XV Krajowa Konferencja Automatyki

Tom III

KKA 2005

Redaktorzy:
Zdzisław Bubnicki
Roman Kulikowski
Janusz Kacprzyk

XV Krajowa Konferencja Automatyki
Tom III

Redaktorzy:
Zdzisław BUBNICKI
Roman KULIKOWSKI
Janusz KACPRZYK

ORGANIZATOR
Komitet Automatyki i Robotyki Polskiej Akademii Nauk
Instytut Badań Systemowych Polskiej Akademii Nauk
WSPÓŁORGANIZATORZY
Politechnika Warszawska
Przemysłowy Instytut Automatyki i Pomiarów
Polskie Stowarzyszenie Pomiarów, Automatyki i Robotyki

ORGANIZATOR

Komitet Automatyki i Robotyki Polskiej Akademii Nauk
Instytut Badań Systemowych Polskiej Akademii Nauk

WSPÓŁORGANIZATORZY

Politechnika Warszawska
Przemysłowy Instytut Automatyki i Pomiarów
Polskie Stowarzyszenie Pomiarów, Automatyki i Robotyki

KOMITET PROGRAMOWY

Przewodniczący	Zdzisław BUBNICKI
Zastępca Przewodniczącego	Roman KULIKOWSKI

CZŁONKOWIE

Stanisław BAŃKA	Michał BIAŁKO
Mikołaj BUSŁOWICZ	Władysław FINDEISEN
Ryszard GESSING	Henryk GÓRECKI
Jakub GUTENBAUM	Jerzy JÓZEFCZYK
Stanisław KACZANOWSKI	Tadeusz KACZOREK
Janusz KACPRZYK	Jerzy KLAMKA
Józef KORBICZ	Zbigniew KOWALSKI
Krzysztof KOZŁOWSKI	Juliusz L. KULIKOWSKI
Krzysztof KUŹMIŃSKI	Kazimierz MALANOWSKI
Krzysztof MALINOWSKI	Wojciech MITKOWSKI
Antoni NIEDERLIŃSKI	Władysław PEŁCZEWSKI
Tadeusz PUCHAŁKA	Leszek RUTKOWSKI
Stanisław SKOCZOWSKI	Roman SŁOWIŃSKI
Jerzy ŚWIĄTEK	Andrzej ŚWIERNIAK
Ryszard TADEUSIEWICZ	Piotr TATJEWSKI
Krzysztof TCHOŃ	Leszek TRYBUS
Jan WĘGLARZ	Andrzej P. WIERZBICKI

KOMITET ORGANIZACYJNY

Przewodniczący	Roman KULIKOWSKI
Zastępcy Przewodniczącego	Janusz KACPRZYK
	Stanisław KACZANOWSKI
	Tadeusz KACZOREK
	Krzysztof MALINOWSKI
Członkowie	Roman OSTROWSKI
	Tadeusz PUCHAŁKA
	Dariusz WAGNER
Sekretarze naukowi	Jan STUDZIŃSKI
	Jan W. OWSIŃSKI

ISBN 83-89475-02-2

Copyright © Instytut Badań Systemowych Polskiej Akademii Nauk
All rights reserved

Druk: ARGRAF, Warszawa

SZTUCZNA INTELIGENCJA

NIEPEWNOŚĆ MODELI SZTUCZNEJ INTELIGENCJI W UKŁADACH DIAGNOSTYKI PROCESÓW*

Józef KORBICZ

Uniwersytet Zielonogórski, Instytut Sterowania i Systemów Informatycznych
ul. Podgórna 50, 65-246 Zielona Góra, e-mail:J.Korbicz@issi.uz.zgora.pl

Streszczenie: W danej pracy omawia się problemy niepewności modeli sztucznej inteligencji w układach diagnostyki. W szczególności rozpatruje się niepewność modeli neuronowych typu GMDH oraz rozmyto-neronowych typu Takagi-Sugeno. W badaniach wykorzystano metodę ograniczonych wartości błędów do estymacji parametrów analizowanych modeli. Pokazano, że wyznaczone przedziały ufności sygnałów wyjściowych modeli można zastosować do określenia adaptacyjnych progów decyzyjnych, w sensie przedziału ufności sygnału residuum. Załączony na końcu pracy przykład odpornego układu diagnostyki dla silnika prądu stałego ilustruje możliwości wykorzystania niepewnego modelu rozmyto-neuronowego.

Słowa kluczowe: Diagnostyka procesów, sztuczne sieci neuronowe, sieci rozmyto-neuronowe, niepewność modeli, adaptacyjny próg decyzyjny.

1. WPROWADZENIE

Wysokie wymagania dotyczące jakości, niezawodności i bezpieczeństwa pracy obiektów technicznych powodują, iż zagadnienia diagnostyki należą do jednych z najważniejszych we współczesnych systemach automatyki przemysłowej. Wśród wielu znanych metod i technik projektowania układów diagnostyki [37], szczególne znaczenie od kilku dziesięcioleci zajmują podejścia oparte na wykorzystaniu modelu diagnozowanego procesu lub obiektu [15, 16, 26]. Główny problem, jaki pojawia się przy takim projektowaniu układów diagnostyki, wynika z faktu niepewności modelu, rozumianej jako różnicy pomiędzy zachowaniem (odpowiedzią) modelu a rozpatrywanym obiektem lub procesem [2]. Miarą niepewności modelu jest obszar ufności jego parametrów tzn. im większy jest obszar ufności estymowanych parametrów tym większa jest niepewność modelu. Dla rozwiązania tego problemu w literaturze zaproponowano wiele podejść, które w zasadzie sprowadzają się do zapewnienia odporności układu diagnostyki na niepewność zastosowanego modelu.

Problemy odporności układów diagnostyki rozwiązywane są w różny sposób, głównie w zależności od przyjętej formy opisu modelu np. modele analityczne, modele sztucznej inteligencji, jak również ich kombinacji wraz z wnioskowaniem analitycznym lub heurystycznym. Zwykle modele analityczne obarczone są błędami modelowania wynikającymi z przyjętych uproszczeń, idealizacji zmienności parametrów, jak również brakiem uwzględnienia pewnych wymuszeń [3, 5, 33]. W takich przypadkach niewątpliwie efektywnym rozwiązaniem są odporne obserwatory, a w szczególności obserwatory o nieznanych wejściach [5, 15, 34, 36].

O ile projektowanie odpornych obserwatorów dla układów liniowych nie stwarza większych problemów, to jednak rozszerzenie tego podejścia na układy nieliniowe jest bardzo ograniczone [34]. Wynika to przede wszystkim z braku ogólnej teorii projektowania obserwatorów nieliniowych, a znane podejścia oparte są na różnych technikach przybliżonych [33]. W układach diagnostyki dla złożonych procesów takie rozwiązania mogą prowadzić do generowania fałszywych alarmów, co w końcowym efekcie powoduje bezużyteczności takiego układu.

Alternatywnym podejściem w stosunku do modeli analitycznych jest zastosowanie modeli sztucznej inteligencji, które nie wymagają znajomości opisu matematycznego diagnozowanych obiektów lub procesów. Modele sztucznej inteligencji budowane są z wykorzystaniem danych empirycznych i wiedzy jakościowej o diagnozowanym obiekcie, co jest podstawową zaletą w stosunku do modeli analitycznych. Najczęściej są to modele neuronowe lub neuronowo-rozmyte [4, 9, 16, 17, 27]. Modele neuronowe budowane są z wykorzystaniem różnych architektur sztucznych dynamicznych sieci neuronowych. Najczęściej są to sieci z dynamicznymi modelami neuronów, np. sieci wielowarstwowe, jednokierunkowe [18, 23, 28], lub sieci typu GMDH (ang. Group Method of Data Handling) [21, 25]. Proces modelowania obiektów diagnostyki realizowany jest również z wykorzystaniem rozmytych sieci neuronowych [6, 13, 30, 31], przy czym podobnie, jak w przypadku stosowania sztucznych sieci neuronowych, rozpatruje się dynamiczne rozmyte sieci neuronowe typu Takagi-Sugeno [17, 19, 20]. W obydwóch przypadkach modelowania obiektów dynamicznych, metodami neurono-

*Praca została przygotowana w ramach projektu badawczego MNiI, pt. *Modelowanie i identyfikacja nieliniowych systemów dynamicznych w odpornych układach diagnostyki*, 2003-2006.

wymi, jak i neuronowo-rozmytymi, istnieje problem niepewności takich modeli z uwagi na proces identyfikacji parametrycznej.
W danej pracy rozpatruje się problemy wyznaczania niepewności modeli neuronowych typu GMDH oraz rozmyto-neuronowych typu Takagi-Sugeno. W tym celu wykorzystano metodę ograniczonych wartości błędów [24] do estymacji parametrów i modelu niepewności, w sensie przedziałów ufności wyjść rozpatrywanych modeli. Należy podkreślić, że taki sposób rozwiązywania stwarza możliwość uniknięcia wielu wad i ograniczeń, jakie posiadają metody statystyczne [1]. Dla wyznaczonych modeli niepewności pokazano możliwość ich zastosowania do opracowania metody odpornej detekcji uszkodzeń, korzystając z techniki adaptacyjnych progów decyzyjnych [9]. W końcowej części pracy zilustrowano możliwości odpornej detekcji uszkodzeń na przykładzie silnika prądu stałego, korzystając z modelu rozmyto-neuronowego.

2. NIEPEWNOŚĆ MODELI SZTUCZNEJ INTELIGENCJI

W tej części ograniczymy się do przedstawienia i opisu niepewności sieci neuronowej typu GMDH oraz rozmyto-neuronowej typu Takagi-Sugeno.

2.1. Model niepewności sieci typu GMDH

Pewną wadą większości sieci neuronowych jest to, że arbitralnie na etapie projektowania definiuje się ich strukturę [8, 12]. Alternatywnym podejściem jest połączenie problemu uczenia sieci z wyznaczaniem jej optymalnej architektury. Takie rozwiązanie można uzyskać stosując metodę grupowej obróbki danych (ang. Group Method of Data Handling). Bazując na tej koncepcji w latach dziewięćdziesiątych opracowano statyczne sztuczne sieci neuronowe typu GMDH [21, 29].

Idea metody grupowej obróbki danych polega na zastąpieniu jednego całościowego modelu systemu strukturą hierarchiczną składającą się z modeli cząstkowych (neuronów) z zastosowaniem zasad selekcji zmiennych. Modele cząstkowe zazwyczaj posiadają niewielką liczbę sygnałów wejściowych $u_i(k)$, $i=1,\dots,m$, oraz zakłada się, że są realizowane przez oddzielne modele neuronu typu GMDH. W takich sieciach dopuszcza się znaczną swobodę w definiowaniu funkcji aktywacji neuronu (rys.1).

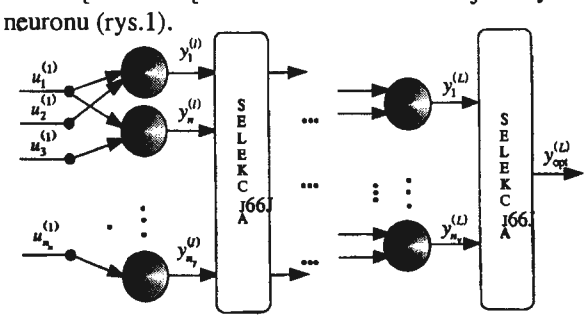

Rys.1. Synteza modelu typu GMDH.

W przypadku takich sieci problem wprowadzenia dynamiki rozwiązano poprzez zastosowanie dynamicznych modeli neuronów [25]. Model takiego neuronu można przedstawić w postaci:

$$\tilde{y}_n^{(l)}(k)=\xi\left(\left(r_n^{(l)}(k)\right)^T\theta_n^{(l)}\right), \tag{1}$$

gdzie $\tilde{y}_n^{(l)}(k)$ oznacza wyjście neuronu (l jest indeksem warstwy, indeksem neuronu w warstwie l-tej), k odpowiada chwilą pomiaru sygnału wejściowego $u(k)\in\mathrm{R}^{n_u}$ systemu, $\xi(\cdot)$ oznacza nieliniową odwracalną funkcję aktywacji neuronu, czyli istnieje $\xi^{-1}(\cdot)$. Ponadto, $r_n^{(l)}(k)=f\left(\left[u_i^{(l)}(k),u_j^{(l)}(k)\right]^T\right)$ dla $i,j=1,2,\dots,n_u$ oraz $\theta_n^{(l)}\in\mathrm{R}^{n_\theta}$ oznaczają odpowiednio wektory regresji oraz nieznanych parametrów. Arbitralnie zadawana funkcja wektorowa $f(\cdot)$ najczęściej przyjmowana jest o strukturze $f(x)=\left[x_1^2,x_2^2,x_1x_2,x_1,x_2\right]^T$, co odpowiada wielomianom stopnia drugiego.

Korzystając z przedstawionego modelu neuronu (1), zgodnie z opisanym algorytmem syntezy [21, 29], można zaprojektować sieć typu GMDH. Należy jednak podkreślić, co zresztą wykazano w pracy [25], że niezależnie od przyjętych metod identyfikacji parametrów modeli cząstkowych, zawsze istnieje problem niepewności modelu neuronowego typu GMDH. W tej sytuacji ważnym staje się wybór właściwej metody estymacji parametrów modeli cząstkowych, które jednocześnie pozwalają na dokładne wyznaczenie niepewności modelu. Jest to bardzo ważne z punktu widzenia projektowania odpornych układów detekcji uszkodzeń, w których znajomość poziomu niepewności modelu i możliwość jej minimalizacji pozwala na poprawienie jakości pracy takiego układu.

W najczęściej stosowanych metodach estymacji parametrów modelu zakłada się, że błędy związane z danymi oraz błędy modelu, przyjmuje się w postaci niezależnych zmiennych losowych o znanym rozkładzie, np. metoda najmniejszych kwadratów. Takie założenia nie zawsze mogą być spełnione w praktyce i dlatego bardziej naturalne jest założenie, że wartości błędów znajdują się w pewnym ograniczonym przedziale. Takie założenia występują w algorytmach estymacji parametrów przy ograniczonych wartościach błędów [24, 32].

Rozważmy system w następującej postaci:

$$y(k)=\left(r_n^{(l)}(k)\right)^T\theta_n^{(l)}+\varepsilon_n^{(l)}(k). \tag{2}$$

Dla uproszczenia dalszych rozważań indeksy $^{(l)}_{n}$ zostaną pominięte. Zakładając pewną wiedzę dotyczącą zbioru dopuszczalnych wartości parametrów, można wyznaczyć przedział ufności wyjścia modelu w postaci:

$$\tilde{y}^m(k)\le y(k)\le\tilde{y}^M(k), \tag{3}$$

gdzie $\tilde{y}^m(k)$ oraz $\tilde{y}^M(k)$ oznaczają minimalne i maksymalne dopuszczalne wartości wyjścia modelu. Dodatkowo zakłada się, że zakłócenie $\varepsilon(k)$ posiada dolne i górne ograniczenia typu:

$$\varepsilon^m(k) \le \varepsilon(k) \le \varepsilon^M(k), \tag{4}$$

gdzie ograniczenia $\varepsilon^m(k)$ i $\varepsilon^M(k)\left(\varepsilon^m(k) \ne \varepsilon^M(k)\right)$ są znane *a'priori*.

Podstawowa idea metody ograniczonych wartości błędów polega na wyznaczeniu obszaru dopuszczalnych wartości parametrów:

$$\mathbb{P} = \{\theta \in \mathrm{R}^{n_\theta} \,|\, y(k) - \varepsilon^M(k) \le r^T(k)\theta \le y(k) - \varepsilon^m(k),\ k = 1,\dots,n_T\} \tag{5}$$

gdzie n_T oznacza liczbę pomiarów wejść i wyjść. Obszar $\mathbb{P}$ może być przedstawiony w postaci wypukłego obszaru w przestrzeni parametrów, który powstaje w wyniku przecięcia n_T par hiperpłaszczyzn $\mathbb{P} = \bigcap_k^{n_T} \mathbb{S}(k)$, gdzie każda para definiuje pasmo parametrów:

$$\mathrm{S}(k) = \left\{\theta \in \mathrm{R}^{n_\theta} \,\middle|\, y(k) - \varepsilon^M(k) \le r^T(k)\theta \le y(k) - \varepsilon^m(k)\right\}. \tag{6}$$

Każdy z wektorów $\hat{\theta}$ zawarty w P jest estymatą θ. W praktyce centrum obszaru P można przyjąć jako estymatę $\hat{\theta}$ w postaci:

$$\hat{\theta}_i = \frac{\theta_i^{\min} + \theta_i^{\max}}{2}, \qquad i = 1,\dots,n_\theta. \tag{7}$$

gdzie:

$$\theta_i^{\min} = \arg\min_{\theta \in P} \theta_i, \qquad i = 1,\dots,n_\theta, \tag{8}$$

$$\theta_i^{\max} = \arg\max_{\theta \in P} \theta_i, \qquad i = 1,\dots,n_\theta. \tag{9}$$

Zadanie wyznaczenia wartości (8), (9) może być rozwiązane z wykorzystaniem technik programowania liniowego [24], ale pewien problem wynika z założenia znajomości ograniczeń $\varepsilon^m(k)$ i $\varepsilon^M(k)$. Trudność ta może być rozwiązana przyjmując, że $\varepsilon^m(k) = \varepsilon^m$ i $\varepsilon^M(k) = \varepsilon^M$, a następuje rozszerzając nieznany wektor parametrów θ o ε^m i ε^M. Przyjmując takie ograniczenia, problem można sformułować następująco:

$$\left(\varepsilon^m, \varepsilon^M\right) = \arg\min_{\varepsilon^M \ge 0, \varepsilon^m \le 0} \left(\varepsilon^M - \varepsilon^m\right), \tag{10}$$

uwzględniając, że:

$$y(k) - \varepsilon^M \le r^T(k)\theta \le y(k) - \varepsilon^m, k = 1,\dots,n_T. \tag{11}$$

W wyniku zastosowania przedstawionej metody otrzymamy estymaty parametrów $\hat{\theta}$ ze zbioru wartości dopuszczalnych P. Z praktycznego punktu widzenia ważniejszym jest wyznaczenie przedziału ufności wyjścia modelu, tzn. przedziału w którym może się znaleźć „prawdziwe" wyjście modelu $\tilde{y}(k)$. Takie rozwiązanie stwarza możliwość wyznaczenia adaptacyjnego progu decyzyjnego [10], i zaprojektowania układu diagnostyki odpornego na niepewność modelu.

Dla rozważanej sieci niepewność modelu GMDH można rozpatrywać sekwencyjnie w miarę budowania kolejnych warstw sieci [25]. Przy czym parametry oraz niepewność modeli cząstkowych, bez uwzględnienia błędu regresora, wyznaczane są jedynie w warstwie pierwszej. Począwszy od drugiej warstwy należy uwzględnić błędy regresora *e(k)* przy wyznaczaniu parametrów modeli cząstkowych. W tym przypadku przedział ufności wyjścia modelu cząstkowego może być zdefiniowany następująco [35] (rys. 2):

$$\tilde{y}^m(k)\left(\theta'^m(k), \theta''^m(k)\right) \le r_n^T\theta \le \tilde{y}^M(k)\left(\theta'^M(k), \theta''^M(k)\right), \tag{12}$$

gdzie:

$$\tilde{y}^m(k)\left(\theta'^m(k), \theta''^m(k)\right) = \left(r(k) - e^M(k)\right)^T \theta'^m(k) + \left(e^m(k) - r(k)\right)^T \theta''^m(k), \tag{13}$$

$$\tilde{y}^M(k)\left(\theta'^M(k), \theta''^M(k)\right) = \left(r(k) - e^m(k)\right)^T \theta'^M(k) + \left(e^M(k) - r(k)\right)^T \theta''^M(k), \tag{14}$$

przy czym:

$$\left(\theta'^m(k), \theta''^m(k)\right) = \arg\min_{(\theta', \theta'') \in V} \tilde{y}^m(k)\left(\theta', \theta''(k)\right), \tag{15}$$

$$\left(\theta'^M(k), \theta''^M(k)\right) = \arg\max_{(\theta', \theta'') \in V} \tilde{y}^M(k)\left(\theta', \theta''(k)\right). \tag{16}$$

Ponadto przyjęto, że każdy z parametrów θ można przedstawić w postaci różnicy dwóch parametrów, czyli $\theta_i = \theta_i' - \theta_i''$, $\theta_i', \theta_i'' \ge 0$.

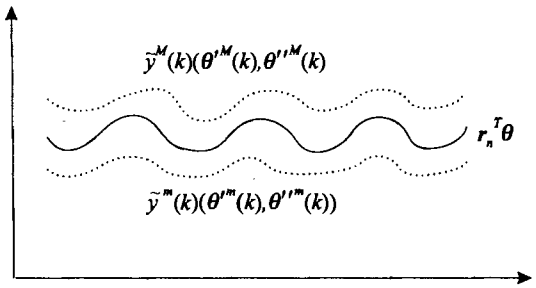

Rys. 2. Przedział ufności wyjścia modelu wyznaczony z uwzględnieniem błędu regesora.

Korzystając z (12) można wyznaczyć przedział ufności wyjścia systemu (rys. 3):

$$\tilde{y}^m(k)\left(\theta'^m(k), \theta''^m(k)\right) + \varepsilon^m(k) \le y(k) \le \tilde{y}^M(k)\left(\theta'^M(k), \theta''^M(k)\right) + \varepsilon^M(k) \tag{17}$$

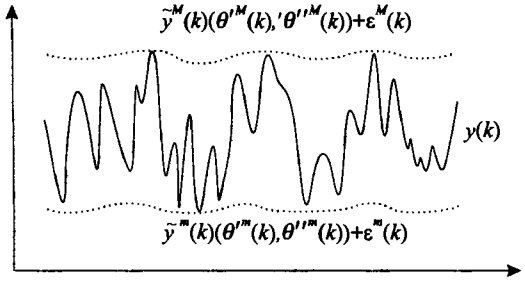

Rys. 3. Przedział ufności wyjścia systemu wyznaczony z uwzględnieniem błędu regresora.

Przedstawioną metodę ograniczonych wartości błędów z powodzeniem zastosowano do projektowania sieci GMDH [24].

2.2. Model niepewności sieci typu Takagi-Sugeno

Struktura sieci Takagi-Sugeno może być przedstawiona w postaci warstwowej [6, 30], podobnie jak sieci neuronowe. Jednakże wiedza zakodowana w takiej strukturze może być przedstawiona w formie reguł rozmytych, czyli:

$$\mathrm{R}_i: IF\ x \text{ is } A_i\ THEN\ y_i = r_i^T \theta_i,\ i = 1,2,\ldots,n\ , \tag{18}$$

gdzie x jest wektorem wejść sieci, A_i – wielowymiarowym zbiorem rozmytym, y_i – wyjściem reguły, r_i – wektorem lokalnego modelu liniowego, θ_i – wektorem parametrów lokalnego modelu. Wyjście takiej sieci y wyznaczane jest na podstawie odpowiedzi wszystkich reguł w postaci:

$$y = \frac{\sum_{i=1}^{n} \mu_i y_i}{\sum_{i=1}^{n} \mu_i}\ , \tag{19}$$

gdzie μ_i jest funkcją przynależności dla i-tej reguły, n – liczbą reguł.

Wprowadzenie dynamiki do takich sieci można zrealizować poprzez wprowadzenie opóźnionych sygnałów wejściowych u_i dla modeli lokalnych (rys. 4) oraz opóźnionego wyjścia y_i, czyli:

$$r_i(k) = [u_i(k), u_i(k-1), \ldots, u(k-n_a), y_i(k-1), y_i(k-2), \ldots, y_i(k-n_b)]^T .$$

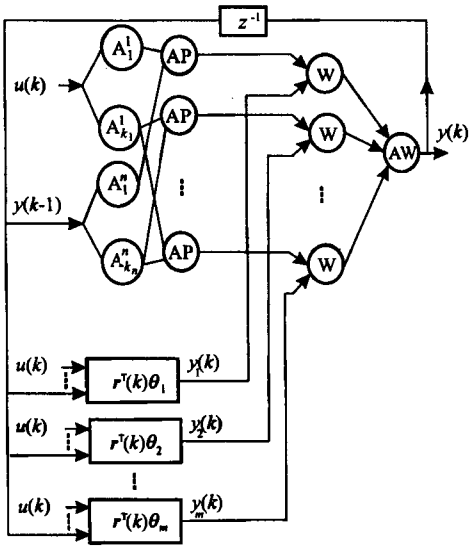

Rys. 4. Struktura dynamicznej sieci typu Takagi-Sugeno, gdzie: AP – spójnik logiczny, W – operacja wnioskowania, AW – agregacja wniosków.

Aby wykorzystać metodę estymacji parametrów przy ograniczonych wartościach błędów do wyznaczania przedziału ufności wyjścia rozpatrywanej sieci typu Takagi-Sugeno, należy przyjąć pewne założenia, aby model takiej sieci był liniowy względem nieznanych parametrów θ [17].

Rozpatrzmy model rozmyto-neuronowej sieci w postaci:

$$\tilde{y}(k) = \sum_{i=1}^{n} \phi_i(k) \tilde{y}_i(k)\ , \tag{20}$$

gdzie $\tilde{y}_i(k)$ jest wyjściem i-tej reguły. Model (20) można przedstawić w postaci liniowej względem parametrów:

$$\tilde{y}(k) = x^T(k)\theta\ , \tag{21}$$

gdzie wektor $x(k)$ zawiera wszystkie zmienne wejściowe modeli cząstkowych przetworzone przez stopnie spełnienia poszczególnych reguł rozmytych. Przyjmując, że $\mu_i(r^{f_s}, \theta_i^{f_s})$ określa stopień i-tej reguły, wówczas ϕ_i oznacza wartość wyznaczoną według wzoru:

$$\phi_i = \frac{\mu_i(r^{f_s}(k), \theta_i^{f_s})}{\sum_{j=1}^{N} \mu_j(r^{f_s}(k), \theta_j^{f_s})}\ , \tag{22}$$

gdzie $r^{f_s}(k)$ jest wektorem zmiennych wejściowych dla warstwy pierwszej sieci, a $\theta_i^{f_s}$ – wektorem parametrów określających stopień przynależności poprzednika i-tej reguły rozmytej. W danym przypadku:

$$x(k) = \begin{bmatrix} \phi_1(k) r_1(k) \\ \phi_2(k) r_2(k) \\ \vdots \\ \phi_n(k) r_n(k) \end{bmatrix},$$

gdzie $r(k)$ jest wektorem zmiennych wejściowych zdefiniowanych dla liniowych modeli cząstkowych reprezentujących następniki reguł rozmytych.

Błąd wyjściowy układu $\varepsilon(k)$ można opisać w postaci:

$$\varepsilon(k) = y(k) - x^T\theta\ , \tag{23}$$

gdzie $y(k)$ jest wyjściem systemu. Dla ograniczonych wartości zapiszemy, że:

$$\varepsilon^{\min}(k) \le \varepsilon(k) \le \varepsilon^{\max}(k)\ . \tag{24}$$

Zakładając, że $\varepsilon^{\max}(k) = \varepsilon$, a $\varepsilon^{\min}(k) = -\varepsilon$, dopuszczalny zbiór parametrów $\mathbb{P}$ dla N punktów danych można przedstawić następująco:

$$\mathbb{P} = \{\theta \in \mathrm{R}^{n_\theta} \mid y(k) + \varepsilon \le x^T(k)\theta \le y(k) - \varepsilon;\ k = 1,\ldots,N\}. \tag{25}$$

Wówczas przedział ufności dla wyjścia systemu zapiszemy w postaci nierówności:

$$x^T(k)\theta^{\min}(k)\varepsilon \le y(k) \le x^T(k)\theta^{max}(k) + \varepsilon, \tag{26}$$

gdzie:

$$\theta^{\max}(k)=\arg\max_{\theta\in P} x^T(k)\theta, \tag{27}$$

$$\theta^{\min}(k)=\arg\min_{\theta\in P} x^T(k)\theta. \tag{28}$$

Należy odnotować, że korzystając z metody ograniczonych wartości błędów do estymacji parametrów rozmytej sieci neuronowej, podobnie jak dla sieci GMDH, występuje problem dużej złożoności obliczeniowej. Pewnym rozwiązaniem tego problemy jest stosowanie zmodyfikowanych metod ograniczonych wartości błędów, w których dopuszczalny obszar parametrów $\mathbb{P}$ jest aproksymowany obszarami o uproszczonych kształtach [7, 32]. Takim przykładem może być metoda zewnętrznych elipsoid ograniczających [6], wykorzystywana w pracy [19] do wyznaczania niepewności modelu rozmytej sieci neuronowej. Ponadto należy zauważyć, że metoda ograniczonych wartości błędów z powodzeniem może być zastosowana na etapie projektowania rozmytej sieci neuronowej do estymacji parametrów modeli cząstkowych [19].

3. ODPORNE UKŁADY DETEKCJI USZKODZEŃ

W układach diagnostyki z modelem (rys. 5) generowane są tzw. sygnały residuów $e_r(k)$, które definiuje się

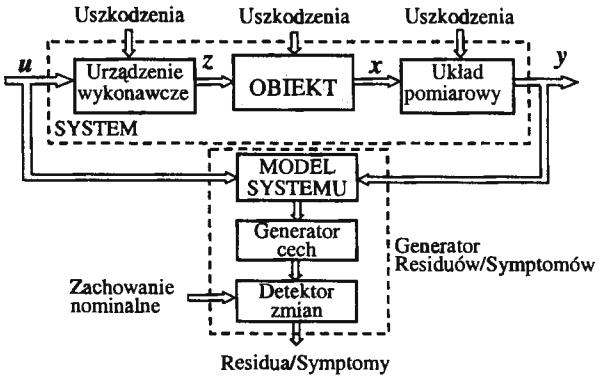

Rys. 5. Ogólny schemat generacji residuów/symptomów w układzie diagnostyki z modelem

jako różnicę pomiędzy sygnałem wyjściowym systemu $y(k)$ i modelu $\tilde{y}(k)$, czyli [15, 26]

$$e_r(k)=y(k)-\tilde{y}(k). \tag{29}$$

W warunkach nominalnej pracy systemu wartość sygnału residuum powinna być zbliżona do zera, co świadczy o dobrej jakości przyjętego modelu. W warunkach występujących uszkodzeń sygnał ten powinien znacznie różnić się od zera i zastosowanie stałego progu może być podstawą do podjęcia właściwej decyzji. Niestety w praktyce takie rozwiązanie napotyka na fundamentalne trudności wynikające z faktu, że residua są obarczone licznymi zakłóceniami oraz niepewnościami modelowania. W tym przypadku nie jest dobrym rozwiązaniem zwiększenie wartości progu decyzyjnego, gdyż prowadzi ono do zmniejszenia czułości układu detekcji, a w innym przypadku zwiększa liczbę fałszywych alarmów. Kompromisowym rozwiązaniem jest projektowanie progów adaptacyjnych [10] (rys. 6). W przypadku stałego progu decyzyjnego w chwili T_{f_a}

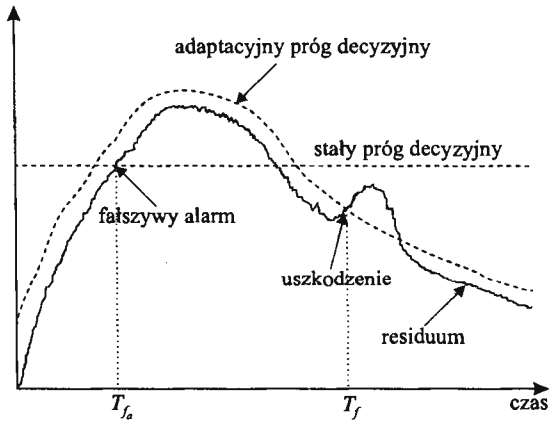

Rys. 6. Mechanizm stosowania adaptacyjnego progu decyzyjnego

sygnał residuum przekroczy wartość przyjętej wartości i będzie sygnalizowany fałszywy alarm. Z kolei w chwili T_f wystąpienia faktycznego uszkodzenia układ taki nie będzie aktywny i uszkodzenie nie zostanie wykryte. Obydwa te przypadki będą właściwie rozpoznawane przy zastosowaniu adaptacyjnego progu decyzyjnego, co powoduje zwiększenie odporności układu detekcji uszkodzeń.

3.1. Adaptacyjny próg decyzyjny z zastosowaniem modeli typu GMDH

Korzystając z wyznaczonego przedziału ufności dla wyjścia systemu (17), oraz definicji sygnału residuum (29), możemy wyznaczyć adaptacyjny próg decyzyjny w postaci przedziału ufności residuum [25, 34]:

$$\begin{aligned}&\tilde{y}^m(k)(\theta'^m(k),\theta''^m(k))-\tilde{y}(k)+\varepsilon^m(k)\le e_r(k)\\&\le\tilde{y}^M(k)(\theta'^M(k),\theta''^M(k))-\tilde{y}(k)+\varepsilon(k).\end{aligned} \tag{30}$$

Zasadę działania tak zdefiniowanego adaptacyjnego progu decyzyjnego ilustruje rys.7. Przekroczenie przez sygnał residuum w chwili T_f górnej wartości przedziału ufności interpretowane jest jako wystąpienie uszkodzenia.

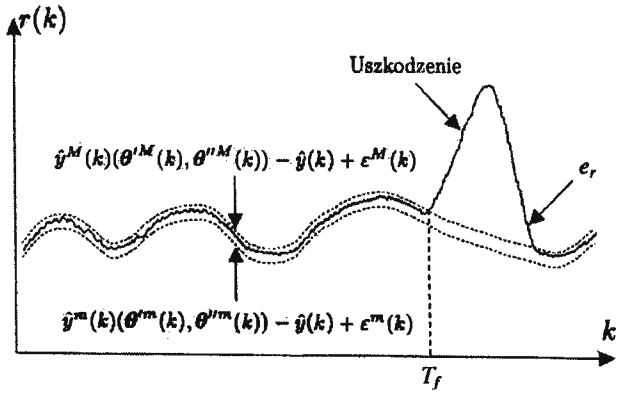

Rys. 7. Mechanizm stosowania adaptacyjnego progu decyzyjnego z uwzględnieniem niepewności modelu.

3.2. Adaptacyjny próg decyzyjny z zastosowaniem rozmytej sieci neuronowej

Postępując analogicznie, jak w przypadku sieci GMDH, adaptacyjny próg decyzyjny można wyznaczyć wykorzystując niepewność modelu rozmytej sieci neuronowej wyrażonej przez przedział ufności jej wyjścia (26). Uwzględniając definicję sygnału residuum (29) oraz przedział ufności (26), można wyznaczyć przedział ufności adaptacyjnego progu decyzyjnego w postaci:

$$\begin{aligned} x^T(k)\theta^{min}(k)+\varepsilon^{min}(k)-\tilde{y}(k)\le e_r(k) \\ \le x^T(k)\theta^{max}(k)+\varepsilon^{max}(k)-\tilde{y}(k). \end{aligned} \tag{31}$$

4. DETEKCJA USZKODZEŃ W SILNIKU ELEKTRYCZNYM

Zmieniające się warunki pracy silników prądu stałego i zmiennego oraz ich intensywna eksploatacja wywołują systematyczne zużycie poszczególnych elementów lub ich trwałe uszkodzenia. Obok tradycyjnych metod monitorowania działania takich silników przez eksperta, prowadzone są prace badawcze nad projektowaniem automatycznych układów diagnostycznych z wykorzystaniem metod obliczeń inteligentnych [11, 22].

Skuteczność metody odpornej detekcji uszkodzeń z zastosowaniem rozmytych sieci neuronowych, korzystając z podejścia adaptacyjnych progów decyzyjnych została pokazana w pracy [19] dla silnika prądu stałego przy zmiennym obciążeniu. Do badań wykorzystano stanowisko laboratoryjne firmy AMIRA znajdujące się w Laboratorium Komputerowych Systemów Sterowania (Instytut Sterowania i Systemów Informatycznych Uniwersytetu Zielonogórskiego).

Realizując układ diagnostyki silnika z modelem, na podstawie badań eksperymentalnych opracowano następujące modele cząstkowe rozmytych sieci typu Takagi-Sugeno [19]:

$$\begin{aligned} y_i(k)=a_1y_i(k-1)+b_1u(k-1) \\ +b_2u(k-2)+b_3u(k-3)+b_4u(k-4)+b_0, \end{aligned} \tag{32}$$

gdzie $y_i(k)$ jest odpowiedzią i-tego modelu cząstkowego, czyli prędkością obrotową silnika, a z kolei $u(k)$ – napięciem sterującym pracą silnika. Nieznane wartości parametrów a_1 oraz $b_0, b_1, ... b_4$ wyznaczono eksperymentalnie.

Zakładając, że błędy modeli cząstkowych nie mogą przekraczać wartości 0.04, wygenerowano 9 reguł, które były podstawą do zaprojektowania rozmytej sieci neuronowej. Dla sprawdzenia efektywności działania tak zaprojektowanego układu detekcji, zdefiniowano 7 potencjalnych uszkodzeń. Były to uszkodzenia prądnicy tachometrycznej służącej do pomiaru prędkości obrotowej silnika oraz uszkodzenia elementów mechanicznych silnika, charakteryzujących się zmniejszeniem wydajności jego pracy. Przyjęto, że uszkodzenia mogą być szybko i wolno narastające, a szybko narastające podzielono na małe, średnie oraz duże.

Na kolejnych rys. 8-10 pokazano przykładowe wyniki badań symulacyjnych pracy układu diagnostyki. Małe i nagłe uszkodzenie f_1 prądnicy tachometrycznej (rys. 8 i 9) zasymulowano w chwili $t_f = 90$, i jest ono obarczone losowymi zakłóceniami. W całym przedziale czasowym wyjście modelu rozmyto-neuronowego znajduje się w wyznaczonym przedziale ufności (rys. 8), a detekcja tego małego uszkodzenia nastąpiła w chwili $t_d = 105$ (rys. 9). Możliwość wykrywania wolno narastającego uszkodzenia f_2 została pokazana na rys. 10, gdzie uszkodzenie pojawiające się w chwili $t_f = 100$ zostało wykryte w chwili $t_d = 120$.

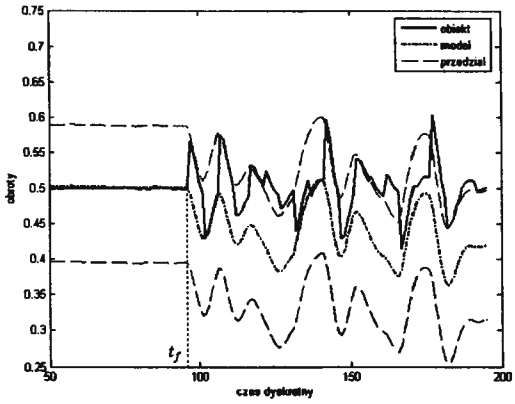

Rys. 8. Przedział ufności oraz wyjścia silnika i modelu: małe uszkodzenie f_1.

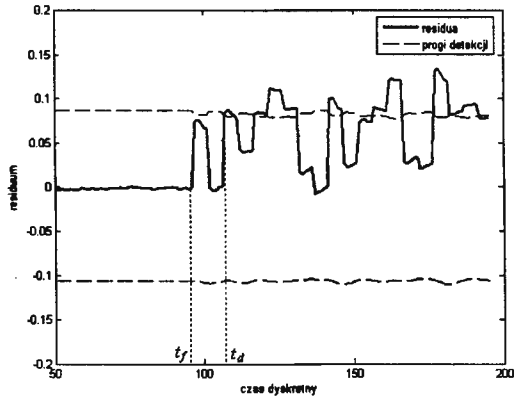

Rys. 9. Przedział ufności dla residuum: małe uszkodzenie f_1.

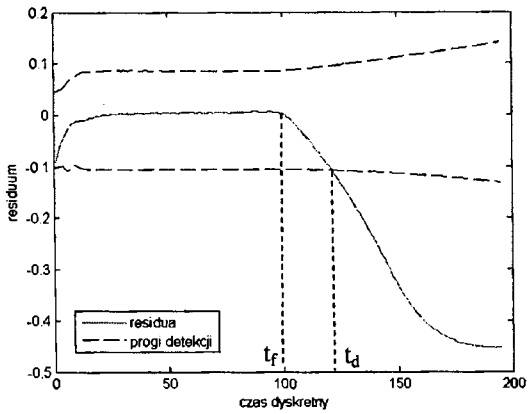

Rys. 10. Przedział ufności dla residuum: wolno narastające uszkodzenie f_2.

5. ZAKOŃCZENIE

W pracy zwrócono uwagę na ważny problem, jakim jest zastosowanie niepewnych modeli sztucznej inteligencji w układach diagnostyki. Pokazano, że korzystając z metody ograniczonych wartości błędów do estymacji nieznanych parametrów modeli neuronowych typu GMDH lub rozmyto-neronowych typu Takagi-Sugeno, można wyznaczyć przedziały ufności dla wyjść takich sieci. Dla tak określonych niepewnych modeli sztucznej inteligencji zaproponowano odporny układ diagnostyki, wyznaczając przedział ufności dla adaptacyjnego progu decyzyjnego. Należy zauważyć, że takie podejście zwiększa efektywność projektowanych układów, w sensie zmniejszenia liczby fałszywych alarmów spowodowanych zakłóceniami i błędami modelowania.

UNCERTAINTY OF ARTIFICIAL INTELLIGENCE MODELS IN FAULT DIAGNOSIS SYSTEMS

Abstract: This paper focuses on the problems of the uncertainty of some artificial intelligence models in fault diagnosis systems. In particular, modeling uncertainty of GMDH neural networks and Takagi-Sugeno neuro-fuzzy networks is considered. A bounded-error approach is used for parameters and model uncertainty estimation. It is shown that the defined output uncertainty for the networks considered can be used to develop a technique for generating an adaptive threshold that permits robust fault detection. In the final part, a robust fault diagnosis system for an electrical motor illustrates the application of neuro-fuzzy model uncertainty.

Literatura

[1] Basseville M., Nikiforov I.V. (1993) *Detection of Abrupt Changes. Theory and Application*. Prentice Hall, Englewood.

[2] Blanke M., Kinnaert M., Lunze J., Staroswiecki M. (2003) *Diagnosis and Fault-Tolerant Control*. Springer-Verlag, New York.

[3] Bubnicki Z. (2004) *Analysis and Decision Making in Uncertain Systems*. Springer-Verlag, London.

[4] Calado J.M.F., Korbicz J., Patan K., Patton R.J., Sá da Costa J.M.G. (2001) Soft computing approaches to fault diagnosis for dynamic systems. *European Journal of Control*, 7, (2–3), 248-286.

[5] Chen J., Patton R.J. (1999) *Robust Model-based Fault Diagnosis for Dynamic Systems*. Kluwer Academic Publishers, London.

[6] Czogała E., Łęski J. (2003) *Fuzzy and Neuro-Fuzzy Intelligent Systems*. Physica-Verlag, Heidelberg.

[7] Dabbenea F., Gayb P., Polyak B.T. (2003) Resursive algorithms for inner ellipsoidal approximation of convex polytopes. *Automatica*, **39**, (6), 1773-1781.

[8] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (Red.) (2000) *Biocybernetyka i inżynieria biomedyczna 2000. Sieci neuronowe*. Akademicka Oficyna Wydawnicza, EXIT, Warszawa, t. 6.

[9] Frank P.M., Marcu T. (2000) Diagnosis strategies and systems. Principles, fuzzy and neural approaches, in: *Intelligent Systems and Interfaces* (Teodorescu H.-N., Mlynek D., Kandel A. and Zimmermann H.-J., Eds.)). Boston, Kluwer.

[10] Frank P.M., Schreier G., Garcia E.A. (1999) Nonlinear observers for fault detection and isolation, in: *New Directions in Nonlinear Observer Design* (Nijmeijer H., Fossen T.I., Eds.) Springer-Verlag, Berlin.

[11] Gao X.Z., Oraska S.J. (2001) Soft computing methods in motor fault diagnosis. *Applied Soft Computing*, 1, 73-81.

[12] Gupta M.M., Jin L., Homma N. (2003) *Static and Dynamic Neural Networks*. John Wiley & Sons, Hoboken, New Jersey.

[13] Jang J.S.R., Sun C.T., Mizutani E. (1997) *Neuro-Fuzzy and Soft Computing*. Prentice-Hall, New Jersey.

[14] Korbicz J., Cempel C. (Eds.) (1993) Analytical and Knowledge-based Redundancy in Fault Detection and Diagnosis. *Appl. Math. & Comp. Sci.*, Spec. Issue, 3, (3).

[15] Korbicz J., Kościelny J.M., Kowalczuk Z., Cholewa W. (Eds.) (2004) *Fault Diagnosis. Models, Artificial Intelligence, Applications*. Springer-Verlag, Berlin Heidelberg.

[16] Korbicz J., Kościelny J.M., Kowalczuk Z., Cholewa W. (Red.) (2002) *Diagnostyka procesów. Modele, Metody sztucznej inteligencji, Zastosowania*. WNT, Warszawa.

[17] Korbicz J., Kowal M. (2001) Systemy neuronowo-rozmyte w diagnostyce procesów, w: *Zbiory rozmyte i ich zastosowania* (Chojcan J., Łęski J., Red.). Wydawnictwo Politechniki Śląskiej, Gliwice, 333–379.

[18] Korbicz J., Patan K., Obuchowicz K. (1999) Dynamic neural networks for process modelling in

fault detection and isolation systems. *Int. J. Appl. Math. and Compt. Sci.*, **9** (3), 519-546.

[19] Kowal M. (2004) *Optymalizacja struktur rozmytych sieci neuronowych w układach detekcji diagnostyki technicznej*. Uniwersytet Zielonogórski, Wydział Elektrotechniki, Informatyki i Telekomunikacji, Rozprawa doktorska..

[20] Kowal M., Korbicz J., Mendes M. J.G.C., Calado J.M.F. (2002) Fault detection using neuro-fuzzy networks. *Systems Science*, **28** (1), 45-57.

[21] Kuś J., Korbicz J., (2000) Statyczne i dynamiczne sieci GMDH, w: Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (Red) *Biocybernetyka i inżynieria biomedyczna 2000. Sieci neuronowe*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, **6**, 227-256.

[22] Liang B., Payne B.S., Ball A.D., Iwnicki S.D. (2002) Simulation and fault detection of three-phase induction motor. *Math. and Compt. in Simulation*, **40**, (12), 190-198.

[23] Marcu T., Mirea L., Frank P.M., (1999) Development of dynamic neural networks with application to observer-based fault detection and isolation. *Int. J. Appl. Math. and Compt. Sci.*, **9** (3), 547-570.

[24] Milanese M., Norton J., Piet-Lahanier H., Walter E. (Eds.) (1996) *Bounding Approaches to System Identification*. Plenum Press, New York.

[25] Mrugalski M. (2003) *Neuronowe modelowanie systemów nieliniowych w układach detekcji uszkodzeń*. Uniwersytet Zielonogórski, Wydział Elektrotechniki, Informatyki i Telekomunikacji, Rozprawa doktorska.

[26] Patton R.J., Frank P.M., Clark R.N. (Eds.) (2000) *Issues of Fault Diagnosis for Dynamic Systems*. Springer-Verlag, Berlin.

[27] Patton R.J., Korbicz J. (Eds.) (1999) Advances in computational intelligence for fault diagnosis systems. *Int. J. Appl. Math. and Compt. Sci.*, **9**, 3, Special issue.

[28] Patan K., Korbicz J., Mrugalski M. (2002) Sztuczne sieci neuronowe w układach diagnostyki, w: *Diagnostyka procesów. Modele, Metody sztucznej inteligencji, Zastosowania* (Korbicz J., Kościelny J.M., Kowalczuk Z., Cholewa W., red.), WNT, Warszawa, 311-352.

[29] Pham D.T., Xing L. (1995) *Neural Networks for Identification, Prediction and Control*. Springer-Verlag, London.

[30] Rutkowska D. (2000) *Neuro-fuzzy Architectures and Hybrid Learning*. Physica-Verlag, Heidelberg.

[31] Rutkowska D., Zadeh L. (Eds.) (2000) Neuro-fuzzy and soft computing. *Int. J. Appl. Math and Compt. Sci*, 10 (4), Special issue.

[32] Walter E., Pronzato L. (1997) *Identification of Parametric Models from Experimental Data*. Springer-Verlag, Berlin.

[33] Witczak M. (2003) *Identification and Fault Detection of Non-linear Dynamic Systems*. University of Zielona Góra Press, Zielona Góra.

[34] Witczak M., Korbicz J., (2004) Observers and genetic programming in the identification and fault diagnosis of non-linear dynamic systems, in: Korbicz J., Kościelny J.M., Kowalczuk Z., Cholewa W., (Eds.) *Fault Diagnosis. Models, Artificial Intelligence, Applications*. Springer-Verlag, Berlin, 457-510.

[35] Witczak M., Korbicz J., Mrugalski M., Patton R. (2005) A GMDH neural network-based approach to robust fault detection and its application to solve the DAMADICS benchmark problem. Control Engineering Practice (w druku).

[36] Witczak M., Obuchowicz A., Korbicz J. (2002) Genetic programming based approaches to identification and fault diagnosis of nonlinear dynamic systems. *Int. J. Control*, **75**(13), 1012-1031.

[37] Żółtowski B., Cempel Cz. (Red.) (2004) *Inżynieria diagnostyki maszyn*. Inst. Technologii Eksploatacji, PIB, Radom.

Instytut Badań Systemowych
Polskiej Akademii Nauk

ISBN 83-89475-00-6