

NEURONOWE MAPY CECH W SYSTEMIE DIAGNOSTYCZNYM ELEKTROWNI

Mariusz GIBIEC

Katedra Robotyki i Dynamiki Maszyn AGH
30-059 Kraków Al.Mickiewicza 30, mg@agh.edu.pl

Streszczenie

Dążenie do zapewnienia jak najdłuższej i bezawaryjnej eksploatacji obiektów technicznych powoduje zapotrzebowanie na dokładną informację stanie obiektu. Instaluje się więc coraz więcej czujników i systemów pomiarowych tworząc systemy diagnostyki. Ilość gromadzonych informacji jest jednak tak duża, że rodzi to problemy z jej przetwarzaniem. W przedstawionej pracy podjęto próbę wykorzystania sztucznych sieci neuronowych typu Kohonena do analizy dużej liczby sygnałów zbieranych w trakcie pracy typowego turbozespołu elektrowni i jego instalacji pomocniczych. Uzyskane sieci neuronowe realizują zadanie wykrywania zmiany stanu maszyny. Zaprezentowano wyniki działania opracowanego oprogramowania do przetwarzania odpowiedzi zaimplementowanych sieci. Jego działanie ukierunkowano na wizualizację graficzną położenia aktywnego neuronu na tle regionów ilustrujących stan maszyny. W pracy pokazano także możliwości korzystania z sieci neuronowych do wykrywania sygnałów, których zmiany umożliwiają określenie stanu maszyny.

Słowa kluczowe: przetwarzanie informacji pomiarowej, systemy diagnostyczne, sieci neuronowe

NEURAL FEATURE MAPS IN POWER PLANT DIAGNOSTIC SYSTEM

Summary

Aspiration for assertion of the longest and nondefect technical machinery exploitation causes demand for high accuracy information of machinery condition. A growing number of sensors and measurement systems one install in the machinery creating diagnostic systems. A quantity of acquired information is so big that one have problems with its analysing. This case study presents an application of a Kohonen's type artificial neural network utilisation for parallel analysing of a big number of signals measured during typical power plant machinery exploitation. Implemented artificial neural networks accomplish detection of the machinery condition change. Results of neural networks answers postprocessing programs are presented. A visualisation of network activity on the map of machinery state regions is done. Detection of signals which changes make possible machinery state assessing using neural networks is implemented.

Keywords: processing of measurement information, diagnostic systems, neural network

1. WSTĘP

Urządzenia i instalacje przemysłowe charakteryzują się wysokimi kosztami inwestycji. Dlatego kluczowe jest ich utrzymanie w stanie pełnej sprawności ponieważ koszty awarii lub nieplanowanego wyłączenia z eksploatacji są bardzo wysokie. Wymagania te nabierają dużej wagi w przypadku maszyn i instalacji wykorzystywanych w przemyśle energetycznym. W przypadku awarii ponoszone koszty to nie tylko te wynikające z jej usuwania ale także cena energii niewyprodukowanej z winy niesprawności środków produkcji. Zatem koszty nawet niewielkich awarii z powyższych powodów sięgają często wysokiego poziomu. W celu zapobiegania sytuacjom awaryjnym stosuje się dwie grupy metod: zapobieganie jej wystąpieniu poprzez staranną obsługę i zapewnienie dużych marginesów bezpieczeństwa (ang. preventive

maintenance) oraz wykrywanie awarii we wczesnym jej stadium poprzez nadzór nad bieżącym stanem maszyny (ang. predictive maintenance). W praktyce stosowane są obie te metody równolegle. W ostatnich latach daje się zaobserwować tendencja do ciągłego usprawniania i zwiększania zakresu funkcji stacjonarnych systemów nadzoru. Korzystając z coraz większych możliwości opomiarowania systemów nadzoru monitoruje się nie tylko podstawowe parametry pracy bloku energetycznego takie jak: moc, parametry pary świeżej, parametry skraplacza, temperaturę łożysk oraz temperaturę i ciśnienie w układzie olejowym ale także wykonuje pomiary specjalne uzyskując dane o stanie dynamicznym maszyny. W tym celu mierzy się: drgania wału w panwiach łożysk, przesuw osiowy, wydłużenia względne i bezwzględne korpusów, mimośrodowość i temperaturę. Inną grupą monitorowanych sygnałów

są pomiary wykonywane na instalacjach pomocniczych.

Obecnie budowane maszyny i urządzenia posiadają standardowo wbudowane elementy aparatury do pomiarów podstawowych i specjalnych stanowiące zabezpieczenie maszyny na najniższym poziomie. Uważane są one za pierwszą warstwę systemu nadzoru i stanowią źródło informacji dla warstw wyższych. Coraz częściej wyposażone są one także w interfejsy komunikacyjne umożliwiające transmisję mierzonych danych.

Komputery zwane stacjami operatorskimi realizują zadania archiwizacji i wizualizacji danych i tworzą drugą warstwę systemu nadzoru. W najprostszym przypadku w ramach archiwizacji tworzone są trendy mierzonych wielkości, zapamiętywane istotne wydarzenia w działaniu maszyny. Przechowywanie próbkowanych sygnałów stwarza określone trudności ze względu na objętość gromadzonych danych. W miarę rozwoju systemów diagnostycznych pojawiła się potrzeba nowych form przedstawiania danych. Zestawy narzędzi diagnostycznych do wizualizacji zwane są nadbudowa diagnostyczną, a systemy w nie wyposażone – systemami monitoringu i diagnostyki. W wyniku upowszechnienia się komputerowych systemów monitoringu uciążliwości związanych z koniecznością analizy informacji diagnostycznych dla kilkuset kanałów pomiarowych montowanych na typowej instalacji w przemyśle energetycznym [7].


W chwili obecnej prowadzone są próby wdrażania systemów ekspertowych. Mają one na celu automatyzację wnioskowania diagnostycznego w oparciu o metody wnioskowania o stanie maszyny wykorzystujące mierzone dane. Z drugiej strony uzyskane relacje symptom – stan, wbudowywane są do systemu ekspertowego jako baza wiedzy. Choć często takie systemy określa się jako inteligentne to ich rozwój nie zmierza do zastąpienia diagnosty w elektrowni. Dlatego często określa się je mianem systemów doradczych lub systemów wspomagania decyzji diagnostycznych [3].

W niniejszej pracy podjęto próbę wykorzystania sztucznych sieci neuronowych do wizualizacji stanu maszyny oraz do analizy danych pomiarowych z wielu kanałów i wspomagania pracy diagnosty w elektrowni.

2. SFORMUŁOWANIE PROBLEMU

Współczesne systemy monitoringu i diagnostyki dostarczają użytkownikowi ogromnej ilości danych. W typowej polskiej elektrowni dla turbiny 200 MW zbieranych jest około tysiąca sygnałów, które przesyłane są do centrali operatorskiej. Są to sygnały z systemu nadzoru drganiowego turbozespołu ale także parametry procesowe między innymi moc czynna, prąd wzbudzenia wirnika, ciśnienie i temperatura w kondensatorze i stopniu regulacyjnym itp. Ponadto zbierane są sygnały

z maszyn i instalacji pomocniczych. Wszystkie te sygnały mają różne zakresy zmienności i częstotliwości próbkowania. Typowy przebieg omawianych sygnałów zebrany w ciągu miesięcznej pracy turbozespołu przedstawiono na rysunku 1.



Rys. 1. Zapis sygnałów przekazywanych do centrali operatorskiej

Jego analiza jest bardzo trudna ze względu na ilość prezentowanych sygnałów oraz ilość możliwych konfiguracji zmieniających się sygnałów. Obserwowana przez obsługę zmiana niektórych sygnałów pociąga za sobą szereg czynności zmierzających do ich identyfikacji tzn. wydzielenia z przebiegu zbiorczego oraz określenia jakich wielkości dotyczą. Zastosowanie prostego mechanizmu wykrywania zmian poprzez określenie zakresów zmienności nie wystarcza ponieważ dla pewnych stanów (patrz rys.1) zmiana wartości następuje dla wielu sygnałów. W takim przypadku konieczne jest wykorzystanie informacji kontekstowych dla określenia sygnałów, których zmiany ilustrują wystąpienie niesprawności. Dużym ułatwieniem dla obsługi jest równoczesna informacja o stanie maszyny jak i zmianach mierzonych sygnałów. Zwłaszcza w sytuacji gdy maszyna wychodzi z obszaru bezpiecznej pracy cennym jest szybkie określenie sygnałów ulegających zmianom. Zawarta w nich informacja o występowaniu niesprawności może zostać przeoczona lub zignorowana przez obsługę. Zazwyczaj do analizy przystępuje się dopiero po wystąpieniu alarmu lub nawet awarii. Tymczasem system dokonujący automatycznie przeglądu tej informacji i dokonujący selekcji danych może zwrócić uwagę operatora maszyny na pojawienie się symptomów niesprawności co zwiększa bezpieczeństwo eksploatacji.

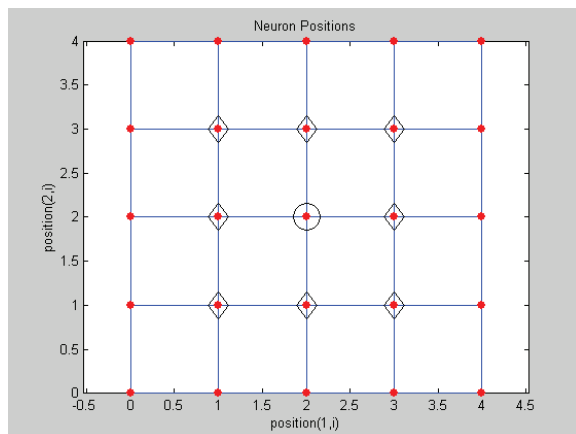
3. ZASTOSOWANIE SIECI NEURONOWYCH TYPU KOHONENA DO WSPOMAGANIA PROCESU DIAGNOZOWANIA STANU

Do rozwiązania przedstawionego wcześniej problemu zaproponowano sztuczne sieci neuronowe typu Kohonena. Jedną z ich zalet jest możliwość

GIBIEC, Neuronowe mapy cech w systemie diagnostycznym elektrowni

przekształcenia dowolnej ilości sygnałów wejściowych do przestrzeni jedno lub dwu wymiarowej z zachowaniem własności topologii. Umożliwia to czytelną i łatwą do interpretacji wizualizację stanu maszyny. Sztuczne sieci neuronowe uczone są w trybie bez nauczyciela. Ich zadaniem jest wykrycie istniejących związków między sygnałami podawanymi na ich wejście i zasygnalizowanie tego w postaci aktywności jednego z neuronów wyjściowych. Ponieważ ilość neuronów reagujących na ten sam stan może być większa niż jeden, a w procesie uczenia nie jest zdefiniowane które to neurony, wykorzystano odmianę sieci samouczących zwaną mapami Kohonena (ang. Self Organizing Feature Maps). Charakterystyczną cechą tego typu sieci neuronowych jest wprowadzenie pewnej topologii rozmieszczenia neuronów np. na płaszczyźnie [1]. Są one umieszczone w węzłach odpowiednio zdefiniowanej sieci (rys. 2). Połączenia prezentowane na rysunku są ilustracją topologii sąsiedztwa neuronów w sieci.

Na rysunku zaprezentowano, w postaci znaków w kształcie rombu, sąsiedztwo neuronu zaznaczonego kółkiem. Promień sąsiedztwa wynosi mniej niż dwa tzn. odległość punktów symbolizujących neurony sąsiedztwa od neuronu centralnego jest mniejsza niż dwa. Zdefiniowanie sąsiedztwa pozwala na wprowadzenie pewnego uporządkowania neuronów już na etapie uczenia. W klasycznej sieci typu Kohonena uczeniu – poprawianiu wartości wag połączeń podlegał tylko jeden neuron, aktualnie reagujący na zadane wejście do sieci.



Rys. 2. Sąsiedztwo neuronu o promieniu mniej niż 2
O – neuron centralny, \diamond - neurony sąsiednie

W przypadku map Kohonena uczenie dotyczy także neuronów należących do jego sąsiedztwa [6]. Zmiana wag neuronów sieci następuje według wzorów (1) podanych poniżej.

$$w_{ni}(t) = w_{ni}(t-1) + \eta \bullet (x(t-1) - w_{ni}(t-1))$$

oraz

$$w_{nj}(t) = w_{nj}(t-1) + 0,5\eta \bullet (x(t-1) - w_{nj}(t-1))$$

dla $j \in \varepsilon_i$

gdzie:

w_{ni} – waga n - tego połączenia zwycięskiego neuronu i,

ε_i - sąsiedztwo neuronu i,

$x(t-1)$ – wektor wejściowy sieci,

η - współczynnik uczenia.

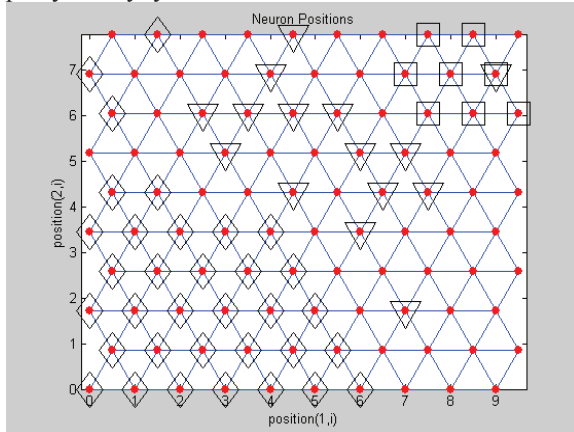
Taka modyfikacja procesu uczenia pozwala zgromadzić w pewnym regionie mapy neurony reagujące na podobne wartości sygnałów wejściowych.

Do korzystnych własności sieci neuronowych należy zdolność do generalizacji tzn. generowania podobnych odpowiedzi na podobne wektory wejściowe. W omawianej strukturze idealnym przypadkiem byłaby aktywność tego samego neuronu. Jednak zarówno ze względu na rozmiar wektora wejściowego jak i różnorodność elementów ciągu uczącego (zmiennosc mierzonych sygnałów dla tego samego stanu maszyny) sieć neuronowa może definiować w swojej strukturze większą ilość zależności między sygnałami wejściowymi co daje w efekcie więcej niż jeden neuron reagujący na ten sam stan maszyny.


Dla rozwiązania problemu przedstawionego w poprzednim paragrafie przygotowano zestaw sztucznych sieci neuronowych wykorzystujących od 64 do 100 neuronów oraz dwa rodzaje topologii rozmieszczenia: uliczną (w odległości równej 1 znajdują się 4 neurony) i heksagonalną (odpowiednio 6 neuronów). Ciąg uczący składał się z 4000 wektorów wejściowych odpowiadających nominalnej pracy maszyny pod obciążeniem i 1000 wektorów zarejestrowanych w czasie wybiegu maszyny. Zgodnie z wymaganiami algorytmu uczenia wektory te poddano normalizacji, a uczenie trwało 4000 pełnych cykli iteracji uczących. Uzyskane wyniki zaprezentowano na kolejnych rysunkach. Otrzymane mapy neuronów testowano na ciągu testowym zawierającym po 1000 wektorów zarejestrowanych dla normalnej pracy maszyny i dla wybiegu. Na rysunkach 3 i 4 symbolem rombu zaznaczono te neurony, które były aktywne przy podaniu na wejście sieci wektorów z ciągu uczącego zawierających sygnały rejestrowane dla nominalnej pracy maszyny oraz symbolem kwadratu neurony aktywne po wybiegu. Można zauważyć, że w otrzymanej mapie Kohonena utworzone zostały regiony odpowiadające różnym stanom maszyny. Ponieważ system ma działać także w stanach przejściowych zarejestrowano odpowiedzi sieci w trakcie wybiegu i zaznaczono na mapie trójkątami.

Dla ciągu testowego, aktywne neurony znajdowały się w odpowiednich regionach zdefiniowanych jak opisano powyżej. Świadczy to o prawidłowej klasyfikacji stanu maszyny. Jednak można zauważyć, że regiony te pokrywają prawie całą mapę i neuronów mogących sygnalizować wystąpienie innego stanu niż te dwa jest niewiele. Jest to spowodowane tym, że w ciągu uczącym

znajdują się tylko przykłady dwóch różnych stanów pracy maszyny.




Rys. 3. Zarejestrowane odpowiedzi sieci o topologii heksagonalnej: \diamond – stan normalnej pracy, ∇ – wybieg, \square – stan po wybiegu




Rys. 4. Zarejestrowane odpowiedzi sieci o metryce ulicznej: \diamond – stan normalnej pracy, ∇ – wybieg, \square – stan po wybiegu

Przedmiotem naszego zainteresowania są te sytuacje gdy w monitorowanych sygnałach wystąpi informacja o możliwości znalezienia się maszyny w innym stanie pracy. Ponieważ nie posiadamy przebiegów je ilustrujących konieczne jest poszerzenie ciągu uczącego w sposób sztuczny. W tym celu w zarejestrowanych przebiegach, na krótkich ich wycinkach dokonano zmian wartości o 20%. Tak utworzone przebiegi prezentowane są na rysunku 5. Przykładowa mapa Kohonena o 100 neuronach uzyskana po uczeniu nowym ciągiem uczącym, z zaznaczeniem regionów dla których stan maszyny jest określony pokazana jest na rysunku 6. Ilość neuronów mogących sygnalizować inne stany maszyny jest teraz znacznie większa. Ponadto ich wagi połączeń uzyskane w procesie uczenia specjalizują je do wykrywania zmian w sygnałach wejściowych – elementach wektora wejściowego do sieci. Na rysunku 8a kołowym markerem zaznaczono aktualnie aktywny neuron reagujący na pojedynczy wektor wejściowy. Śledzenie położenia tego markera na mapie Kohonena – jego przynależności do regionów tej mapy, pozwala na wizualizację stanu maszyny. Obserwacja zaś jego

przemieszczania się po mapie może być pomocna przy określaniu tendencji do zmiany stanu maszyny.



Rys. 5. Przebiegi sygnałów wykorzystane w ciągu uczącym



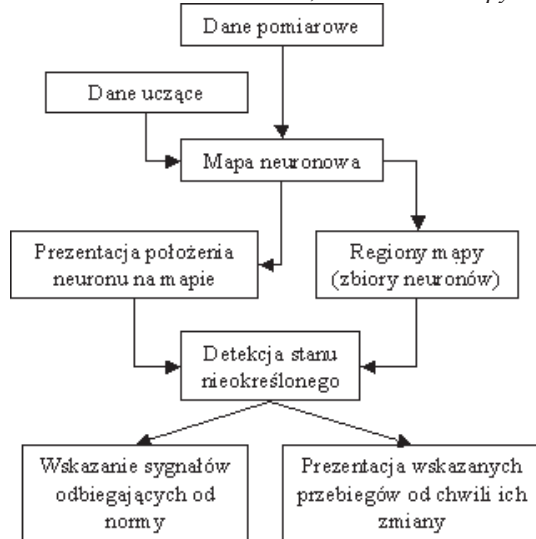
Rys. 6. Zarejestrowane odpowiedzi sieci o metryce ulicznej: \diamond – stan normalnej pracy, ∇ – wybieg, \square – stan po wybiegu

4. PROCEDURA WSPOMAGANIA DECYZJI DIAGNOSTYCZNYCH Z WYKORZYSTANIEM SIECI NEURONOWYCH

Jakkolwiek wizualizacja stanu maszyny w postaci punktu w przestrzeni dwu-wymiarowej oraz pewnych obszarów tej przestrzeni jest już dużym udogodnieniem dla obsługi, to struktura sieci Kohonena pozwala na automatyzację określania przynależności do poszczególnych obszarów przestrzeni oraz wykrywania sygnałów, które uległy zmianie powodując wyjście z określonych obszarów. Schemat realizacji takiej procedury pokazano na rysunku 7.

W etapie wstępnym przeprowadzany jest proces uczenia sieci neuronowej na przykładach zgromadzonych w ciągu uczącym. Te same dane uczące wykorzystywane są do określenia regionów mapy charakterystycznych dla stanów maszyny. W sieci neuronowej typu Kohonena każdy z neuronów ma swój numer, który identyfikuje jednoznacznie także jego położenie na mapie. Zatem określenie regionów sprowadza się do znalezienia i umieszczenia w zbiorze wyliczeniowym numerów neuronów do nich należących.

GIBIEC, Neuronowe mapy cech w systemie diagnostycznym elektrowni



Rys. 7. Schemat procedury wspomaganie decyzji diagnostycznych

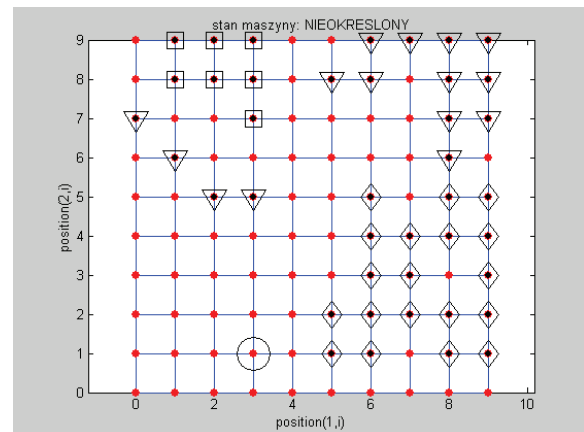
Działanie opisywanej procedury polega na podaniu na wejście sieci neuronowej danych pomiarowych w formie wektora wejściowego i obliczeniu odpowiedzi sieci w postaci numeru aktywnego neuronu. Następnie określana jest jego przynależność do regionu. Determinuje ją relacja zawierania się numeru aktywnego neuronu w zbiorze numerów neuronów definiujących region. Jeżeli relacja ta nie jest spełniona zasygnalizowany zostaje stan nieokreślony poprzez prezentację położenia aktywnego neuronu na mapie oraz komunikat w oknie stan maszyny: "NIEOKREŚLONY". Kolejnym etapem działania procedury jest wskazanie sygnałów, których nieoczekiwana zmiana może być przyczyną kłopotów z określeniem stanu maszyny oraz prezentacja ich przebiegów z zaznaczeniem chwili w której ta zmiana nastąpiła.

Ostatni etap procedury jest bardzo użyteczny z punktu widzenia wspomaganie podejmowania decyzji diagnostycznych dlatego jego dokładniejszy opis przedstawiono w dalszej części pracy. Przygotowane oprogramowanie dokonujące pewnego post processingu odpowiedzi sieci neuronowej pozwala nie tylko na rozpoznanie stanu maszyny ale w przypadku gdy jest on nieokreślony (w aspekcie odpowiedzi sieci) prezentację jego przyczyny. Tej przyczyny należy poszukiwać w wektorze wejściowym sieci ponieważ to zmiana jego elementów implikuje zmianę odpowiedzi sieci. Zadaniem sieci neuronowej jest zatem wspomaganie pracy operatora przez wskazanie jaki sygnał lub sygnały uległy zmianie od ostatniego określonego stanu maszyny. Może to zostać zrealizowane na dwa sposoby:

1. Przechowywanie w buforze wektora wejściowego odpowiadającego ostatniej określonej odpowiedzi sieci, znalezienie różnic między nim, a aktualnym wektorem wejściowym;

2. Znalezienie najbliższego sąsiada aktualnie aktywnego neuronu, który należy do regionu i odczytanie różnic między wektorem wejściowym sieci a wagami tego neuronu.

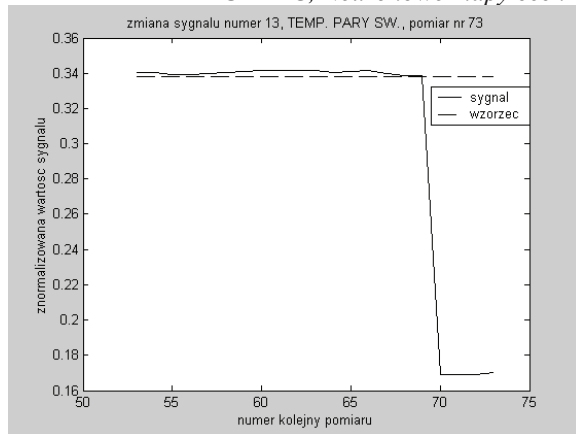
Drugi ze sposobów jest szybszy ponieważ operuje na różnicach już obliczonych w trakcie liczenia odpowiedzi sieci. W procesie uczenia bez nauczyciela poszczególne neurony sieci neuronowej uzyskują zestawy wag połączeń stanowiące pewne wzorce wektorów wejściowych dla których aktywność neuronu jest największa. Stąd różnica między wektorem wejściowym, a najbliższym wzorcem określającym stan maszyny, służy do wykrycia tych sygnałów które uległy zmianie. Zwrócenie uwagi operatora na te sygnały następuje przez informację o niemożności określenia stanu maszyny, prezentację położenia kołowego markera na mapie Kohonena oraz otwarcie nowego okna lub okien graficznych gdzie dokonywane jest porównanie aktualnej wartości sygnału, który uległ zmianie z przebiegiem jego 20 poprzednich wartości, a także jego wartością wzorcową definiowaną przez odpowiednią wagę neuronu o określonej przynależności do regionu. Przykładowy ekran pojawiający się na konsoli operatora w omawianym przypadku pokazano na rysunku 8a i b.



Rys. 8a. Aktualna odpowiedź mapy neuronów – O,
Oznaczenia regionów: \diamond – stan normalnej pracy,
 ∇ - wybieg, \square - stan po wybiegu

Okno prezentujące przebieg zmienionego sygnału zawiera także numer sygnału, informację o wielkości która uległa zmianie oraz momencie w którym ta zmiana nastąpiła.

Mierzone sygnały wprowadzane są na wejście sieci neuronowej w postaci wektora. Zawartość jego elementów jest ściśle określona i pogrupowana. Kolejne grupy sygnałów w wektorze wejściowym dotyczą pomiarów zmiennych procesowych, pomiarów wykorzystywanych do określenia stanu dynamicznego oraz instalacji pomocniczych. Taki format wektora wejściowego pozwala na posługiwanie się numerami mierzonych sygnałów do określenia grupy urządzeń lub rodzaju sygnałów dla których wykryto zmiany.



Rys.8b. Porównanie mierzonego sygnału z wzorcem

W sytuacji gdy zmiany nastąpiły w kilku mierzonych sygnałach, a sieć neuronowa wykryła stan nieokreślony, prezentowane są przebiegi tych sygnałów identyfikowane na podstawie odczytania różnic między wektorem wejściowym sieci, a wagami aktywnego neuronu.

W ramach dalszych prac nad rozwojem oprogramowania przetwarzającego odpowiedzi sieci neuronowej możliwe będzie prezentowanie listy sygnałów, których zmianę wykryto, z podziałem na określone grupy dotyczące elementów maszyny, zmiennych procesowych i urządzeń pomocniczych.

5. PODSUMOWANIE

Przetwarzanie informacji zbieranej jednocześnie z wielu punktów pomiarowych w dużych instalacjach takich jak elektrownie jest jednym z trudniejszych problemów występujących w systemach diagnostyki. Bardzo dobre wyniki osiąga się stosując systemy ekspertowe. Jednak przetwarzanie dużej liczby reguł może być czasochłonne. Alternatywnym podejściem jest zastosowanie sieci neuronowych. Nieskomplikowana struktura zastosowanych sieci neuronowych typu Kohonena pozwala uzyskać dużą szybkość działania.

Przekształcenie wektora wejściowego mierzonych sygnałów (w opisywanym przykładzie około 1000 elementów) do przestrzeni dwuwymiarowej, dokonywane przez sieć neuronową, daje w efekcie intuicyjnie zrozumiałą i łatwą do interpretacji prezentację możliwych stanów pracy maszyny w postaci mapy z wyróżnionymi obszarami (regionami). Charakterystyczna dla sieci neuronowych typu Kohonena aktywność tylko jednego neuronu na wyjściu sieci zapewnia czytelną wizualizację stanu maszyny. Przetestowane w trakcie badań sieci z topologią uliczną i heksagonalną wykazały przydatność do realizacji zadania klasyfikacji stanu maszyny.


Drugim zadaniem zrealizowanym w pracy było wykrywanie w wektorze wejściowym tych sygnałów, które w sposób znaczący uległy zmianie.

Sieć neuronowa wykazała zdolność do przetwarzania informacji kontekstowych inaczej reagując na zmiany sygnałów przy dozwolonej zmianie stanu maszyny oraz przy innych zmianach. Dla uzyskania wrażliwości sieci na zmiany pojedynczych sygnałów niezbędnym okazało się poszerzenie ciągu uczącego o przykłady je ilustrujące.

Sieci neuronowe typu Kohonena dzięki uporządkowanej strukturze – definiowanemu przez sąsiedztwo położeniu neuronów na mapie – umożliwiły przygotowanie prostego oprogramowania do przetwarzania informacji przez nie generowanych. Oprogramowanie to wykorzystuje nie tylko odpowiedź sieci ale także wyniki obliczeń wykonywanych przez sieć wewnątrz jej elementów. Pozwala to na szybką prezentację informacji o stanie maszyny ale także przebiegów zmieniających się sygnałów gdy stan maszyny trudno jest do określenia.

6. LITERATURA

- [1] Baumann T., Germond A., Tschudi D.: Impuls test fault diagnosis on power transformers using Kohonen's self-organizing neural network. - Proc. Workshop Neural Network Computing for Electric Power Industry, London: Lawrence Erlbaum Associates, 1992.
- [2] Cempel C., Wibroakustyczna diagnostyka maszyn, WNT, 1992.
- [3] Cholewa W. Dynamiczne systemy doradcze. Mat. Sympozjum AI-MECH 2000, Gliwice 2000
- [4] 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.
- [5] Ikonomopoulos A., R.E.Uhrig, Tsoukalas T.H, Use of Neural Networks to Monitor Power Plants Components, Proc. of the 54th American Power Conference, Chicago, IL, April 1, 1992.
- [6] Tadeusiewicz R. Sieci Neuronowe, Akademicka Oficyna Wydawnicza, Warszawa 1993.
- [7] Uhl T. Trends and progress in monitoring and diagnostic systems. PAK, no.4 1999.



Dr inż. Mariusz Gibiec jest adiunktem w Katedrze Robotyki i Dynamiki Maszyn AGH. Jego zainteresowania dotyczą zastosowań metod 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.