dlatego też mogą z powodzeniem być zastosowane w zagadnieniach, w których dane wykazują np. znaczną, nieoczekiwaną nieliniowość. Z dużym powodzeniem sieci neuronowe znajdują zastosowanie do rozwiązywania problemów, w których dane wejściowe obciążone są znacznym poziomem szumów lub wahań wartości. W takich sytuacjach inne metody zazwyczaj zawodzą.

Biorąc pod uwagę wymienione możliwości, w niniejszym opracowaniu wykorzystano program Neuronix 2,3 i jego symulator sieci neuronowej do analizy procesu zużycia powierzchni po nagniataniu oscylacyjnym realizowanego na stanowisku badawczym. Otrzymane wyniki porównano z wielkościami obliczonymi na podstawie równań otrzymanych z planowego eksperymentu i regresji wielokrotnej [6, 8].

2. CHARAKTERYSTYKA PROGRAMU

Pakiet SPHINX został opracowany przez firmę AITECH [8]. Zawiera on następujące moduły:

- System Ekspertowy PC-SHELL,
- System Wspomagania Inżynierii Wiedzy CAKE (ang. *Computer Aided Knowledge Eingeering* – komputerowo wspomagana inżynieria wiedzy),
- Symulator Sieci Neuronowych NEURONIX.

Dla naszych zagadnień wykorzystano podsystem NEUONIX będący narzędziem służącym do wszechstronnej analizy danych poprzez tworzenie modeli różnorodnych procesów spotykanych w ekonomii i technice. Zastosowanie tej sieci neuronowej pozwala na automatyczne utworzenie modelu bez konieczności głębokiej znajomości modelowania procesu. Cały mechanizm budowy modelu sprowadza się do zapisania danych w arkuszu kalkulacyjnym, podobnie jak to czynimy na przykład w programie Excel w postaci tabeli, w której określimy wyjścia i wejścia.

Pakiet Neuronix jest wyposażony w moduł kodujący, który pozwala tworzyć tzw. *modele jakościowe*. Dzięki niemu użytkownik może pracować bezpośrednio na danych w postaci symbolicznej, są to tzw. *zmienne lingwistyczne*. Oznacza to w praktyce, że jeżeli chcielibyśmy opisać np. aktualny stan giełdy, możemy użyć zmiennej wejściowej, której jedną z możliwych wartości jest „umiarkowana hossa”. Pojęcia tego nie można precyzyjnie wyrazić w postaci konkretnej liczby. W podobny sposób trudno byłoby sprecyzować nastrój inwestorów. Można go określić za pomocą jakiegoś wskaźnika, ale konstrukcja takiego wskaźnika byłaby bardzo złożona i powstałby problem, jak to zrobić. Dużo prościej jest takie dane wprowadzić na wejście sieci i pozwolić jej podjąć samodzielną decyzję o włączeniu jej do budowanego modelu.

Sieć neuronowa zdobywa wiedzę na etapie uczenia. Program Neuronix pozwala na uruchomienie uczenia, śledzenie wskaźników dających wgląd w jej bieżący stan, sterowanie uczeniem w trybie pracy krokowej oraz na dodatkowe czynności związane z bezpieczeństwem, do których należą automatyczne zapisywanie wag w trakcie uczenia.

W wykorzystywanej wersji symulatora Neuronix stosuje się trzy wskaźniki, które pozwalają oszacować jakość wiedzy, jaką sieć zdobyła na etapie uczenia. Podstawowym miernikiem jest błąd średniokwadratowy RMS. Dodatkowe informacje, takie jak tolerancja, pozwalają

stwierdzić, na ile pojedyncze wyjście sieci różni się od pożądanej dla niego wartości. Użytkownik ma możliwość śledzenia wartości tych wielkości, co pozwala mu na podjęcie decyzji o zakończeniu uczenia. Jeżeli stwierdza, że proces uczenia przebiega sprawnie, może ustawić dla wskaźników pewne wartości progowe, przy których nastąpi natychmiastowe zakończenie tego procesu.

Warunki niezbędne do uruchomienia uczenia:

Przed uruchomieniem uczenia należy przygotować:

- plik uczący przy użyciu arkusza danych lub dowolnego edytora tekstowego,
- plik testowy, jeżeli częstość testowania jest większa od 0.

Ponadto konieczne jest:


- wskazanie pliku wag, do którego będą zapisywane aktualne wagi sieci,
- ustawienie wartości parametrów, jeżeli mają być inne niż domyślne.

3. ODPORNOŚĆ NA ZUŻYCIE POWIERZCHNI POWSTAŁEJ PODCZAS NAGNIATANIA OSCYLACYJNEGO

3.1. Badania stanowiskowe

W dotychczas stosowanych metodach obróbki powierzchniowej części maszyn, struktura jej mikroprofilu określana jest zazwyczaj wyróżnikami klasyfikacyjnymi określonymi w normach, a charakteryzującymi chropowatość, udział nośny, falistość itp. System ten wynika z występowania znacznej niejednorodności jej struktury, najczęściej mającej stochastyczny układ, co uniemożliwia ściśle matematyczne zaprogramowanie modelu rzeczywistego ukształtowania powierzchni w trakcie trwania procesu obróbki.

Obróbka nagniataniem oscylacyjnym umożliwia otrzymanie jednorodnego i regularnego mikroprofilu kształtowanego według założonego modelu matematycznego i możliwego do zaprogramowania parametrów obróbki [4]. Pozwala to na analityczne określenie większej ilości wyróżników geometrycznych dotyczących jej jakości, a będących funkcją założonych parametrów obróbki [4].



Rys. 1. Schemat nagniatania oscylacyjnego

Biorąc pod uwagę ściśle matematyczne zależności między poszczególnymi parametrami procesu nagniatania, można określić wyróżniki topografii otrzymanej powierzchni którymi są:

φ – kąt przecięcia toru elementu nagniatającego z kierunkiem tworzącej w położeniu zerowym [°],

e – przesunięcie okresu oscylacji (przesunięcie fazy śladów obróbkowych),

p – posuw elementu nagniatającego [mm/obr],

F_k – względna powierzchnia mikrokanalików [%],

L – długość drogi tarcia [m].

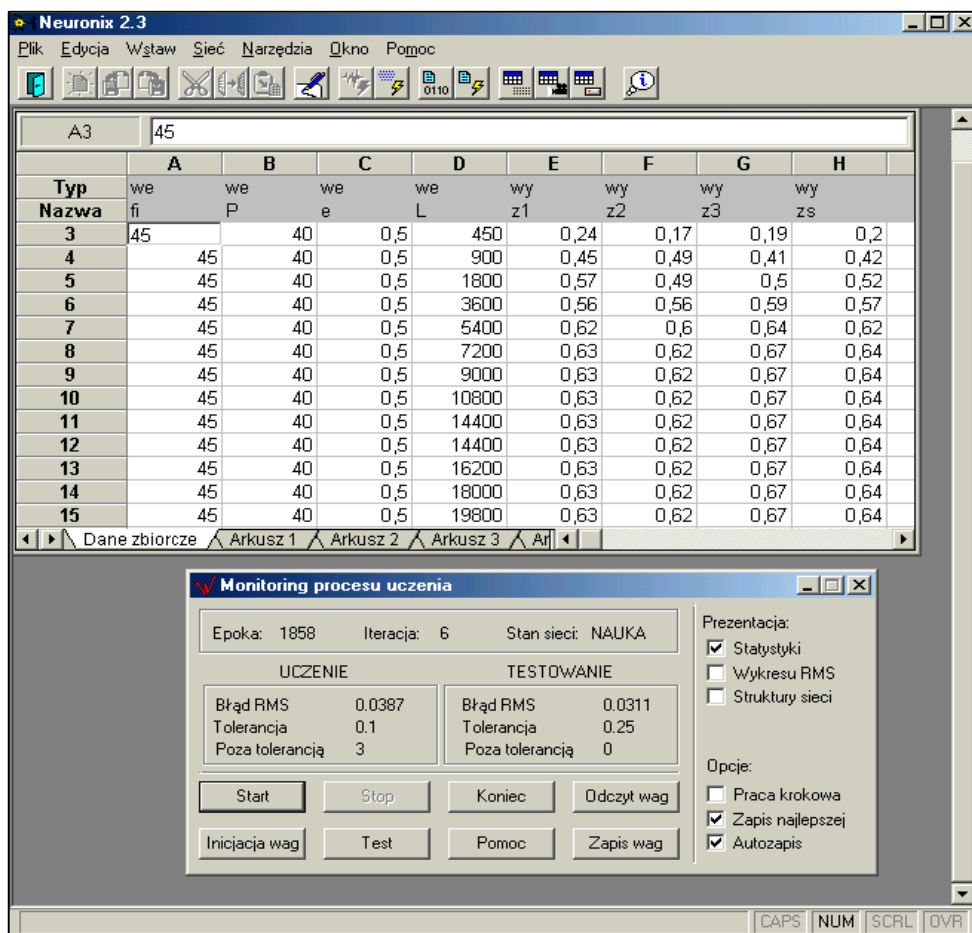
Badania stanowiskowe wpływu struktury powierzchni uzyskanej po nagniataniu oscylacyjnym na wielkość zużycia liniowego w warunkach tarcia mieszanego przeprowadzono w oparciu o metodę planowego eksperymentu i regresji wielokrotnej. W efekcie takiego postępowania uzyskano model w postaci równania regresji opisującego proces zużycia warstwy wierzchniej w funkcji wyróżników opisujących mikronierówności powierzchni powstałej po nagniataniu oscylacyjnym [4].

W oparciu o wyniki uzyskane w czasie badań, obliczono współczynniki regresji, a następnie stosując analizę wariancyjną, określono za pomocą testu t-Studenta ich istotność. Równanie określające wielkość zużycia Z po sprawdzeniu jego adekwatności testem F-Snedecora przy poziomie istotności $\alpha = 0,1$ przyjmuje postać [4]:

$$\begin{aligned} Z = & 5,2434 - 0,0954\varphi - 56,6121e - 62,3506p + 0,3202F_k - 0,0016\varphi^2 - \\ & - 0,6480e^2 - 162,3332p^2 - 0,0058F_k^2 - 0,2490\varphi e + 0,5588\varphi p - \\ & - 0,0019\varphi F_k - 52,9412ep + 1,0148eF_k + 1,4860pF_k \end{aligned} \quad (1)$$

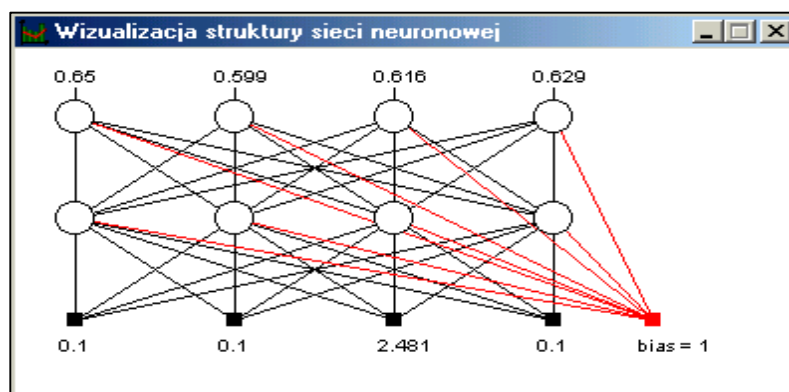
3.2. Projekt i symulacja sieci z wykorzystaniem symulatora

Dane otrzymane podczas eksperymentu stanowiskowego zużywania warstwy wierzchniej po nagniataniu oscylacyjnym, na podstawie których otrzymano przedstawione równanie (1) posłużyły również do zaprogramowania symulatora sztucznych sieci neuronowych Neuronix. Na tej podstawie będzie możliwe określenie wpływu kąta przecięcia toru elementu nagniatającego z kierunkiem tworzącej oznaczonego symbolem φ wielkości oraz względnego pola powierzchni kanalików na proces zużywania warstwy wierzchniej obrabianej nagniataniem oscylacyjnym. Taki sposób prowadzenia eksperymentu pozwolił na porównanie wyników z dwóch zastosowanych metod analizy procesu tarcia zużycia. Na rysunku 2 przedstawiono widok okna z wprowadzonymi danymi zużywania powierzchni przy kącie $\varphi = 45^\circ$.



Rys. 2. Okno programu z danymi zużycia dla kąta $\varphi = 45^\circ$ i monitoringu procesu uczenia sieci

Graficzną strukturę sieci dla tego przypadku przedstawiono na rys. 3.



Rys. 3. Wizualizacja struktury sieci neuronowej dla kąta $\varphi = 45^\circ$

W przypadku zużycia dla kąta $\varphi = 40^\circ$ obliczenia wyglądają następująco:

The screenshot displays the Neuronix 2.3 interface. The main window shows a spreadsheet with the following data:

Typ	A	B	C	D	E	F	G	H
Nazwa	we P	we fi	we e	we L	wy z1	wy z2	wy z3	wy zs
3	40	40	0,5	450	0,03	0,04	0,08	0,05
4	40	40	0,5	900	0,06	0,08	0,19	0,11
5	40	40	0,5	1800	0,29	0,3	0,4	0,33
6	40	40	0,5	3600	0,72	0,73	0,79	0,75
7	40	40	0,5	5400	0,82	0,83	0,9	0,85
8	40	40	0,5	7200	0,92	0,94	0,96	0,94
9	40	40	0,5	9000	0,98	0,99	1,05	1,01
10	40	40	0,5	10800	1,06	1,07	1,11	1,08
11	40	40	0,5	14400	1,18	1,2	1,28	1,22
12	40	40	0,5	14400	1,18	1,2	1,28	1,22
13	40	40	0,5	16200	1,18	1,2	1,28	1,22
14	40	40	0,5	18000	1,18	1,2	1,28	1,22
15	40	40	0,5	19800	1,18	1,2	1,28	1,22
16	40	40	0,5	21600	1,18	1,2	1,28	1,22
17	40	40	0,5	64800	1,18	1,2	1,28	1,22

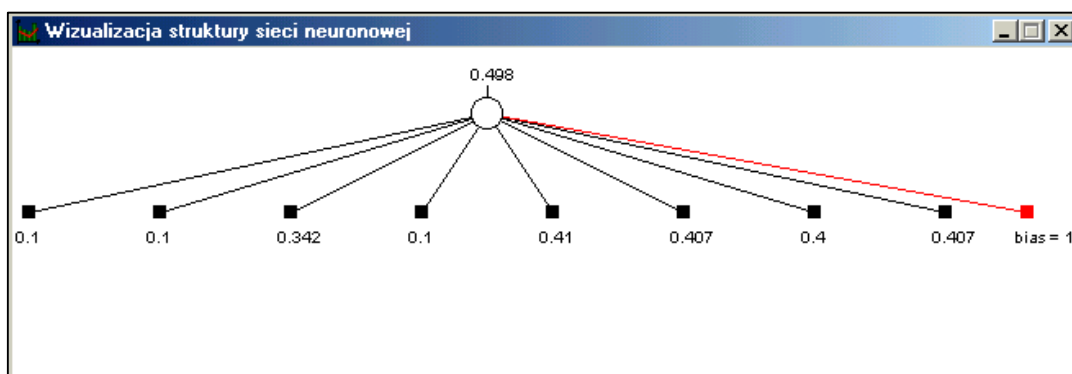
The 'Monitoring procesu uczenia' window shows the following details:

- Epoka: 1719, Iteracja: 4, Stan sieci: NAUKA
- UCZENIE:** Błąd RMS: 0.1231, Tolerancja: 0.1, Poza tolerancją: 2
- TESTOWANIE:** Błąd RMS: 0, Tolerancja: 0.25, Poza tolerancją: 0
- Prezentacja: Statystyki, Wykresu RMS, Struktury sieci
- Opcje: Praca krokowa, Zapis najlepszej, Autozapis

Rys. 4. Obliczenie zużycia dla kąta $\varphi = 40^\circ$

Jak wynika z obliczeń, zużycie rośnie wraz ze wzrostem drogi zużycia L podobnie jak dla przypadku, gdzie kąt $\varphi = 45^\circ$. Stałą wartość $Z_s = 1,22$ [μm] osiąga dla $L = 14\,400$ [m].

Wizualizację struktury sieci dla tego przypadku, gdy kąt $\varphi = 40^\circ$, przedstawiono na rys. 5.



Rys. 5. Wizualizacja struktury sieci neuronowej dla kąta $\varphi = 40^\circ$

Dla przypadku zużycia dla kąta $\varphi = 10^\circ$ proces obrazuje rysunek 6.

	A	B	C	D	E	F	G	H
1	we	we	we	wy	wy	wy	wy	
2	fi	e	L	z1	z2	z3	Zs	
3		10	0,5	450	0,04	0,02	0,03	0,03
4		10	0,5	900	0,07	0,05	0,02	0,07
5		10	0,5	1800	0,69	0,77	0,79	0,75
6		10	0,5	3600	1,43	1,39	1,47	1,43
7		10	0,5	5400	1,87	1,88	1,92	1,89
8		10	0,5	7200	1,98	2,04	1,98	2
9		10	0,5	9000	2,09	2,06	2	2,05
10		10	0,5	10800	2,05	2,1	2,15	2,1
11		10	0,5	14400	2,17	2,2	2,17	2,18
12		10	0,5	14400	2,36	2,26	2,28	2,3
13		10	0,5	16200	2,42	2,37	2,41	2,4
14		10	0,5	18000	2,46	2,39	2,41	2,42
15		10	0,5	19800	2,46	2,39	2,41	2,42
16		10	0,5	21600	2,46	2,39	2,41	2,42
17		10	0,5	23400	2,46	2,39	2,41	2,42
18								

Monitoring procesu uczenia

Epoka: 1780 Iteracja: 11 Stan sieci: TEST

UCZENIE		TESTOWANIE	
Błąd RMS	0.1063	Błąd RMS	0
Tolerancja	0.1	Tolerancja	0.25
Poza tolerancją	5	Poza tolerancją	0

Prezentacja:

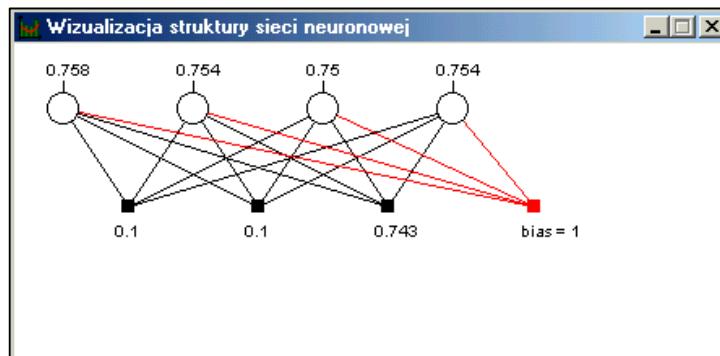
- Statystyki
- Wykresu RMS
- Struktury sieci

Opcje:

- Praca krokowa
- Zapis najlepszej
- Autozapis

Rys. 6. Okno dla procesu zużycia przy kącie $\varphi = 10^\circ$ [5]

W tym przypadku przy tym kącie ($\varphi = 10^\circ$) obserwujemy, że zużycie jest znacznie większe niż w przypadku, gdzie kąty wynoszą 40° i 45° . Obraz takiej sieci neuronowej przedstawiono na rys. 7.



Rys. 7. Wizualizacja struktury sieci neuronowej dla kąta $\varphi = 10^\circ$

Dzięki wykorzystaniu symulatora sztucznej sieci neuronowej Neuronix 2.3 można prognozować wpływ struktury topografii powierzchni i jej mikronierówności na zużycie w procesie tarcia i zużywania w warunkach tarcia mieszanego. Wprowadzając dane uzyskane w eksperymencie stanowiskowym, możemy dostać prosty aparat pozwalający na dokonywanie określonych analiz. W naszym przypadku największą odpornością na zużycie charakteryzuje się powierzchnia po nagniataniu oscylacyjnym w porównaniu z powierzchniami toczonymi. Minimalne zużycie wystąpiło przy kącie $\varphi = 45^\circ$.

Otrzymane wyniki z sieci sztucznej inteligencji porównano z obliczonymi przy wykorzystaniu zależności (1). Przy poziomie istotności $\alpha = 0,1$ pokrywają się. Możemy zatem wnioskować, że w badaniach tribologicznych możemy tworzyć modele sieci neuronowych do obliczeń prognozujących zużycie.

4. PODSUMOWANIE

Nowa dziedzina, jaką są sztuczne sieci neuronowe, coraz częściej jest stosowana w sterowaniu procesami technologicznymi oraz w procesach badawczych. Na podstawie obliczeń realizowanych za pomocą sztucznych sieci neuronowych można prognozować również procesy tribologiczne.

Spośród wielu dostępnych aplikacji służących do symulacji sztucznych sieci neuronowych program Neuronix wersja 2.3 z pakietu Sphinx w pełni może być stosowany do analizy tego typu zadań.

LITERATURA

- [1] Tadeusiewicz R.: *Wstęp do informatyki*, Akademia Ekonomiczna, Kraków 1997.
- [2] Tadeusiewicz R.: *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998.
- [3] Rutkowska D., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy i systemy rozmyte*, PWN, Warszawa 1999.

- [4] Czarnecki H.: *Wpływ topografii powierzchni na własności użytkowe warstwy wierzchniej*, Instytut Technologii ITMiAP – Politechnika Częstochowska – materiały nieopublikowane.
- [5] Internet: <http://www.pz.zgora.pl>
- [6] Strona Instytutu Sterowania i Systemów Informatycznych pod kierownictwem prof. dr hab. inż. Józefa Korbicza, rok 2001.
- [7] <http://www.aitech.com.pl>
- [8] Michalik K.: *Neuronix 2.3 dla Windows 9x/NT*, Katowice 1999.
- [9] Radzikowski W.: *Komputerowe systemy wspomagania decyzji*, PWE, Warszawa 1990.
- [10] Żurada J., Barski M.: *Sztuczne sieci neuronowe*, PWN, Warszawa 1996.