

**Zofia M. ŁABĘDA-GRUDZIAK**

INSTYTUT AUTOMATYKI I ROBOTYKI, POLITECHNIKA WARSZAWSKA  
ul. św. Andrzeja Boboli 8, 02-525 Warszawa

**Odporna detekcja uszkodzeń przy zastosowaniu addytywnego modelu regresji**

Mgr Zofia M. ŁABĘDA-GRUDZIAK

Absolwentka Wydziału Matematyki i Nauk Informatycznych Politechniki Warszawskiej. Doktorantka Instytutu Automatyki i Robotyki na Wydziale Mechatroniki Politechniki Warszawskiej. Zajmuje się diagnostyką procesów przemysłowych, szczególnie identyfikacją, symulacją oraz metodami odkrywania wiedzy z danych dla potrzeb detekcji uszkodzeń w złożonych instalacjach technologicznych.



e-mail: Z.Labeda@mchtr.pw.edu.pl

**Streszczenie**

W artykule przedstawiono wykorzystanie addytywnego modelu regresji oraz statystycznych technik eksploracji danych do konstrukcji układu detekcji uszkodzeń odpornej na zakłócenia i niepewność modelu, a następnie do oceny wrażliwości modelu na występowanie poszczególnych uszkodzeń. Do uzyskania właściwości odporności, niepewność otrzymanego modelu wyznaczana jest poprzez zastosowanie techniki modelowania błędów modelu addytywnego. Przedstawione rozwiązanie zostało przetestowane dla przykładowego zaworu regulacyjnego na podstawie danych laboratoryjnych próbkowanych na stanowisku regulacji poziomu wody w zbiorniku walczkowym.

**Słowa kluczowe:** detekcja uszkodzeń, model addytywny, niepewność modelu, modelowanie.

**Robust fault detection with application of the additive regression model****Abstract**

The detection of faults in engineering systems is of great practical significance. The detection performance of the diagnostic technique is characterized by important and quantifiable benchmarks, like the fault sensitivity and the reaction speed. Also its robustness, i.e., the ability of the technique to operate in the presence of noise, disturbances and modelling errors, is affected by the design of a detection algorithm. This paper develops a new approach to the design of robust fault detection systems via an additive model and knowledge discovery data. To achieve robustness, an uncertainty associated with the additive model is also taken into account. The model error modelling is used to deal with noise corrupting the data and unmodelled dynamics. The backfitting algorithm with nonparametric smoothing techniques has been used for estimation of the additive model. The modelling results as well as the fault detection procedures are presented. The proposed approach is tested on an example of a control valve for measurement tracks in the boiler laboratory setup in order to demonstrate the sensitivity of faults.

**Keywords:** fault detection, additive model, data mining, model uncertainty, modelling.

**1. Wprowadzenie**

Rozwój przemysłu obserwowany w ciągu ostatnich kilkudziesięciu lat spowodował zwiększenie złożoności układów automatyki sterujących procesami oraz zaostrzenie wymagań dotyczących ich niezawodności. Dlatego też nowoczesne systemy sterowania powinny być wyposażone w mechanizmy detekcji uszkodzeń. Wczesne wykrycie uszkodzeń umożliwia podjęcie odpowiednich działań zabezpieczających i naprawczych [1, 2].

Detekcja uszkodzeń może być prowadzona z zastosowaniem modeli obiektu lub bez wykorzystania modeli. Rozwój metod detekcji uszkodzeń z wykorzystaniem modelu procesu nierozdzielnie łączy się z rozwojem systemów komputerowych i inżynierii oprogramowania. Idea metody polega na zbudowaniu spójnego

modelu komputerowego obiektu, który pozwoli na generację residuów, które odzwierciedlają niezgodności pomiędzy stanem nominalnym, a stanami wadliwymi oraz ocenę wartości residuów polegającą na konwersji ilościowych sygnałów residuów na jakościowe sygnały diagnostyczne wraz z podejmowaniem decyzji o wykryciu symptomów uszkodzeń.

Do podstawowych grup modeli stosowanych w detekcji uszkodzeń można zaliczyć modele analityczne, w tym modele fizyczne, modele liniowe typu *wejście-wyjście*, liniowe równania stanu oraz obserwatory i filtry Kalmana [3, 4, 5], modele neuronowe i rozmyte [1, 6, 7] oraz ich kombinacje. Dla wielu obiektów opracowanie modelu na podstawie równań fizycznych jest bardzo trudne lub wręcz niemożliwe, a identyfikacja parametrów modelu dostarcza dodatkowych trudności. Ponadto zwiększenie liczby wejść procesu gwałtownie zwiększa nakłady obliczeniowe w modelowaniu neuronowym i liczbę reguł w modelowaniu rozmytym. Alternatywnym podejściem, które redukuje problemy wymiarowości jest zastosowanie modeli addytywnych [8, 9].

Schemat detekcji uszkodzeń z modelami obiektu opiera swoje działanie na wyidealizowanych założeniach, że model jest wierną repliką obiektu i idealnie reprezentuje jego dynamikę oraz, że szumy, zakłócenia występujące w systemie są znane. Założenia te nie mogą być ze względów oczywistych spełnione w praktyce. Odporność w kontekście detekcji uszkodzeń można zdefiniować jako maksymalizację wykrywalności uszkodzeń przy jednoczesnej minimalizacji niepożądanych efektów takich jak zakłócenia, szumy pomiarowe, zmiany w sygnałach wejściowych i stanach systemu [3]. W celu uzyskania właściwej odporności, w pracy wykorzystano mechanizm podejmowania decyzji o uszkodzeniach w oparciu o obwiednie obszaru niepewności otrzymane przy użyciu modelowania residuum, będącego estymatą błędów modelu podstawowego w stosunku do niezamodelowanej dynamiki obiektu czy szumów [10, 11].

**2. Addytywny model regresji**

Metoda identyfikacji i symulacji oparta na addytywnym modelu regresji jest nowym podejściem w diagnostyce procesów przemysłowych i została przedstawiona w pracach, opublikowanych w pozycjach [9,12,15] spisu literatury. Poniżej omówiono istotę metody w odniesieniu do przeprowadzonych badań.

Rozważając strukturę MISO (ang. *Multiple Input Single Output*), dla  $p > 1$  sygnałów wejściowych  $X_1, X_2, \dots, X_p$  oraz jednego sygnału wyjściowego  $Y$ , zdefiniujemy model addytywny (ang. *Additive Model*) w postaci [9]:

$$Y = a + \sum_{j=1}^p f_j(X_j) + \varepsilon, \quad (1)$$

gdzie  $a$  jest pewną stałą, błąd  $\varepsilon$  jest niezależny od  $(X_1, X_2, \dots, X_p)$ ,  $E(\varepsilon) = 0$  i  $Var(\varepsilon) = \sigma^2$  oraz  $\varphi_j$  są jednowymiarowymi mierzalnymi funkcjami zmiennej  $X_j$ , niekoniecznie liniowymi. Nie zakładamy monotoniczności funkcji  $\varphi_j$ , ani tym bardziej znajomości analitycznych postaci tych funkcji. Funkcje  $\varphi_j$  są szacowane na podstawie danych. Stąd modele prognozy mogą być nieliniowe względem sygnałów  $X_j$ , ale nadal są liniowe względem sygnałów  $\varphi_j(X_j)$ . Należy podkreślić, że nie jest przyjmowane założenie o niezależności sygnałów  $X_j$ . Stąd

użycie linii opóźniających sygnały  $X_j$  zapewnia dynamiczne własności modelu (1).

## 2.1. Dobór struktury modelu

Dokładność identyfikacji, a w konsekwencji poprawne działanie systemu diagnostycznego w dużym stopniu zależy od poprawnego wyboru struktury modelu. W przypadku modelu addytywnego, problem sprowadza się przede wszystkim do ustalenia wielkości charakteryzujących obiekt badań, wyboru struktury modelu oraz określenia rzędu modelu [12].

Ponieważ model procesu przemysłowego powinien jak najlepiej odwzorowywać przebieg rzeczywistych zmian stanu procesu, konieczne jest określenie zbioru sygnałów wejściowych i wyjściowego. Bardzo istotna jest w tym etapie postępowania wiedza *a priori* o procesie.

Ponadto większość procesów przemysłowych posiada właściwości dynamiczne, z tego powodu ważne jest aby modele uzyskiwane w wyniku identyfikacji odzwierciedlały ich dynamiczny charakter. Oprócz poprawnego odzwierciedlenia dynamiki procesu należy dążyć do zwiększenia odporności modelu (i tym samym zwiększenia odporności układu detekcji uszkodzeń) na wpływ impulsowych zakłóceń oddziałujących na sygnały pomiarowe. Zadanie to można zrealizować poprzez wprowadzenie dodatkowych wejść, na które podaje się opóźnione sygnały wejściowe:

$$Y_t = \varphi(X_{t-1}, \dots, X_{t-m_x}) \quad (2)$$

gdzie  $X_t = (X_{1,t}, \dots, X_{p,t})$ ,  $m_x$  reprezentuje liczbę opóźnień każdego sygnału  $X_{j,t}$  oraz funkcja  $\varphi$  jest wielowymiarową funkcją, która będzie przybliżana za pomocą modelu addytywnego. Model (2) jest rzędu  $p \cdot m_x$  i nazywany jest modelem o strukturze FIR rzędu  $m_x$  (ang. *Finite Impulse Response*). Dobranie odpowiedniej struktury modelu wiąże się z ustaleniem wartości rzędu modelu [12]. W wyborze wartości  $m_x$  należy kierować się zasadą oszczędności struktury modelu.

## 2.2. Uczenie modelu addytywnego

Ponieważ model procesu do poprawnego działania wymaga uprzedniego nauczania, to znaczy dostarczenia wiedzy o prawidłowym działaniu procesu, należy wybrać z bazy danych zbiór uczący, na podstawie którego dokonujemy identyfikacji modelu i zbiór testowy, na podstawie którego, oceniana jest jakość i zdolność predykcji oszacowanego modelu. Kryterium doboru danych uczących powinna być jak największa zmienność sygnałów wejściowych i wyjściowego, reprezentująca najbardziej skrajne stany.

Na podstawie wybranego zbioru uczącego można przystąpić do identyfikacji parametrów modelu (1). Intuicyjnie chcemy aby funkcje  $\varphi_j$  były dopasowywane jednocześnie, stąd potrzebujemy niekonwencjonalnych metod estymacji modelu addytywnego. W badaniach wykorzystano iteracyjny algorytm dopasowania wstecznego (ang. *Backfitting Algorithm*) [13].

Abi osiągnąć większą elastyczność, relacje  $\varphi_j$  między sygnałem wyjściowym a sygnałami wejściowymi są szacowane przez zastosowanie nieparametrycznych technik wygładzania, takich jak naturalne kubiczne funkcje sklepane (ang. *Natural Cubic Splines*) [14]. Metody te posiadają pojedyncze parametry wygładzające, które kontrolują "gładkość" estymatora funkcji regresji i zwykle ich wartości wybierane są poprzez optymalizację kryterium uogólnionej krosvalidacji (ang. *Generalized Cross-validation*) [14, 15].

## 2.3. Wskaźniki oceny modelu procesu

Model obiektu jest uproszczonym opisem rzeczywistości. Spowodowane jest to niedokładnością wyznaczenia parametrów modelu

oraz nieadekwatnością struktury modelu. Stąd dla oceny błędów modelowania można wyznaczyć wskaźniki jakości otrzymanego modelu, takie jak średni kwadrat błędów (MSE), średni moduł błędów (MADE), średni bezwzględny błąd procentowy względem zakresu wyjściowego sygnału pomiarowego (MAPE) oraz wariancję błędów (VAR):

$$\text{MSE} = \frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2 \quad (3)$$

$$\text{MADE} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (4)$$

$$\text{MAPE} = \frac{1}{N} \sum_{t=1}^N \frac{|y_t - \hat{y}_t|}{(y_{t,\max} - y_{t,\min})} \cdot 100\% \quad (5)$$

$$\text{VAR} = \frac{1}{N-1} \sum_{t=1}^N (y_t - \bar{y})^2 \quad (6)$$

gdzie  $y_t$  i  $\hat{y}_t$  oznacza odpowiednio wartość i estymowaną wartość zmiennej wyjściowej procesu w chwili  $t$ ,  $y_{t,\min}$  i  $y_{t,\max}$  oznaczają odpowiednio najmniejszą i największą wartość zmiennej wyjściowej procesu,  $\bar{y}$  oznacza średnią wartość estymowanej zmiennej wyjściowej procesu oraz  $N$  jest licznoscią próby.

## 3. Modelowanie niepewności modelu

Realizacji odpornego układu detekcji uszkodzeń dokonuje się za pomocą procedury odpornej identyfikacji. Idea prezentowanej metody polega na przeprowadzeniu procesu identyfikacji metodą błędu predykcji wykorzystującej addytywny model regresji, a następnie wykonanie dodatkowych działań mających na celu określenie niepewności związanej z uzyskanym modelem.

W technice modelowania błędów (ang. *Model Error Modelling*) wykorzystuje się sygnał residuum  $r_t$ , otrzymany jako różnicę między sygnałem zarejestrowanym w procesie  $y_t$ , pochodzącym z czujnika a odpowiednią zmienną  $\hat{y}_t$ , obliczoną analitycznie za pomocą przyjętego modelu addytywnego, na podstawie zmiennych procesowych  $x_1, \dots, x_p$ . Na podstawie otrzymanego residuum szacuje się niepewność modelu. W tym przypadku zakłada się, że niepewność jest miarą niezamodelowanej dynamiki procesu, szumów pomiarowych i wszelkiego rodzaju innych zakłóceń.

Procedurę formowania obwiedni niepewności w dziedzinie czasu, przeznaczonej do przeprowadzania działań diagnostycznych opisuje algorytm przedstawiony w pracach Patana [16] i Korbicza [11]. Poniżej przedstawiono wersję tej metody bazującą na addytywnym modelu regresji:

### i. Uformułuj zbiór danych

$$(r_t, x_t)_{t=1}^N$$

gdzie  $x_t = (x_{1,t}, \dots, x_{p,t})$  jest wektorem wartości sygnałów wejściowych wykorzystywanych w fazie identyfikacji addytywnego modelu procesu, residuum  $r_t = y_t - \hat{y}_t$ , gdzie  $y_t$  i  $\hat{y}_t$  są wyjściami odpowiednio procesu i addytywnego modelu procesu.

### ii. Przeprowadź procedurę modelowania modelu błędów, przy wykorzystaniu addytywnego modelu regresji:

$$r_t = b + \sum_{j=1}^p \xi_j(x_{jt}) + \tau_t \quad (*)$$

gdzie  $b$  jest pewną stałą, błąd  $\tau_i$  jest błędem modelowania residuum  $r_i$ , o  $E(r_i) = 0$  i  $Var(r_i) = \sigma^2$  oraz  $\xi_j$  są jednowymiarowymi funkcjami. Otrzymany model jest estymatą błędu modelu procesu w stosunku do niezamodelowanej dynamiki procesu czy szumów.

iii. Wyznacz środek obszaru niepewności jako

$$\hat{y}_i + \hat{r}_i,$$

gdzie  $\hat{r}_i$  jest odpowiedzią modelu błędu (\*).

iv. Zakładając, że odpowiedź modelu błędu (\*) jest zgodna z rozkładem normalnym (lub nieznacznie o niego odbiega) wyznacz dwa progi adaptacyjne, górny  $T_g$  i dolny  $T_d$ , określające obszar niepewności modelu procesu:

$$\begin{cases} T_g = \hat{y}_i + \hat{r}_i + u_\alpha \cdot \hat{\sigma}_{\hat{r}_i} \\ T_d = \hat{y}_i + \hat{r}_i - u_\alpha \cdot \hat{\sigma}_{\hat{r}_i} \end{cases}, \quad (7)$$

gdzie  $u_\alpha$  jest kwantylem rozkładu normalnego o zadanym poziomie ufności równym  $1 - \alpha$ ,  $\hat{\sigma}_{\hat{r}_i}$  jest nieobciążonym estymatorem odchylenia standardowego sygnału  $\hat{r}_i$ , wyznaczonym zgodnie z poniższym wzorem:

$$\hat{\sigma}_{\hat{r}_i} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N \left( \hat{r}_i - \frac{1}{N} \sum_{i=1}^N \hat{r}_i \right)^2}. \quad (8)$$

Należy zaznaczyć, że  $\hat{r}_i$  reprezentuje nie tylko sygnał residuum, ale także niepewność strukturalną czy zakłócenia. Z tego względu progi (7) będą dobrze określać obszar niepewności tylko wtedy, kiedy sygnał  $\hat{r}_i$  będzie posiadał rozkład prawdopodobieństwa zgodny z rozkładem normalnym.

Ponieważ środek obszaru niepewności  $\hat{y}_i + \hat{r}_i \approx y_i$  przybliży odpowiedź obiektu  $y_i$ , zadanie detekcji uszkodzeń sprowadza się do obserwowania wyjścia diagnozowanego procesu  $y_i$  względem obszaru niepewności. Dopóki  $y_i$  nie wykracza poza górny i dolny próg obszaru niepewności, proces pracuje prawidłowo i uszkodzenie nie będzie sygnalizowane.

#### 4. Wskaźniki jakości detekcji

W celu sprawdzenia jakości proponowanego algorytmu detekcji w badaniach wykorzystane zostaną następujące wskaźniki jakości diagnozowania [16]:

- czas detekcji:

$$t_{dt} = t_{fs} - t_f, \quad (9)$$

który jest czasem mierzonym od czasu rozpoczęcia symulowania uszkodzenia  $t_f$  do czasu wystąpienia jego symptomu  $t_{fs}$ ,

- stopień fałszywej detekcji:

$$\theta_{fd} = \frac{\sum_i t_{fd}^i}{t_f - t_{on}}, \quad (10)$$

gdzie  $t_{fd}^i$  oznacza czas trwania  $i$ -tego fałszywego alarmu,  $t_{on}$  jest początkiem symulacji. Jego wartość informuje o tym jak wiele wystąpiło fałszywych alarmów,

- stopień prawdziwej detekcji:

$$\theta_{td} = \frac{\sum_i t_{td}^i}{t_h - t_f}, \quad (11)$$

gdzie  $t_{td}^i$  oznacza czas trwania  $i$ -tej prawdziwej detekcji uszkodzenia,  $t_h$  jest czasem trwania symulacji.

### 5. Odporna detekcja uszkodzeń zaworu regulacyjnego

Skuteczność zaprezentowanego odpornego algorytmu detekcji przetestowano dla zaworu regulacyjnego na stanowisku regulacji poziomu wody w zbiorniku walczkowym, przy użyciu programu R-project [17] przeznaczonego do zaawansowanych obliczeń statystycznych. Urządzenie wykonawcze składa się z zaworu regulacyjnego, pneumatycznego serwowatora i ustawnika pozytywnego. Dokładny opis działania oraz schemat zespołu wraz z opomiarowaniem został przedstawiony w pozycji [9] spisu literatury.

#### 5.1. Modelowanie procesu

Biorąc pod uwagę strukturę urządzenia wykonawczego oraz wiedzę ekspertów na temat procesu technologicznego, został zaproponowany następujący model procesu przepływu wody przez zawór regulacyjny:

$$F = \varphi(CV, P1, P2), \quad (12)$$

gdzie  $\varphi$  jest nieznaną funkcją nieliniową oraz  $CV$  - sygnał sterujący położeniem zaworu (0-100[%]),  $P1$  - ciśnienie przed i za zaworem (0-400[Kpa]),  $P2$  - ciśnienie za zaworem (0-200[Kpa]),  $F$  - przepływ wody za zaworem (0-5 [ $m^3/h$ ]).

Wybór odpowiedniej struktury modelu został dokonany metodą prób i błędów, biorąc pod uwagę nie tylko jakość modelowania, ale także złożoność struktury modelu addytywnego. W rozważanym przypadku najlepiej wypadł model addytywny o strukturze FIR rzędu 2, postaci:

$$F_t = f_1(CV_{t-1}) + f_2(CV_{t-2}) + f_3(P1_{t-1}) + f_4(P1_{t-2}) + f_5(P2_{t-1}) + f_6(P2_{t-2}) + \varepsilon_t, \quad (13)$$

gdzie  $t = 3, \dots, N$ ,  $F_t := F_t - \hat{a}$  dla  $\hat{a} = \frac{1}{N} \sum_{t=1}^N F_t$  oraz  $\varepsilon_t$  są niezależnymi zakłóceniami losowymi. Na podstawie modelu (13) można wyznaczyć residua  $r_t = F_t - \hat{F}_t$ , które są w przybliżeniu próbkami błędów  $\varepsilon_t$ .

Identyfikacja modelu diagnozowanego obiektu została przeprowadzona z wykorzystaniem archiwalnych danych laboratoryjnych próbkowanych na stanowisku regulacji poziomu wody w zbiorniku walczkowym, sterowanym przez system Industrial IT. Aby dostępna baza danych była przydatna do celów eksploracji danych, dokonano wstępnej obróbki danych w formie ich czyszczenia i oraz identyfikacji punktów oddalonych [18]. Zbiór danych pomiarowych został podzielony na zbiór uczący i testowy. Kryterium doboru była jak największa zmienność sygnałów wejściowych i wyjściowych, reprezentująca najbardziej skrajne stany.

W celu estymacji modelu addytywnego, wybrano algorytm dopasowania wstecznego z naturalną kubiczną funkcją sklejaną z parametrem wygładzającym  $df=4$ , utożsamianym z liczbą stopni swobody [12]. Dla próby uczącej zweryfikowano z jakim błędem model (13) naśladuje zachowanie się rzeczywistego procesu, wyznaczając wartości miar dopasowania (3)-(6). Wyniki przedstawiono w tab. 1.


Tab. 1. Wskaźniki jakości dopasowania modelu addytywnego  
Tab. 1. Criteria of the additive model fitting quality

Próba ucząca			
MSE	MADE	MAPE	VAR
3e-04	0.099	0.32%	3e-4

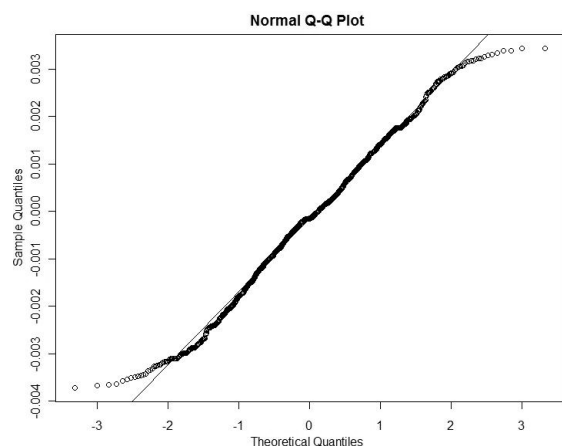
Jakość modelowania, w sensie średniego bezwzględnego błędu procentowego nie przekracza 0.4% zakresu zmienności sygnału wyjściowego.

## 5.2. Obszar niepewności

Mechanizm podejmowania decyzji o uszkodzeniach jest przeprowadzany za pomocą obwiedni obszaru niepewności, otrzymanych przy użyciu modelowania błędu modelu addytywnego. Przetestowano wiele struktur używając metody prób i błędów. Model addytywny o strukturze FIR rzędu 6 najlepiej odzwierciedlał dynamikę residuów  $r_t$ . Do określenia obszaru niepewności zastosowano poziom istotności równy 95% i wygenerowano dwa progi adaptacyjne (7). Wyjście modelu błędu oraz sygnał residuum przedstawia rys. 1.



Rys. 1. Residuum (kolor czarny) i wyjście modelu błędu (kolor szary) dla procesu w stanie zdatności  
Fig. 1. The residual signal (black) and output of the error model (grey) under nominal operating conditions



Rys. 2. Wykres kwantylowy dla rozkładu normalnego  
Fig. 2. The normal Q-Q plot for the residua


W celu sprawdzenia, czy wyjście modelu błędu posiada rozkład zgodny z rozkładem normalnym narysowano wykres kwantylowy, który przedstawiono na rys. 2. Są na nim porównane kwantyle rozkładu wyjścia modelu błędu z teoretycznymi kwantylami rozkładu normalnego. Ponieważ punkty na wykresie układają się wzdłuż linii prostej (z lekkimi ogonami) możemy wnioskować, że wyjście modelu błędu pochodzi z rozkładu normalnego.

## 5.3. Detekcja uszkodzeń

Do badania odpornego algorytmu detekcji wykorzystano próbę testową składającą się z danych pochodzących ze stanu zdatności  $f_0$  oraz ze sztucznie wprowadzonymi uszkodzeniami:


- $f_1$  i  $f_2$ : otwarcie drugiego zaworu regulacyjnego [10%]; 65 – 150[s] i 185 – 230[s],
- $f_3$  i  $f_4$ : otwarcie toru obejścia przepływomierza; 270 – 315[s] i 335 – 365[s],
- $f_5$ : przytkanie zaworu; 412 – 475[s],
- $f_6$ : Podanie przeciwności na komorę siłownika; 510 – 545[s].

Na rys. 3-6 przedstawiono wykresy wyjścia procesu wraz obszarami niepewności, gdzie progi adaptacyjne zaznaczono liniami przerywanymi.



Rys. 3. Obszar niepewności i wyjście procesu w warunkach nominalnych  $f_0$  i wystąpienia uszkodzeń  $f_1$  i  $f_2$

Fig. 3. Confidence bands and the system output under nominal operating conditions  $f_0$  and scenario of fault  $f_1$  and  $f_2$




Rys. 4. Obszar niepewności i wyjście procesu w warunkach nominalnych  $f_0$  i wystąpienia uszkodzeń  $f_3$  i  $f_4$

Fig. 4. Confidence bands and the system output under nominal operating conditions  $f_0$  and scenario of fault  $f_3$  and  $f_4$


Na podstawie otrzymanych wykresów można wyraźnie zaobserwować wrażliwość algorytmu detekcji na występowanie poszczególnych uszkodzeń. Przykładowo na rys. 3 widać, że po

kilku sekundach od rozpoczęcia symulacji uszkodzenia  $f_1$  wyjście procesu na stałe wykroczyło poza obszar niepewności i algorytm detekcji uszkodzeń zasygnalizował wystąpienie uszkodzenia. Podobnie jest w przypadku pozostałych uszkodzeń.



Rys. 5. Obszar niepewności i wyjście procesu w warunkach nominalnych  $f_0$  i wystąpienia uszkodzenia  $f_5$

Fig. 5. Confidence bands and the system output under nominal operating conditions  $f_0$  and scenario of fault  $f_5$



Rys. 6. Obszar niepewności i wyjście procesu w warunkach nominalnych  $f_0$  i wystąpienia uszkodzenia  $f_6$

Fig. 6. Confidence bands and the system output under nominal operating conditions  $f_0$  and scenario of fault  $f_6$

Wyniki wskaźników jakości detekcji (9)-(11) dla poszczególnych uszkodzeń zestawiono w tab. 2.

Tab. 2. Wskaźniki jakości detekcji  
Tab. 2. Criteria of the fault detection quality

Wskaźnik	Zasymulowane uszkodzenia					
	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
$\theta_{td}$	0.651	0.739	0.891	0.839	0.828	0.75
$t_{dt}$	5	5	4	5	3	5

Uzyskane wyniki wskaźników jakości detekcji są zadowalające i są zdecydowanie lepsze niż przy zastosowaniu algorytmu detekcji o stałych wartościach progowych (por. [9]). Najwyższą wartość wskaźnika prawdziwej detekcji zanotowano na poziomie 89.1% dla uszkodzenia  $f_3$ , zaś najwyższą wartość wskaźnika fałszywych alarmów zanotowano na poziomie 3.49%. Algorytm detekcji wykrywa uszkodzenia z opóźnieniem co najwyżej 5 sekund, stąd można twierdzić, że reakcja na wystąpienie poszczególnych uszkodzeń jest w miarę szybka.

## 6. Podsumowanie

W artykule zaprezentowano efektywne rozwiązanie umożliwiające identyfikację zarówno modelu procesu przepływu medium przez zawór regulacyjny, jak i jego niepewności za pomocą addytywnego modelu regresji. Podstawową zaletą modelu addytywnego jest możliwość uchwycenia trudno wyczuwalnych zależności oraz modelowanie procesów z nieliniowościami o trudnej do określenia postaci, dzięki zastosowaniu nieparametrycznego estymatora, będącego funkcją sklejaną.

W rozpatrywanej metodzie realizacji odpornego modelu kluczowym zagadnieniem jest wybór odpowiedniej struktury modelu błędu, co może być bardziej trudnym zadaniem niż modelowanie samego procesu. Wykorzystanie w tym celu addytywnego modelu regresji, który omija problemy wymiarowości umożliwiło opracowanie odpornego układu detekcji uszkodzeń.

Autor dziękuje Ministerstwu Nauki i Szkolnictwa Wyższego za sfinansowanie przedstawionych badań w ramach grantu promotorskiego KBN pt. "Zastosowanie addytywnego modelu regresji do generacji residuów dla potrzeb detekcji uszkodzeń", nr N N514 238337.

## 7. Literatura

- [1] Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W.: Fault Diagnosis. Models, artificial intelligence, application. Springer, 2004.
- [2] Kościelny J.M.: Diagnostyka procesów przemysłowych. EXIT, Warszawa, 2001.
- [3] Chen J., Patton R.: Robust model-based fault diagnosis for dynamic systems. Kluwer Academic Publishers, Boston, 1999.
- [4] Gertler J.: Fault Detection and Diagnosis in Engineering Systems. Marcel Dekker, Inc. New York - Basel - Hong Kong, 1998.
- [5] Isermann R.: Process fault detection based on modeling and estimation methods — a survey. Automatica, 20(4), 1994, 387–404.
- [6] Piegat A.: Modelowanie i sterowanie rozmyte, AOW EXIT, 1999, Warszawa.
- [7] Tadeusiewicz R.: Sieci neuronowe, Akademicka Oficyna Wydawnicza PLJ, 1995, Warszawa.
- [8] Hastie T., Tibshirani R.: Generalized additive models. Chapman and Hall, 1990.
- [9] Łabęda Z. M.: Additive model applications for the fault detection of actuators. Pomiary, Automatyka i Kontrola, 55(3), 2009, 152 - 155.
- [10] Reinelt W., Garulli A., Ljung L.: Comparing different approaches to model error modeling in robust identification. Automatica, 38, 2002, 787–803.
- [11] Korbicz J., Kościelny J. M.: Modelowanie, diagnostyka i sterowanie nadrzędne procesami. Implementacja w systemie DiaSter. WNT, Warszawa, 2009.
- [12] Łabęda-Grudziak, Z. M.: Dobór struktury modelu addytywnego dla potrzeb detekcji uszkodzeń obiektów dynamicznych. Zeszyty Naukowe WSInf, 9(3), 2010, 99–112.
- [13] Breiman L. i Friedman J. H.: Estimating optimal transformations for multiple regression and correlations (with discussion). Journal of the American Statistical Association 80(391), 1985, 580–619.
- [14] Buja A., Hastie T., Tibshirani R.: Linear smoothers and additive models (with discussion). The Annals of Statistics, 17(2), 1989, 453 - 510.
- [15] Łabęda-Grudziak Z. M.: Smoothing parameters selection in the additive regression models approach for the fault detection scheme. Pomiary, Automatyka i Kontrola, 55(3), 2011, 152 - 155.
- [16] Patan K., Korbicz J.: Fault detection in catalytic cracking converter by means of probability density approximation. Engineering Applications of Artificial Intelligence, 20, 2007, 912–923.
- [17] Good P.I.: Introduction to statistics through resampling methods and R/S-PLUS. Wiley, 2005.
- [18] Larose D.T.: Discovering Knowledge in Data: An Introduction to DATA MINING, Wiley, 2005.