


Józef KORBIĆZ

POLITECHNIKA ZIELONOGÓRSKA
INSTYTUT ROBOTYKI I INŻYNIERII OPROGRAMOWANIA

Sztuczne sieci neuronowe i ich zastosowanie w diagnostyce procesów przemysłowych

Prof. dr hab. inż. Józef KORBIĆZ – od 1975 r. pracuje na Politechnice Zielonogórskiej. Stopnie naukowe uzyskuje w latach: doktora w 1980 r. i doktora habilitowanego nauk technicznych w 1986 r.; tytuł naukowy profesora otrzymał w 1993 r. Jego zainteresowania naukowe to zagadnienia modelowania, estymacji stanu i parametrów procesów z czasoprzestrzenną dynamiką oraz problem optymalizacji pomiarów. Jest autorem 15 monografii, książek, skryptów i prac zwartych oraz 126 artykułów i referatów naukowych. Obecnie pełni funkcję dziekana Wydziału Elektrycznego w kadencji 1996–1999.



W pracy o charakterze przeglądowym omówiono możliwości zastosowania sztucznych sieci neuronowych w układach diagnostyki technicznej, a w szczególności w diagnostyce procesów przemysłowych. Analizuje się różne znane struktury sieci neuronowych, jak np. wielowarstwowy perceptron, sieci samoorganizujące typu Kohonena lub sieci ewolucyjne typu GMDH (ang. Group Method of Data Handling). Przyjmując uogólnioną strukturę układu diagnostyki procesów przemysłowych omawia się funkcje i zadania jakie można rozwiązywać z wykorzystaniem sztucznych sieci neuronowych.

ABSTRACT

This overview paper presents the applications possibility of artificial neural networks in technical diagnostics, and especially in diagnostics of industrial processes. The various known structures of neural networks i.e. the multilayer perceptron, the Kohonen self-organizing feature maps, and so-called Group Method of Data Handling (GMDH) networks are discussed. Considering the general scheme of the diagnostic system, the different problems, functions and tasks which can be solved using the artificial neural networks are presented.

Wstęp

Większość współczesnych obiektów i instalacji przemysłowych powinna spełniać wysokie wymagania niezawodnościowe i bezpieczeństwa pracy. Spełnienie tych wymagań stanowi podstawowy problem teorii i praktyki diagnostyki technicznej [1, 2] oraz diagnostyki procesów przemysłowych [16, 20, 27], która znajduje się na pograniczu automatyki, informatyki i diagnostyki technicznej.

Znane dzisiaj metody i techniki pozwalające na zwiększenie niezawodności systemów i obiektów umownie można podzielić na mody redundacji sprzętowej i analitycznej. Z uwagi na fakt, że metody redundacji sprzętowej sprowadzają się do powielania, np. dublowania całych układów lub bloków, ich zastosowanie jest ograniczone z uwagi na znaczne koszty. Atrakcyjność metod redundacji analitycznej polega na formalnym zastosowaniu metod i technik teorii sterowania [27], przetwarzania sygnałów [2], modelowania jakościowego [6, 8, 18] oraz teorii systemów ekspertowych [34]. Zagadnienia klasyfikacji znanych metod, podejścia i techniki detekcji i lokalizacji uszkodzeń były podejmowane w wielu pracach przeglądowych, np. [7, 9, 21]. Metodologia projektowania takich układów diagnostycznych najczęściej opiera się na wykorzystaniu modeli diagnozowanych procesów, przy czym mogą to być modele analityczne [5, 27], modele jakościowe [6, 8, 12] lub ich kombinacje [19].

Wybór odpowiedniej metody zależy od złożoności diagnozowanego procesu oraz od formy opisu zasad jego funkcjono-

wania. Stosowalność metod opartych na wykorzystaniu modeli analitycznych jest ograniczona z uwagi na trudności uzyskania dokładnych modeli, które najczęściej są nieliniowe. W takich przypadkach alternatywnym rozwiązaniem jest zastosowanie modeli jakościowych, opartych przede wszystkim na technikach i metodach obliczeń inteligentnych [6, 14, 31].


Wśród metod obliczeń inteligentnych badanych i stosowanych w ostatnich latach w układach diagnostycznych należy wyróżnić systemy ekspertowe [19, 34], sztuczne sieci neuronowe [12, 14, 26] oraz teorię zbiorów rozmytych [6, 29]. Z metodologicznego punktu widzenia atrakcyjnym rozwiązaniem jest budowa układów diagnostycznych opartych na zastosowaniu systemów ekspertowych. Takie systemy [19] pozwalają na tworzenie bazy wiedzy o diagnozowanym procesie zarówno z wykorzystaniem wiedzy heurystycznej (operatorskiej), jak i proceduralnej (modele matematyczne, algorytmy teorii identyfikacji). Przy zastosowaniu takiego podejścia istnieje możliwość integracji wielu metod i technik diagnostyki, co daje możliwość budowy bardziej efektywnych układów diagnostycznych dla złożonych obiektów i procesów przemysłowych.

W prezentowanej pracy przeglądowej, będącej rozszerzeniem i uaktualnieniem poprzednich prac [14, 15], ograniczymy się do omówienia możliwości stosowania sztucznych sieci neuronowych w układach detekcji i lokalizacji uszkodzeń. Atrakcyjność sieci neuronowych w diagnostyce procesów przemysłowych polega przede wszystkim na możliwości neuronowej statycznej aproksymacji dowolnych nieliniowości procesu. Dodatkowo wprowadzenie do struktury sieci neuronowej elementów dynamicznych: takich jak filtry, linie opóźniające lub człony całkujące, daje możliwość efektywnego neuronowego modelowania procesów przemysłowych. Inną atrakcyjną własnością sieci neuronowych jest ich zdolność uczenia się np. z wykorzystaniem danych pomiarowych diagnozowanego procesu oraz duża tolerancja na wewnętrzne uszkodzenia.

W dalszej części pracy zostaną przedstawione typowe architektury sieci neuronowych: wielowarstwowy perceptron, sieci samoorganizujące się typu Kohonena oraz ewolucyjne typu GMDH. Pokażemy strukturalne sposoby wykorzystania różnych typów sieci neuronowych w układach diagnostycznych, a przede wszystkim do klasyfikacji uszkodzeń, modelowania procesu (generacji residuów) oraz przetwarzania residuów i lokalizacji uszkodzeń.

Problem diagnostyki

W ogólnym przypadku diagnozowany układ automatycznego sterowania przedstawiono na rys. 1, gdzie u jest wektorem



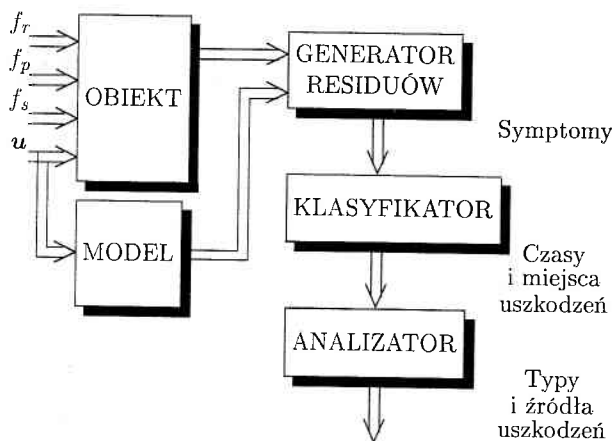
Rys. 1. Uszkodzenia w układzie automatycznego sterowania

wejsć, a y – wektorem wyjść, f_r, f_p i f_s – wektory uszkodzeń odpowiednio regulatorów, procesu oraz czujników pomiarowych. W danym przypadku celem układu diagnostyki jest detekcja odpowiednich uszkodzeń oraz dostarczenie informacji o ich rozmiarach i źródłach.

Z praktycznego punktu widzenia w układach diagnostyki opartych na zastosowaniu modeli procesów są realizowane trzy podstawowe zadania [5]:

1. Generacja residuów (symptomów), tzn. generacja sygnałów charakteryzujących poszczególne uszkodzenia.
2. Ewaluacja residuów (klasyfikacja uszkodzeń), tzn. logiczne przetwarzanie symptomów w celu określenia czasu pojawienia się uszkodzenia oraz jego miejsca.
3. Analiza uszkodzeń, tzn. określenie typu uszkodzenia, rozmiaru (intensywności) oraz przyczyn.

Struktura typowego układu diagnostyki z wydzielonymi blokami realizującymi wymienione zadania jest pokazana na rys. 2.




Rys. 2. Struktura układu diagnostyki z wykorzystaniem modeli obiektu

Możliwości zastosowania sztucznych sieci neuronowych w takim uogólnionym układzie diagnostyki są różne zarówno ze względu na realizowane funkcje, jak i znane architektury sieci.

Neuronowe klasyfikatory

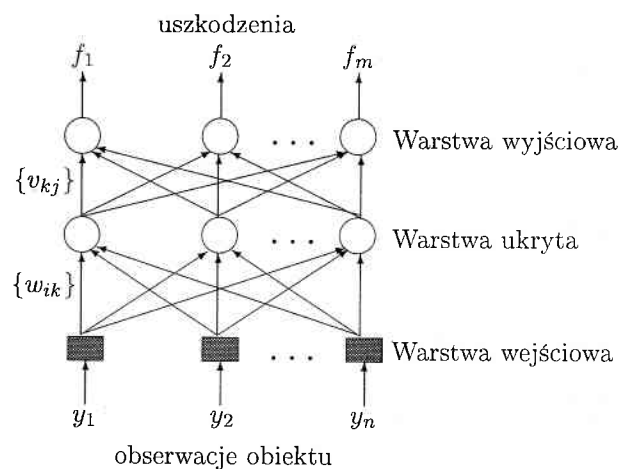
Zarówno pierwsze zastosowania sieci neuronowych w diagnostyce procesów przemysłowych w przemyśle chemicznym [22], jak i późniejsze [4, 12] są oparte na metodologii rozpoznawania obrazów [24]. W uproszczeniu rozwiązanie takie jest pokazane na rys. 3, gdzie blok *Neuronowy Detektor* może być realizowany za pomocą sieci jednokierunkowych typu propagacji wstecznej [18], sieci z uczeniem nienadzorowanym typu Kohonena [11] lub sieci typu GMDH [28]. Przy takim rozwiązaniu zadaniem *Neuronowego Detektora* jest dokonywanie klasyfikacji uszkodzeń f_1, f_2, \dots, f_p na podstawie dostępnych sygnałów wyjściowych y_1, y_2, \dots, y_n [4] lub residuów [26].



Rys. 3. Neuronowy detektor/klasyfikator uszkodzeń

Sieci typu propagacji wstecznej

Przykładową strukturę neuronowego detektora zaprojektowanego za pomocą sieci neuronowych typu propagacji wstecznej przedstawiono na rys. 4. Na etapie uczenia sieci, czyli wyznaczania odpowiednich wartości wag połączeń $\{w_{ik}\}$, $i = 1, 2, \dots, n$, $k = 1, 2, \dots, n_k$ oraz $\{v_{kj}\}$, $j = 1, 2, \dots, p$ należy korzystać ze znanych relacji: typowy obraz wejściowy $\{y_1, y_2, \dots, y_n\}$ oraz stosowne uszkodzenie f_j , $j = 1, 2, \dots, p$. Wartości wag wyznacza się za pomocą algorytmu propagacji wstecznej [18, 33]. Z uwagi na stosunkowo powolną zbieżność algorytmu oraz silne nieliniowości odwzorowań $\{y_1, y_2, \dots, y_n\} \rightarrow f_j$, $j = 1, 2, \dots, p$, wprowadza się w warstwie wejściowej dodatkowo algorytm ortogonalnego przetwarzania [4]. Stosunkowo pełna analiza możliwości stosowania sieci neuronowych typu propagacji wstecznej w diagnostyce procesów przemysłowych w stanie ustalonym jest przedstawiona w pracy [22].



Rys. 4. Neuronowy detektor typu propagacji wstecznej

Należy zauważyć, że problem projektowania neuronowych detektorów typu propagacji wstecznej jest stosunkowo prosty, gdyż liczba elementów w warstwie wejściowej odpowiada liczbie symptomów lub mierzonych zmiennych procesowych i parametrów $\{y_1, y_2, \dots, y_n\}$, a liczba elementów w warstwie wyjściowej – liczbie przyjętych potencjalnych uszkodzeń f_j , $j = 1, 2, \dots, p$. Problemem niezdefiniowanym w sposób formalny jest liczba warstw ukrytych oraz liczby elementów w poszczególnych warstwach. Z praktycznych zastosowań wynika [12, 22], że przyjęcie jednej lub dwóch warstw ukrytych pozwala na efektywne zakończenie procesu uczenia neuronowych detektorów tego typu.

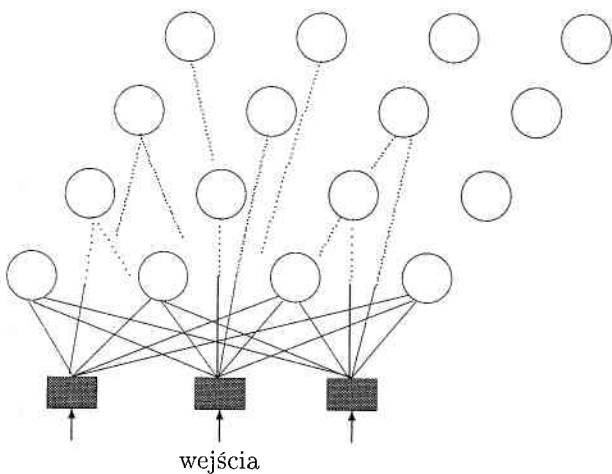
Sieci odwzorowań Kohonena

Samoorganizująca się sieć odwzorowań Kohonena [11] bazuje na nienadzorowanym algorytmie uczenia typu konkurencyjnego. Zwykle mapa cech odwzorowań jest przyjmowana w postaci dwuwymiarowej sieci. Przykładowa sieć przedstawiona na rys. 5 składa się z 16 elementów w warstwie neuronowej oraz 3 elementów wejściowych.

Jeśli przyjąć oznaczenie wektora wejściowego przez $u = [u_0, u_1, u_2, \dots, u_p]^T$, wektora wag elementu odwzorowań i przez $w_i = [w_i^0, w_i^1, \dots, w_i^p]^T$, to algorytm uczenia sieci Kohonena może być opisany przez samoorganizujące się operacje [11, 18]. Dla kolejnych kroków iteracji wyznacza się:

- element zwycięzca c

$$\|u(k) - w_c(k)\| = \min_i \{\|u(k) - w_i(k)\|\} \quad (1)$$



Rys. 5. Samoorganizująca się sieć odwzorowań Kohonena

- nowy wektor wag


$$w_i(k+1) = \begin{cases} w_i(k) + \alpha(k)[u(k) - w_i(k)], & i \in N_c \\ w_i(k) & i \notin N_c \end{cases} \quad (2)$$

gdzie:

α – monotonicznie malejąca funkcja k ;

N_c – otoczenie elementu zwycięzcy c .

Przykład dwuwymiarowej „nauczonej” sieci Kohonena, składającej się z 25. elementów w warstwie przetwarzania neuronowego, pokazano na rys. 6. Liczby zawarte w kółeczkach oznaczają wyniki klasyfikacji, a np. „N” oznacza stan nominalny procesu, puste kółeczka oznaczają elementy, które ani razu nie były zwycięzcami w procesie uczenia, a kółeczka




Rys. 6. Samoorganizująca się dwuwymiarowa sieć Kohonena po zakończeniu procesu uczenia

z liczbami 1 ... 5 – zakodowane numery poszczególnych uszkodzeń. Taka klasteryzacja wyników jest prowadzona w sposób nienadzorowany na etapie uczenia sieci, czyli prezentacji obrazów wejściowych charakteryzujących różne stany obiektu. Istotnym elementem w zastosowaniach sieci Kohonena jest umiejętność skojarzenia wyników klasteryzacji z wynikami rozwiązywanego problemu, np. detekcji uszkodzeń (rys. 6).

Neuronowe modelowanie i ewaluacja residuów

W danym przypadku zgodnie ze schematem ogólnym (rys. 2) zarówno model diagnozowanego obiektu, jak i przetwarzanie



Rys. 7. Układ diagnostyki z neuronowym modelowaniem obiektu i przetwarzaniem residuów

residuów są realizowane za pomocą sieci neuronowych. Przy takich założeniach ogólny schemat może być przedstawiony tak jak na rys. 7 [5, 26]. Według podobnego schematu zrealizowano system diagnostyczny dla laboratoryjnego zestawu trzech zbiorników [26] oraz przemysłowego urządzenia wykonawczego [13]. Przy czym w ostatnim zastosowaniu przyjęto neuronową ewaluację residuów, a do generacji residuów wykorzystano algorytm identyfikacji parametrycznej [9].

Neuronowa realizacja modelu oraz klasyfikatora w układzie diagnostyki (rys. 7) może być wykonana z wykorzystaniem różnych struktur sieci neuronowych: perceptronu wielowarstwowego [26, 35], sieci typu RCE [13], sieci rekurencyjnych [32] oraz sieci typu GMDH [28].

Sieci wielowarstwowe

Stosowanie sieci wielowarstwowo z nadzorowanym algorytmem uczenia do realizacji modelu obiektu wymaga znajomości danych pomiarowych wejścia/wyjścia diagnozowanego obiektu. Z kolei dostarczanie parametrów neuronowego klasyfikatora odbywa się na podstawie wydzielonych zestawów cech poszczególnych uszkodzeń. W pracy [26] układ diagnostyczny, analogiczny jak na rys. 7, zrealizowano za pomocą wielowarstwowego perceptronu dla złożonego systemu dynamicznego jakim jest zestaw trzech zbiorników. Należy zauważyć, że neuronowy model wykorzystano jednocześnie jako predyktor stanu obiektu.


Inny rodzaj sieci neuronowej typu RCE (ang. Restricted Coulomb Energy) został zastosowany do neuronowej ewaluacji residuów w pracy [13]. Jest to sieć jednokierunkowa z nadzorowanym algorytmem uczenia, która w odróżnieniu od perceptronu wielowarstwowego ma możliwość dodawania nowych neuronów w zależności od złożoności rozpatrywanego problemu, np. diagnostyki.

Sieć typu GMDH

Sieci tego typu są neuronową realizacją metody selekcji grupowej wielkości wejściowych, oryginalnie opracowanej przez Iwachnię [10]. Przykładowa struktura „nauczonej” sieci typu GMDH jest pokazana na rys. 8. Elementy oznaczone skrótem N-A są to elementy neuronowe typu Adaline (ang. Adaptive Linear Element) z nieliniowym przetwarzaniem wstępnym [18].

W odróżnieniu od sieci neuronowych rozpatrywanych wyżej, mających stałą strukturę, struktura sieci GMDH „rośnie” w miarę postępowania procesu uczenia [28]. Zwykle każdy neuron w sieci GMDH ma dwa wejścia: u_1 i u_2 oraz jedno wyjście y . Przyjmując wielomianowy model neuronu, np. kwadratowy, możemy zapisać [28]

$$y = w_0 + w_1 u_1 + w_2 u_1^2 + w_3 u_2 + w_4 u_2^2 + w_5 u_1 u_2 \quad (3)$$

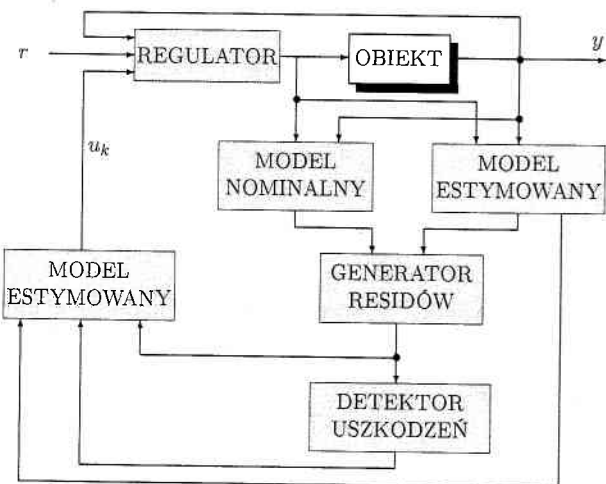


Rys. 8. „Nauczona” sieć typu GMDH

Proces uczenia takich sieci rozpoczyna się od dostrajania wag połączeń elementów warstwy wejściowej z elementami pierwszej warstwy neuronowej. Stosując odpowiednie kryterium selekcji „najlepszych” elementów neuronowych [10] odrzucane są elementy „najgorsze”. Następnie jest konfigurowana kolejna warstwa neuronowa, przy czym – podobnie jak w pierwszej warstwie na początku procesu uczenia – liczba neuronów zależy od liczby wyselekcjonowanych wyjść warstwy poprzedniej. Proces rozbudowy sieci i dostrajania jej wag połączeń jest kontynuowany dopóki nie będzie osiągnięta założona dokładność odwzorowania wejścia-wyjście według założonego kryterium [28]. Dostrajanie wag połączeń w sieciach GMDH najczęściej dokonuje się za pomocą metody najmniejszych kwadratów [17] lub adaptacyjnego algorytmu Widrowa-Hoffa [28]. W układach diagnostyki sieci GMDH stosuje się głównie do modelowania diagnozowanych obiektów [23]. Wykorzystując modele diagnozowania obiektu typu GMDH problem ewaluacji generowanych residuów w pracy [17] rozwiązano technikami systemów ekspertowych.

Uogólniony układ diagnostyki

Uogólnieniem struktury układu diagnostycznego przedstawionego na rys. 2 jest architektura układu przedstawiona na rys. 9 [30]. Ogólne założenia takiego układu są oparte na porównywaniu wyjść z modelu nominalnego i estymowanego oraz generacji residuów. W odróżnieniu od znanych architektur układów diagnostyki, w danym przypadku w bloku *Korekcja Sterowania* jest generowany sygnał korekcyjny u_k oddziałujący na obiekt sterowania, w którym wystąpiło określone uszkodzenie. Przy czym uszkodzenia mogą być podzielone na uszkodzenia oczekiwane (przechowywane w odpowiednim banku uszkodzeń) oraz nieoczekiwane. Każde nieoczekiwane



Rys. 9. Uogólniony układ diagnostyczny z aktywnym oddziaływaniem na obiekt sterowania

uszkodzenie po pojawieniu się w układzie jest przekazywane do banku znanych uszkodzeń.

Jako podstawy realizacji układu (rys. 9) przyjęto [30] algorytmy on-line aproksymacji oraz zasadę adaptacji układu do zmieniających się warunków pracy obiektu sterowania po wystąpieniu uszkodzenia. W przedstawionym na rys. 9 układzie jednym z podstawowych problemów jest budowa estymowanego modelu obiektu. Przyjmując model obiektu i addytywny charakter uszkodzeń $f(t)$ w postaci równania

$$\frac{dx(t)}{dt} = \xi(x, u) + \beta(t - T)f(u, x) \quad (4)$$

estymowany model zapiszemy odpowiednio [30]

$$\frac{d\hat{x}(t)}{dt} = \xi(x, u) + \hat{f}(x, u, \hat{\theta}) + G(\hat{x} - x) \quad (5)$$

gdzie:

x i \hat{x} – wektory stanu obiektu i modelu;

u – wektor sterowania;

ξ i f – gładkie funkcje wektorowe;

$\beta(\cdot)$ – funkcja opisująca profil czasowy uszkodzeń;

$\hat{f}(\cdot)$ – model on-line aproksymacji;

$\hat{\theta}$ – wektor dostrajanych parametrów lub wag;

$G(\cdot)$ – macierz stabilizacji.

Dla tak sformułowanego modelu (4) problem sprowadza się do realizacji on-line aproksymatora $\hat{f}(x, u, \hat{\theta})$. Zadanie to może być rozwiązane między innymi za pomocą perceptronu wielowarstwowego lub sieci z radialnymi funkcjami bazowymi [30].

$$\hat{f}_n(z, \hat{\theta}) = \sum_{i=1}^n \hat{\theta}_i w_i(z) \quad (6)$$

gdzie:

$z = [x^T u^T]^T$ – wektor wejść sieci;

w_i – wyjście i -tej funkcji bazowej, np. funkcji gaussowskiej.

Podsumowanie

Dotychczasowe wyniki badań w zakresie zastosowania sztucznych sieci neuronowych w diagnostyce technicznej wskazują na ich potencjalne duże możliwości. Podstawową zaletą stosowania sieci neuronowych jest brak wymagań znajomości modelu matematycznego diagnozowanego obiektu. Możliwość stosowania sieci neuronowych w układach diagnostycznych bazujących na modelach obiektu wynika z faktu, że faktycznie neuronowy model obiektu jest budowany na etapie uczenia z wykorzystaniem danych wejście/wyjście obiektu. Należy przy tym zauważyć, że sieci neuronowe mogą być wykorzystane do realizacji różnych funkcji/bloków w układach diagnostyki: neuronowy klasyfikator uszkodzeń, model neuronowy diagnozowanego obiektu, neuronowa ewaluacja residuów, neuronowy lokalizator uszkodzeń lub neuronowy on-line aproksymator.

Pomimo tak wielu możliwości zastosowań sieci neuronowych w diagnostyce technicznej, problemem trudnym i częściowo otwartym jest uwzględnianie dynamiki diagnozowanych obiektów. Należy sądzić, że rozwiązaniem tego problemu mogą być sieci rekurencyjne ze sprzężeniami lokalnymi (sieci dynamiczne) lub globalnymi [3, 25]. Jednak złożoność takich sieci, a w szczególności złożoność algorytmów uczenia dotychczas nie pozwala na ich efektywne zastosowanie.

LITERATURA

- [1] Cz. CEMPEL: Podstawy wibroakustycznej diagnostyki maszyn. WNT, Warszawa 1982.
- [2] W. CHOLEWA, J. KAŻMIERCZAK: Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów. Wyd. Politechniki Śląskiej, Gliwice 1992.
- [3] R. DA, Ch. F. LIN: Failure diagnosis systems using ARTMAP neural networks. *J. Guidance, Control and Dynamics* 1995, vol. 18, nr 4, s. 696–701.
- [4] J. Y. FAN, M. NIKOLAOU, R. E. WHITE: An approach to fault diagnosis of chemical processes via neural networks. *AIChE Journal* 1993, vol. 39, nr 1, s. 82–88.
- [5] P. M. FRANK: Advances in fault tolerance by model-based fault diagnosis. Proc. European Science Foundation Workshop „Control of Complex Systems COSY”. Włochy, Rzym, 6–7 września 1995, s. 15–21.
- [6] P. M. FRANK: Fuzzy supervision. Application of fuzzy logic to process supervision and fault diagnosis. Int. Workshop „Fuzzy Technologies in Automation and Intelligent Systems. Fuzzy Duisburg '94”. Niemcy, Duisburg, 7–8 kwietnia 1994, s. 36–59.
- [7] P. M. FRANK: Fault diagnosis in dynamics systems using analytical and knowledge-based redundancy. *Automatica* 1990, vol. 26, s. 458–474.
- [8] E. GATNAR: Metody modelowania jakościowego. Akademia Oficyna Wydawnicza, Warszawa 1994.
- [9] R. ISERMANN: On the applicability of model-based fault detection for technical processes. *Control Eng. Practice* 1994, vol. 2, nr 3, s. 439–450.
- [10] A. G. IWACHNIENKO: Induktivnyj metod samoorganizacji modelej složnych sistem. „Naukova Dumka”, Kijów 1982.
- [11] T. KOHONEN: Self-Organization and Associative Memory. Springer-Verlag, Berlin 1984.
- [12] H. N. KOIVO: Artificial neural networks in fault diagnosis and control. *Control Eng. Practice* 1994, vol. 2, nr 7, s. 89–101.
- [13] B. KÖPPEN-SELIGER, P. M. FRANK: Residual evaluation for fault detection and isolation with RCE neural networks. Proc. „American Control Conference”. USA, Seattle 1995, s. 3264–3268.
- [14] J. KORBIĆZ: Neural networks and their application in fault detection and diagnosis. Proc. Int. IFAC Symp. „Fault Detection, Supervision and Safety for Technical Process SAFEPROCESS '97”. Wielka Brytania, Hull 1997, vol. 1, s. 377–382.
- [15] J. KORBIĆZ: Zastosowanie sieci neuronowych w detekcji i lokalizacji uszkodzeń. Mat. I Krajowej Konf. Naukowo-Technicznej „Diagnostyka Procesów Przemysłowych”. Podkowa Leśna k. Warszawy 10–12 czerwca 1996, s. 35–41.
- [16] J. KORBIĆZ, Cz. CEMPEL (Eds.): Analytical and Knowledge-Based Redundancy in Fault Detection and Diagnosis. Special issue of *Applied Mathematics and Computer Science* 1993, vol. 3, nr 3.
- [17] J. KORBIĆZ, J. KUŚ: Knowledge-based fault detection system using evolutive observer approach. *Systems Science* 1997, vol. 23, nr 1, s. 77–87.
- [18] J. KORBIĆZ, A. OBUCHOWICZ, D. UCIŃSKI: Sztuczne sieci neuronowe. Podstawy i zastosowania. Akademia Oficyna Wydawnicza PLJ, Warszawa 1994.
- [19] J. KORBIĆZ, D. UCIŃSKI, A. PIECZYŃSKI, G. MARCZEWSKA: An integrated approach to fault detection and diagnosis in power plant. Proc. Int. Symp. „Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '94”. Finlandia, Helsinki 1994, vol. 1, s. 140–146.
- [20] J. M. KOŚCIELNY: Diagnostyka ciągłych automatyzowanych procesów przemysłowych metodą dynamicznych tablic stanu. Politechnika Warszawska, Prace naukowe, *Elektronika z. 95*, Warszawa.
- [21] J. M. KOŚCIELNY, P. SZCZEPANIAK: Terminologia oraz klasyfikacja metod detekcji i diagnostyki procesów przemysłowych. Mat. II Krajowej Konferencji Naukowo-Technicznej „Diagnostyka Procesów Przemysłowych. Łągow k. Zielonej Góry, 8–11 września 1997, s. 57–68.
- [22] M. A. KRAMER, J. A. LEONARD: Diagnosis using backpropagation neural networks. Analysis and criticism. *Computers chem. Engng.* 1990, vol. 14, nr 12, s. 1323–1338.
- [23] J. KUŚ: Diagnostyka obiektów technicznych metodą obserwatorów genetycznych. Praca doktorska. Politechnika Warszawska, Wydział Mechaniki Precyzyjnej, Warszawa 1995.
- [24] T. MARCU: Pattern recognition techniques using fuzzily labeled data for process fault detection. *Appl. Math. And Comp. Sci.* 1996, vol. 6, nr 4, s. 815–840.
- [25] K. PATAN, J. KORBIĆZ: Some dynamic neural network architectures in identification problems. Proc. 3rd Conf. „Neural Networks and their Application”. Kule 14–18 października 1997, s. 538–543.
- [26] R. J. PATTON, J. CHEN, T. M. SIEW: Fault diagnosis in nonlinear dynamic systems via neural networks. Proc. IEE Int. Conf. CONTROL '94. Wielka Brytania, Coventry 21–24 marca 1994, s. 1346–1351.
- [27] R. PATTON, P. FRANK, R. CLARK: Advances in Fault Diagnosis for Dynamic Systems. Springer-Verlag, Berlin 1997.
- [28] D. T. PHAM, L. XING: Neural Networks for Identification, Prediction and Control. Springer=Verlag, Londyn 1995.
- [29] A. PIECZYŃSKI, R. ERBER: Zastosowanie zbiorów rozmytych do diagnostyki symulatora elektrowni cieplnej. Mat. „Kongres Diagnostyki Technicznej KDT '96”. Gdańsk 1996, t. 2, s. 139–144.
- [30] M. M. POLYCARPOU, A. J. HELNICKI: Automated fault detection and accommodation. A learning systems approach. *IEEE Trans. Systems, Man and Cybernetics* 1995, vol. 25, nr 11, s. 1447–1458.
- [31] D. RUTKOWSKA, PILIŃSKI, L. RUTKOWSKI: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. PWN, Warszawa 1997.
- [32] M. SCHUBERT, B. KÖPPEN-SELIGER, P. M. FRANK: Recurrent neural networks for nonlinear system modelling in fault detection. Proc. Int. IFAC Symp. „Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '97”. Wielka Brytania, Hull 1997, vol. 2, s. 713–718.
- [33] R. TADEUSIEWICZ: Sieci neuronowe. Akademia Oficyna Wydawnicza RM, Warszawa 1995.
- [34] S. G. TZAFESTAS (Ed.): Knowledge-Based System Diagnosis, Supervision and Control. Plenum, Nowy Jork 1989.
- [35] J. ZHOU, S. BENNETT: Dynamic system fault diagnosis based on neural network modelling. Proc. Int. IFAC Symp. „Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '97”. Wielka Brytania, Hull 1997, vol. 1, s. 54–59.