

DIAGNOSTYKA MASZYN PRZY UŻYCIU SENSOROWYCH MATERIAŁÓW ŁOŻYSKOWYCH

Wiesław RAKOWSKI, Stanisław RABIASZ

Laboratorium Tribologii i Inżynierii Powierzchni
AGH, 30-059 Kraków, fax. (+12) 6234306, rakowski@agh.edu.pl

Streszczenie

Nowa metoda diagnozowania maszyn przy użyciu sensorowych kompozytów ślizgowych znacznie ułatwia diagnozowanie stanu obiektu, upraszcza układ diagnostyczny, zmniejsza koszt jego wykonania i koszt eksploatacji. Kompozyt polimerowy spełnia równocześnie dwie funkcje: powłoki ślizgowej w węźle kinematycznym oraz sensora temperatury i obciążenia mechanicznego. Sygnał diagnostyczny w postaci zmian rezystancji powłoki jest podawany na wejście sieci neuronowej. Odpowiednio rozbudowana sieć neuronowa po dekompozycji sygnału wejściowego umożliwia uzyskanie podstawowych informacji o temperaturze i naciskach występujących w strefie tarcia.

Słowa kluczowe: diagnostyka, powłoki ślizgowe, kompozyty sensorowe.

DIAGNOSTIC OF MACHINES WITH SENSOR BEARING MATERIALS

Summary

New method of machines diagnosis with sensor bearing film makes easy diagnosis of bearings, and simplified the diagnostic system. The developed sensor polymer composites are a new class of materials which due to their good tribological and sensor properties are both sliding material of the friction node, and measuring element of the diagnostic system. The resistance of coating as a diagnostic signal is an input of neural network. The temperature and applied load of bearing can be obtained as the output data.

Keywords: diagnostic, bearing coatings, sensor composites.

1. WSTĘP

Metoda diagnozowania węzłów kinematycznych maszyn przy użyciu ślizgowych warstw sensorowych opiera się na całkowicie nowej klasie materiałów, umożliwiających konstruowanie węzłów kinematycznych zdolnych do samodiagnozowania się. W takim łożysku materiałem ślizgowym jest kompozyt sensorowy, którego charakterystyki użytkowe są tak ukształtowane, aby cienka warstwa przypowierzchniowa spełniała rolę zarówno elementu układu diagnostycznego jak i elementu układu tribologicznego. Kompozyty tego typu zostały wytworzone w Laboratorium Tribologii i Inżynierii Powierzchni AGH, na bazie żywic poliimidowych, poliesterimidowych lub epoksydowych, zawierających grafit, sadzę, cynę, ind, związki metaloorganiczne oraz inne wypełniacze nadające im odpowiednie właściwości elektryczne czujnika piezorezystywnego oraz kształtujące ich właściwości ślizgowe. [1-4].

Cechami charakterystycznymi tych kompozytów są: niski współczynnik tarcia,

samosmarowność, dobre związanie warstwy z podłożem, odporność na zużycie oraz odpowiednio duża zmiana rezystancji warstwy jako reakcja na zmianę temperatury lub zmianę obciążenia zewnętrznego. Do tych właściwości można jeszcze dodać łatwość kształtowania i nakładania cienkich warstw oraz łatwość ich docierania.


Sygnałem diagnostycznym z warstwy sensorowej jest zmiana rezystancji pod wpływem zarówno zmiany temperatury jak i zmiany obciążenia mechanicznego. Zadaniem układu diagnostycznego jest przeprowadzenie takiej analizy sygnału otrzymywanego w postaci zmiany rezystancji, aby możliwa była identyfikacja przyczyny tej zmiany.

2. ZJAWISKO PRZEWODZENIA KOMPOZYTÓW SENSOROWYCH

Dominującym mechanizmem przewodzenia prądu elektrycznego przez kompozyty polimerowe jest tworzenie ścieżek pomiędzy ziarnami fazy przewodzącej. Mechanizm ten jest opisywany na gruncie teorii perkolacji. Przewodzenie może

następować także poprzez mechaniczne tworzenie kwantowych tuneli pomiędzy przewodzącymi cząstkami, termiczną aktywację przeskoków elektronów przez poziomy energetyczne w paśmie zabronionym lepiszcza, oraz w niektórych przypadkach także w wyniku emisji polowej.

Na gruncie teorii perkolacji można opisać zmiany przewodnictwa kompozytu w zależności od udziału objętościowego frakcji przewodzącej oraz, w pewnym zakresie, zmiany następujące pod wpływem obciążeń zewnętrznych i temperatury [1,2,5].




Rys.1. Zależność rezystywności od udziału objętościowego fazy przewodzącej [1]

Teoria perkolacji dobrze opisuje zarówno zależność rezystywności kompozytu od udziału objętościowego wypełniacza jak i zmianę przewodnictwa pod wpływem odkształceń termicznych i mechanicznych.

Istnieje pewien krytyczny udział objętościowy ziaren fazy przewodzącej, przy którym ziarna zaczynają tworzyć ścieżki przewodzące prąd elektryczny. Wraz ze wzrostem udziału objętościowego frakcji przewodzącej tworzy się coraz więcej tych ścieżek powodując spadek rezystywności kompozytu. Dla kompozytów o udziałach objętościowych przewodzącego wypełniacza kilkanaście procent powyżej wartości progowej następuje zbliżenie do stanu nasycenia i rezystywność kompozytu monotonicznie zbliża się do rezystywności fazy przewodzącej.

W przypadku tunelowania elektronowego możliwe jest wyznaczenie prawdopodobieństwa P przeniesienia elektronu przez barierę potencjału o wysokości W_0 i szerokości a . Szerokość bariery potencjału a jest interpretowana jako średnia odległość między sąsiednimi ziarnami przewodzącymi:



Rys.2. Model tunelowania elektronowego. (W_0 – bariera potencjału, a – odległość pomiędzy ziarnami przewodzącymi) [5]

$$P \approx \exp\left[-4 \cdot \pi \cdot a / h \cdot \sqrt{(2 \cdot m_e \cdot W_0)}\right]$$

gdzie m jest masą elektronu a h stałą Planck'a.

Rezystywności jest odwrotnie proporcjonalna do prawdopodobieństwa transmisji:

$$\rho \approx \exp(B \cdot \sqrt{W_0} \cdot a)$$

gdzie: $B = \sqrt{2 \cdot m_e} \cdot 4 \cdot \frac{\pi}{h}$.

Pozostałe zjawiska przewodzenia jak: termiczna aktywacja przeskoków elektronów przez poziomy energetyczne w paśmie zabronionym lepiszcza oraz emisja polowa odgrywają stosunkowo niewielką rolę w przypadku kompozytów polimerowych na podstawie żywic poliimidowych i epoksydowych.

3. EKSPERYMENT

Celem badań eksperymentalnych było uzyskanie odpowiednio dużego zbioru danych w postaci sygnałów pomiarowego z miniaturowego łożyska, dla dokonania wyboru optymalnej metody analizy tego sygnału do celów diagnostycznych [1].

3.1. Otrzymywanie kompozytu

W Laboratorium Tribologii i Inżynierii Powierzchni AGH znajduje się ciąg technologiczny do otrzymywania past kompozytowych, precyzyjnego nakładania warstw i utwardzania kompozytu. Wszystkie operacje związane z otrzymywaniem kompozytu sensorowego muszą być wykonane szczególnie starannie i dokładnie, gdyż nie tylko skład kompozytu, lecz także technologia wytwarzania warstw ma decydujący wpływ na charakterystyki sensorowe i tribologiczne tego kompozytu. Powłokę ślizgowo-sensorową formuje się w kilku następujących etapach: przygotowanie prekursora żywica-grafit,


odpowiednia aktywacja proszków, analiza granulometryczna, łączenie w odpowiednich warunkach termicznych prekursora z wypełniaczami ziarnistymi, nakładanie i suszenie oraz utwardzanie w piecach strefowych wg specjalnego programu [1].

3.2. Stanowisko pomiarowe

W celu uzyskania odpowiedniego zbioru danych diagnostycznych do oceny przydatności poszczególnych metod analizy sygnału i wybrania optymalnej, zbudowano stanowisko badawcze, a którym obiektem badań było miniaturowe łożysko z warstwą ślizgową wykonaną z materiału sensorowego. Stanowisko zostało wyposażone w następujące tory pomiarowe: siły tarcia, temperatury w węźle tarcia, rezystancji warstwy sensorowej raz szacowania zużycia. Podczas badań możliwa jest płynna regulacja prędkości obrotowej a także wzmacnianie i rejestracja sygnałów z czujników siły tarcia, obrotów, temperatury i multimetru, dzięki wielokanałowemu terminalowi i komputerowi wyposażonemu w odpowiednią kartę pomiarową.


3.3. Parametry i warunki badań

Badano powłoki z kompozytu wybranego w oparciu o wyniki badań wstępnych, wykonanego na podstawie żywicy poliestrowoimidowej, z proszkami grafitu, sadzy i metali oraz dodatki zmniejszające tarcie. Powłokę polimerową nałożono na powierzchnię stalowej tulei miliłożyska o średnicy 1,5mm, współpracującej ze stalowym wałkiem. Pomiary wykonano dla skokowo zmienianego nacisku w zakresie: $p = 0,1; 0,3; 1; 2$ [MPa] oraz prędkości ślizgania $v = 0,3; 1; 3$ [m/s].



Rys. 3. Schemat stanowiska pomiarowego: 1- głowica, 2- panewka łożyskowa z warstwą kompozytu, 3- belka tensometryczna, 4- wałek, G- zadawane obciążenie, T- pomiar temperatury, R- pomiar rezystancji, F- pomiar siły tarcia, v- kierunek obrotów wałka


Dzięki takiej konstrukcji głowicy uzyskano równomierny rozkład nacisków wzdłuż osi wału.



Rys.4. Schemat głowicy: 1- pokrywa, 2- wkładka izolacyjna, 3- wałek, 4- panewka łożyskowa z warstwą kompozytu, 5- łącznik

3.4. Wyniki badań

Baza danych utworzona w wyniku badań zawiera zbiór wartości rezystancji układu z przyporządkowaną każdej z nich wartością temperatury warstwy przy powierzchniowej i wartością siły tarcia, w danych warunkach parametrów pracy miliłożyska. Na rys. 4 zamieszczony jest przykładowy diagram sygnału diagnostycznego $R(F, T)$.



Rys.5. Diagram sygnału diagnostycznego; R-rezystancja, F-siła, T-temperatura

Sygnał diagnostyczny w postaci zmiany rezystancji badanego układu jest funkcją temperatury i siły tarcia równocześnie. W wielu przypadkach diagnozowania maszyn celowa jest taka analiza tego sygnału, aby mierząc tylko jedną wielkość w postaci rezystancji można było uzyskać oddzielnie informację o temperaturze a oddzielnie o obciążeniu mechanicznym. Dla osiągnięcia tego celu konieczne jest znalezienie metody optymalnie dobranej do dekompozycji tego sygnału.

4. ANALIZA SYGNAŁU DIAGNOSTYCZNEGO

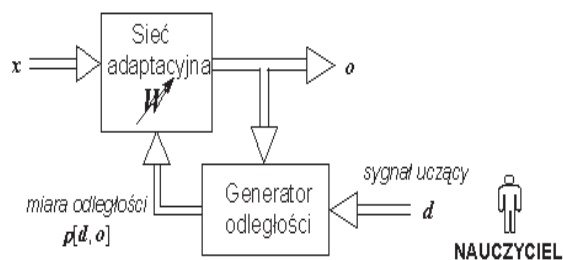
Programy analizy sygnału diagnostycznego opierają się na rachunku prawdopodobieństwa,

a najczęściej stosowane są sieci neuronowe, logika rozmyta i algorytmy genetyczne. Do analizy sygnału z powłok sensorowo-ślizgowych szczególnie przydatne okazały się metody sztucznej inteligencji przede wszystkim ze względu na brak wymagania znajomości modeli matematycznych diagnozowanych obiektów [6,7] Ponadto zaletami sztucznej inteligencji jest między innymi to, że:

- potrafią kojarzyć istotne informacje zawarte w dużej ilości danych pomiarowych eliminując informacje nieistotne
- potrafią prowadzić poprawny proces wnioskowania diagnostycznego nawet w przypadku częściowego uszkodzenia torów pomiarowych
- mają zdolność do stopniowej akumulacji wiedzy i tworzenia nowych reguł na podstawie informacji zbieranych w trakcie eksploatacji, co ma szczególne znaczenie w przypadku takich obiektów jak węzły tarcia.

Wnioskowania o stanie węzła tarcia z sygnału rezystancyjnego można sprowadzić do problemu znalezienia odwzorowania z przestrzeni jednowymiarowej do przestrzeni dwuwymiarowej. Z matematycznego punktu widzenia jest to zadanie bardzo trudne. Poszukiwane odwzorowanie definiowane jest przez wartości sygnałów z jednej przestrzeni i odpowiadające im wartości w drugiej przestrzeni. Jednym z użytecznych narzędzi do aproksymacji dowolnych odwzorowań, zarówno liniowych jak i nieliniowych są sztuczne sieci neuronowe.

W rozważanym przypadku analizy sygnału z węzła tarcia sieć neuronowa jest najlepszym narzędziem, ponieważ istotą jej działania jest fakt, że poszczególne neurony są ze sobą powiązane połączeniami będącymi odpowiednikiem połączeń synaptycznych. W sieci ulegają modyfikacji tzw. wagi połączeń. Informacje przechowywane w sieci mają charakter rozproszony, tzn. prawie niemożliwe jest stwierdzenie, który fragment sieci odzwierciedla jej cechę. Konsekwencją tego jest stosunkowo duża odporność na uszkodzenia i przekłamania związane z przesyłaniem sygnału z węzła tarcia [1].



Rys. 6. Schemat nadzorowanego procesu trenowania sieci

Znaczne zainteresowanie zastosowaniami sieci neuronowych w diagnostyce układów technicznych wynika z atrakcyjnych własności sieci.

Możliwość równoległego przetwarzania informacji, aproksymacja dowolnych nieliniowości, uczenie i douczanie sieci na podstawie obserwacji sygnałów obiektu to tylko niektóre ich cechy.


Typowy sposób wykorzystania sieci neuronowych w diagnostyce sprowadza się do budowy neuronowego klasyfikatora stanu pracującego na podstawie zebranych i aktualnych danych pomiarowych. W ogólnym przypadku problem stosowania sieci neuronowych do w diagnostyce uszkodzeń obiektu technicznego można sprowadzić do następujących działań:

- zdefiniowanie listy uszkodzeń
- określenie typowych sygnałów, mierzonych w stanie ustalonym, odpowiadających typowemu uszkodzeniu oraz normalnemu stanowi obiektu
- wybór struktury sieci i algorytmu jej uczenia
- uczenie sieci z wykorzystaniem zbioru zawierającego typowe mierzone sygnały
- testowanie sieci dla dowolnych stanów obiektu.

W przypadku każdej aproksymacji występują pewne niedokładności. Zadaniem jest poszukiwanie takiej koncepcji wykorzystania sieci neuronowych i takiego szczególnego ich rozwiązania by niedokładności te ograniczyć. Do realizacji tej koncepcji wykorzystano rodzinę sieci neuronowych z nauczycielem, uczonych metodą wstecznej propagacji błędu. Uproszczony schemat takiej sieci jest pokazany na rys.

Sieć neuronowa ma następującą architekturę (rys.):

- jedno wejście, na które podawane są mierzone wartości rezystancji
- zmienną ilość neuronów o nieliniowej funkcji aktywacji w pierwszej warstwie ukrytej
- zmienną ilość neuronów o nieliniowej funkcji aktywacji w drugiej warstwie ukrytej
- dwa neurony o liniowej funkcji aktywacji w warstwie wyjściowej, na wyjściu których oczekiwane są wartości siły nacisku i temperatury
- pętla sprzężenia zwrotnego o zmiennej ilości opóźnień, łącząca wyjścia sieci z wejściem pierwszej warstwy ukrytej



Rys. 7. Sieć ze wsteczną propagacją błędu

Dla tego typu sieci możliwe jest wykorzystanie mechanizmu przesyłającego wartość błędu z wyjścia sieci na jej wejście. Wykorzystuje on pochodne funkcji aktywacji (z założenia różniczkowalne w sieciach neuronowych), wartości przetwarzanych sygnałów oraz macierze wag połączeń w postaci oryginalnej. Wartości przesyłanego błędu określane są dla każdego z neuronów zgodnie ze wzorem:

$$\partial_j^{mk} = f'(\varphi_j^{mk}) \cdot \sum_{l=1}^n \partial_l^{(m+1)k} w_{lj}^{m+1}$$

gdzie:

∂ - wartość błędu

j - numer neuronu

m - numer warstwy neuronów

k - numer wzorca podawanego na wejście

f' - pochodna funkcji aktywacji

φ - sumaryczne pobudzenie neuronu

$\partial_l^{(m+1)k}$ - wartość błędu neuronu o numerze l w warstwie $(m+1)$ powstającego przy prezentacji wzorca o numerze k

w_{lj}^{m+1} - waga połączenia neuronu o numerze j w warstwie m z neuronem o numerze l w warstwie $m+1$.

Opisany powyżej mechanizm dla uzyskanej wcześniej sieci implementowano w postaci programu w środowisku Matlab. Uzyskane wyniki w postaci błędów na wyjściu neuronów pierwszej warstwy ukrytej przedstawiono na rysunku 10.

Zastosowanie dwóch warstw ukrytych konieczne jest ze względu na brak przybliżonej chociaż znajomości charakteru szukanego odwzorowania, a zatem słuszne wydaje się spełnienie założeń twierdzenia o zdolności sieci neuronowej do aproksymacji dowolnego odwzorowania z zadaną dokładnością.


Poszczególne warstwy sieci mogą także wykonywać jednocześnie obliczenia przekazując cyklicznie ich wyniki w głąb sieci. Przetwarzanie danych odbywa się zatem potokowo. Jest to bardzo cenne ponieważ my analizujemy jeden sygnał rozkładając go na dwa pod sygnały (temperatura i naciski) równoległe w czasie. Wielkości fizyczne takie jak: siła [N] i temperatura [°C] w naszych badaniach eksperymentalnych są ze sobą powiązane z racji zjawisk zachodzących podczas procesu tarcia. Czyli zmiana jednego pod sygnału ma pewien wpływ na drugi. Sieć neuronowa może więc odwzorowywać ten proces.

Ponieważ dekompozycja jednego sygnału na dwa sygnały o odmiennym charakterze może być dokonywana na wiele sposobów, korzystnym wydaje się dostarczenie sieci neuronowej dodatkowej informacji o charakterze oczekiwanych sygnałów wyjściowych. Takie zadanie realizuje pętla sprzężenia zwrotnego przekazując na wejście sieci kilka kolejnych wartości sygnałów

składowych. Jest to informacja dobrze uzupełniająca przepis na dekompozycję zawarty w przykładach uczących. Zastosowanie tego dodatkowego połączenia w budowanej sieci neuronowej wpłynęło korzystnie także na przebieg procesu uczenia.

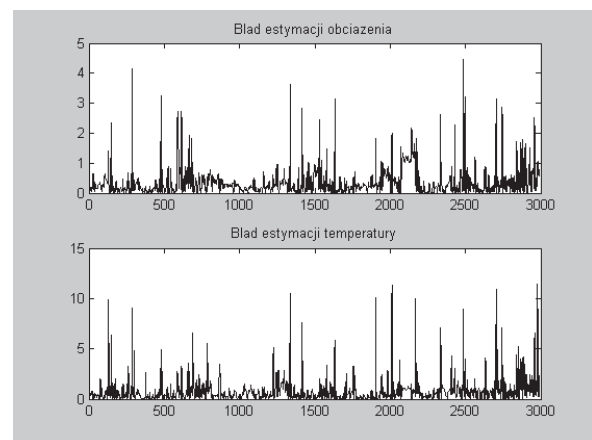
Opierając się na powyższych założeniach projektowych przygotowano cztery zestawy sieci neuronowych i poddano je procesowi uczenia.

Na rysunkach 8 i 9. przedstawione są wybrane wyniki odwrotnego odwzorowania sieci neuronowej - estymacji obciążenia i temperatury [1].




Rys. 8. Wyniki odwrotnego odwzorowania sieci neuronowej

Przedstawione powyżej wyniki są tylko przykładami uzyskanego materiału. Ilustrują one przebieg procesu badawczego i skłaniają do wniosku, że wraz ze wzrostem rozmiaru warstw ukrytych rośnie dokładność osiąganych wyników. Również zwiększenie ilości opóźnień w sprzężeniu zwrotnym powoduje podobny efekt. Zatem można stwierdzić, że poczynione założenia projektowe wydają się słuszne.



Rys. 9. Błędy estymacji odwrotnego odwzorowania sieci neuronowej



Rys. 10. Porównanie rzeczywistych wartości rezystancji z wartościami wygenerowanymi przez sieć neuronową. 1 – wyniki pomiarów, 2 – wyniki generowane przez sieć neuronową

PODSUMOWANIE

Przedstawiona realizacja koncepcji odwracania odwzorowania z wykorzystaniem sieci neuronowych jest zadaniem złożonym i pracochłonnym. Wymaga budowy dwóch sieci neuronowych oraz mechanizmu przesyłania sygnału wstecz przez jedną z nich. Uzyskane wyniki estymacji zarówno obciążenia jak i temperatury cechują się dość dużą dokładnością. Występujące niedokładności są w głównej mierze efektem tego, że wykorzystano aproksymację odwzorowania, a nie jego dokładną matematyczną postać, która nie jest znana. Kolejnym miejscem generującym niedokładności jest druga z sieci neuronowych dokonująca przekształcenia wyników wstecznej propagacji na sygnały wejściowe z zadaną dokładnością. Zatem dalsze prace powinny koncentrować się na poprawieniu jakości działania obu sieci neuronowych.

Podsumowując należy stwierdzić, że zastosowanie sieci neuronowych z wsteczną propagacją błędów do aproksymacji odwzorowania pozwala na odwrócenie tej aproksymacji przez wykorzystanie mechanizmu wstecznej propagacji. Również proces przygotowania sieci neuronowej realizującej aproksymację pierwotnego odwzorowania jest łatwiejszy i mniej czasochłonny. Zatem druga z zaproponowanych koncepcji wydaje się być bardziej obiecująca.

LITERATURA

- [1] Metoda diagnozowania węzłów tarcia maszyn i robotów przy użyciu sensorowych warstw ślizgowych. Sprawozdanie KBN-7T07C01418, AGH Kraków, 2002.
- [2] Rakowski W. Kot M.: Model for piezoresistive bearing layer, World Congress on Tribology, Wiedeń, 2001, s.1624-1627.

- [3] Rakowski W., Rabiasz S. Barkhausen effect applied to bearing sensor layer, Tribologia. --- 2002 vol. 33 nr 6 s. 1583--1593
- [4] Rakowski W., Zimowski S., Tribological system with sensor-bearing coating, AUSTTRIB '02 : Perth, 2002. s. 1723—1736.
- [5] Harsányi G.: Polymer films in sensor applications. Technology Materials Devices. Technomic Publishing Company Book (1995)
- [6] Hertz J., Krogh A., Palmer R., "Wstęp do teorii obliczeń neuronowych", Wydawnictwa Naukowo-Techniczne, Warszawa 1995.
- [7] Korbicz J., Obuchowicz A., Uciński D., "Sztuczne sieci neuronowe. Podstawy i zastosowania", Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [8] Żurada J., Barski M., Jędruch W., "Sztuczne sieci neuronowe", Wydawnictwo Naukowe PWN, Warszawa 1996.

Autorzy dziękują Komitetowi Badań Naukowych za finansowe wsparcie projektu badawczego T07C 00218. Szczególne podziękowania wyrażamy dr Mariuszowi Gibcowi za udzieloną nam pomoc.



Wiesław Rakowski jest profesorem w Akademii Górniczo-Hutniczej w Krakowie na Wydziale Inżynierii Mechanicznej i Robotyki. Kieruje Laboratorium Tribologii i Inżynierii Powierzchni.



Stanisław Rabiasz jest doktorantem na Wydziale Inżynierii Mechanicznej i Robotyki Akademii Górniczo-Hutniczej w Krakowie