

**Zofia Magdalena Łabęda-Grudziak**

Politechnika Warszawska, Instytut Automatyki I Robotyki

02-525 Warszawa, ul. św. Andrzeja Boboli 8

email: z.labeda@mchtr.pw.edu.pl

## **DOBÓR STRUKTURY MODELU ADDYTYW- NEGO DLA POTRZEB DETEKЦИИ USZKO- DZEŃ OBIEKTÓW DYNAMICZNYCH <sup>1</sup>**

**Streszczenie** – W artykule przedstawiono wykorzystanie addytywnego modelu regresji oraz statystycznych technik eksploracji danych do identyfikacji nieliniowych obiektów dynamicznych. W szczególności zaprezentowano metodę doboru struktury modelu addytywnego oraz metodę estymacji nieznanymi funkcjami predyktorów, będących parametrami tego modelu. Pozyskana wiedza posłużyła do konstrukcji algorytmów detekcji uszkodzeń, a następnie do oceny wrażliwości na występowanie poszczególnych uszkodzeń. Badania przeprowadzono dla zaworu regulacyjnego znajdującego się w pierwszym stopniu stacji wyparnej cukrowni "LUBLIN" S.A.

**Słowa kluczowe:** identyfikacja, detekcja uszkodzeń, obiekty dynamiczne, model addytywny, eksploracja danych.

### **1 Wstęp**

Rozwój przemysłu obserwowany w ciągu ostatnich kilkudziesięciu lat spowodował zwiększenie złożoności układów automatyki sterujących procesami oraz zaostrzenie wymagań dotyczących ich niezawodności. W instalacjach technologicznych w przemyśle energetycznym, chemicznym, hutniczym, spożywczym i wielu innych, pomimo stosowania elementów o dużej niezawodności, dochodzi jednak do uszkodzeń komponentów instalacji technologicznej, urządzeń pomiarowych i wykonawczych, a także występują błędy obsługi operatorskiej. Powodują one często znaczne i długotrwałe zakłócenia przebiegu procesu produkcyjnego, zmniejszające jego efektywność, pogarszając jakość produktu finalnego, a czasami prowadzą wręcz do zatrzymania procesu. Straty ekonomiczne w takich przypadkach są bardzo duże. Niektóre uszkodzenia prowadzą do stanów awaryjnych, np. zniszczenia instalacji technologicznej, skażenia środowiska naturalnego, a także mogą stanowić za-

---

<sup>1</sup> Praca została częściowo zrealizowana w ramach grantu promotorskiego KBN o numerze N N514 238337.

grożenie dla zdrowia i życia ludzi. Dlatego też, nowoczesne systemy sterowania powinny być wyposażone w mechanizmy detekcji uszkodzeń, czyli wykrywania nieprawidłowych stanów procesów oraz uszkodzeń urządzeń technologicznych, wykonawczych i pomiarowych [4,8,9].

Efektywna eksploatacja obiektów mechanicznych czy maszyn w procesach przemysłowych wymaga wiarygodnej informacji o ich stanie technicznym. Informacja ta jest często rozszerzona o predykcję zmiany ich stanu technicznego. Ma to szczególne znaczenie w przypadku maszyn o krytycznym znaczeniu w procesie, wymagających specjalnych skomputeryzowanych systemów wspomagających operatorów przy diagnozowaniu lub wypracowujące diagnozę w sposób automatyczny. W zautomatyzowanych procesach przemysłowych dostępne są zarówno bieżące dane pomiarowe, jak również wartości archiwizowanych zmiennych procesowych. To stwarza dogodną sytuację do budowy modeli obiektów w stanie pełnej zdadności na podstawie danych pomiarowych oraz wiedzy eksperta o powiązaniach między zmiennymi (strukturze modelu). Jednocześnie wraz z rozwojem technologii informatycznej pojawiły się nowe możliwości zwiększania ilości gromadzonych danych oraz szybkości ich przetwarzania. Dziedzina zajmująca się tym zagadnieniem stała się znana jako eksploracja danych (ang. *data mining*) [6,10]. Jej kluczowym zadaniem w zagadnieniach diagnostycznych, jest wydobycie z danych, użytecznych informacji, które szybciej i trafniej, pomogą podjąć decyzję o rozpoznaniu zmian stanu procesu w trakcie jego eksploatacji.

Dla obiektów złożonych coraz powszechniej stosowane są techniki sztucznej inteligencji, a wśród nich modele neuronowe i rozmyte. Jednakże w przypadku tych modeli pojawia się problem wymiarowości, gdyż zwiększenie liczby wejść procesu gwałtownie zwiększa nakłady obliczeniowe w modelowaniu neuronowym i liczbę reguł w modelowaniu rozmytym [8,9]. W pracy przedstawiono alternatywną technikę, która przezwycięża ograniczenia związane z nieliniowym modelowaniem wielowymiarowym, redukując wymiar zagadnienia. Są to modele addytywne (ang. *additive models*), oryginalnie zaproponowane w pracy Friedmana i Stuetzle'a [3] oraz spopularyzowane w pracy Hastiego i Tibshiraniego [7].

## 2 Model addytywny

Wielkości fizyczne wpływające na proces będziemy nazywać wejściami zaś mierzalne wielkości powstałe w wyniku działania procesu, wyjściami. 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 w postaci

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

błąd  $\varepsilon$  jest niezależny od  $(X_1, X_2, \dots, X_p)$ ,  $E(\varepsilon) = 0$ ,  $Var(\varepsilon) = \sigma^2$  oraz  $\varphi_j$  są jednowymiarowymi funkcjami zmiennej  $X_j$ , niekoniecznie liniowymi. Przykładowo  $\varphi_j$  mogą być pierwiastkami, logarytmami lub funkcjami trygonometrycznymi. Stąd modele prognozy mogą być nieliniowe względem sygnałów  $X_j$ , ale nadal są liniowe względem sygnałów  $\varphi_j(X_j)$ . Podkreślmy, że nie zakładamy, że sygnały  $X_j$  są niezależne [12], fakt ten wykorzystamy dalej. Wiążąc wielkości fizyczne w procesie oraz czas, model ten może posłużyć do opisu zachowania się procesu i może naśladować jego działanie [13,14].

Zauważmy, że bez poczynienia dodatkowego założenia, dotyczącego występowania stałych w modelu (1), stałe te nie będą mogły być wyznaczone w sposób jednoznaczny. Dzieje się tak, gdyż dodanie stałej w składniku jednej z funkcji i odjęcie jej w składniku drugiej nie zmienia modelu. Ażeby uniknąć powyższej niejednoznaczności nakłada się na funkcje  $\varphi_j(\cdot)$  warunek identyfikowalności

$$E(\varphi_j(X_j)) = 0, \quad (2)$$

co pociąga za sobą spełnienie warunku

$$E(Y) = \alpha. \quad (3)$$

Dla danych pomiarowych  $\{(x_i, y_i)\}_{i=1}^n$ , gdzie  $x_i = \{x_{ij}\}_{j=1}^p$ , warunki identyfikowalności (2)-(3) przyjmują postać

$$\frac{1}{n} \sum_{i=1}^n \hat{\varphi}_j(x_{ij}) = 0, \quad (4)$$

$$\hat{\alpha} = \frac{1}{n} \sum_{i=1}^n y_i. \quad (5)$$

Formalnie, zadanie wyznaczenia modelu addytywnego na podstawie danych pomiarowych, rejestrowanych w trakcie eksploatacji obiektu, możemy zapisać jako zadanie minimalizacji sumy kwadratów błędów

$$\arg \min_{\{\alpha, \varphi_j\}} \sum_{i=1}^n (y_i - \alpha - \sum_{j=1}^p \varphi_j(x_{ij}))^2, \quad (6)$$

które oznacza znalezienie stałej  $\alpha$ , równej  $\hat{\alpha}$  oraz  $p$  funkcji jednej zmiennej  $\hat{\varphi}_j(\cdot)$ . Estymatory funkcji  $\varphi_j$  są znajdowane przez zastosowanie ustalonych funkcji wygładzających. Funkcje wygładzające, którymi będziemy się posługiwać są liniowymi funkcjami wygładzającymi (ang. *linear smoother*), co oznacza, że dopasowanie w punktach  $x_{1j}, x_{2j}, \dots, x_{nj}$  może być zapisane w postaci liniowej funkcji punktów próby

$$\hat{\varphi}_j(x_{ij}) = \sum_{i=1}^n S_{il} y_l. \quad (7)$$

Wtedy dla  $\forall j = 1, \dots, p$  wektor wartości estymatora  $\hat{\varphi}_j = (\hat{\varphi}_j(x_{1j}), \dots, \hat{\varphi}_j(x_{nj}))^T$  może być zapisany jako  $\hat{\varphi}_j = \mathbf{S}_j \mathbf{y}$ , gdzie  $\mathbf{S}_j$  jest macierzą wygładzającą wymiaru  $n \times n$  (ang. *smoother matrix*) z elementami  $S_{il}$  będącymi pewnymi funkcjami punktów próby  $x_{kj}$  oraz wektor  $\mathbf{y} = (y_1, \dots, y_n)^T$ . Do najbardziej wykorzystywanych liniowych metod wygładzania należą m.in. wygładzanie lokalnie wielomianowe oraz wygładzanie za pomocą wielomianowej funkcji sklepanej.

Intuicyjnie chcemy aby funkcje  $\varphi_j$  były dopasowywane jednocześnie, stąd odpowiednie funkcje wygładzające w modelu addytywnym są znajdowane za pomocą iteracyjnego algorytmu dopasowania wstecznego (ang. *backfitting algorithm*) [7, 11]. Można udowodnić, że przy spełnieniu pewnych założeń, algorytm zbiega do jednoznacznego rozwiązania, startując z dowolnych wartości początkowych [1, 11].

### 3 Algorytm dopasowania wstecznego

Ustalmy rodzaj liniowego wygładzania, wtedy estymacja modelu addytywnego przebiega w następujących krokach:

- ♦ Wyznacz  $\hat{\alpha} = \frac{1}{n} \sum_{i=1}^n y_i$  oraz przyjmij początkowe estymatory

$$\hat{\varphi}_{j,j=1,\dots,p}^{(0)} \equiv 0.$$

- ♦ Dla  $j = 1, \dots, p$  oblicz:

$$\hat{\varphi}_j^{(m)} = \mathbf{S}_j (\mathbf{y} - \hat{\alpha} - \sum_{k \neq j} \hat{\varphi}_k^{(m-1)}) \quad (8)$$

- ♦ Powtarzaj krok (8) aż do spełnienia warunku:

$$\max_j \|\hat{\varphi}_j^{(m)} - \hat{\varphi}_j^{(m-1)}\| < \delta,$$

gdzie  $\delta$  jest ustaloną, małą liczbą a  $\|\cdot\|$  ustaloną normą w przestrzeni funkcyjnej.


Jest to algorytm, który polega na iteracyjnym dopasowywaniu funkcji kolejnych zmiennych objaśniających  $X_j$ . Tak, więc mając w danym kroku algorytmu obliczoną stałą  $\hat{\alpha}$  oraz aktualne funkcje przybliżające  $\hat{\varphi}_k(\cdot)$  dla  $k \neq j$ , znajdujemy estymator  $\hat{\varphi}_j$  funkcji  $\varphi_j$ , stosując do danych  $(x_{ij}, y_j - \hat{\alpha} - \sum_{k \neq j} \hat{\varphi}_k(x_{ik}))$  dowolny ustalony nieparametryczny estymator funkcji regresji (np. naturalną kubiczną funkcję sklejaną lub estymator lokalnie liniowy). Za estymatory początkowe wzięto funkcje tożsamościowo równe zero, ale można również wybrać liniowe estymatory regresyjne. Dodatkowo, aby spełnić warunek (4) po obliczeniu estymatora (8) powinniśmy dokonać jego modyfikacji obliczając

$$\hat{\varphi}_j^{(m)} = \hat{\varphi}_j^{(m)} - \sum_{i=1}^n \hat{\varphi}_j^{(m)}(x_{ij}). \quad (9)$$

Zamiast tego zastępujemy  $\mathbf{S}_j$  przez tzw. scentrowaną macierz wygładzającą  $\mathbf{S}_j := (\mathbf{I} - \mathbf{1}\mathbf{1}^T / n)\mathbf{S}_j$ , gdzie  $\mathbf{1} = (1, \dots, 1)^T$  oraz  $\mathbf{I}$  jest macierzą jednostkową. To zapewnia, że w każdym kroku procedury  $\hat{\varphi}_j$  ma średnią zero.

#### 4 Model addytywny w diagnostyce

Model addytywny jest matematycznym modelem obiektu dynamicznego, który w algorytmie diagnostycznym symuluje na podstawie sygnałów wejściowych sygnał wyjściowy. Przedmiotem analizy są residua  $r$ , czyli różnica między sygnałem zarejestrowanym w obiekcie  $y$ , pochodzącym z czujnika a odpowiednią zmienną  $y_m$  obliczoną analitycznie na podstawie przyjętego modelu. Schemat przedstawiający generowanie residuów za pomocą modelu addytywnego przedstawiono na rys. 1.



Rys. 1. Schemat generowania residuów z wykorzystaniem modelu addytywnego

Zadanie detekcji można podzielić na dwa etapy: generowanie residuów  $r$ , które są mało czułe na zakłócenia, bardzo czułe na uszkodzenia i zmierzają do zera, przy poprawnej pracy instalacji oraz zaprojektowanie reguły decyzyjnej, na podstawie której następuje ocena wartości residuów oraz podejmowana jest decyzja o wykryciu symptomu  $S$  uszkodzenia.

Mając więc dwa sygnały wyjściowe możemy porównać czy wartości zmiennej procesowej znacznie odbiegają od wartości tej samej zmiennej, estymowanej z modelu addytywnego. Dla większości prawidłowych stanów pracy obiektu, różnica powinna być bliska bądź równa zero, zaś tam gdzie mamy do czynienia z uszkodzeniami, różnica pomiędzy danymi sygnałami powinna w widoczny sposób zmieniać swoją wartość. Zakres zmian wartości residuum można znormalizować do przedziału  $[-1; 1]$ , poprzez podzielenie jego wartości przez zakres zmienności sygnału:

$$r := \frac{y - y_m}{y_{\max} - y_{\min}}, \quad (10)$$

gdzie  $y_{\max}$  i  $y_{\min}$  jest odpowiednio maksymalną i minimalną wartością zmiennej  $y$ . Takie przeskalowanie umożliwia lepszą interpretację uzyskanych wartości residuów.

Detekcja uszkodzeń ma na celu zauważenie powstania uszkodzenia w obiekcie i określenie chwili detekcji, poprzez automatyczną realizację testów diagnostycznych. Testy wykrywające uszkodzenia są to algorytmy podejmowania decyzji o wykryciu uszkodzenia na podstawie oceny wartości residuum. Zbiór testów powinien być tak dobrany, aby umożliwić wykrycie wszystkich możliwych uszkodzeń. Najprostszym algorytmem decyzyjnym jest porównanie wartości residuum z wartościami progowymi. Symptom uszkodzenia zostaje wykryty, jeśli sygnał diagno-

styczny  $s_1(r_i)$  przyjmuje wartość 1, to znaczy kiedy wartość  $K_1$  lub  $K_2$  została przekroczona przez  $i$ -te residuum:

$$s_1(r_i) = \begin{cases} 0 & \text{gdy } K_1 \leq r_i \leq K_2 \\ 1 & \text{gdy } r_i < K_1 \vee r_i > K_2 \end{cases} \quad (11)$$

Alternatywnie, w celu zwiększenia odporności detekcji uszkodzeń na wpływ impulsowych zakłóceń elektromagnetycznych oddziałujących na sygnały pomiarowe, decyzja o wykryciu uszkodzenia jest podejmowana na podstawie średniej wartości residuum w przesuwanym oknie zawierającym  $N$  ostatnich wartości residuum:

$$s_2(r_i) = \begin{cases} 0 & \text{gdy } \tilde{K}_1 \leq \tilde{r}_i \leq \tilde{K}_2 \\ 1 & \text{gdy } \tilde{r}_i < \tilde{K}_1 \vee \tilde{r}_i > \tilde{K}_2 \end{cases}, \quad (12)$$

gdzie

$$\tilde{r}_i = \frac{1}{N} \sum_{l=0}^{N-1} |r_{i,k+l}|. \quad (13)$$

Należy zauważyć, że wybór stałej  $N$  oraz stałej  $k$ , przesądza o tym w jaki sposób następować będzie wygładzanie trajektorii procesu. Dla ustalonego optymalnego  $N$ , należy dobrać odpowiednią wartość  $k < N$ , tak aby wrażliwość testu na uszkodzenia była możliwie największa.

Możliwość generacji fałszywych symptomów zależy również w dużym stopniu od wartości przyjętych ograniczeń za dopuszczalne wartości residuów i przedziału czasu, na podstawie którego podejmowana jest decyzja. Wartości progowe  $K_1$  i  $K_2$  są wyliczane z wykorzystaniem danych charakteryzujących przebieg wartości residuum w stanie normalnej eksploatacji w następujący sposób:

$$\begin{aligned} K_1 &= \min\{r_i\} - \gamma \cdot \hat{\sigma}\{r_i\} \\ K_2 &= \max\{r_i\} + \gamma \cdot \hat{\sigma}\{r_i\} \end{aligned} \quad (14)$$

gdzie  $\hat{\sigma}\{r_i\} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (r_i - \frac{1}{n} \sum_{i=1}^n r_i)^2}$  jest nieobciążonym estymatorem

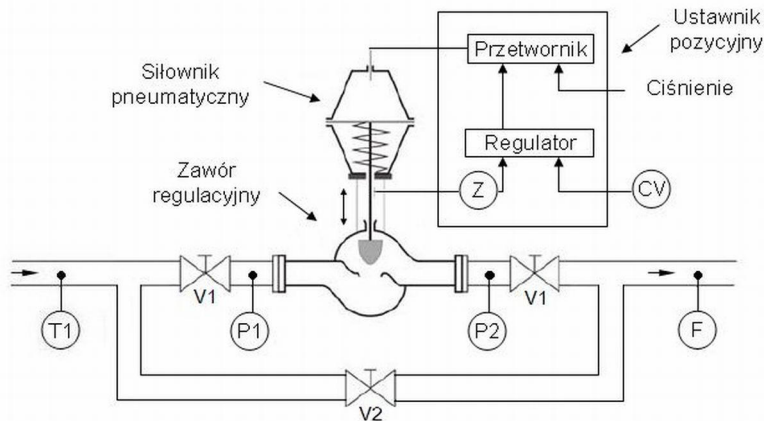
odchylenia standardowego próby residuów  $r_i$ , uwzględnianym ze względu na niepewność związaną z niedokładnością modelu procesu i skalowanym przez stałą  $\gamma$ , której wartość zwykle zwiększa się wraz ze

zwiększeniem rozproszenia danych. W przypadku testu (12) wartości progowe  $\tilde{K}_1$  i  $\tilde{K}_2$  są wyznaczane analogicznie jak wartości  $K_1$  i  $K_2$ , ale na podstawie średnich bezwzględnych wartości residuum w przesuwanym oknie (13).

## 5 Przykład

Skuteczność modeli addytywnych i eksploracyjnej analizy danych w zadaniach identyfikacji oraz detekcji uszkodzeń nieliniowych obiektów dynamicznych została zaprezentowana dla zaworu regulacyjnego znajdującego się w pierwszym stopniu stacji wyparnej cukrowni "LUBLIN" S.A., przy użyciu programu R-project [5] przeznaczonego do zaawansowanych obliczeń statystycznych.

Stacja wyparna składa się z kilku (4-7) aparatów wyparnych, przez które kolejno przepływa sok buraczany i jest kondensowany poprzez odparowanie z niego wody. Badane urządzenie wykonawcze składa się z zaworu regulacyjnego i pneumatycznego siłownika membranowo - sprężynowego z ustawnikiem pozycyjnym. Schemat zespołu przedstawiony jest na rys.2.



Rys. 2. Schemat zespołu wykonawczego wraz z opomiarowaniem

Model diagnozowanego obiektu został opracowany z wykorzystaniem danych archiwalnych z przebiegu kampanii cukrowniczej w 2001 roku [2]. Dane te zostały udostępnione w formie plików tekstowych, zawierających 33 sygnały rejestrowane co sekunda, co daje łącznie 86400 próbek. W ciągu całej kampanii zarejestrowano 25 plików tekstowych, co odpowiada 25 dniom pracy instalacji. Zbiór danych pomiarowych został podzielony na zbiór uczący i testowy. W celu uniknięcia obciążenia da-



nym trudnym do wychwycenia trendem wywołanym powolnymi zmianami procesu (np. osadami pojawiającymi się w rurociągach) wybrano dane uczące pochodzące z różnych okresów pierwszych 15 dni pracy instalacji (29.10.2001 - 12.11.2001), o łącznej liczbie 19000 próbek. Kryterium doboru była jak największa zmienność sygnałów wejściowych i wyjściowego, reprezentująca najbardziej skrajne stany. Eksploracyjna analiza danych wykazała istnienie 119 punktów odstających, a także istnienie w zbiorze z dnia 30.11.2001 brakujących danych oraz danych znajdujących się w formacie nieodpowiednim dla celów modelowania. Rekordy z brakującymi danymi pominięto podczas analizy. Ze względu na bardzo dużą liczbę dostępnych próbek, operacja ta nie doprowadziła do analizy obciążonego zbioru danych ani utraty informacji o zachowaniu się procesu.

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

$$F = \Phi(CV, P1, P2, T1), \quad (15)$$

gdzie  $\Phi(\cdot)$  jest nieznaną funkcją nieliniową. Wykaz zmiennych wykorzystanych podczas budowy modelu przedstawiono w tab. 1.

Tabela. 1. Zmienne użyte w modelowaniu

Symbol	Opis	Zakres
F	Przepływ wody za zaworem	0-500 [m <sup>3</sup> /h]
CV	Sygnał sterujący położeniem zaworu	0-100 [%]
P1	Ciśnienie przed zaworem	0-1000 [kPa]
P2	Ciśnienie za zaworem	0-1000 [kPa]
T1	Temperatura soku przed zaworem	50-150 °C

W celu prawidłowego odzwierciedlenia dynamiki obiektu oraz zwiększenia odporności detekcji uszkodzeń na wpływ impulsowych zakłóceń oddziałujących na sygnały pomiarowe, zastosowano model addytywny o strukturze FIR (ang. *finite impulse response filter*) rzędu 4, postaci

$$\begin{aligned}
 F_t = & \alpha + \varphi_1(CV_{t-1}) + \varphi_2(CV_{t-2}) + \varphi_3(CV_{t-3}) + \varphi_4(CV_{t-4}) \\
 & + \varphi_5(P1_{t-1}) + \varphi_6(P1_{t-2}) + \varphi_7(P1_{t-3}) + \varphi_8(P1_{t-4}) \\
 & + \varphi_9(P2_{t-1}) + \varphi_{10}(P2_{t-2}) + \varphi_{11}(P2_{t-3}) + \varphi_{12}(P2_{t-4}) \\
 & + \varphi_{13}(T1_{t-1}) + \varphi_{14}(T1_{t-2}) + \varphi_{15}(T1_{t-3}) + \varphi_{16}(T1_{t-4}) + \varepsilon_t,
 \end{aligned} \quad (16)$$

gdzie  $t = 5, \dots, n$ ,  $F_t = F_t - \alpha$ ,  $\varphi_1, \dots, \varphi_{16}$  są jednowymiarowymi funkcjami opóźnionych poszczególnych sygnałów oraz  $\varepsilon_t$  są niezależnymi zakłóceniami losowymi. Zwiększenie rzędu filtru nie skutkowało znaczną poprawą wyników modelowania w stosunku do wzrostu złożoności modelu. Na podstawie modelu (16) można wyznaczyć residua

$$r_t = F_t - \hat{F}_t, \quad (17)$$

które są przybliżeniem błędów  $\varepsilon_t$ .

### **Wyniki modelowania**

Dla danych uczących, pochodzących ze stanu zdatności procesu, otrzymano estymowane wartości przepływu medium (predykcja F) wraz z rzeczywistymi wartościami przepływu medium danymi z procesu (F), a następnie zweryfikowano z jakim błędem model naśladuje zachowanie się rzeczywistego procesu. Jakość modelowania, w sensie średniego bezwzględnego błędu procentowego [6,10], nie przekracza 1.6% zakresu zmienności sygnału wyjściowego. Na podstawie analizy residuów jako granice dopuszczalnych odchyłek od stanu zdatności procesu wybrano stałe  $K_1 = -0.133$  i  $K_2 = 0.153$  dla testu 1 (11) oraz  $\tilde{K}_1 = -4.16$  i  $\tilde{K}_2 = 9.76$  dla testu 2 (12), przyjmując współczynnik  $\gamma = 3$  oraz  $k=80$  i  $N=100$ .

### **Wskaźniki jakości detekcji**

Do badania algorytmów detekcyjnych, bazujących na otrzymanym modelu, wykorzystano próbę testową składającą się z danych pomiarowych z 3 dni kampanii, pochodzących zarówno ze stanu zdatności  $f_0$ , jak i ze sztucznie wprowadzonymi uszkodzeniami, których opis przedstawiono w tab. 2.

Tabela. 2. Zasymlowane uszkodzenia

Nr	Oznaczenie	Opis
1	$f_1$	Otwarcie zaworu obejścia przepływomierza
2	$f_2$	spadek ciśnienia zasilającego pozycjoner
3	$f_3$	uszkodzenie toru pomiarowego ciśnienia P2

Należy zauważyć, że  $f_3$  jest to uszkodzenie zewnętrzne, nie związane bezpośrednio z urządzeniem wykonawczym. Dokładny czas symulacji uszkodzeń został przedstawiony w tab. 3.

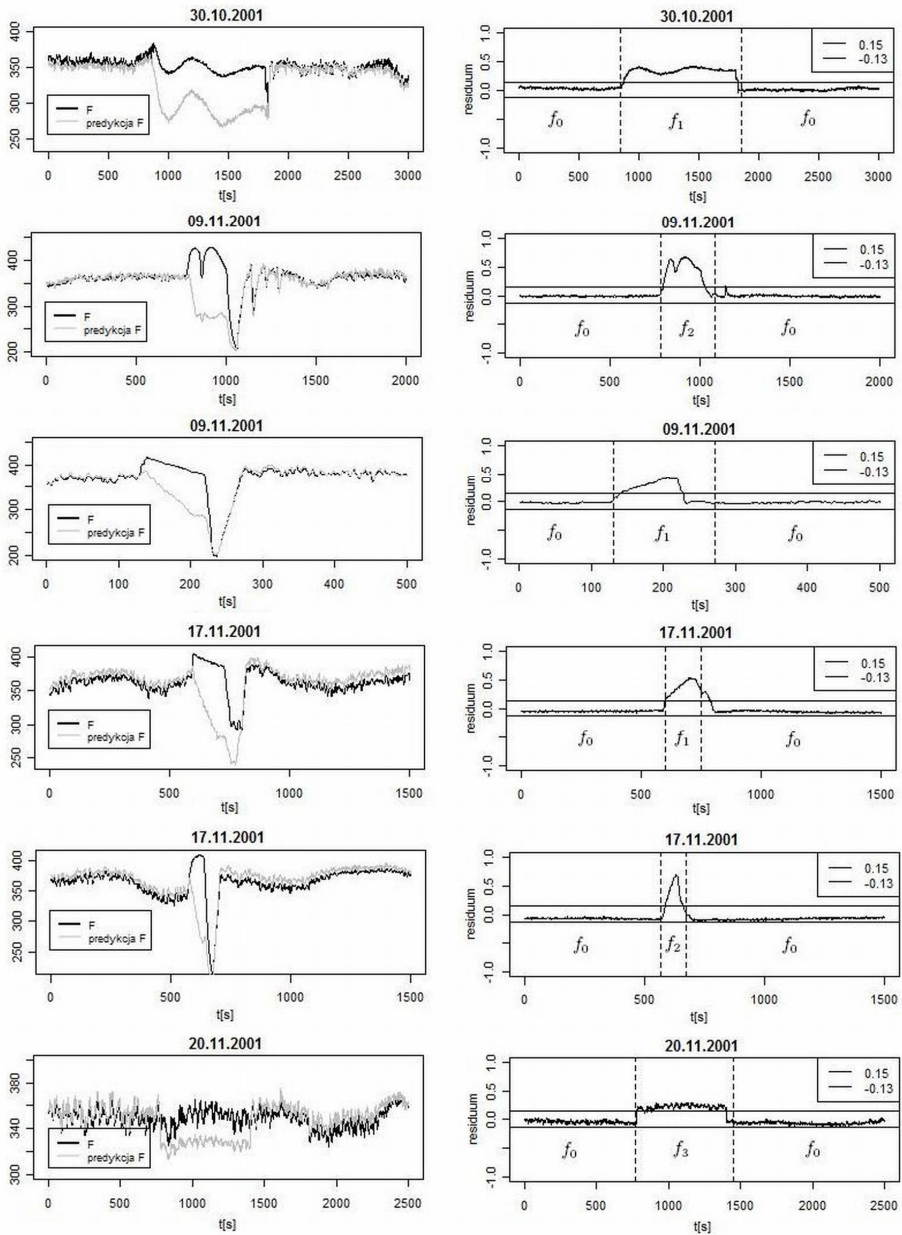
Tabela. 3. Czas symulacji uszkodzeń

Uszkodzenie	Próbki	Dzień kampanii
$f_1$	850-1850	30.10.2001
$f_1$	130-271	9.11.2001
$f_1$	600-750	17.11.2001
$f_2$	780-1080	9.11.2001
$f_2$	570-671	17.11.2001
$f_3$	770-1450	20.11.2001

Szczegółowe wykresy scenariuszy symulujących odpowiednio nominalne warunki pracy  $f_0$  i poszczególne uszkodzenia  $f_1$ ,  $f_2$ ,  $f_3$  zasy-mulowane w poszczególnych dniach kampanii oraz odpowiadających im wartości residuów zostały przedstawione na rys. 3.

Na podstawie poniższych przebiegów sygnałów podczas symulacji na danych z poszczególnymi uszkodzeniami można jednoznacznie zaobserwować zaistniałe symptomy i ich brak w przypadku próby zdatności. W chwili wystąpienia uszkodzenia wartości residuów zaczynają odbiegać wyraźnie od zera. Po przekroczeniu ustalonych wartości progowych przez residua, następuje detekcja uszkodzenia. Po ustąpieniu uszkodzenia wartości residuów ponownie zaczynają wahać się w okolicach wartości zerowych. Dlatego też, w takim przypadku, rozbieżności pomiędzy sygnałami procesowym i modelowanym należy uznać za wynikającą ze sztucznie wprowadzonych uszkodzeń a nie z błędu modelowania.

Potwierdzają to wyniki wskaźników jakości dopasowania modelu addytywnego i zastosowanych algorytmów detekcyjnych dla prób z wyodrębnionymi uszkodzeniami  $f_1$ ,  $f_2$ ,  $f_3$ , w zależności od dnia kampanii, przedstawione w tab. 4. Spośród 3 możliwych uszkodzeń zaprojektowany system detekcyjny (test 1 (11) i test 2 (12)) był w stanie wykryć (na poziomie 8% dopuszczalnych odchyłek od stanu zdatności) wszystkie uszkodzenia, jednocześnie nie wykrywając istotnych nieprawidłowości w próbach pochodzących ze stanu zdatności.



Rys. 3. Przebiegi sygnałów pomierzonego i modelowanego oraz residuum dla prób zawierających poszczególne uszkodzenia w zależności od dnia kampanii

Tabela. 4. Wyniki testów diagnostycznych dla prób testowych z zasymulowanymi uszkodzeniami

Próba testowa	Test 1	Test 2
$f_1$ , 30.10.2001	92.7 %	100 %
$f_1$ , 9.11.2001	85.1 %	99.1 %
$f_1$ , 17.11.2001	56.9 %	100 %
$f_2$ , 9.11.2001	100 %	100 %
$f_2$ , 17.11.2001	77.2 %	99.2 %
$f_3$ , 20.11.2001	99.5 %	99 %

## 6 Podsumowanie

Dokładność identyfikacji, a w konsekwencji poprawne działanie systemu diagnostycznego w dużym stopniu zależy od poprawnego wyboru struktury modelu i tym samym jest jednym z ważniejszych problemów związanych z modelowaniem nieliniowych systemów dynamicznych. W pracy zaprezentowano efektywne rozwiązanie umożliwiające modelowanie i przewidywanie stanu procesu przepływu medium przez zawór regulacyjny dla potrzeb detekcji uszkodzeń. Jest to nowe podejście w diagnostyce procesów przemysłowych, które omija problemy wymiarowości, redukując oryginalny wymiar zagadnienia. Podstawową zaletą modelu addytywnego jest możliwość uchwycenia trudno wyczuwalnych zależności oraz modelowanie procesów z nieliniowościami o trudnej do określenia postaci, dzięki zastosowaniu nieparametrycznego estymatora.

Ponadto zastosowany algorytm estymacji modelu jest zbieżny do jednoznacznej odpowiedzi i nie wymaga dużych nakładów obliczeniowych. Szczególnie ważny, z praktycznego punktu widzenia jest fakt, że doboru struktury modelu addytywnego dokonuje się na podstawie danych uczących jeszcze przed estymacją jego parametrów oraz, że aplikowane metody nie wymagają konieczności stosowania w fazie uczenia danych z rzeczywistymi uszkodzeniami, stanowi to szczególną przewagę prezentowanej metody w stosunku do tych, które takich właściwości nie mają. Zaprezentowana metoda nie nakłada żadnych ograniczeń na strukturę modelu addytywnego, dlatego też może być stosowana w przypadku dowolnych modeli dynamicznych. Otrzymane wyniki są zadowalające, gdyż zaprezentowane metody pozwoliły na wykrycie wszystkich zasymulowanych uszkodzeń.

---

**Literatura**

- [1] Ansley C.F, Kohn R., Convergence of the backfitting algorithm for additive models, *Journal of the Australian Mathematical Society* (Series A), Vol.57, pp. 316-329, 1994.
- [2] DAMADICS: Strona internetowa RTN DAMADICS: Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems, <http://diag.mchtr.pw.edu.pl/damadics>.
- [3] Friedman J.H., Stuetzle W., Projection pursuit regression, *Journal of the American Statistical Association*, 76, 1981, pp.817-823.
- [4] Gertler J., *Fault Detection and Diagnosis in Engineering Systems*, Marcel Dekker, Inc. New York - Basel - Hong Kong, 1998.
- [5] Good P.I., *Introduction to statistics through resampling methods and R/S-PLUS*, Wiley, 2005.
- [6] Hand D., Mannila H., Smyth P., *Principles of Data Mining*.
- [7] Hastie T., Tibshirani R., *Generalized additive models*, Chapman and Hall, 1990.
- [8] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W.(red), *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002.
- [9] Kościelny J.M., *Diagnostyka procesów przemysłowych*, EXIT, Warszawa 2001.
- [10] Larose D.T., *Discovering Knowledge in Data: An Introduction to DATA MINING*. Wiley, 2005.
- [11] Łabęda Z.M., *Wykorzystanie addytywnego modelu regresji w eksploracyjnej analizie danych*, VI Sympozjum Modelowanie i Symulacja Komputerowa w Technice, Łódź 2008.
- [12] Łabęda Z.M., *Identyfikacja procesu autoregresyjnego AR(p) oraz procesu z warunkową autoregresyjną heteroskedastycznością ARCH(p) przy użyciu modelu addytywnego*, III Konferencja Naukowo-Techniczna Doktorantów i Młodych Naukowców, Warszawa, 2008.
- [13] Łabęda Z.M., *Zastosowanie modelu addytywnego dla potrzeb detekcji uszkodzeń zaworów regulacyjnych*, III Konferencja Naukowo-Techniczna Doktorantów i Młodych Naukowców, Warszawa, 2008.
- [14] Łabęda Z.M., Additive model applications for the fault detection of actuators, *Pomiary, Automatyka i Kontrola*, Vol.55, pp. 152-155, (3)2009.

## ADDITIVE MODEL STRUCTURE SELECTION FOR THE FAULT DETECTION IN DYNAMIC SYSTEMS

Summary – this paper presents a nonlinear dynamic systems identification method based on additive regression models with knowledge discovery data. In particular, the model order and input delay choices, and iterative algorithm are proposed in an attempt to estimate additive models structure. The final part of this work contains an illustrative example regarding the application of proposed approach in order to demonstrate the sensitivity of faults in the analyzed structure. All research has been carried out based on archival process data recorded in the Lublin Sugar Factory S.A.

**Keywords:** identification, fault detection, dynamic systems, additive model, data mining.