ISSN 1733-8670

ZESZYTY NAUKOWE NR 5(77)
AKADEMII MORSKIEJ
W SZCZECINIE

OBSŁUGIWANIE MASZYN I URZĄDZEŃ OKRĘTOWYCH
O M i U O 2 0 0 5

Jacek Dybała

Rozpoznawanie stanu technicznego przekładni zębatych z wykorzystaniem sieci neuronowej CP

Słowa kluczowe: sieci neuronowe, klasyfikacja, diagnostyka wibroakustyczna, przekładnie zębate

W artykule przedstawiono sposób zastosowywania neuronowego klasyfikatora zbudowanego na bazie sieci neuronowej z propagacją przeciwną w diagnostyce wibroakustycznej przekładni zębatych. W końcowej części artykułu przedstawiono jako przykład wyniki eksperymentu laboratoryjnego.

Identification of the Technical State of Toothed Gears with the Use of CP Neural Network

Key words: neural networks, classification, vibroacoustic diagnostics, toothed gears

This article presents a way of applying a neural classifier constructed on the basis of a counter-propagation neural network in vibroacoustic diagnosis of toothed gears. In the final part of the article the results of a laboratory experiment are presented.

Wprowadzenie

Procesy wibroakustyczne dobrze odwzorowują stan eksploatacyjny maszyn [1]. Śledząc zatem charakter ich zmian można ocenić rzeczywisty stan eksploatacyjny obiektu. Niestety, ocena stanu obiektu technicznego na podstawie analizy sygnału wibroakustycznego generowanego przez ten obiekt nie należy jednak w ogólnym przypadku do prostych zadań. Informacja diagnostyczna zawarta w sygnale drganiowo-hałasowym ma bowiem zazwyczaj różnorodną postać. Wynika to z faktu, że zmiany stanu obiektu mogą wpływać w szerokim zakresie na wartość i strukturę sygnału wibroakustycznego. W wielu wypadkach zbudowanie efektywnych regresyjnych modeli diagnostycznych jest istotnie utrudnione lub nawet niemożliwe, ze względu na brak wiedzy o strukturze obiektu oraz niepełną i niepewną informację o przebiegu zjawiska czy procesu. W takiej sytuacji szczególnego znaczenia nabierają metody i techniki bazujące na sieciach neuronowych, coraz częściej i z coraz lepszymi efektami stosowane w diagnostyce technicznej.

1. Klasyfikacja stanu obiektu

Każdy obiekt w danej chwili znajduje się w pewnym określonym stanie. Stan obiektu opisany jest zbiorem chwilowych wartości cech (właściwości) stanu obiektu. Uporządkowany ciąg N wartości cech stanu obiektu $\{x_1, x_2, ..., x_N\}$ nazywa się wektorem obserwacji stanu obiektu [10]. Z geometrycznego punktu widzenia, składowe wektora obserwacji stanu obiektu można traktować jako współrzędne definiujące punkt w N-wymiarowej przestrzeni obserwacji stanu obiektu. Punkt ten jest obrazem stanu obiektu.

Liczba możliwych stanów obiektu jest nieskończona. Przyczyną zmian stanu są pojawiające się uszkodzenia i inne zdarzenia wpływające na zmianę jakości działania obiektu. W praktyce pełne rozpoznanie stanu technicznego obiektu nie zawsze jest możliwe i konieczne. Godząc się z pewnym dopuszczalnym poziomem nieokreśloności stanu wprowadzamy ustaloną liczbę klas stanu odpowiadających rozróżnialnym stanom obiektu, czyli stanom, których rozpoznanie jest uzasadnione ze względu na dalsze postępowanie z obiektem. W takim wypadku rozpoznawanie stanu technicznego obiektu sprowadza się do klasyfikacji stanu rozumianej jako proces zaszeregowania stanu obiektu do odpowiedniej klasy stanu.

Urządzenie dokonujące klasyfikacji stanu nazywane jest systemem klasyfikującym lub krótko klasyfikatorem (rys. 1).

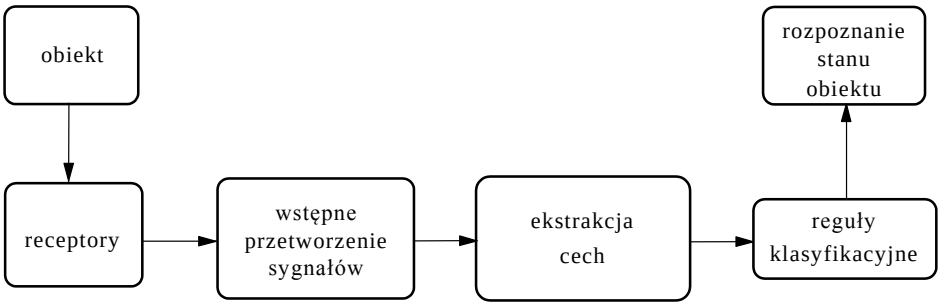

Rys. 1. Schemat funkcjonalny klasyfikatora
Fig. 1. The functional diagram of the classifier

Pobieranie informacji o obiekcie odbywa się przy pomocy czujników (receptorów). Sygnał musi zostać następnie przetworzony do zbioru cech (parametrów, symptomów), których wartości opisują stan diagnozowanego obiektu. Kluczowym elementem każdego systemu klasyfikującego są reguły klasyfikacyjne określające relacje między cechami a rozróżnialnymi stanami obiektu. Niestety, powiązanie przyczynowo-skutkowe między stanem obiektu a cechami nie zawsze jest znane w sensie analitycznym. Z tego powodu atrakcyjnym narzędziem realizacji klasyfikatora wydają się być sieci neuronowe, które nie wymagają podawania wprost reguł klasyfikacyjnych, potrafią bowiem same je zbudować na podstawie dostarczonych w procesie uczenia przykładów diagnozy (programowanie przez uczenie).

2. Sieć neuronowa CP

Najczęściej do budowy neuronowego klasyfikatora stanu obiektu wykorzystuje się jednokierunkowe wielowarstwowe sieci nieliniowe (perceptrony wielowarstwowe). Ciekawą alternatywą wobec jednokierunkowych sieci nieliniowych wydają się być hybrydowe sieci neuronowe bazujące na uczeniu konkurencyjnym, nazywanym także często uczeniem z rywalizacją (neurony jakby rywalizują, konkurują ze sobą o możliwość korekty wag, czyli o możliwość nauki). Przykładem takiej sieci może być sieć neuronowa z kontrapropagacją (propagacją przeciwną) zwana również siecią CP (Counter Propagation) [6, 7, 9, 11]. Sieci CP stosowane są wprawdzie do węższej klasy zagadnień niż jednokierunkowe sieci nieliniowe, ale za to uczą się znacznie szybciej, a ustalenie ich struktury jest prostsze. Znajdują zastosowania głównie w wektorowym przetwarzaniu danych jako klasyfikatory wektorowe. Doskonale zdają egzamin jako systemy klasyfikacji i rozpoznawania obrazów.

Sieć CP została opracowana przez Roberta Hecht-Nielsena w latach 1987 – 1988 i jest kombinacją dwóch rodzajów sieci: sieci konkurencyjnej i sieci

liniowej [5]. Połączenie tych sieci w jedną stworzyło sieć o nowych właściwościach. Schemat sieci neuronowej CP klasyfikującej stan badanego obiektu przedstawiono na rysunku 2.

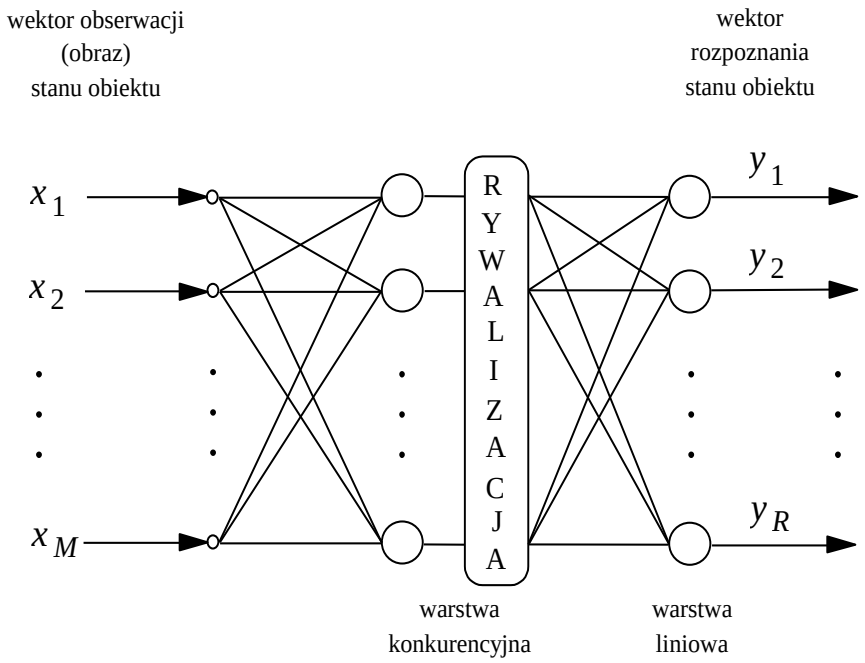

Rys. 2. Schemat sieci neuronowej CP
Fig. 2. The diagram showing a CP neural network

Poszczególne warstwy sieci spełniają w procesie rozpoznawania stanu obiektu różne zadania.

Warstwa konkurencyjna dzieli przestrzeń obserwacji stanu obiektu na strefy wpływów poszczególnych neuronów konkurencyjnych (tzw. wielościany Voronoi). Każdy wielościan zawiera zatem obszar najbliższy (w sensie wybranej metryki) danemu neuronowi konkurencyjnemu. Neuronem zwycięzcą zostaje ten neuron, w którego strefie wpływów znajduje się prezentowany wektor obserwacji stanu obiektu. Przestrzeń obserwacji stanu obiektu jest więc podzielona jak mozaika Voronoi, a dowolny wektor obserwacji jest reprezentowany przez określony wielościan (neuron zwycięzcę). Wagi neuronu konkurencyjnego stanowią sygnaturę pewnego stanu obiektu.

Warstwa liniowa przypisuje (adresuje) poszczególne wielościany do określonych klas stanu obiektu. Poszczególne sygnatury stanu obiektu są zatem kojarzone z rozróżnialnymi stanami obiektu za pomocą wag neuronów liniowych.

Uczenie sieci przebiega równocześnie w obydwu warstwach sieci. Wektor rozpoznania stanu obiektu należy interpretować w następujący sposób: jeżeli sieć neuronowa uzna, że stan obiektu odpowiada klasie stanu 2, to na wyjściu numer 2 pojawi się najsilniejszy sygnał. Miarą poprawności działania sieci neuronowej, nazywaną także sprawnością sieci, jest procent poprawnie rozpoznanych stanów obiektu.

3. Eksperyment

3.1. Stanowisko pomiarowe

Obiektem badań była przekładnia zębata jednostopniowa, redukująca z kołami walcowymi o zębach śrubowych (typoszereg 1N100), wyprodukowana przez Fabrykę Reduktorów i Motoreduktorów „Befared" S.A. w Bielsku Białej i charakteryzująca się następującymi parametrami konstrukcyjnymi: moduł nominalny m_n = 2 mm, liczba zębów zębnika z_1 = 20, liczba zębów koła z_2 = 79, kąt pochylenia linii śrubowej zęba 8°6'34", kierunek pochylenia linii zębów koła prawy, szerokość wieńca 40 mm. Katalogowa moc reduktora wynosiła 8,9 kW przy 1000 obr/min.

W celu umożliwienia symulacji odchyłek wykonawczo-montażowych przekładnia została wyposażona w mimośrodowe osadzenie łożysk wału koła [8]. Ramię mimośrodów wynosiło 1 mm. Na obu mimośrodach można było uzyskać po 24 położenia. Błędy ustawienia osi wału koła były traktowane jako uszkodzenia przekładni i stanowiły przedmiot diagnozy. Do ich określenia użyto następujących wielkości: kąt przekoszenia osi wału koła w płaszczyźnie poziomej (płaszczyźnie wałów) „p_h" oraz kąt przekoszenia osi wału koła w płaszczyźnie pionowej „p_v". Klasy stanu przekładni zdefiniowano następująco: p_h = 0 i p_v = 0 (klasa stanu 1), p_h ≥ 0 i p_v > 0 (klasa stanu 2), p_h > 0 i p_v ≤ 0 (klasa stanu 3), p_h ≤ 0 i p_v < 0 (klasa stanu 4), p_h < 0 i p_v ≥ 0 (klasa stanu 5).

Badania wykonano na stanowisku badawczym zainstalowanym w Pracowni Wibroakustyki IPBM PW, którego schemat przedstawiono na rysunku 3.

Badany reduktor napędzały oraz hamowały silniki elektryczne prądu stałego. Wał zębnika oraz wał koła zostały połączone z silnikiem oraz z hamownicą za pomocą podatnych sprzęgieł. W celu umożliwienia analizy synchronicznej drgań przekładni, do sprzęgła na wale zębnika została przymocowana stalowa tarcza z pojedynczym nacięciem, a do sprzęgła na wale koła – tarcza z 60 nacięciami. Podczas pracy przekładni nacięcia te powodowały powstawanie impulsów napięciowych w optoelektronicznych czujnikach prędkości obrotowej. Impulsy te były następnie wykorzystywane do dokładnego określania prędkości obrotowej oraz do synchronizacji przebiegów drganiowych podczas uśredniania

w dziedzinie czasu [8]. Do pomiarów przyspieszeń drgań korpusu przekładni wykorzystano dwa tory pomiarowe składające się z przetworników piezoelektrycznych drgań oraz przedwzmacniaczy ładunkowych. Czujnik kanału pierwszego przykręcony był do korpusu reduktora nad łożyskiem zębnika od strony silnika napędzającego, zaś czujnik kanału drugiego nad łożyskiem zębnika od strony hamownicy. Do kanału trzeciego urządzenia rejestrującego podłączono napięciowy sygnał znacznika obrotów wału zębnika, zaś do kanału czwartego – napięciowy sygnał znacznika obrotów wału koła.

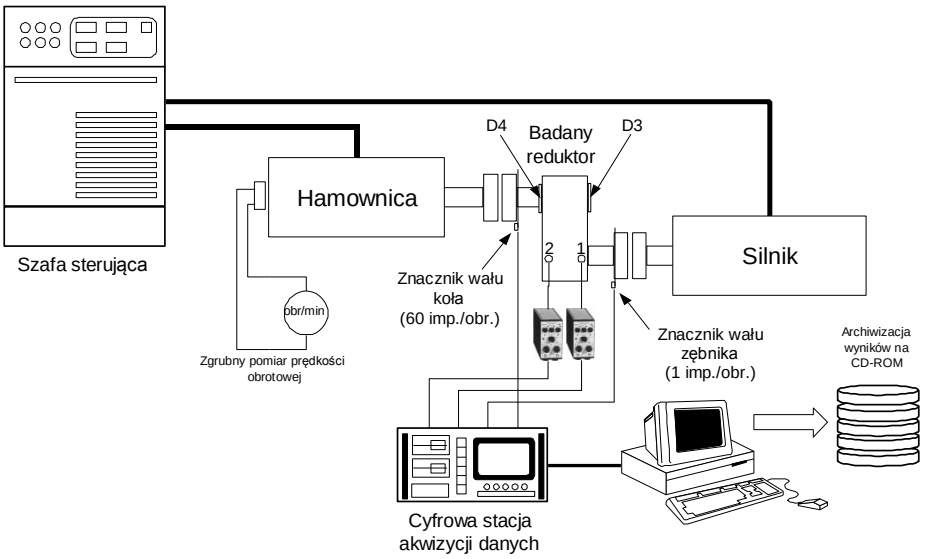

Rys. 3. Schemat stanowiska badawczego
Fig. 3. The diagram of the test station

3.2. Przebieg badań

Dla wybranych dwunastu różnych ustawień mimośrodów wykonano 82 rejestracje przyspieszeń drgań korpusu przekładni przy siedmiu prędkościach obrotowych: 900, 950, 1000, 1050, 1100, 1150 i 1200 obr/min i obciążeniu koła 45 Nm. Rejestrowano przebiegi czasowe przyspieszeń w ciągu 6 sekund procesu ustalonego przy rozdzielczości czasowej około 0,00002 sekundy. W celu wyodrębnienia z zarejestrowanych sygnałów składników związanych przyczynowo z poszczególnymi wałami poddawano je procedurze uśredniania synchronicznego, przy czym podstawą uśredniania były odpowiednio obroty wału zębnika i koła.

Przyjęto założenie, że stany przekładni będą odwzorowywać się w widmach przyspieszeń drgań jej korpusu. W związku z tym wykonano widma amplitudowe uśrednionych synchronicznie sygnałów w zakresie częstotliwości od 0 do 3000 Hz. Przykładowe widmo amplitudowe przyspieszenia drgań korpusu mierzonych od strony silnika (uśrednianie obrotami wału koła) przedstawiono na rysunku 4.

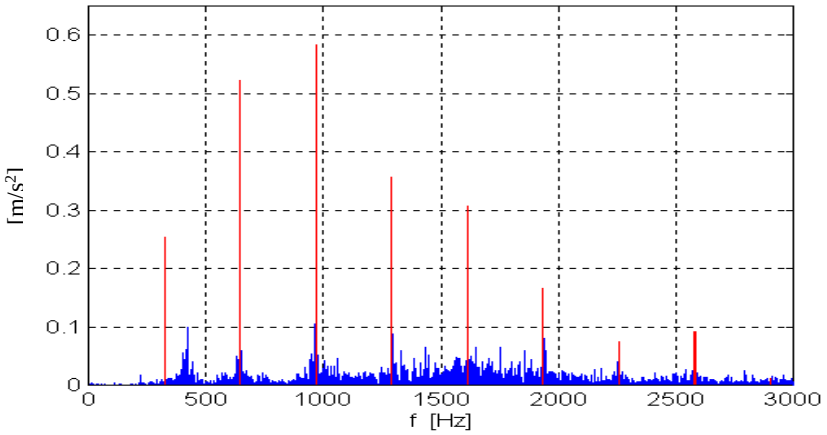

Rys. 4. Widmo amplitudowe przyspieszenia drgań korpusu
Fig. 4. Amplitude spectrum of the acceleration of body vibration

Za podstawę opisu stanu przekładni przyjęto wartości amplitud przyspieszeń drgań korpusu przekładni kolejnych dziewięciu harmonicznych częstotliwości zazębienia. Wprowadzono następujące symbole przyjętych cech stanu obiektu: cechy 1 ÷ 9 – amplitudy przyspieszeń drgań mierzonych od strony silnika i uśrednianych obrotami wału koła, cechy 10 ÷ 18 – amplitudy przyspieszeń drgań mierzonych od strony hamownicy i uśrednianych obrotami wału koła, cechy 19 ÷ 27 – amplitudy przyspieszeń drgań mierzonych od strony silnika i uśrednianych obrotami wału zębnika, cechy 28 ÷ 36 – amplitudy przyspieszeń drgań mierzonych od strony hamownicy i uśrednianych obrotami wału zębnika.

Następnie, przy pomocy dwóch kryteriów: zmodyfikowanego kryterium Sebestyena oraz kryterium liczby wzorców klas [4], dokonano selekcji cech stanu ograniczając się do zestawu cech o symbolach 13, 21, 22, 25, 29, 35. Wybrane cechy były parametrami wejściowymi sieci neuronowej (wektor obserwacji stanu obiektu składał się z tych wybranych cech).

3.3. Klasyfikacja stanu przekładni

W procesie uczenia wykorzystywano połowę (41) posiadanej liczby wektorów obserwacji stanu obiektu. Przy budowie ciągu uczącego posługiwano się wynikami uzyskanymi na etapie selekcji cech stanu. Reszta obrazów stanu obiektu (41) przeznaczana była do testowania sieci neuronowej. Liczba prezentacji uczących wektorów obserwacji była 30 razy większa od liczby wektorów obserwacji stanu obiektu zgromadzonych w ciągu uczącym. Prezentowane wektory obserwacji były wybierane z ciągu uczącego w sposób losowy.

Reguły zmian współczynników uczenia poszczególnych warstw sieci neuronowej dobrano w ten sposób, że w początkowej fazie procesu uczenia intensywniej uczyła się warstwa konkurencyjna, a w końcowej fazie – warstwa liniowa [2, 3]. Uczenie warstwy konkurencyjnej odbywało się z zastosowaniem funkcji sąsiedztwa. Używana funkcja sąsiedztwa jednakowo preferowała wszystkie neurony z sąsiedztwa neuronu zwycięzcy, które zmniejszało się w trakcie przebiegu procesu uczenia. Naukę sieci powtarzano 25 razy i wybierano najlepszy uzyskany wynik.

Liczba neuronów liniowych była równa liczbie rozpoznawanych klas stanu obiektu (5) a wszystkie ich wagi były na początku procesu uczenia równe zero. Początkowa liczba neuronów konkurencyjnych była 3 razy większa od liczby wektorów obserwacji stanu obiektu zgromadzonych w ciągu uczącym ($3 \cdot 41 = 123$). Wszystkie neurony konkurencyjne miały na początku procesu uczenia jednakowe wagi. Po zakończeniu prezentacji uczących wektorów obserwacji wagi neuronów liniowych były zaokrąglane do najbliższej wartości całkowitej. Dzięki temu wektor rozpoznania stanu obiektu miał postać wektora zerojedynkowego, w którym położenie jedynki określało rozpoznaną klasę stanu obiektu. Z sieci wyeliminowane zostały te neurony konkurencyjne, które nie posiadały aktywnych (niezerowych) połączeń z którymkolwiek neuronem liniowym. W ten sposób ustalana była ostateczna liczba neuronów konkurencyjnych (około 50). Zastosowanie takiej procedury skutkowało tym, że ostateczna struktura sieci CP była wynikiem procesu uczenia i różniła się dla poszczególnych treningów.

Symulację sieci neuronowej CP wykonano posługując się środowiskiem programowania MATLAB z wykorzystaniem przybornika Neural Networks.

Nauka sieci doprowadziła do uzyskania klasyfikatora bezbłędnie rozpoznającego stan przekładni (sprawność sieci na ciągu uczącym i testującym wynosiła 100%).

Podsumowanie

Sieci neuronowe CP bazujące na uczeniu konkurencyjnym są jak dotąd rzadko wykorzystywane do rozpoznawania i klasyfikowania stanu obiektów technicznych. Wydaje się jednak, że mogą być one ciekawym narzędziem diagnostycznym. Wyniki uzyskane w eksperymencie wykazują, że możliwe stało się prawidłowe wykrywanie błędów montażowych reduktora zębatego na podstawie obserwacji drgań mechanicznych jego obudowy.

Przeprowadzony eksperyment diagnostyczny umożliwia sformułowanie następujących wniosków:

1. Skuteczne rozpoznawanie stanu przekładni wymagało jednoczesnego użycia cech pochodzących z obu punktów pomiarowych. Poszczególne punkty pomiarowe dostarczały zatem różnej, wzajemnie się uzupełniającej informacji diagnostycznej, co podkreśla wagę odpowiedniego usytuowania czujników zbierających informacje o obiekcie.
2. Bardziej użyteczne diagnostycznie okazywały się wyższe harmoniczne częstotliwości zazębienia. Zdefiniowane błędy montażu uwidoczniają się zatem przede wszystkim w wyższych harmonicznych częstotliwości zazębienia, w mniejszym stopniu wpływając na zmiany podstawowej harmonicznej.

Literatura

1. Cempel C., *Podstawy wibroakustycznej diagnostyki maszyn*, Wydawnictwa Naukowo-Techniczne, Warszawa 1982.
2. Dybała J., *Wykrywanie uszkodzeń w przekładni zębatej na podstawie analizy sygnału wibroakustycznego z wykorzystaniem modeli symulacyjnych*, Rozprawa doktorska, Politechnika Warszawska, Warszawa 1999.
3. Dybała J., Radkowski S., *Failure Diagnosis with the Use of Neural Classifier*, Machine Dynamics Problems, Wydawnictwo MeT, Vol. 19, Warszawa 1998, s. 29 – 44.
4. Dybała J., Radkowski S., *Geometryczna metoda selekcji informacji diagnostycznej*, Diagnostyka, vol. 30, tom 1, 2004, s. 159 – 162.
5. Hecht-Nielsen R., *Applications of counterpropagation networks*, Neural Networks, vol. 1, 1988, s. 131 – 139.
6. Hertz J., Krogh A., Palmer R., *Wstęp do teorii obliczeń neuronowych*, Wydawnictwa Naukowo-Techniczne, Warszawa 1993, 267 – 306.
7. Korbicz J., Obuchowicz A., Uciński D., *Sztuczne Sieci Neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.

8. Mączak J., *Wykorzystanie zjawiska modulacji sygnału wibroakustycznego w diagnozowaniu przekładni o zębach śrubowych*, Rozprawa doktorska, Politechnika Warszawska, Warszawa 1998.
9. Osowski S., *Sieci Neuronowe*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1994, s. 203 – 211.
10. Sobczak W., Malina W., *Metody selekcji informacji*, Wydawnictwa Naukowo-Techniczne, Warszawa 1978.
11. Tadeusiewicz R., *Sieci Neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993.

Praca naukowa finansowana ze środków Komitetu Badań Naukowych w latach 2004 – 2006 jako projekt badawczy.

Wpłynęło do redakcji w lutym 2005 r.

Recenzenci

dr hab. inż. Piotr Bielawski, prof. AM
dr hab. Zenon Zwierzewicz, prof. AM

Adres Autora

dr inż. Jacek Dybała
Politechnika Warszawska
Wydział SiMR, Instytut Podstaw Budowy Maszyn
ul. Narbutta 84, 02-524 Warszawa
e-mail: jdybala@simr.pw.edu.pl