

Tomasz MNICH

SIECI NEURONOWE W DIAGNOSTYCE SILNIKÓW INDUKCYJNYCH

Streszczenie. W artykule przedstawiono wyniki badań architektur sztucznych sieci neuronowych, wykorzystywanych w diagnostyce uszkodzeń klatki silników indukcyjnych. Omówiono założenia, jakimi się kierowano przy określaniu architektury poszczególnych sieci, oraz główne problemy i ograniczenia wyboru danych uczących sieci neuronowej.

NEURAL NETWORKS IN DIAGNOSTICS OF INDUCTION MOTORS

Summary. The assumptions made when determining the architecture of particular networks and the main problems as well as limitations dealing with choice of the data training neural networks are discussed in the paper too.

1. WPROWADZENIE

W diagnozowaniu kłatek silników indukcyjnych powszechnie znaną i stosowaną metodą jest analiza częstotliwościowa prądu stojana, którą stosunkowo łatwo można zrealizować podczas pracy silnika. Wykorzystując składowe prądu stojana pojawiające się przy uszkodzeniu klatki wirnika w charakterze sygnałów diagnostycznych oraz w charakterze sygnałów uczących sieć neuronową, dzięki którym można w końcowym efekcie rozpoznać uszkodzenie za pomocą sztucznej sieci neuronowej. We wstępnej fazie prac nad zagadnieniem diagnozowania stanów silników indukcyjnych postanowiono zaprojektować sztuczną sieć neuronową, której zadaniem byłoby diagnozowanie stanu silnika indukcyjnego na podstawie analizy spektralnej prądu stojana. Zaprojektowano sztuczną sieć neuronową, której zadaniem było rozpoznawanie konkretnych wartości będących wynikiem analizy spektralnej prądu stojana wykonanej za pomocą specjalistycznego przyrządu pomiarowego Wide Band Power Analyser 6100 firmy LEM INSTRUMENTS. W dalszej części pracy

zaprojektowano sieć neuronową, rozpoznającą przedziały zmienności sygnału diagnostycznego, ponieważ takie rozwiązanie daje znacznie pewniejszą diagnostykę stanu silnika od rezultatów otrzymanych z sieci neuronowej nauczonej rozpoznawania konkretnych wartości. Przedziały zmienności sygnałów diagnostycznych zostały określone również na podstawie analizy spektralnej prądu stojana, przeprowadzonej za pomocą tego samego przyrządu.

Badane sztuczne sieci neuronowe zaprojektowano, przy wykorzystaniu programu NEURAL NETWORK TOOLBOX, będącego integralną częścią pakietu MATLAB. Badane sieci były uczone metodą wstecznej propagacji błędu.

2. SIEĆ NEURONOWA ROZPOZNAJĄCA KONKRETNE WARTOŚCI SYGNAŁÓW DIAGNOSTYCZNYCH

W początkowym etapie badania sztucznych sieci neuronowych wykorzystywanych do detekcji uszkodzeń klatki wirnika silnika indukcyjnego, należało ustalić odpowiednią architekturę sieci neuronowej oraz przyjąć metodę jej uczenia. Na podstawie wskazówek zawartych w literaturze poświęconej zagadnieniom uczenia sztucznych sieci neuronowych oraz własnych badań symulacyjnych różnych architektur sieci określono, że najkorzystniejsze efekty daje sieć trójwarstwowa, uczona metodą wstecznej propagacji błędu. Metoda wstecznej propagacji, jak również różne jej modyfikacje, są szeroko opisywane w literaturze.

Przyjęto, że danymi wejściowymi, będącymi podstawą diagnozowania, są składowe prądu stojana. Z tego powodu założono, że sieć będzie miała tyle wejść, ile jest tych składowych spektralnych dla rozpatrywanych uszkodzeń klatki wirnika silnika indukcyjnego. Dane wejściowe, które powinna rozpoznawać sieć neuronowa, są wartościami względnymi dwóch składowych spektralnych prądu stojana w otoczeniu podstawowej harmonicznej, o częstotliwościach:

$$f^{01} = f_0(1 + 2s),$$

oraz

$$f^{02} = f_0(1 - 2s),$$

gdzie:

- f_0 - częstotliwość sieci zasilającej ($f_0 = 50$ Hz),
- s - poślizg silnika, będący funkcją prędkości obrotowej $s = \frac{n_0 - n_1}{n_0}$,

$$n_0 = \frac{60 f_0}{p} - \text{prędkość synchroniczna.}$$

- p – liczba par biegunów,
- n_1 - rzeczywista prędkość obrotowa silnika.

W zależności od rodzaju uszkodzenia klatki wirnika, w widmie prądu stojana zawarte są sygnały diagnostyczne, których zawartość w widmie prądu jest charakterystyczna dla różnych rodzajów uszkodzeń. W tabeli 1 zestawiono przykładowe wartości względne (odniesione do prądu znamionowego) składowych spektralnych silnika indukcyjnego, zmierzone przy różnych uszkodzeniach klatki wirnika.

Tabela 1

Zmierzone sygnały diagnostyczne prądu stojana o częstotliwościach:


$$I^{01} = f_0 (1+2s), I^{02} = f_0 (1-2s)$$

Rodzaj uszkodzenia oraz przyjęte oznaczenie		Składowe diagnostyczne prądu stojana	
		I^{01}	I^{02}
Brak uszkodzenia	N1	0,0086	0,0017
Uszkodzony jeden pręt	N2	0,0285	0,0059
Uszkodzone dwa pręty (co podziałkę)	N3	0,0555	0,0111
Uszkodzone dwa pręty (obok siebie)	N4	0,0776	0,0158
Uszkodzone trzy pręty (co podziałkę)	N5	0,0953	0,0178
Uszkodzone trzy pręty (obok siebie)	N6	0,134	0,0253

Ustalając architekturę sieci neuronowej przyjęto, że w warstwie wejściowej sieć posiada 12 elementów przetwarzających, po dwa elementy dla każdego rodzaju uszkodzenia. Przyjęto ponadto, że każdy element w warstwie wejściowej musi rozpoznawać tylko jedną wartość, której został nauczony, natomiast każda inna wartość powinna zostać przez niego odrzucona, jako nieznaną. Wynika z tego, że zadaniem projektowanej sieci neuronowej będzie rozpoznawanie sześciu różnych stanów. Dlatego przyjęto, że każdemu stanowi odpowiadał będzie jeden element przetwarzający, a więc sieć powinna posiadać sześć elementów w warstwie wyjściowej. Kolejne założenie dotyczyło faktu, że przy braku uszkodzenia wirnika musi istnieć pewna tolerancja istniejących składowych diagnostycznych, których sieć nie powinna klasyfikować jako uszkodzenie, lecz powinna je ignorować. Powodem takiego założenia jest fakt, że w stanie braku uszkodzenia klatki wirnika silnika, widmo prądu zawiera również niezerowe składowe diagnostyczne. Pojawienie się tych składowych w widmie prądu stojana może być spowodowane dowolną deformacją pola magnetycznego w szczelinie

powietrznej maszyny (np. na skutek uszkodzenia łożysk). Nie narzucono ilości elementów w warstwie ukrytej, ponieważ nie jest możliwe jednoznaczne określenie ilości tych elementów. Ich ilość zależy jedynie od dokładności odpowiedzi sieci.

Z tabeli 1 widać, że sygnały diagnostyczne mają małe wartości. Uczenie sieci neuronowej sygnałów, które mają tak małą wartość, jest utrudnione, dlatego pierwotne wartości zestawione w tabeli 1 przeskalowano, mnożąc je przez stałą wartość równą 10.



Rys. 1. Schemat zbudowanej sieci neuronowej, wraz z przyjętymi oznaczeniami poszczególnych elementów, oraz połączeń między nimi
 Fig. 1. Diagram of the designed neural network with assumed denotations of particular elements and connections between them

Uwzględniając powyższe założenia oraz mając odpowiednio przygotowane dane wejściowe, zbudowano sieć neuronową, rozpoznającą konkretne wartości wejściowe jako stany awaryjne pracy maszyny indukcyjnej.

Na podstawie badań symulacyjnych, stwierdzono, że najbardziej optymalna z punktu widzenia otrzymanych wyników jest sieć przedstawiona na rys. 1. Sieć składa się z 12 elementów wejściowych, 36 elementów w warstwie ukrytej oraz 6 elementów wyjściowych.

Badania przeprowadzone na tak zaprojektowanej sztucznej sieci neuronowej obejmowały określenie czasu uczenia sieci zadanych wartości, który nie byłby zbyt długi, co wiąże się z ilością cykli uczących L_r . Proces uczenia sieci neuronowej zadawanych wartości przebiegał bardzo wolno, z uwagi na małą wartość stałej uczącej η która zawierała się w przedziale od $\eta_{\min} = 0,03$ do $\eta_{\max} = 0,05$. Tak małe wartości stałej uczącej η , wynikają z potrzeby bardzo dokładnego zaklasyfikowania danego uszkodzenia. Założono, że sieć powinna maksymalnie jednoznacznie rozpoznawać konkretny typ uszkodzenia, a każdy sygnał, którego sieć się wcześniej nie uczyła, powinien zostać odrzucony jako nieznan. Oznacza to, że sieć neuronowa powinna identyfikować tylko wartości zestawione w tabeli 1.

Miaram dokładności sieci, rozumianej jako różnica między wartością wejściową a odpowiedzią sieci w cyklu uczenia, korzystając z algorytmu wstecznej propagacji, jest błąd średniokwadratowy δ , obliczany według zależności:

$$\delta = \sum_{i=1}^6 (I - N(i))^2,$$

gdzie:

- I – wektor wejściowy, w postaci: $I = \begin{bmatrix} I^{01} \\ I^{02} \end{bmatrix}$,
- $N(i)$, $i=1...6$, – i -ty stan.

Na początku uczenia sieci neuronowej należało ustalić dopuszczalny poziom błędu δ_{\min} , który może być zaakceptowany, przy wykorzystaniu jej do celów diagnostycznych. Sieć po osiągnięciu założonej wartości δ_{\min} automatycznie przerwie uczenie. W przypadku sieci rozpoznającej konkretne wartości, błąd ten powinien być minimalny. Wstępnie ustalono wartość błędu na poziomie $\delta_{\min} \leq 10^{-5}$.

W trakcie badań zmieniano wartość stałej uczącej η w dość szerokim zakresie, jednak zadowalające wyniki pracy sieci uzyskano jedynie dla przedziału od $\eta_{\max} = 0,05$ do $\eta_{\min} = 0,03$. Jednak tak mała wartość stałej uczącej η powoduje, że sieć wymaga bardzo dużej ilości cykli uczenia, a co za tym idzie, czas uczenia sieci jest bardzo długi. W badanym przypadku ilość cykli uczących, potrzebnych, aby sieć była w stanie osiągnąć założoną wartość δ_{\min} , zawierała się w przedziale $L_r = (5 \div 11) \cdot 10^4$. Jest to bardzo duża ilość cykli uczących, lecz taka ilość zapewniała osiągnięcie założonej wartości δ_{\min} , a co za tym idzie, poprawność diagnozowanych stanów. Dla większych wartości stałej uczącej η , sieć nie była

w stanie redukować błędów δ do wartości założonej. Takie zachowanie sieci może być uzasadnione procedurami numerycznymi, zawartymi w pakiecie programowym NEURAL.

Tak nauczoną sieć poddano badaniom mającym na celu określenie, w jakim zakresie mogą się zmieniać wartości wejściowe, które zostaną przez sieć rozpoznane. Stwierdzono, że dla różnych wartości sygnałów, których sieć się uczyła, można było zmieniać wartości wejściowe w szerszych lub węższych granicach. Pełny zestaw wyników badań przedstawia tabela 2.

Tabela 2

Graniczne wartości, sygnałów wejściowych rozpoznawanych przez sieć neuronową

Oznaczenie uszkodzenia	I^{01}	$I_{\min. gr}^{01}$	$I_{\max. gr}^{01}$	I^{02}	$I_{\min. gr}^{02}$	$I_{\max. gr}^{02}$
N1	0,086	0	0,28	0,017	0	0,062
N2	0,285	0,285	0,287	0,059	0,063	0,068
N3	0,555	0,554	0,567	0,111	0,111	0,111
N4	0,776	0,749	0,787	0,158	0,158	0,159
N5	0,953	0,916	1,052	0,178	0,174	0,184
N6	1,34	1,34	1,34	0,253	0,253	0,253

Oznaczenia:

- $I_{\min. gr}^{01}, I_{\min. gr}^{02}$ - minimalna wartość składowych sygnału diagnostycznego, jaki można podać na sieć, aby został on zaklasyfikowany jako stan,
- $I_{\max. gr}^{01}, I_{\max. gr}^{02}$ - maksymalna wartość składowych sygnału diagnostycznego, jakie można podać na sieć, aby został on zaklasyfikowany jako stan.

Wartości podane w tabeli 2, są wartościami przeskalowanymi w sposób omówiony powyżej.

Z przeprowadzonych badań wynika, że zakres zmian wartości sygnałów diagnostycznych podawanych na sieć neuronową jest zależny od rodzaju uszkodzenia klatki wimnika. Uszkodzenia typu N2, N3, N6 (tabela 2) są klasyfikowane z bardzo dużą dokładnością, co potwierdza założoną własność zaprojektowanej sieci. Natomiast uszkodzenia typu N4, N5 sieć neuronowa rozpoznaje w dość wąskim przedziale, co widać w przedziałach zmienności tych sygnałów, zestawionych w tabeli 2.

Z punktu widzenia diagnostyki sieć neuronowa rozpoznająca konkretne wartości nie znajdzie szerszego zastosowania. Nie można mieć bowiem absolutnej pewności, że przy ponownym pomiarze składowych diagnostycznych, na tym samym obiekcie, wystąpią

dokładnie takie same wartości składowych I^{01} , I^{02} . Może to być spowodowane np. nałożeniem się na sygnał diagnostyczny, czynników powodujących zwiększenie lub zmniejszenie się wartości tego sygnału. W takim przypadku sieć źle zaklasyfikuje rodzaj uszkodzenia, co może mieć złe następstwa, szczególnie w przypadku uszkodzeń, których zaistnienie powinno spowodować natychmiastowe wyłączenie silnika z eksploatacji.

3. SIEĆ NEURONOWA ROZPOZNAJĄCA PRZEDZIAŁY ZMIENNOŚCI SKŁADOWYCH DIAGNOSTYCZNYCH

Wykorzystując przedstawione uwagi, zaprojektowano kolejną sieć neuronową, której zadaniem jest rozpoznawanie przedziałów zmienności sygnałów diagnostycznych. W tym celu na podstawie tabeli 1 określono przedziały zmienności sygnałów diagnostycznych, których sieć miała się nauczyć rozpoznawać. Pełny zakres zmian wartości wejściowej przedstawia tabeli 3, natomiast zaproponowany pełny zestaw odpowiedzi sieci na dowolną wartość przedstawiono graficznie – rys.3a i 3b.

Nowa sieć jest modyfikacją sieci klasyfikującej konkretne wartości, ponieważ nie zmienione pozostają założenia dotyczące ilości wejść i wyjść sieci. Kompletny model, wraz z przyjętymi oznaczeniami, przedstawia rys.2. W celu uproszczenia struktury sieci przyjęto założenie, że element sieci, którego zadaniem będzie rozpoznawanie stanu oznaczonego jako N2 (uszkodzony jeden pręt), będzie odpowiadał:


- wartością 1 - dla sygnałów będących w granicach przedziału N2,
- wartością 0,1 – dla sygnałów mniejszych (stan N1 – brak uszkodzenia) od N2,
- wartością 0 – dla sygnałów większych niż wartości zawarte w przedziale N2.

Podobnie jest w przypadku, gdy sygnał będzie większy od największego zmierzonego sygnału, element sieci, którego zadaniem będzie rozpoznanie tego przedziału, odpowie:

- wartością 0 – jeśli wartość sygnału będzie mniejsza od wartości z przedziału N6,
- wartością 0,9 – jeśli wartość sygnału będzie zawarta w przedziale N6,
- wartością 1 – jeśli wartość sygnału będzie większa od zawartych w przedziale N6.

Na wszystkie pozostałe rodzaje uszkodzeń klatki wirnika sieć neuronowa odpowie:

- wartością 1 – gdy sygnał będzie zawarty w przedziale rozpoznawanym przez dany element sieci,
- wartością 0 – gdy sygnał będzie poza przedziałem.



Rys.2. Schemat sieci neuronowej wraz z przyjętymi oznaczeniami poszczególnych elementów oraz połączeń między nimi, wykorzystywanej do rozpoznawania przedziałów

Fig.2. Diagram of neural network with assumed denotations of particular elements and connections between them, used to identify ranges

Podobnie jak w przypadku pierwszej części badań, przeskalowano wartości zawarte w tabeli 1, lecz tym razem przemnożono je przez stałą wartość równą 100.


Określenie przedziałów zmienności wartości sygnałów rozpoznawanych przez sieć neuronową nie jest rzeczą prostą, z uwagi na pewną niekorzystną własność sieci neuronowej. Aby sieć była w stanie rozpoznać różnicę pomiędzy dwoma wartościami bądź przedziałami wartości, muszą one spełniać warunek tzw. liniowej separowalności. Własność ta polega na

określeniu pewnej płaszczyzny zwanej płaszczyzną decyzyjną warunkującą odpowiedź sieci neuronowej.

Tabela 3


Zestawienie wszystkich wartości, które sieć ma rozpoznawać, oraz przedziały, które sieć powinna odrzucić

Uszkodzony jeden pręt				N2
I^{01}	2,3000	2,5000	4,0000	4,3000
I^{02}	0,3000	0,4000	0,7000	0,8500
Uszkodzone dwa pręty – co podziałkę biegunową				N3
I^{01}	4,5000	5,0000	6,0000	6,2000
I^{02}	0,9000	1,0000	1,3000	1,4000
Uszkodzone dwa pręty – obok siebie				N4
I^{01}	6,5000	7,0000	8,0000	8,2000
I^{02}	1,4500	1,5000	1,6000	1,6800
Uszkodzone trzy pręty – co podziałkę biegunową				N5
I^{01}	8,5000	8,7000	9,7000	10,0000
I^{02}	1,7800	1,8500	2,0000	2,1000
Uszkodzone trzy pręty – obok siebie				N6
I^{01}	11,0000	12,0000	20,0000	21,0000
I^{02}	2,2000	2,4000	3,0000	3,5000



Rys. 3a. Graficzna prezentacja przedziałów które sieć ma klasyfikować jako stany, dla składowej diagnostycznej I^{01}


Fig. 3a. Graphical presentation of ranges which should be classified by the network as the states for the diagnostic component I^{01}



Rys.3b. Graficzna prezentacja przedziałów które sieć ma klasyfikować jako stany, dla składowej diagnostycznej I^{02}

Fig.3b. Graphical presentation of ranges which should be classified by the network as the states for the diagnostic component I^{02}

Określenie takiej płaszczyzny jest rzeczą stosunkowo prostą w przypadku, gdy zadaniem sieci jest rozdział dwóch zbiorów, których wartości są wyraźnie zróżnicowane, ponieważ różnica pomiędzy tymi wartościami jest na tyle duża, że sieć bez trudu będzie w stanie ją obliczyć. Problem pojawia się dopiero w przypadku, gdy klasyfikowane wartości znajdują się bardzo blisko siebie. Taki przypadek jest znacznie trudniejszy, ponieważ granica pomiędzy wartościami jest bardzo wąska. Wtedy aby sieć mogła znaleźć płaszczyznę rozgraniczającą te wartości, należy ją uczyć bardzo wolno, tzn. należy przyjąć bardzo małą wartość stałej uczącej. Może się jednak okazać, że ze względu na zbyt małe zróżnicowanie zbiorów, które należy rozdzielić, sieć nie będzie w stanie ich odseparować i wystąpi wówczas przypadek zbiorów liniowo nieseparowalnych, tzn. takich, których sieć nigdy nie nauczy się rozpoznawać. Problem liniowej separowalności obrazuje rys. 4.



Rys. 4. Graficzna prezentacja problemu liniowej separowalności dwóch zbiorów, jako określenie płaszczyzny decyzyjnej rozdzielającej oba przedziały


Fig. 4. Graphical presentation of the linear separation problem of two sets as determination of decision plane separating both ranges

Na podstawie badań tak zaprojektowanej sieci rozpoznającej przedziały zmienności sygnałów wejściowych stwierdzono, że czasy cykli uczących sieć są nieporównywalnie dłuższe w porównaniu z poprzednią siecią neuronową rozpoznającą konkretne wartości sygnałów wejściowych. Stała ucząca sieć również była znacznie mniejsza, bo zawarta była w przedziale $\eta_{\max} = 0,005$ do $\eta_{\min} = 0,003$, była więc o rząd mniejsza od poprzedniej wartości. Na taki dobór stałej uczącej miał wpływ fakt, że przedziały, które sieć miała klasyfikować, leżały bardzo blisko siebie i dla większych wartości stałej uczącej sieć nie była w stanie odseparować od siebie poszczególnych wartości. Kolejnym ograniczeniem był tu również fakt, że żaden przedział zmienności dla składowych diagnostycznych I^{01} , I^{02} nie może

nachodzić na inny przedział, ani być styczny do niego. Gdyby zdarzyło się, że któraś wartość sygnału znalazłaby się w przedziale zarezerwowanym dla innego stanu, wówczas sieć może wymagać większej ilości cykli uczących bądź douczenia. Problem taki pojawia się dla składowej I^{02} dla większych uszkodzeń, jak np. N6, która znajduje się w przedziale zarezerwowanym dla sygnału I^{01} dla uszkodzenia N2. Po wykonaniu $L_r = 2 \cdot 10^5$ odpowiedź była niejednoznaczna, tzn. na wyjściu sieci pojawiały się dwie niezerowe wartości. Problem był o tyle niewygodny, że w przypadku, gdy na wejście sieci podawano wartość z przedziału uszkodzeń N6, neuron klasyfikujący stan N6 odpowiadał, że mamy do czynienia z uszkodzeniem N6, lecz neuron odpowiedzialny za klasyfikację stanu N2 nie odrzucał tej wartości, lecz dawał odpowiedź równą 0.5. Problem został usunięty poprzez odpowiednie douczenie sieci, które wymagało znacznie większej ilości cykli uczących, bo około $L_r = 8 \cdot 10^5 + 10^6$. W trakcie uczenia można było obserwować stopniowe zmniejszanie się odpowiedzi na wyjściu klasyfikującym stan N2. Gdy stała uczenia η miała większą wartość niż η_{\max} , sieć nie uczyła się w ogóle, tzn. nie zmniejszała ona wartości błędu średniokwadratowego δ , lecz bardzo szybko go zwiększała. Dla wartości stałej uczącej η , bliskiej wartości $\eta_{\max} = 0,005$, sieć była w stanie określić jedynie jedną płaszczyznę, a co za tym idzie, rozpoznawała jedynie część przedziału. Wartości graniczne, które sieć odseparowała, były określane poprawnie, natomiast inne wartości, znajdujące się w przedziale, którego miała się sieć nauczyć, jak również wartości większe od założonego przedziału były źle klasyfikowane. Sieć zamiast dawać jednoznaczną odpowiedź, np. 1 – czyli że wartość została rozpoznana, lub 0 – wartość nie została rozpoznana, odpowiadała zawsze wartością 0,5, czyli taką jakby podana wartość znajdowała się w połowie wartości między tą z przedziału a tą poza nim. Widać to było również w trakcie uczenia. Błąd średniokwadratowy miał wartość równą np. $\delta = 0,500023$, co oznaczało, że jeden przedział jest rozpoznawany dobrze $\delta_1 = 0,000023$, natomiast drugi nie był rozpoznawany, zatem sieć przyjmowała jako odpowiedź wartość średnią, będącą różnicą pomiędzy wartością, której się uczyła, a obrazem tej wartości na wyjściu. Odpowiedź była równa $\delta_2 = 0,5$. Błąd średniokwadratowy, jaki obliczała sieć, był sumą błędów, jaki popełniała sieć dla jednego przedziału, oraz błędu dla drugiego przedziału $\delta = \delta_1 + \delta_2$.

Innym zagadnieniem, na które należy zwrócić uwagę przy omawianiu własności zbudowanej sieci, jest jej odpowiedź na granicy przedziałów, które sieć ma rozdzielić. Powstaje tutaj pewna niejednoznaczność odpowiedzi sieci, spowodowana tym, że sieć neuronowa ma pewną dokładność odseparowywania zbiorów wartości. Zbiór wartości, który sieć ma za zadanie rozpoznawać jako konkretny stan, musi się znajdować w pewnej

odległości od zbioru, który ma być rozpoznawany jako inny stan. Im mniejsza jest odległość tych zbiorów od siebie, tym z jednej strony odpowiedź sieci jest bardziej jednoznaczna, lecz tym trudniej jest sieci obliczyć funkcję separującą oba przedziały. Zatem należy tak dobrać odległość obu przedziałów, aby z jednej strony odpowiedź była jak najbardziej wiarygodna, a z drugiej strony, aby sieć mogła w ogóle znaleźć funkcję separującą. Zadanie jest jeszcze bardziej złożone, gdy mamy do czynienia z kilkoma przedziałami zmienności, które na dodatek leżą blisko siebie. Odpowiedź sieci na granicy przedziałów jest w pewnym stopniu niejednoznaczna, tzn. im bliżej granicy jednego z przedziałów, tym bardziej odpowiedź sieci zbliża się do tej wartości, którą sieć ma rozpoznawać. Ilustruje to rys.5, w którym przyjęto oznaczenia z tabeli 4.



Rys. 5. Zmienność odpowiedzi sieci na granicy przedziałów w przypadku, gdy obie składowe sygnału diagnostycznego się zmieniają

Fig. 5. Variability of the network answers at the range limits in case of changes of both diagnostic signal components

Tabela 4


Odpowiedź sieci neuronowej na granicy przedziałów, gdy zmieniają się obie składowe

Oznaczenie	1	2	3	4	5	6	7	8	9	10	11
i^{01}	8,5	8,52	8,52	8,56	8,58	8,6	8,62	8,64	8,66	8,68	8,7
i^{02}	1,78	1,787	1,787	1,801	1,808	1,815	1,822	1,829	1,836	1,843	1,85
Odp. sieci	0,0126	0,0164	0,0164	0,0477	0,12	0,3417	0,7053	0,9098	0,9683	0,9843	0,991

Z rys. 5 widać, że odpowiedź sieci warunkuje funkcja aktywacji, przy użyciu której była ona uczona. Przebieg odpowiedzi sieci będzie tym bardziej przypominał przebieg funkcji aktywacji, im lepiej sieć zostanie nauczona. W tabeli.4 są zestawione konkretne wartości składowych oraz odpowiedzi sieci.


Interesujące jest również zachowanie się sieci w przypadku, gdy zmienia się tylko jeden sygnał, a drugi pozostaje na stałym poziomie, lub gdy zmieniają się oba sygnały.

Zbudowaną sieć neuronową badano zmieniając jeden sygnał diagnostyczny, pozostawiając drugi jako stały, oraz gdy oba sygnały się zmieniały. Wartość jednego z sygnałów raz była w przedziale, który sieć miała za zadanie odrzucać, następnie brano wartość z przedziału, który sieć miała za zadanie rozpoznawać jednocześnie zmieniając drugi sygnał. W przypadku gdy jeden z sygnałów się zmienia, a drugi znajduje się w przedziale który powinien zostać odrzucony przez sieć, sieć neuronowa jest w stanie rozpoznawać sygnały jedynie gdy zmienia się sygnał I^{02} , a sygnał I^{01} pozostaje poza przedziałem. Odpowiedzi sieci obrazuje poniższy wykres na rys.6. Widać z niego, że stosunkowo niewielka zmiana tej składowej wystarczy, aby sieć rozpoznała rodzaj uszkodzenia. Jednak gdy poza przedziałem pozostaje składowa I^{02} , a zmienia się składowa I^{01} , sieć nie rozpoznaje sygnału, nawet wówczas, gdy I^{01} znajdzie się w przedziale, którego sieć się uczyła.



Rys. 6. Odpowiedź sieci neuronowej na zmiany składowej I^{02} , gdy składowa I^{01} pozostaje poza przedziałem rozpoznawanym przez sieć

Fig. 6. Answer of neural network to changes of the component I^{02} , when the component I^{01} is outside the range identified by the network



Rys.7. Odpowiedź sieci neuronowej na zmiany składowej I^{02} , w przypadku gdy składowa I^{01} znajduje się w nauczonego przedziale

Fig.7. Answer of neural network to changes of the component I^{02} , when the component I^{01} is inside the range identified by the network

Inaczej zachowuje się sieć w przypadku, gdy wartość jednego z sygnałów znajduje się w przedziale, którego sieć się uczyła. Jeśli do przedziału nauczonego należy składowa I^{01} , sieć zachowuje się podobnie jak w poprzednim przypadku. Sytuacja się zmienia, gdy do nauczonego przedziału należy składowa I^{02} , wówczas sieć rozpoznaje uszkodzenie, nawet w przypadku gdy składowa I^{01} znajduje się na granicy przedziałów. W tej sytuacji sieć bardzo dobrze rozpoznaje sygnał I^{02} i ten sygnał wystarczy sieci do podjęcia decyzji o zaklasyfikowaniu uszkodzenia (rys. 7).

4. UWAGI KOŃCOWE

Na podstawie przeprowadzonych badań symulacyjnych stwierdzono, że można zbudować sieć neuronową, której zadaniem będzie poprawna diagnostyka stanów klatki wirnika silnika indukcyjnego. Budowanie sieci neuronowych, reagujących na konkretne wybrane wartości, nie ma większego sensu praktycznego, gdyż w zasadzie nigdy nie można być pewnym, czy wartości, które zostały zmierzone, a których sieć się nauczyła, będzie można ponownie zdjąć pomiarowo, oraz czy nawet takie same uszkodzenie, powstałe w innym miejscu, będzie powodowało powstanie dokładnie takiej samej względnej wartości składowych prądu I^{01} , I^{02} . Aby zbudować sieć neuronową opartą na takich założeniach, należy sieć nauczyć wszystkich możliwych przypadków uszkodzeń, we wszystkich możliwych przypadkach, co już choćby z uwagi na ilość otrzymanych danych pomiarowych jest niemożliwe. Wydaje się zatem celowa budowa sieci neuronowej rozpoznającej przedziały. Taka sieć, choć jej architektura jest dość rozbudowana, daje znacznie lepsze rezultaty, gdyż rozpoznaje wszystkie możliwe wartości, jakie są zawarte w danym przedziale. Sieć taka jest siecią, której w niektórych przypadkach wystarczy jeden sygnał diagnostyczny, aby podjąć prawidłową decyzję, jednak z uwagi na to, aby odpowiedź była jak najbardziej prawdopodobna, musimy podawać na jej wejście obie składowe, wówczas możemy być pewni poprawności odpowiedzi sieci.

Można wreszcie zbudować sieć, której zadaniem będzie rozpoznawanie nie przedziałów, lecz procentowego udziału danego sygnału diagnostycznego w przebiegu głównym.

LITERATURA

1. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne Sieci Neuronowe – podstawy i zastosowania. Akademicka Oficyna Wydawnicza PLJ. Warszawa 1994.
2. Dzierżanowski A., Hickiewicz J., Szymaniec S., Wach P.: Diagnostyka stanu klatek silników indukcyjnych w oparciu o analizę częstotliwościową prądu stojana. XXIX Sympozjum Maszyn Elektrycznych, Szklarska Poręba, czerwiec 1993.
3. Rams W., Rusek J., Wyznaczanie wartości sygnałów diagnostycznych uszkodzenia klatki silników indukcyjnych, Katedra Maszyn Elektrycznych, AGH Kraków. Praca zrealizowana w oparciu o Grant KBN nr 8 T10A 067 10.

4. Kudła J., Kapinos J., Identyfikacja parametrów i właściwości silników indukcyjnych. Prace własne Katedry Maszyn i Urządzeń Elektrycznych Politechniki Śląskiej w Gliwicach.

Recenzent: Prof. dr hab. inż. Roman Nadolski

Wpłynęło do Redakcji dnia 20 grudnia 1998 r.

Abstract

The paper deals with a neural network used for diagnostics of an induction motor cage. The results of spectral analysis of the stator current of the following diagnostic frequencies (about the basic harmonic):

- $f^{01} = f_0(1 + 2s)$ - corresponding to the I^{01} component,
- $f^{02} = f_0(1 - 2s)$ - corresponding to the I^{02} component.

have been used as the training data of the designed neural networks. The component I^{01} and I^{02} have been given as relative quantities with the stator current basic harmonic as a reference quantity. The measurement results and assumed denotations have been presented in Table 1. Two models of artificial neural networks have been worked out for such data. The first neural network, shown in Fig.1, has been trained recognize specific values being the results of spectral analysis. Its task has been to recognize only the values measured on the read object, in which the chosen rotor cage faults have been modeled. The other neural network Fig.2, whose architecture is a modification of the network recognizing specific values, has been trained to recognize intervals of diagnostic signal changeability. These intervals have been determined intervals of changeability has been given in Table 3 and shown in Fig.3a and 3b. Both of the neural networks have been trained when using the method of error backpropagation.

From investigation of the designed neural networks it follows that the best results of diagnostic of the induction motor rotor cage faults have been obtained form the network trained to recognize the intervals of diagnostic signal changeability. This network has precisely recognized the condition of an induction motor as well as it has determined the type

of its fault. Investigation of the designed networks has pointed out problems arisen when working out the network architecture choosing the intervals of diagnostic signal changeability and the network answer at the limits of two intervals of diagnostic signal changeability.