

WYKORZYSTANIE POMIARÓW AKUSTYCZNYCH DO OCENY STANU MASZYN ELEKTRYCZNYCH

Mariusz GIBIEC Lucjan MIĘKINA

*Katedra Robotyki I Dynamiki Maszyn, Akademia Górniczo-Hutnicza,
Al. Mickiewicza 30, 30-059 Kraków, e-mail: mgi@uci.agh.edu.pl*

Streszczenie

W niniejszym artykule zaprezentowano przykład oceny stanu maszyn elektrycznych na podstawie analizy sygnałów akustycznych. Przedmiotem badań była ocena jakości nowych podzespołów schodzących z linii produkcyjnej. W tym przypadku pierwsze symptomy niepełnej zdatości ujawniają się w dziedzinie sygnałów akustycznych, a dopiero w trakcie dalszej eksploatacji rozwijają się do stadium wykrywanego przez pomiary drganiowe. Podstawą oceny było widmo fali akustycznej ujednoczone dla wszystkich egzemplarzy względem prędkości obrotowej. Wykorzystywanym narzędziem jest odpowiednio przygotowana sieć neuronowa typu Kohonena. Efekty jej działania porównano z wynikami metody minimalnoodległościowej opartej o uśrednione wzorce widmowe.

Słowa kluczowe: ocena stanu maszyn, sygnały akustyczne, sieci neuronowe

APPLICATION OF ACOUSTIC MEASUREMENTS FOR ELECTRICAL MACHINES CONDITION ASSESSMENT

Summary

In this article, an example of electric machines condition assessment is presented. The case study were new components quality control. In such case first symptoms of unserviceability disclose in acoustic domain and then in later exploitation they develop into form detectable in vibration measurements. The basis of assesment was acoustic wave spectrum normalized in relation to rotating speed. The assessing tool is adequatly prepered neural network of Kohonen's type. Its performance was compared to results of minimum distance method basing on averaged spectrum patterns.

Key words: machine state assesment, acoustic signals, neural networks

1. WSTĘP

Sygnały akustyczne w zastosowaniach diagnostycznych są rzadziej wykorzystywane niż drganiowe. Jest to spowodowane ich większą podatnością na zakłócenia zewnętrzne. Jednak już ich pojemność informacyjna (bez trudności mierzony zakres częstotliwości dochodzi do kilkudziesięciu kHz) jest porównywalna a nawet przewyższa sygnały drganiowe.

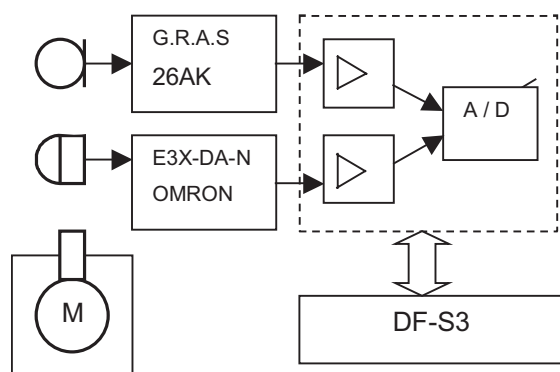
Zalety pomiarów drganiowych wynikają z łatwiejszej identyfikacji dróg przenoszenia się energii i eliminacji niepożądanych wpływów zewnętrznych. Jednak w niektórych zastosowaniach nie jest możliwe dotarcie z czujnikiem do miejsca powstawania drgań. Również w przypadku kontroli jakości masowo produkowanych podzespołów czas potrzebny na montaż i demontaż czujników wydaje się zbyt dużym wydatkiem. Ze względu na brak wyżej wymienionych niedogodności pomiar generowanej przez nie fali akustycznej może być obiecującym rozwiązaniem. Jest to zadanie

trudniejsze, jednak możliwe do zrealizowania dzięki rozwojowi metod przetwarzania i analizy sygnałów. Modelowanie pola akustycznego spotykanego w realnych warunkach (złożone kształty powierzchni ograniczających, nieznane współczynniki pochłaniania dźwięku i warunki propagacji) generuje problemy szczególnie, jeśli wymaga rozwiązywania modelu w czasie rzeczywistym. Dlatego zaproponowane zostało wykorzystanie metod z obszaru sztucznej inteligencji: sztucznych sieci neuronowych i logiki rozmytej. Nie wymagają one najczęściej znajomości struktury modelu, co pozwala pominąć etap modelowania. Ich istotną cechą jest zdolność do aproksymacji dowolnych funkcji nieliniowych. W niniejszym artykule zaprezentowano przykład zastosowania proponowanych metod do oceny stanu maszyn elektrycznych na podstawie analizy sygnałów akustycznych. Przedmiotem badań była ocena jakości nowych podzespołów schodzących z linii produkcyjnej. W tym przypadku pierwsze symptomy niepełnej zdatości ujawniają się w

dziedzinie sygnałów akustycznych, a dopiero w trakcie dalszej eksploatacji rozwijają się do stadium wykrywanego przez pomiary drganiowe. Dlatego skoncentrowano się na sygnale akustycznym jako nośniku informacji o stanie maszyny. Badane maszyny charakteryzowały się szerokim widmem generowanego sygnału akustycznego, ze względu na konstrukcję (komutator) i funkcję użytkową (przepływ zasysanego powietrza), co dodatkowo utrudnia proces klasyfikacji.

2. OPIS EKSPERYMENTU

W trakcie eksperymentu wykonano cyfrowe pomiary i rejestrację przebiegów ciśnienia akustycznego towarzyszącego pracy komutatorowych silników elektrycznych prądu zmiennego małej mocy. Ze względu na funkcję użytkową są one wyposażone w zintegrowany wentylator typu promieniowego. Stanowi on dodatkowo źródło hałasu typu aerodynamicznego, charakteryzujące się ciągłym widmem. Silniki pochodziły z jednej serii produkcyjnej i były zaklasyfikowane jako wadliwe, z określonym typem podstawowego defektu (drgania od wirnika, luz wirnika, uszkodzenie łożyska, zwiększona głośność). Pomiary zostały wykonane w komorze bezchowej Katedry Mechaniki i Wibroakustyki AGH, co pozwoliło wyeliminować wpływ zakłóceń zewnętrznych, odbić i rezonansów pomieszczenia badawczego. Oprócz przebiegów hałasu, równoległe rejestrowano przebieg prostokątny o częstotliwości obrotowej badanego silnika. Przebieg prędkości obrotowej może być wykorzystany do skalowania widm sygnału akustycznego i do widmowej analizy synchronicznej. Przeprowadzono dwie serie badań, odpowiednio dla biegu luzem i pod obciążeniem (dławienie przepływu po stronie ssania). W każdej serii rejestrowano po 30 sek. przebiegu przy trzech ustalonych prędkościach obrotowych, ponieważ w trakcie wstępnych, słuchowych testów stwierdzono dla niektórych z badanych silników wyraźną zależność widma od prędkości obrotowej. Badania wykonano w układzie pomiarowym pokazanym na rys. 1.



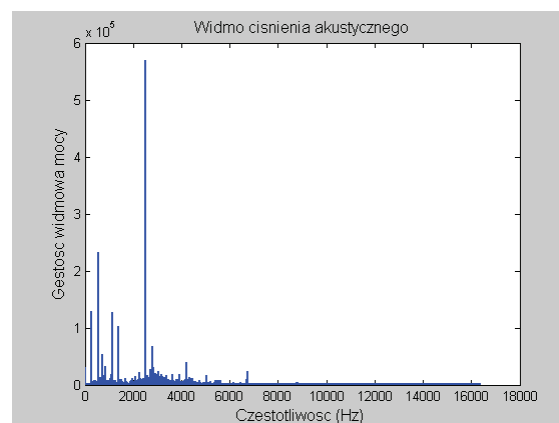
Rys. 1 Schemat układu pomiarowego

Badane silniki były umocowane w specjalnie ukształtowanym łożysku, wykonanym z materiału tłumiącego drgania. Łożysko to pełniło również funkcję układu dolotowego dla zasysanego powietrza. Mikrofon pomiarowy G.R.A.S. wraz z przedwzmacniaczem 26 AK umieszczono na statywie w odległości 0.5 [m] nad badanym silnikiem od strony komutatora. Do pomiaru prędkości obrotowej wykorzystano cyfrowy fotowłącznik światłowodowy E3X-DA-N firmy OMRON, który współpracował z elementem odbijającym strumień światła, przymocowanym na osi badanego silnika. Do rejestracji wykorzystano dwukanałowy analizator DF-1 firmy TEAC, współpracujący z programem DF-S3 firmy TEAC, uruchomionym na komputerze PC, który spełniał funkcję nadrzędnego układu sterującego i zapisującego strumień danych.

W trakcie eksperymentu rejestrowano również uśrednione widma mocy sygnału, dla wstępnej oceny badanego procesu. Widma te charakteryzują się dużą złożonością: na tle widma ciągłego o relatywnie wysokim poziomie, można wyróżnić pewną liczbę składowych harmonicznnych, które mają indywidualny rozkład dla poszczególnych rodzajów uszkodzeń.

3. ANALIZA OTRZYMANYCH DANYCH

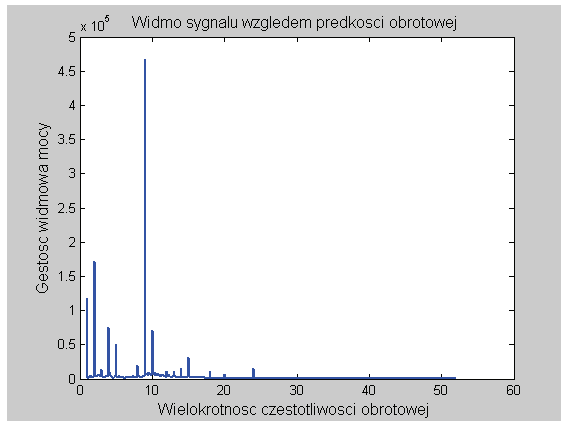
Przebiegi czasowe ciśnienia akustycznego dla wszystkich badanych maszyn są podobne. Również charakteryzujące je estymaty mają zbliżone wartości. Dlatego podjęto decyzję o dalszej analizie danych w dziedzinie częstotliwości. Do analizy widmowej zastosowano okno o rozmiarze równym ilości próbek rejestrowanych w ciągu 1 sekundy. Przykładowe widmo zaprezentowano na rysunku 2.



Rys. 2 Widmo fali akustycznej

W trakcie analizy stwierdzono, że poszczególne maszyny mają różne prędkości robocze. Aby zapewnić obiektywne warunki analizy dokonano normalizacji widma wykorzystując pomiar prędkości obrotowej. Możliwe jest także określenie podstawowej harmonicznnej z wykresu widma. Zapewniono by znormalizowane widmo zawierało

składowe dla wielokrotności podstawowej harmonicznej z dokładnością do jej 1/100. Przykładowe widmo pokazano na rysunku 3.



Rys. 3 Zależność widma od prędkości obrotowej

Otrzymane widma mają bardzo duży rozmiar – 16385 elementów, co utrudnia budowanie relacji symptom stan w oparciu o klasyczne metody klasyfikacji. Nawet w przypadku określenia widmowych wzorców dla poszczególnych uszkodzeń maszyn aktualnie analizowane widmo może zostać źle sklasyfikowane. Jest to spowodowane tym, że jeśli widmo różni się od innych wzorców tylko w kilku punktach, to przy tak dużym rozmiarze testowanego wektora różnica może nie być znacząca. Dlatego zaproponowano inną niż odległościowe, metodę znajdowania podobieństwa między badanymi widmami.

Ponieważ znany jest stan maszyny, dla której zmierzono przebieg ciśnienia akustycznego, można zastosować sieci neuronowe uczone z nauczycielem. Sieci te posiadają zdolność do aproksymacji odwzorowań definiowanych za pomocą przykładów. W tym przypadku dostępny jest zbiór przykładowych par widmo – stan maszyny. Jednak wykorzystywane w procesie uczenia takiej sieci metody gradientowe wymagają dużych zasobów pamięci, zależnych od wielkości wektora wejściowego i ilości przykładów. W tym przypadku rozmiar ten przekracza możliwości komputera. Koniecznym jest, zatem zmniejszenie rozmiaru wektora wejściowego.

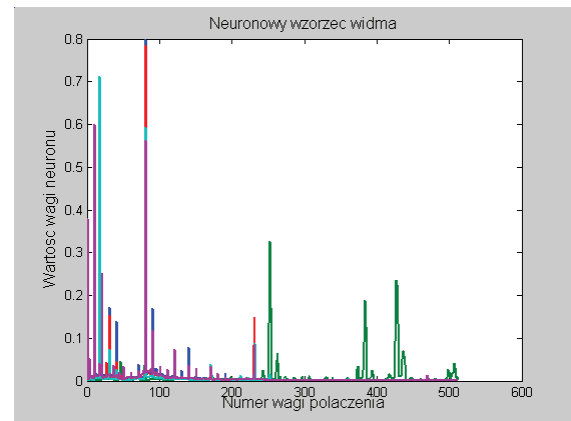
Innym rozwiązaniem może być wykorzystanie sieci neuronowych uczonych bez nauczyciela, których cechą jest łatwość przetwarzania dużej ilości danych wejściowych. Warunkiem ich stosowania jest normalizacja wektora wejściowego oraz określenie, z pewnym nadmiarem, spodziewanej ilości grup, które można wyróżnić w danych. Efektem działania takiej sieci jest wartość 1 na wyjściu jednego z neuronów oraz 0 na pozostałych. Na podstawie odpowiedzi sieci dla opisanych wcześniej przykładów identyfikuje się, dla których neuronów wartość wyjścia 1 oznacza dany stan maszyny. Pamiętając o powyższych założeniach,

procesowi uczenia poddano sieć o 7 neuronach (przy 5 rodzajach uszkodzeń). Pomimo wielokrotnego przebiegu procesu uczenia otrzymano sieć rozpoznającą tylko dwa stany maszyny. Są to bieg luzem i pod obciążeniem. Świadczy to o tym, że w widmie występuje znacznie więcej elementów charakterystycznych dla warunków pracy niż dla poszczególnych uszkodzeń. Do dalszych badań wykorzystane zostały tylko pomiary wykonane dla biegu luzem.

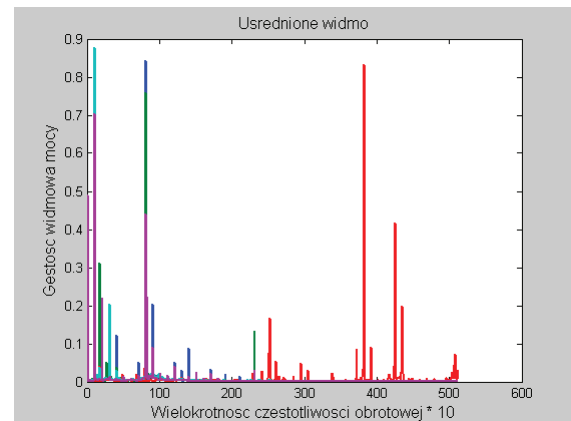
Przygotowano ciąg uczący zawierający 60 elementów dla maksymalnej prędkości pracy maszyny i 15 elementów testowych. Po przeprowadzeniu procesu uczenia otrzymano prawidłowo działającą sieć neuronową o 10 neuronach. Ilość neuronów stopniowo ograniczano ponawiając proces uczenia. Ostatecznie otrzymano sieć neuronową o rozmiarze 5, która generuje prawidłowe odpowiedzi zarówno dla ciągu uczącego, jak i testowego.

4. WYNIKI

W trakcie procesu uczenia wagi poszczególnych neuronów tworzą wzorec wektora wejściowego charakterystycznego dla danego stanu maszyny. Na rysunku 4 zaprezentowano wzorce zidentyfikowane przez sieć neuronową. Dla porównania na kolejnym rysunku pokazano uśrednione widma dla różnych stanów maszyny.



Rys. 4 Neuronowy wzorec widma



Rys. 5 Uśrednione widmo sygnału akustycznego. Porównanie powyższych rysunków pokazuje, że w analizowanym przypadku zadanie klasyfikacji nie jest trywialne – otrzymane wzorce różnią się. Oba typy wzorców wykorzystano do oceny stanu maszyny na podstawie widm testowych. Wynikiem działania sieci był numer aktywnego neuronu, zaś w przypadku uśrednionych wzorców numer wzorca, od którego odległość testowanego widma jest najmniejsza. Rezultaty zawarto w tabeli nr 1. Odpowiedzi sieci neuronowej są prawidłowe, wykorzystanie uśrednionych wzorców nie zawsze generuje poprawną ocenę stanu maszyny.

Tabela 1

	Ocena stanu maszyny
Prawidłowa	1 4 5 3 2 1 4 5 3 2 1 4 5 3 2 1 4 5 3 2
Sieć neuronowa	1 4 5 3 2 1 4 5 3 2 1 4 5 3 2 1 4 5 3 2
Uśredn. widmo	1 4 3 4 2 1 4 5 4 2 1 4 5 4 2 1 4 5 4 2

Ponieważ normalizacja widma względem prędkości obrotowej powinna pozwolić na poprawną ocenę stanu również dla maszyn pracujących z inną prędkością od maksymalnej, przetestowano opisane wcześniej rozwiązania dla prędkości równej 75% maksymalnej. Wyniki zestawiono w tabeli 2. Pogrubiono błędne oceny stanu maszyny

Tabela 2

	Ocena stanu maszyny
Prawidłowa	1 4 5 3 2 1 4 5 3 2 1 4 5 3 2 1 4 5 3 2
Sieć neuronowa	1 4 2 3 2 1 4 5 3 5 1 4 2 3 1 1 4 5 3 5
Uśredn. widmo	1 4 5 1 1 1 4 2 4 1 1 3 2 4 1 1 4 5 1 1

Wykorzystanie uśrednionego widma prowadzi do błędnych ocen stanu. Sieć neuronowa prawidłowo ocenia stan maszyny dla przypadków 1, 2 i 4. Świadczy to o osiągniętej przez sieć, w procesie uczenia, zdolności do generalizacji. Można też stwierdzić, że przypadki te są łatwiej rozróżnialne. Przypadki 3 i 5 są oceniane błędnie. Umieszczenie w ciągu uczącym przykładów pracy maszyny przy różnych prędkościach powinno poprawić działanie sieci.

Kolejnym testem była próba oceny stanu maszyny w trakcie pracy pod obciążeniem. Jednak ze względu na inny charakter widma dla tego trybu pracy nie otrzymano prawidłowych wyników dla obu metod.

5. PODSUMOWANIE

W niniejszej pracy wykorzystano mierzone sygnały akustyczne do oceny stanu maszyn elektrycznych. Analizy sygnałów dokonywano w dziedzinie częstotliwości. Różne parametry pracy badanych maszyn wymagają ujednoczenia widma względem prędkości obrotowej. Duży rozmiar wektora amplitud widma utrudnia wykorzystanie metod odległościowych, jak i sieci neuronowych uczonych z nauczycielem do oceny stanu. Zastosowane sieci

neuronowe Kohonena dokonują poprawnej oceny jakości nowych podzespołów schodzących z linii produkcyjnej. Oceny tej dokonano na podstawie widma generowanej przez podzespół fali akustycznej dla pracy bez obciążenia i znamionowej prędkości obrotowej. Otrzymana sieć neuronowa wykazuje poprawne działanie dla trzech z pięciu przypadków, również przy prędkościach innych od znamionowej. Dla pracy pod obciążeniem oceny dokonywane przez sieć są błędne. Może to być spowodowane odmienną strukturą widma analizowanego sygnału od widma otrzymywanego w trybie bez obciążenia.

LITERATURA

- [1] W. Batko, M. Gibiec, Neural Networks for Automatic Machine Condition Assessment, Proc. of the IASTED International Conference MODELLING, IDENTIFICATION AND CONTROL, Innsbruck 2000, pp. 578-584.
- [2] Z. Żyszkowski, Miernictwo akustyczne, WNT, W-wa, 1987.
- [3] TEAC DF-S3 user's manual. Teac Corp., Tokyo, 2003
- [4] Gibiec M., Doskowski G., Uhl T., Kohonen Neural Networks Utilisation to Aid Diagnostic Process, AI-METH 2002, Gliwice
- [5] Kohonen T.: The self-organizing map. Springer, Berlin Heidelberg, 1995.



Dr inż. Mariusz GIBIEC jest adiunktem w Katedrze Robotyki i Dynamiki Maszyn AGH. Jego zainteresowania dotyczą zastosowań metod eksploracji danych oraz sztucznej inteligencji (sieci neuronowych i zbiorów rozmytych) w Diagnostyce Technicznej. Jest autorem prac

nad wykorzystaniem powyższych technik w systemach monitorujących do realizacji zadań filtracji, predykcji, klasyfikacji stanu maszyn oraz oceny obciążeń zmęczeniowych konstrukcji mechanicznych.



Dr inż. Lucjan Miękina jest adiunktem w Katedrze Robotyki i Dynamiki Maszyn AGH. Jego zainteresowania dotyczą cyfrowych pomiarów i analizy sygnałów, identyfikacji układów dynamicznych, obiektowozorientowanej inżynierii oprogramowania dla systemów

akwizycji i analizy sygnałów w diagnostyce przemysłowej i w innych zastosowaniach. Jest autorem prac nad wykorzystaniem powyższych technik w systemach monitorujących pracujących w czasie rzeczywistym.