


Józef KORBICZ, Marcin WITCZAK, Andrzej OBUCHOWICZ
 UNIwersYTET ZIELONOGÓRSKI
 INSTYTUT STEROWANIA I SYSTEMÓW INFORMATYCZNYCH

Obserwatory stanu i programowanie genetyczne w identyfikacji i diagnostyce systemów przemysłowych¹

Prof. dr hab. inż. Józef KORBICZ

Jest dyrektorem Instytutu Sterowania i Systemów Informatycznych Uniwersytetu Zielonogórskiego. Główne badania prowadzi w zakresie teorii sztucznej inteligencji (sztuczne sieci neuronowe, systemy rozmyte, algorytmy ewolucyjne, systemy eksper-
 towe), zastosowań metod obliczeń inteligentnych w układach diagnostyki procesów oraz teorii sterowania stochastycznych układów o parametrach rozłożonych. Jest kierownikiem projektu DAMADICS realizowanego w ramach 5 Programu Ramowego UE. Od 1993 roku jest redaktorem naczelnym międzynarodowego kwartalnika naukowego pt. *International Journal of Applied Mathematics and Computer Science*.



Dr inż. Marcin WITCZAK

Tytuł doktora nauk technicznych uzyskał w 2002 roku na Politechnice Wrocławskiej. Pracuje w Instytucie Sterowania i Systemów Informatycznych Uniwersytetu Zielonogórskiego na stanowisku adiunkta. Główny kierunek badań naukowych to identyfikacja, sterowanie i diagnostyka systemów zarówno liniowych jak i nieliniowych, ze szczególnym uwzględnieniem zastosowań przemysłowych.



Dr inż. Andrzej OBUCHOWICZ

Tytuł doktora w zakresie fizyki uzyskał w 1992 roku na Politechnice Wrocławskiej. Pracuje w Instytucie Sterowania i Systemów Informatycznych Uniwersytetu Zielonogórskiego na stanowisku adiunkta. Główny kierunek badań naukowych to algorytmy ewolucyjne, sieci neuronowe i ich zastosowania w modelowaniu i identyfikacji systemów nieliniowych.



Streszczenie

Tematem pracy jest problem projektowania układu detekcji uszkodzeń dla pewnej klasy systemów nieliniowych. Jednym z zadań jest zaprezentowanie wykorzystania programowania genetycznego do wyznaczania modeli systemów nieliniowych w przestrzeni stanów. Innym zadaniem jest zastosowanie zmodyfikowanej wersji, obserwatora o nieznanym wejściu do zaprojektowania deterministycznego obserwatora dla potrzeb generacji residuum. W końcowej części pracy przedstawione jest zastosowanie proponowanego rozwiązania do detekcji uszkodzeń zaworu stanowiącego jeden z elementów pierwszego stopnia stacji wyparnej cukrowni Lublin S.A.

Abstract

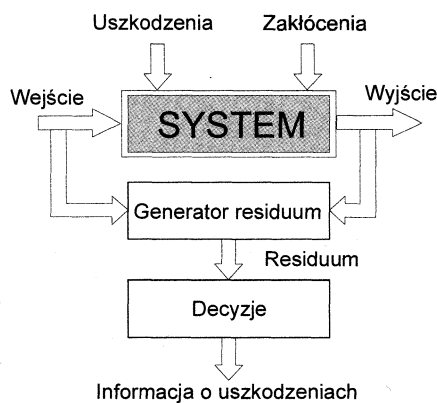
This paper is focused on the problem of designing a fault diagnosis scheme for a class of non-linear systems. The one objective is to show how to employ a genetic programming technique to obtain state-space models of non-linear systems. Another objective is to employ a modified version of the unknown input observer to form a non-linear deterministic

observer for the purpose of residual generation. The final part of the paper shows how to use the proposed approach to tackle fault detection concerning the valve actuator of the first stage of the evaporation station at the sugar factory Lublin S.A.

1. Wprowadzenie

Nieustanny wzrost złożoności współczesnych procesów przemysłowych, oczekiwań wobec ich efektywności i bezpieczeństwa pracy, czyni jednym z najistotniejszych kierunków rozwoju problem diagnostyki uszkodzeń w systemach dynamicznych. Jego zadaniem jest rozpoznawanie nieprawidłowości procesu, uszkodzeń komponentów instalacji technologicznej, czujników pomiarowych oraz urządzeń wykonawczych. Jedną z klas metod detekcji i lokalizacji uszkodzeń (*ang.* Fault Detection and Isolation, FDI) opiera się na identyfikacji systemu i generacji sygnału residuum (różnicy pomiędzy zachowaniem systemu a modelem), którego analiza pozwala na rozpoznanie uszkodzenia: jego zaistnienia, lokalizacji i rozmiarze (rys. 1).

¹ Praca została częściowo wykonana w ramach 5-go Programu Ramowego Unii Europejskiej RTN: projekt pt. Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems, DAMADICS (2000-2003r.) oraz projektu dofinansowanego przez KBN, nr 131/E-372/SPUB-M/5 PR UE/DZ 58/2001.



Rys. 1. Ogólny schemat układu diagnostycznego

Istnieje duża różnorodność rozwiązań zagadnienia diagnostyki systemów dynamicznych opartych na modelu obiektu, zarówno w sferze teoretycznej jak i aplikacyjnej (por. [3,8]). Najkorzystniejszym wydaje się być zastosowanie modeli fizycznych, tzn. bazujących na prawach fizyki rządzących zachowaniem się systemu, gdyż estymowane parametry modelu mają swoją fizyczną interpretację. Niestety stopień komplikacji większości systemów przemysłowych nie pozwala na zaprojektowanie wystarczająco dokładnego modelu fizycznego. W tym przypadku konieczne jest zastosowanie modeli odzwierciedlających jedynie zachowanie wejściowo-wyjściowe systemu. Szczególnie sztuczne sieci neuronowe są atrakcyjnym i bardzo popularnym narzędziem modelowania systemów nieliniowych [4,5,6,7]. Modele neuronowe niosą jedynie informację ilościową, podobnie jak modelowany system stanowią tzw. „czarną skrzynkę”. Alternatywnym podejściem jest zastosowanie techniki programowania genetycznego (*ang.* Genetic Programming, GP), w procesie którego można poszukiwać modelu wejściowo-wyjściowego systemu bądź jego reprezentacji przestrzenno-stanowej [10,11].

Niestety zastosowanie nieliniowego modelu nie oznacza całkowitego wyeliminowania niepewności modelu. Jednym ze sposobów rozwiązania takiego problemu jest zastosowanie rozszerzonego obserwatora o nieznanym wejściu (*ang.* Extended Unknown Input Observer, EUIO) zaproponowanego w pracy [11].

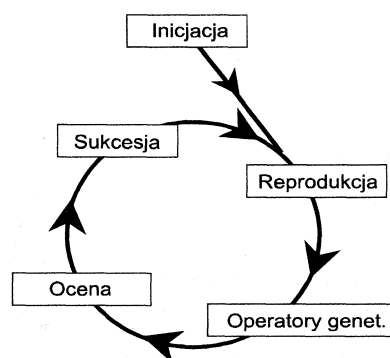
Dalsze punkty pracy zorganizowane są w następujący sposób. Algorytm programowania genetycznego omawia się w punkcie drugim. Kolejny punkt przedstawia zastosowanie GP do wyznaczania modeli systemów nieliniowych w przestrzeni stanów. Punkt czwarty opisuje metodologię projektowania rozszerzonego obserwatora o nieznanym wejściu. Natomiast punkt piąty przedstawia praktyczną aplikację rozważanych narzędzi w diagnostyce uszkodzeń wybranych elementów stacji wyparnej Cukrowni Lublin S.A. Punkt ostatni zawiera wnioski otrzymane na podstawie prowadzonych badań.

2. Programowanie genetyczne

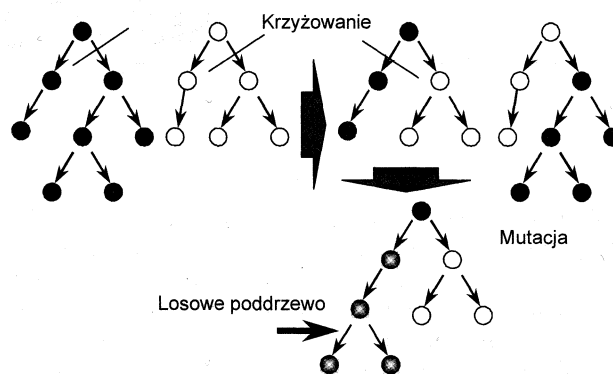
Algorytm programowania genetycznego należy do klasy algorytmów ewolucyjnych [1]. Oparty jest na procesie kolektywnego uczenia populacji punktów, zwanych osobnikami, przestrzeni przeszukiwań, zwanej środowiskiem bądź krajobrazem adaptacyjnym. Osobnika w GP reprezentuje drzewo o węzłach losowo wybranych z dwóch zbiorów: liście drzewa

dobierane są ze zbioru argumentów $T = \{t_i \mid i = 1, \dots, n_t\}$, pozostałe węzły ze zbioru operatorów $F = \{o_i \mid i = 1, \dots, n_o\}$. W zależności od definicji obu zbiorów T i F , osobnik może reprezentować funkcję matematyczną, zdanie logiczne, czy fragment kodu programu w zadanym języku programowania.

Proces ewolucyjny rozpoczyna losowy wybór n_m osobników populacji, następnie powtarzana jest sekwencja czterech operacji: reprodukcji, operacji genetycznych, oceny i sukcesji, dopóki nie spełnione zostanie zadane kryterium zatrzymania algorytmu (rys. 2). Stochastyczny operator reprodukcji, polega na wyborze z aktualnej populacji n osobników rodzicielskich, na podstawie których generowane będą nowe osobniki potomne. Osobniki rodzicielskie poddane są operatorom genetycznym mającym na celu wymieszanie informacji w nich zawartych (krzyżowanie) i wprowadzenie innowacji do tejsze informacji (mutacja) (rys. 3).



Rys. 2. Ogólny schemat algorytmu GP



Rys.3. Operatory genetyczne w GP

Tak otrzymane osobniki potomne poddane są ocenie, tzn. wyznacza się wartości optymalizowanego kryterium jakości, zwanym funkcją dopasowania. W wyniku sukcesji, spośród osobników potomnych, a w niektórych realizacjach również populacji pierwotnej, wybierana jest nowa populacja.

3. Przestrzenno-stanowa reprezentacja systemu

Rozważmy nieliniowy system dyskretny opisany równaniami stanu postaci:

$$\mathbf{x}_{k+1} = \mathbf{A}(\mathbf{x}_k) + \mathbf{h}(\mathbf{u}_k) + \mathbf{w}_k, \quad (4)$$

$$\mathbf{y}_{k+1} = \mathbf{C}\mathbf{x}_{k+1} + \mathbf{v}_{k+1}, \quad (5)$$

gdzie $\mathbf{x}_k \in \mathfrak{R}^n$ oznacza stan, a $\mathbf{y}_k \in \mathfrak{R}^m$ - wyjście systemu, $\mathbf{w}_k \in \mathfrak{R}^n$ i $\mathbf{v}_k \in \mathfrak{R}^m$ oznaczają odpowiednio szum procesu i pomiarów. Elementami macierzy diagonalnej $\mathbf{A}(\cdot)$ i wektora $\mathbf{h}(\cdot)$ są nieliniowe funkcje, odpowiednio stanu i wejścia. Model systemu (4)-(5) można przedstawić w następującej postaci:

$$\hat{\mathbf{x}}_{k+1} = \mathbf{A}(\hat{\mathbf{x}}_k) + \mathbf{h}(\mathbf{u}_k), \quad (6)$$

$$\hat{\mathbf{y}}_{k+1} = \mathbf{C}\hat{\mathbf{x}}_{k+1}, \quad (7)$$

gdzie $\hat{\mathbf{x}}_k$ oznacza estymatę stanu. W pracach [10,11] wykazano, że model (6)-(7) jest globalnie asymptotycznie stabilny, jeżeli $\max |a_{i,i}| < 1$, gdzie $a_{i,i}$ są elementami diagonalnymi macierzy $\mathbf{A}(\cdot)$. Warunek ten implikuje następującą strukturę elementów diagonalnych:

$$a_{i,i}(\hat{\mathbf{x}}_k) = \tanh(s_{i,i}(\hat{\mathbf{x}}_k)), \quad i = 1, \dots, n, \quad (8)$$

gdzie $\tanh(\cdot)$ oznacza funkcję tangens hiperboliczny, a $s_{i,i}(\cdot)$ jest pewną nieliniową funkcją, którą można wyznaczyć za pomocą GP. W rezultacie każdy element macierzy diagonalnej $\mathbf{A}(\cdot)$ i każdy element wektora $\mathbf{h}(\cdot)$ może być wyznaczony za pomocą populacji drzew, odpowiednio ewoluowanych przez algorytm GP. Szczegóły implementacyjne rozważanej techniki wyznaczania modeli przestrzenno-stanowych można znaleźć w pracach [10,11].

4. Projektowanie obserwatorów diagnostycznych

Rozważmy klasę systemów nieliniowych opisaną następującymi równaniami:

$$\mathbf{x}_{k+1} = \mathbf{g}(\mathbf{x}_k) + \mathbf{h}(\mathbf{u}_k + \mathbf{L}_{1,k}\mathbf{f}_k) + \mathbf{E}_k\mathbf{d}_k, \quad (9)$$

$$\mathbf{y}_{k+1} = \mathbf{C}_{k+1}\mathbf{x}_{k+1} + \mathbf{L}_{2,k+1}\mathbf{f}_{k+1}, \quad (10)$$

gdzie $\mathbf{g}(\cdot)$ jest funkcją różniczkowalną względem \mathbf{x}_k , \mathbf{f}_k oznacza wektor uszkodzeń, $\mathbf{f}_k = \mathbf{0}$ przy poprawnej pracy systemu, \mathbf{d}_k jest tzw. nieznanym wejściem mogącym reprezentować błędy modelowania, jak również rzeczywiste zakłócenia oddziałujące na rozważany system. $\mathbf{L}_{1,k}$, $\mathbf{L}_{2,k}$, \mathbf{E}_k są znanymi macierzami rozkładu uszkodzeń i nieznanego wejścia. Proponowana struktura rozszerzonego obserwatora o nieznanym wejściu przedstawia się następująco:

$$\hat{\mathbf{x}}_{k+1/k} = \mathbf{g}(\mathbf{x}_k) + \mathbf{h}(\mathbf{u}_k), \quad (11)$$

$$\hat{\mathbf{x}}_{k+1} = \hat{\mathbf{x}}_{k+1/k} + \mathbf{H}_{k+1}\boldsymbol{\varepsilon}_{k+1/k} + \mathbf{K}_{1,k+1}\boldsymbol{\varepsilon}_k, \quad (12)$$

gdzie $\boldsymbol{\varepsilon}_{k+1/k} = \mathbf{y}_{k+1} - \mathbf{C}_{k+1}\hat{\mathbf{x}}_{k+1/k}$, natomiast błąd wyjściowy (residuum) dany jest wzorem $\boldsymbol{\varepsilon}_k = \mathbf{y}_k - \hat{\mathbf{y}}_k$. Zadanie projektowania obserwatora sprowadza się do wyznaczania macierzy $\mathbf{K}_{1,k}$ tak aby zminimalizować różnicę pomiędzy $\hat{\mathbf{x}}_k$ a \mathbf{x}_k oraz \mathbf{H}_k w taki sposób, aby wyeliminować wpływ nieznanego wejścia na sygnał residuum. Tym samym uzyskuje się odporny generator residuum. Szczegóły implementacyjne dotyczące obserwatora (11)-(12) przedstawiono w pracach [10,11]. Głównym problemem związanym z zastosowaniem obserwatora (11)-(12) dla systemów klasy (9)-(10) jest fakt, że jest on przeznaczony dla systemów stochastycznych, tzn.

takich w których równania stanu i obserwacji zawierają szumy procesu \mathbf{w}_k i pomiarów \mathbf{v}_k o macierzach kowariancji \mathbf{Q}_k i \mathbf{R}_k . W przypadku systemów klasy (9)-(10) zakłada się, że szumy procesu i pomiarów nie występują. Oznacza to, że macierze instrumentalne \mathbf{Q}_k i \mathbf{R}_k powinny być macierzami zerowymi. Tego typu rozumowanie prowadzi do rozbieżności obserwatora i poważnych problemów obliczeniowych. Stosując podejście Lapunowa do analizy zbieżności EUIO [11] można dowiedzieć, że w celu otrzymania zbieżnego obserwatora, a jednocześnie zachowania dostatecznej szybkości zbieżności macierze instrumentalne powinny przyjąć postać:

$$\mathbf{Q}_k = \beta_1\boldsymbol{\varepsilon}_k^T\boldsymbol{\varepsilon}_k\mathbf{I} + \delta_1\mathbf{I}, \quad \mathbf{R}_k = \beta_2\boldsymbol{\varepsilon}_k^T\boldsymbol{\varepsilon}_k\mathbf{I} + \delta_2\mathbf{I}, \quad (11)$$

gdzie \mathbf{I} oznacza macierz jednostkową, β_1 , β_2 są odpowiednio dużymi, a δ_1 , δ_2 odpowiednio małymi stałymi nieujemnymi.

5. Przykład przemysłowy


Rozważanym urządzeniem przemysłowym jest zawór stanowiący fragment instalacji pierwszej sekcji stacji wyparnej Cukrowni Lublin S.A. (rys. 4).

Zawór taki można traktować jako system o czterech wejściach $\mathbf{u}_k = (CV, P1, P2, T1)$ i dwóch wyjściach $\mathbf{y}_k = (F, X)$, gdzie CV oznacza sygnał sterujący, $P1$, $P2$ są ciśnieniami na wejściu i wyjściu zaworu, $T1$ jest temperaturą soku, F jest przepływem soku na wyjściu zaworu, X oznacza przesunięcie rdzenia serwowatora. Dane pomiarowe dostępne są na stronie internetowej programu badawczego Unii Europejskiej DAMADICS [3].


W celu sprawdzenia efektywności i niezawodności układów detekcyjnych konieczne jest generowanie uszkodzeń. Oczywiście jest to bardzo trudne lub nawet niemożliwe w przypadku pracującego urządzenia przemysłowego. Dlatego też postanowiono skonstruować symulator zaworu z zastosowaniem rzeczywistych danych i środowiska MATLAB *Simulink*. Narzędzie to umożliwiło generowanie danych pomiarowych dla przypadku 19 różnych uszkodzeń, jak też dla poprawnej pracy zaworu. Pełen opis rozważanych uszkodzeń można znaleźć na stronie internetowej [3].

5.1. Wyznaczanie modelu zaworu

Naszym zadaniem jest wyznaczenie modelu zaworu z zastosowaniem podejścia opisanego w punkcie trzecim. Dla porównania, za pomocą przybornika *System Identification* programu MATLAB wyznaczono również modele liniowe w konfiguracji przestrzenno-stanowej. Jak wykazały badania związek pomiędzy wejściem \mathbf{u}_k a pierwszym z wyjść $y_{1,k}$ nie może być opisany za pomocą modelu liniowego. W tym przypadku błąd modelowania wyniósł aż 35%. Z drugiej strony, związek między wejściem a wyjściem drugim $y_{2,k}$ może być przybliżony za pomocą modelu liniowego. Pamięając o powyższych uwarunkowaniach, proces identyfikacji został podzielony na dwie części, tzn.: (1) wyznaczenie związku pomiędzy wejściem a $y_{2,k}$ za pomocą modelu liniowego, (2) wyznaczenie związku pomiędzy wejściem a $y_{1,k}$ za pomocą techniki z punktu trzeciego.



Rys.4. Pierwsza sekcja stacji wyparnej



Rys. 5. Wyjście systemu (przerywana) i modelu (ciągła)

Rezultaty eksperymentów wykazały, że w obu przypadkach najlepszy model był rzędu drugiego, co oznacza że rząd całego modelu jest równy $n=4$. Błąd średniokwadratowy dla otrzymanego modelu wyniósł 0.0079. Na podstawie dopasowania modelu do rzeczywistego systemu (rys. 5) można wywnioskować, że główna różnica między zachowaniem modelu, a systemu występuje podczas nasycenia zaworu. Tego typu niedokładność może być przyczyną powstawania błędnych decyzji diagnostycznych. Błędne decyzje diagnostyczne implikują zatrzymanie produkcji, co wiąże się z określonymi skutkami ekonomicznymi.

W celu zminimalizowania rozbieżności pomiędzy modelem, a rozważanym systemem przemysłowym zaprojektowano obserwator o nieznanym wejściu. W kolejnych podpunktach omawia się procedurę jego projektowania. Przechodząc od określenia niepewności modelu, interpretowanej jako sygnał nieznanego wejścia, poprzez generowanie odpowiednich poziomów granicznych dla celów detekcji uszkodzeń.

5.2. Detekcja uszkodzeń z obserwatorem

5.2.1 Estymacja nieznanego wejścia i dobór macierzy instrumentalnych

Wyznaczenie macierzy rozkładu nieznanego wejścia E_k (9) stanowi bardzo ważny etap podczas projektowania obserwatora EUIO. Bez jej znajomości nie jest możliwe zaprojektowanie obserwatora, a w konsekwencji otrzymanie odpornego generatora residuum.

W ogólnym przypadku nieliniowym problem estymacji nieznanego wejścia może być postrzegany jako zadanie optymalizacji bez ograniczeń:

$$\hat{\mathbf{d}}_k^* = \underset{\mathbf{d} \in \mathbb{R}^n}{\operatorname{argmin}} \mathbf{e}_{k+1}^T \boldsymbol{\varepsilon}_{k+1}. \quad (12)$$

Można wykazać, że rozwiązanie problemu (12) jest tożsame z rozwiązaniem układu równań liniowych:


$$\mathbf{C}_{k+1}^T \mathbf{C}_{k+1} \hat{\mathbf{d}}_k = \mathbf{C}_{k+1}^T \boldsymbol{\varepsilon}_{k+1/k}. \quad (13)$$

Należy jasno zaznaczyć, że rozwiązanie układu równań (13) w sposób analityczny możliwe jest jedynie, gdy macierz \mathbf{C}_k jest rzędu n . Taki warunek jest zazwyczaj niemożliwy do spełnienia w zastosowaniach praktycznych. Rozwiązanie przybliżone można otrzymać minimalizując normę różnicy lewej i prawej strony równania (13), np. za pomocą metod programowania nieliniowego [9].

Należy zaznaczyć, że nieznanne wejście, zgodnie z (12), otrzymuje się minimalizując błąd wyjściowy (residuum) ze względu na nieznanne wejście, a nie błąd estymacji stanu jak to ma miejsce w wielu publikacjach dotyczących systemów liniowych [8]. Upraszcza to, lub nawet czyni możliwym, estymację nieznanego wejścia. Jest tak dlatego, że błąd wyjściowy można bezpośrednio wyznaczyć na podstawie wyjścia systemu i modelu. Takie rozwiązanie jest w pełni uzasadnione w przypadku odpornych układów diagnostycznych, ponieważ w takich zastosowaniach konieczne jest jedynie wy-

eliminowanie wpływu nieznanego wejścia na residuum, a nie na błąd estymacji stanu.

Znając estymatę $\hat{\mathbf{d}}_k$ nieznanego wejścia \mathbf{d}_k , $k = 1, \dots, N$, zadanie wyznaczenia macierzy \mathbf{E}_k i \mathbf{H}_k staje się stosunkowo łatwe [11]. Znając macierz \mathbf{H}_k można określić wartości stałych definiujących macierze instrumentalne (11). Dla rozważanego przykładu dobrym rozwiązaniem jest: $\beta_1 = 10$, $\beta_2 = 10^3$ i $\delta_1 = \delta_2 = 0.01$. Przy tak dobranych parametrach obserwatora błąd średniokwadratowy został zredukowany z 0.0079 do 0.0022, co ilustruje rys. 6.



Rys. 6. Wyjście systemu (przerywana) i obserwatora (ciągła).

5.2.2. Detekcja uszkodzeń

W praktycznych aplikacjach, próżnym jest oczekiwanie, że sygnał residuum będzie przyjmował poziom bliski zeru podczas poprawnej pracy systemu. Jak pokazuje się w poprzednim punkcie, zastosowanie obserwatorów umożliwia redukcję wpływu tzw. nieznanego wejścia. Idealne wyeliminowanie wpływu czynników takich jak szумы, zakłócenia czy błędy modelowania na residuum nie jest raczej możliwe.


Efektom takiego stanu rzeczy było przeprowadzenie wielu badań w zakresie podniesienia odporności układów diagnostycznych na etapie podejmowania decyzji opierających się na analizowanym residuum [2,8]. Dobrze znanym z praktyki jest fakt, że ustawienie stałego poziomu granicznego dotyczącego sygnału residuum (którego przekroczenie określa wystąpienie uszkodzenia) nie jest najlepszym rozwiązaniem. Podobnie, zastosowanie metod statystycznych u których podstaw leży założenie o Gaussowskim charakterze niepewności modelu rzadko kiedy daje oczekiwane rezultaty. Dzieje się tak m.in. z powodu niemożliwości „pełnego” wyeliminowania wpływu nieznanego wejścia.

Bardziej efektywnym rozwiązaniem jest zastosowanie adaptacyjnego poziomu granicznego, tzn. poziomu granicznego, który zmienia się w czasie zgodnie z określonymi regułami.

W niniejszej pracy proponuje się bardzo proste rozwiązanie, u którego podstaw leży założenie, że czynnikiem regulującym zmiany poziomu granicznego jest sygnał wejściowy. Natomiast, sam poziom graniczny można zamodelować za

pomocą wielomianu stopnia n , oraz przedziałów ufności związanymi z jego parametrami [9]. Rysunek 7 przedstawia sygnał residuum i jego poziomy graniczne (zakładając 99% poziom ufności) dla rozważanego zaworu.

Wyznaczenie odpowiedniego poziomu granicznego umożliwia przeprowadzenie testów sprawdzających niezawodność proponowanego rozwiązania w kontekście detekcji uszkodzeń. Wyniki przeprowadzanych badań przedstawia Tab. 1.



Rys. 7. Residuum i jego poziomy graniczne.

Tab.1. Rezultaty detekcji uszkodzeń (W – wykrywalne, N – wykrywalne)

Rodzaj uszkodzenia	f_1	f_2	f_7	f_8	f_{10}	f_{11}	f_{12}
Małe	W		W	N	W		N
Średnie	W		W	N	W		N
Duże	W	W	W	N	W	W	W
Rodzaj uszkodzenia	f_{13}	f_{15}	f_{16}	f_{17}	f_{18}	f_{19}	
Małe	W		N		W	W	
Średnie	W		N		W	W	
Duże	W	W	W	W	W	W	

6. Podsumowanie

Jednym z zadań pracy było przedstawienie metodologii identyfikacji nieliniowych systemów dynamicznych. Do zrealizowania postawionego problemu wykorzystano relatywnie mało znaną technikę programowania genetycznego. Rozważano modele zarówno w konfiguracji wejściowo-wyjściowej, jak i w przestrzeni stanów. Szczególną uwagę poświęcono modelom opisanym w przestrzeni stanów, głównie ze względu na ich potencjalne wykorzystanie w układach detekcji uszkodzeń opierających się na obserwatorach stanu. Zaznaczono, że proponowany model przestrzenno-stanowy jest globalnie, asymptotycznie stabilny przy spełnieniu pewnych warunków.

Główną wadą proponowanego rozwiązania zadania identyfikacji jest koszt obliczeniowy przekładający się na stosunkowo długi czas konstruowania modelu. Należy jednak zaznaczyć, że procedura identyfikacji jest zazwyczaj wykonywana na etapie budowania systemu diagnostycznego a nie w

trakcie jego pracy, co znacząco zmniejsza znaczenie czasochłonności. Inną wadą jest to, że rząd dynamiki rozważanych modeli musi być wyznaczany metodą prób i błędów. Jakkolwiek jest to typowy problem dla wszystkich technik identyfikacji nieliniowych systemów dynamicznych.

Biorąc pod uwagę znaczącą popularność obserwatorów jako generatorów residuum zarówno w przypadku systemów liniowych jak i nieliniowych, opracowano rozszerzony obserwator o nieznanym wejściu. Główną zaletą prezentowanego obserwatora jest prostota procedury jego projektowania. W pracy zaznaczono również wpływ macierzy instrumentalnych na zbieżność i prędkość zbieżności, podając jednocześnie pewne wskazówki praktyczne odnośnie ich wyboru.

Innym czynnikiem przemawiającym za popularnością obserwatorów jest możliwość ich zastosowania w układach sterowania.

Istnieje oczywiście wiele różnych obserwatorów, które można zastosować w przypadku systemów nieliniowych, a w szczególności nieliniowych systemów deterministycznych. Logicznie myśląc liczba praktycznych wdrożeń obserwatorów stanu (nie tylko przykładów symulacyjnych) powinna stale rosnąć. Niestety, jak dotąd nie ma to miejsca. Wydaje się, że istnieją dwa powody dlaczego tak relatywnie sformalizowane metody nie znajdują zastosowania w praktyce inżynierskiej. Po pierwsze, złożoność implementacyjna istniejących rozwiązań nie zachęca inżynierów do stosowania ich w praktyce. Po drugie, zastosowanie obserwatorów stanu ograniczone jest znajomością nieliniowego modelu przestrzenno-stanowego rozważanego systemu, co jest zazwyczaj poważnym problemem w przypadku wielu złożonych systemów przemysłowych. Wyjaśnia to dlaczego większość przykładów prezentowanych w literaturze poświęcona jest systemom symulowanym bądź prostym systemom laboratoryjnym, np. układ dwóch, trzech lub nawet czterech zbiorników, odwrócone wahadło, itd. W tym miejscu autorzy chcieliby zaznaczyć, że powyższe uwarunkowania były głównym czynnikiem zachęcającym do opracowania metody wyznaczania modeli przestrzenno-stanowych z zastosowaniem programowania genetycznego.

Kolejnym celem pracy było przedstawienie przemysłowego zastosowania proponowanych rozwiązań w kontekście diagnostyki zaworu, stanowiącego fragment instalacji pierwszego stopnia stacji wyparnej Cukrowni Lublin S.A. Pokazano jak wyznaczyć model rozważanego urządzenia wykonawczego dysponując zbiorem danych pomiarowych. Na rozważanym przykładzie omówiono szczegółowo kolejne kroki projektowania rozszerzonego obserwatora o nieznanym wejściu. W szczególności pokazano jak określić sygnał nieznanego wejścia i w konsekwencji macierz jego rozkładu. Rozważano również konieczność wyznaczenia odpowiedniego poziomu granicznego residuum dla potrzeb detekcji uszkodzeń, proponując relatywnie proste i efektywne rozwiązanie problemu. Na przykładzie ze sztucznie generowanymi uszkodzeniami pokazano wysoką skuteczność proponowanego rozwiązania.

Autorzy mają nadzieję, że zaprezentowany przykład przemysłowy zachęci innych badaczy do testowania na nim różnego rodzaju rozwiązań diagnostyki technicznej. Pokazując w ten sposób praktyczne możliwości ich zastosowania,

zachęcające inżynierów pracujących w przemyśle do ich wdrażania.

Literatura

- [1] J. Arabas: Wykład z algorytmów ewolucyjnych. WNT. Warszawa. 2001.
- [2] J. Chen, R.J. Patton: Robust Model-based fault diagnosis for dynamic systems. Kluwer Academic Publishers. London. 1999.
- [3] Damadics: Strona internetowa programu badawczego Unii Europejskiej pt. *Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems*, DAMADICS (2000-2003). <http://diag.mchtr.pw.edu.pl/damadics/>
- [4] W. Duch, J. Korbicz, L. Rutkowski, R. Tadeusiewicz (Red.): Biocybernetyka i inżynieria biomedyczna. Sieci neuronowe. Akademicka Oficyna Wydawnicza Exit. Warszawa. 2000.
- [5] S.J. Farlow: Self-Organizing Methods in Modeling - GMDH Type Algorithms. Marcel Dekker, New York. 1984.
- [6] J. Hertz, R. Krogh, G. Palmer: Introduction to the neural computation. Addison-Wesley Publishing Company Inc. 1991.
- [7] J. Korbicz, K. Patan, A. Obuchowicz: Dynamic neural networks for process modelling in fault detection and isolation systems. Int. Jour. Appl. Math. and Comp. Sci. 1999, Vol.9, No.3.
- [8] R.J. Patton, P. Frank, R.N. Clark (Eds.): Issues of Fault Diagnosis for Dynamic Systems. Springer-Verlag. Berlin. 2000.
- [9] E. WALTER, L. PRONZATO: Identification of Parametric Models from Experimental Data. Springer. Berlin. 1997.
- [10] M. Witczak, J. Korbicz: Programowanie genetyczne diagnostyce uszkodzeń i identyfikacji nieliniowych systemów dynamicznych. W: J.Korbicz, J.M. Kościelny, Z. Kowalczyk, W. Cholewa (Edytorzy): Diagnostyka Procesów. Modele. Metody sztucznej inteligencji. Zastosowania. WNT. Warszawa. 2001.
- [11] M. Witczak, A. Obuchowicz, J. Korbicz: Genetic programming based approaches to identification and fault diagnosis of non-linear dynamic systems. Int. J. Control. 2002, Vol. 75, No. 13, pp. 1012-1031.

Artykuł recenzowany.