

Zofia M. Łabęda-Grudziak

Politechnika Warszawska, Instytut Automatyki i Robotyki
e-mail: z.labeda@mchtr.pw.edu.pl

ALGORYTM ODPORNEJ IDENTYFIKACJI ADDYTYWNEGO MODELU REGRESJI DLA POTRZEB DETEKCJI USZKODZEŃ*

Streszczenie – W artykule przedstawiono algorytm odpornej identyfikacji modeli obiektów dynamicznych dla potrzeb detekcji uszkodzeń. W tym celu wykorzystano addytywny model regresji wraz z nieparametrycznymi technikami estymacji, który posłużył zarówno do identyfikacji modelu obiektu metodą błędu predykcji, jak i modelowania błędu modelu addytywnego. Pozyskana wiedza posłużyła do konstrukcji odpornego układu 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.

1 Wstęp

Diagnostyka procesów przemysłowych polega na przeprowadzeniu szeregu operacji, które w rezultacie doprowadzą do wykrycia, lokalizacji i identyfikacji możliwych uszkodzeń. Niniejszy artykuł podejmuje zagadnienie pierwszego etapu postępowania diagnostycznego, mianowicie detekcji uszkodzeń, czyli wykrywania nieprawidłowych stanów procesów oraz uszkodzeń urządzeń technologicznych, wykonawczych i pomiarowych [3,6,7].

W diagnostyce procesów przemysłowych obiektami diagnozowania są złożone instalacje technologiczne wraz z urządzeniami wykonawczymi i pomiarowymi oraz procesy zachodzące w tych instalacjach. Typowymi obiektami diagnozowania są instalacje w przemyśle chemicznym, petrochemicznym, energetycznym, hutniczym itp., w których detekcja może być prowadzona na podstawie dostępnych sygnałów pomiarowych, które w trybie on-line system diagnostyczny pobiera na drodze transmisji cyfrowej z systemu automatyki. Zmniejsza to wymagane nakłady finansowe na realizację funkcji diagnostycznych.

* Praca została zrealizowana w ramach grantu promotorskiego KBN o numerze N N514 238337

Podział systemów diagnostycznych na różne klasy wprowadza sposób detekcji [7]. Może być ona prowadzona z zastosowaniem modeli obiektu lub bez wykorzystania modeli. Rozwój metod detekcji uszkodzeń z wykorzystaniem modelu procesu nierozzerwalnie łączy się z rozwojem systemów komputerowych i inżynierii oprogramowania. Idea metody polega na zbudowaniu spójnego modelu komputerowego obiektu, który pozwoli na symulację procesu oraz zaawansowaną analizę stanów normalnych i stanów z uszkodzeniami. Taka wiedza symulacyjna może doskonale uzupełnić wiedzę operatora i eksploatatora procesu oraz stanowić źródło wiedzy diagnostycznej.

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, modele neuronowe i rozmyte oraz ich kombinacje [3,7]. 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 (ang. *Additive Models*) [5,8-10].

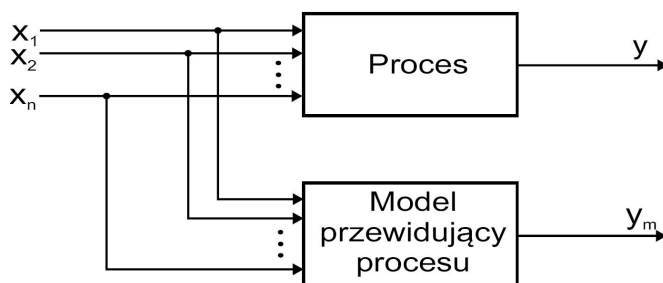
W ostatnich latach obserwuje się wzrost zainteresowania metodami identyfikacji zapewniającymi oszacowanie niepewności budowanego modelu na potrzeby układów diagnostyki uszkodzeń [6]. Schemat detekcji uszkodzeń z modelami systemu opiera swoje działanie na wyidealizowanych założeniach, że model jest wierną repliką systemu i idealnie reprezentuje jego dynamikę oraz, że szумы, 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, szумы pomiarowe, zmiany w sygnałach wejściowych i stanach systemu. 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 błędu modelu podstawowego w stosunku do niezamodelowanej dynamiki obiektu czy szumów [6].

2 Addytywny model regresji

Aparatura kontrolująca procesy przemysłowe dostarcza olbrzymich ilości danych pomiarowych, które mogą być użyte podczas złożonych

badań, mających na celu zmniejszenie ryzyka powstania uszkodzenia. Jednocześnie wraz z rozwojem technologii informatycznej pojawiły się nowe sposoby zwiększania ilości gromadzonych danych oraz szybkości ich przetwarzania. To stworzyło możliwość budowy modeli procesów przemysłowych na podstawie danych pomiarowych z obiektu oraz wiedzy eksperckiej o strukturze modelu. W związku z tym powstało zapotrzebowanie na nowe metody i narzędzia informatyczne wspomagające człowieka w efektywnej eksploatacji obiektów przemysłowych, która wymaga wiarygodnej informacji o ich stanie technicznym. Informacja ta jest często rozszerzona o predykcję zmiany ich stanu technicznego.

Istota przewidywania polega na identyfikacji modeli procesu przemysłowego, a następnie obserwowaniu, jak się one zachowują z upływem (modelowego) czasu i dokonywaniu projekcji wyników z powrotem na rzeczywisty obiekt diagnozowany. Modelowanie przewidujące jest uczeniem się odwzorowywania z wejściowego wektora pomiarów $x = \phi(x_1, \dots, x_n)$ na skalarną wartość wyjściową y . Celem modelowania przewidującego jest zatem oszacowanie odwzorowania lub funkcji $y_m = f(x, \theta)$, mogącej przewidzieć wartość wyjściową y przy zadanym wejściowym wektorze zmierzonych wartości y oraz zbiorze oszacowanych parametrów θ dla modelu ϕ . Możemy zatem wyznaczyć residua $r = y - y_m$ i porównać czy wartości zmiennej procesowej znacznie odbiegają od wartości tej samej zmiennej, estymowanej z przyjętego modelu. Jest to przykład wykorzystania redundancji informacyjnej. Ogólny schemat generowania residuum na podstawie modelu przewidującego procesu przedstawiono na rys. 1.



Rys. 1. Schemat generowania residuum na podstawie modelu przewidującego procesu.

Jeśli zmienna wyjściowa jest zmienną ilościową, to problem szukania modelu odpowiada problemowi regresji. Ponieważ proces przemysłowy rzadko może być postrzegany jako niezmienny w czasie, w pracy

wykorzystano dynamiczne addytywne modele regresyjne. Jakość prognozy modeli zależy zasadniczo od dwóch czynników: od tego na ile model jest ścisły, tzn. sformalizowany matematycznie i na ile wiernie odzwierciedla realia.

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

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

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

gdzie α jest pewną stałą, błąd ε jest niezależny od (X_1, X_2, \dots, X_p) , $E(\varepsilon) = 0$, $Var(\varepsilon) = \sigma^2$ oraz φ_j są jednowymiarowymi funkcjami sygnału X_j , niekoniecznie liniowymi. Przykładowo φ_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, 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.

3 Algorytm odpornej identyfikacji modelu obiektu

Algorytm odpornej identyfikacji powinien dostarczyć nie tylko model rozważanego systemu, ale także niezawodną estymatę niepewności związanej z modelem. Idea prezentowanej metody polega na przeprowadzeniu procesu identyfikacji metodą błędu predykcji wykorzystującej addytywny model regresji, a następnie wykonaniu dodatkowych działań mających na celu określenie niepewności związanej z uzyskanym modelem.

Identyfikacja metodą błędu predykcji

Opis działań mających na celu opracowanie modelu procesu przemysłowego nazywa się identyfikacją modelu. Składa się on z wielu etapów, które gwarantują prawidłowy przebieg identyfikacji. Identyfikacja jest prowadzona wyłącznie na podstawie danych pomiarowych, stąd opiera się ona na metodach eksploracyjnej analizy danych (ang. *Data Mining*), a jakość danych decyduje o powodzeniu obliczeń i jakości wynikowego modelu. W zautomatyzowanych procesach przemysłowych dostępne są wartości archiwizowanych zmiennych procesowych. To stwarza możliwość budowy modeli na podstawie danych pomiarowych z obiektu oraz wiedzy eksperckiej o strukturze modelu.

Odkrywanie wiedzy w bazach danych w zakresie identyfikacji ilościowych modeli diagnostycznych jest procesem o iteracyjnym charakterze. Aby eksploracja danych przyniosła zadowalające rezultaty, musi być zachowana odpowiednia kolejność wykonywanych działań. Wyróżniamy następujące ogólne etapy: zrozumienie uwarunkowań badawczych, zrozumienie danych, przygotowanie danych, identyfikacja, ewaluacja i wdrożenie [8,9]. Każdy następny w kolejności etap często zależy od wyników z poprzedniego etapu. W dowolnym momencie może nastąpić powrót do poprzedniego etapu, a nawet w drastycznych przypadkach proces odkrywania wiedzy może rozpocząć się na nowo.

Należy podkreślić dużą rolę użytkownika w procesie identyfikacji. Stosowanie tego procesu wymaga wielu umiejętności oraz podejmowania różnych decyzji. Stąd użytkownik systemu odkrywania wiedzy powinien posiadać dobre zrozumienie dziedziny zastosowania, tak aby wybrać właściwy podzbiór danych, określić, jakie są zadania analizy, jaka powinna być reprezentacja poszukiwanej wiedzy, których algorytmów należy użyć. Dlatego system odkrywania wiedzy powinien być oprogramowaniem interaktywnym, a nie narzędziem w pełni automatycznym.

Formalnie, zadanie wyznaczenia modelu addytywnego na podstawie danych pomiarowych $\{(x_i, y_i)\}_{i=1}^N$ gdzie $x_i = \{x_{ij}\}_{j=1}^p$, rejestrowanych w trakcie eksploatacji obiektu, możemy zapisać jako zadanie minimalizacji sumy kwadratów błędów

$$\operatorname{argmin}_{\{\alpha, \varphi_j\}} \sum_{i=1}^N (y_i - \alpha - \sum_{j=1}^p \varphi_j(x_{ij}))^2, \quad (2)$$

które oznacza znalezienie stałej $\hat{\alpha}$ oraz p funkcji jednej zmiennej $\hat{\varphi}_j(\cdot)$. Estymatory funkcji φ_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

$$\hat{\varphi}_j(x_{ij}) = \sum_{l=1}^N S_{il} y_l. \quad (3)$$

Wtedy dla $\forall j = 1, \dots, p$ wektor wartości estymatora $\hat{\varphi}_j = (\hat{\varphi}(x_{1j}), \dots, \hat{\varphi}(x_{Nj}))^T$ może być zapisany jako

$$\hat{\varphi}_j = \mathbf{S}_j \mathbf{y}, \quad (4)$$

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 (ang. *Locally Polynomial Smoothers*) oraz wygładzanie za pomocą naturalnej kubicznej funkcji skleianej (ang. *Natural Cubic Splines*) [8,9].

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*) [8]. Możliwa jest także metoda graficzna pomagająca w wyborze odpowiedniej wartości.

Intuicyjnie chcemy aby funkcje φ_j były dopasowywane jednocześnie, stąd odpowiednie funkcje wygładzające w modelu addytywnym są znajdowane za pomocą iteracyjnego algorytmu dopasowania wstecznego (ang. *Backfitting Algorithm*) [1,5,8]. 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 $\hat{\varphi}_j(\cdot)$ funkcji $\varphi_j(\cdot)$ 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.

Algorytm dopasowania wstecznego

1. Wyznacz $\hat{\alpha} = \frac{1}{N} \sum_{t=1}^N y_t$
 oraz przyjmij początkowe estymatory $\hat{\phi}_{j,j=1,\dots,p}^{(0)} \equiv 0$

2. Dla $j = 1, \dots, p$ oblicz $\hat{\phi}_j^{(m)} = S_j \left(y - \hat{\alpha} - \sum_{k \neq j} \hat{\phi}_k^{(m-1)} \right)$

3. Powtarzaj krok 2 aż do spełnienia warunku:

$$\max_j \|\hat{\phi}_k^{(m)} - \hat{\phi}_k^{(m-1)}\| < \delta$$

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

Można udowodnić, że przy spełnieniu pewnych założeń, algorytm zbiega do jednoznacznego rozwiązania, startując z dowolnych wartości początkowych [1,8].

Modelowanie błędu predykcji

W technice modelowania błędu (ang. *Model Error Modelling*) wykorzystuje się sygnał residuum, otrzymany jako różnicę między sygnałem zarejestrowanym w procesie, pochodzącym z czujnika a odpowiednią zmienną obliczoną analitycznie na podstawie przyjętego modelu addytywnego i na jego podstawie szacuje się niepewność modelu. W tym przypadku zakłada się, że niepewność jest miarą niezamodelowanej dynamiki procesu, szumów pomiarowych i wszelkiego rodzaju innych zakłóceń. W wyniku modelowania sygnału residuum uzyskuje się model błędu (ang. *Error Model*). Odpowiedź tego modelu jest wykorzystywana do obliczenia dolnej i górnej obwiedni niepewności.

Kluczowym zagadnieniem przy budowie odpornego modelu jest wybór odpowiedniej struktury modelu błędu. Jeśli wybrana struktura dobrze odzwierciedla dane, może zostać wykorzystana do wyznaczenia obszaru niepewności. W innym przypadku należy zwiększyć stopień skomplikowania modelu.

Procedurę formowania obwiedni niepewności w dziedzinie czasu, przeznaczoną do przeprowadzania działań diagnostycznych opisuje algorytm przedstawiony w pracy Korbicza [6]. Poniżej przedstawiono wersję tej metody, w której schemat modelowania błędu modelu autor

zrealizował z wykorzystaniem addytywnego modelu regresji. Jest to nowe podejście, dotychczas niestosowane.

Algorytm modelowania niepewności modelu

1. Uformułuj zbiór danych $\{(x_i, y_i)\}_{i=1}^N$, gdzie $x_i = \{x_{ij}\}_{j=1}^p$ 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.
2. Przeprowadź procedurę modelowania modelu błędu, przy wykorzystaniu addytywnego modelu regresji:

$$r_t = \beta + \sum_{j=1}^p \xi_j(x_{tj}) + \tau_t, \quad (*)$$

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

3. Wyznacz środek obszaru niepewności jako $\hat{y}_t + \hat{r}_t$, gdzie \hat{r}_t jest odpowiedzią modelu błędu (*).
4. Zakładając, że odpowiedź modelu błędu (*) jest zgodna z rozkładem normalnym (lub nieznacznie od niego odbiega), użyj statystycznych charakterystyk sygnału \hat{r}_t do określenia obszaru niepewności. Na tej podstawie wyznacz dwa progi adaptacyjne, górny $T_{g,t}$ i dolny $T_{d,t}$, które określają obszar niepewności modelu procesu.

Progi adaptacyjne wyznaczone są w następujący sposób:

$$\begin{cases} T_{g,t} = \hat{y}_t + \hat{r}_t + u_\alpha \hat{\sigma}_{\hat{r}_t} \\ T_{d,t} = \hat{y}_t + \hat{r}_t - u_\alpha \hat{\sigma}_{\hat{r}_t} \end{cases} \quad (5)$$

gdzie u_α jest kwantylem rozkładu normalnego o zadanym poziomie ufności równym $1 - \alpha$, $\hat{\sigma}_{\hat{r}_t}$ jest nieobciążonym estymatorem odchylenia

standardowego sygnału \hat{r}_t . Należy zaznaczyć, że \hat{r}_t reprezentuje nie tylko sygnał residuum, ale także niepewność strukturalną czy zakłócenia. Z tego względu progi (5) będą dobrze określać obszar niepewności tylko wtedy, kiedy sygnał \hat{r}_t będzie posiadał rozkład prawdopodobieństwa zgodny z rozkładem normalnym.

Wskaźniki oceny jakości identyfikacji

Model obiektu jest uproszczonym opisem rzeczywistości. Spowodowane jest to niedokładnością wyznaczenia parametrów modelu. Stąd dla oceny błędów identyfikacji modelu procesu i modelu błędu procesu można wyznaczyć następujące wskaźniki jakości otrzymanego modelu:

- **MSE** - średni kwadrat błędów (ang. *Mean Square Error*),
- **MADE** - średni moduł błędów (ang. *Mean Absolute Deviation Error*),
- **MAPE** - średni bezwzględny błąd procentowy wyrażony zakresie pomiarowym wartości wyjścia (ang. *Mean Absolute Percentage Error*),
- **VAR** - wariancja błędów (ang. *Error Variance*).

4 Detekcja uszkodzeń

Detekcja uszkodzeń ma na celu zauważenie powstania uszkodzenia w obiekcie i określenie chwili detekcji, poprzez realizację testów diagnostycznych. Zbiór testów wykonywany jest automatycznie przez komputer i powinien być tak dobrany, aby umożliwić wykrycie wszystkich uszkodzeń, które mogą wystąpić podczas eksploatacji obiektu przemysłowego.

Ponieważ środek obszaru niepewności $\hat{y}_t + \hat{r}_t \approx y_t$ przybliża odpowiedź obiektu y_t , zadanie detekcji uszkodzeń sprowadza się do obserwowania wyjścia diagnozowanego procesu y_t względem obszaru niepewności. Dopóki y_t nie wykracza poza górny i dolny próg obszaru niepewności, proces pracuje prawidłowo i uszkodzenie nie będzie sygnalizowane. Zatem zadanie detekcji można podzielić na cztery etapy:

- generowanie błędu modelu procesu r_t ,
- generowanie estymaty błędu modelu procesu \hat{r}_t ,
- generowanie progów adaptacyjnych: $T_{g,t}$ i $T_{d,t}$,

- obserwowanie wyjścia procesu y_t względem obszaru niepewności $(T_{d,t}, T_{g,t})$.

Wskaźniki jakości detekcji

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

- t_{dt} - czas detekcji, który jest czasem mierzonym od czasu rozpoczęcia symulowania uszkodzenia do czasu wystąpienia jego symptomu,
- θ_{fd} - stopień fałszywej detekcji, którego wartość informuje o tym jak wiele wystąpiło fałszywych alarmów,
- θ_{td} - stopień prawdziwej detekcji, którego wartość informuje o efektywności detekcji uszkodzeń.

5 Przykład

Skuteczność algorytmu odpornej identyfikacji modelu addytywnego dla potrzeb detekcji uszkodzeń została zaprezentowana dla zaworu regulacyjnego znajdującego się w pierwszym stopniu stacji wyparnej cukrowni "LUBLIN" S.A., przy użyciu programu *R-project* [4] 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 [9,10].

Model diagnozowanego obiektu został opracowany z wykorzystaniem danych archiwalnych z przebiegu 25 dniowej kampanii cukrowniczej w 2001 roku [2]. Zbiór danych pomiarowych został podzielony na zbiór uczący i testowy. Biorąc pod uwagę strukturę urządzenia wykonawczego został zaproponowany model przepływu soku przez zawór regulacyjny. W celu prawidłowego odzwierciedlenia dynamiki obiektu zastosowano model addytywny o strukturze FIR (ang. *Finite Impulse Response Model*) rzędu 4, postaci

$$\begin{aligned}
 F_t = & \varphi_1(CV_{t-1}) + \varphi_2(CV_{t-2}) + \varphi_3(CV_{t-3}) + \varphi_4(CV_{t-4}) + \\
 & \varphi_5(P1_{t-1}) + \varphi_6(P1_{t-2}) + \varphi_7(P1_{t-3}) + \varphi_8(P1_{t-4}) + \varphi_9(P2_{t-1}) + \\
 & \varphi_{10}(P2_{t-2}) + \varphi_{11}(P2_{t-3}) + \varphi_{12}(P2_{t-4}) + \varphi_{13}(T1_{t-1}) + \varphi_{14}(T1_{t-2}) + \\
 & \varphi_{15}(T1_{t-3}) + \varphi_{16}(T1_{t-4}) + \varepsilon_t
 \end{aligned} \tag{6}$$

gdzie $F_t[0-500m^3/h]$ - przepływ soku za zaworem, $CV[0-100\%]$ - sygnał sterujący zaworem, $P1$ i $P2[0-1000kPa]$ - ciśnienie soku odpowiednio przed i za zaworem, $T1[50-150^\circ C]$ - temperatura soku przed zaworem, $t=1,\dots,5$, $F_t = F_t - \alpha$, $\varphi_1,\dots,\varphi_{16}$ są jednowymiarowymi funkcjami.

Wyniki jakości identyfikacji modelu przepływu

Dla danych uczących, pochodzących ze stanu zdadności procesu, otrzymano estymowane wartości przepływu medium wraz z rzeczywistymi wartościami przepływu medium danymi z procesu. Wskaźniki jakości identyfikacji modelu (6) przedstawiono w tab. 1.

Tabela. 1. Wskaźniki jakości identyfikacji

<i>MSE</i>	<i>MADE</i>	<i>MAPE</i>	<i>VAR</i>
7.2453	2.0428	1.0108%	7.2454

Uzyskano jakość modelowania rzędu 1% zakresu zmienności sygnału wyjściowego.

Wyniki jakości identyfikacji błędu modelu

Na podstawie modelu (6) można wyznaczyć residua $r_t = F_t - \hat{F}_t$, a następnie wyznaczyć odporną estymatę niepewności związanej z modelem (6). W tym celu zastosowano model błędu o strukturze ARMA (ang. *Autoregressive Moving Average Model*) rzędu 4, z pięcioma sygnałami wejściowymi ($X, CV, P1, P2, T1$) i sygnałem wyjściowym stanowiącym sygnał residuum r_t . Wybór wysokiego rzędu modelu był podyktowany jakością odwzorowania dynamiki sygnału residuum.

Błędy **MADE** i **MAPE** modelowania błędu modelu były rzędu 0.9%. Do określenia obszaru niepewności założono poziom ufności o wartości 95% i wygenerowano dwa progi adaptacyjne $T_{g,t}$ i $T_{d,t}$, zgodnie z zależnością (5).


Wyniki jakości detekcji

Do badania algorytmów detekcyjnych, bazujących na algorytmie odpornej identyfikacji, wykorzystano próbę testową składającą się z danych pomiarowych pochodzących z wybranych trzech dni kampanii,


zarówno ze stanu zdatności f_0 , jak i ze sztucznie wprowadzonymi uszkodzeniami:

- f_1 - otwarcie zaworu obejścia (30.10.2001),
- f_2 - spadek ciśnienia zasilającego pozycjoner (17.11.2001),
- f_3 - uszkodzenie toru pomiarowego ciśnienia P_2 (20.11.2001).


Na rys. 2-4 przedstawiono obszary niepewności (linie szare: jasna i ciemna) i wyjście procesu (linia czarna) w warunkach nominalnych oraz wystąpienia poszczególnych uszkodzeń. Można zaobserwować, iż przedział ufności wyjścia systemu generowany za pomocą zaprojektowanego modelu addytywnego obejmuje wyjście procesu w warunkach nominalnych oraz leży na zewnątrz obszaru niepewności w trakcie symulacji uszkodzeń



Rys. 2. Obszar niepewności i wyjście procesu w warunkach nominalnych f_0 i wystąpienia uszkodzenia f_1 z dnia 30.10.2001.



Rys. 3. Obszar niepewności i wyjście procesu w warunkach nominalnych f_0 i wystąpienia uszkodzenia f_2 z dnia 17.11.2001.



Rys. 4. Obszar niepewności i wyjście procesu w warunkach nominalnych f_0 i wystąpienia uszkodzenia f_3 z dnia 20.11.2001.

Wyniki wskaźników jakości detekcji poszczególnych uszkodzeń przedstawiono w tab. 2.

Tabela. 2. Wskaźniki jakości detekcji uszkodzeń.

Miara	Zasymulowane uszkodzenia		
	f_1	f_2	f_3
θ_{td} [%]	97.01	89.11	99.98
t_{dt}	25	6	1

Wartości wskaźnika fałszywej detekcji dla poszczególnych dni kampanii plasowały się między 1.2% a 3.49%.

6 Podsumowanie

W artykule zaprezentowano efektywne rozwiązanie umożliwiające identyfikację zarówno modelu procesu przepływu medium przez zawór regulacyjny, jak jego niepewności za pomocą addytywnego modelu regresji. Jest to nowe podejście w diagnostyce procesów przemysłowych.

Zaprezentowany eksperyment pokazuje potencjał i możliwości zastosowań algorytmu odpornej identyfikacji w układach diagnostycznych. Uzyskane wyniki 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 25 sekund, stąd można twierdzić, że reakcja na wystąpienie poszczególnych uszkodzeń jest w miarę szybka.

7 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.
- [3] Gertler J., *Fault Detection and Diagnosis in Engineering Systems*. Marcel Dekker, Inc. New York - Basel - Hong Kong, 1998.
- [4] Good P.I., *Introduction to statistics through reasampling methods and R/S-PLUS*. Wiley, 2005.
- [5] Hastie T., Tibshirani R., *Generalized additive models*, Chapman and Hall, 1990.
- [6] Korbicz J., Kościelny J.M., *Modelowanie, diagnostyka i sterowanie nadrzędne procesami. Implementacja w systemie DiaSter*. WNT, Warszawa 2009.
- [7] Kościelny J.M., *Diagnostyka procesów przemysłowych*. EXIT, Warszawa 2001.
- [8] Łabęda Z.M., *Wykorzystanie addytywnego modelu regresji w eksploracyjnej analizie danych*, VI Sympozjum Modelowanie i Symulacja Komputerowa w Technice, Łódź 2008.
- [9] Łabęda-Grudziak Z.M., *Dobór struktury modelu addytywnego dla potrzeb detekcji uszkodzeń obiektów dynamicznych*, VI Sympozjum Modelowanie i Symulacja Komputerowa w Technice, Łódź 2010.
- [10] Łabęda Z.M., *Additive model applications for the fault detection of actuators*, *Pomiary, Automatyka i Kontrola*, Vol.55, pp. 152-155, (3)2009.

ROBUST IDENTIFICATION ALGORITHM FOR THE ADDITIVE REGRESSION MODEL FOR FAULT DETECTION

Summary - this paper presents an algorithm for robust identification of dynamic systems for fault detection. To achieve robustness, the additive regression model with nonparametric estimation techniques was used to identify a model by prediction error methods and also to estimate an uncertainty associated with the model. The planned aim is the fault detection of the actuator in the evaporation station. The results of the modeling and the fault detection procedures have been presented. All research has been carried out based on the real process data recorded in the Lublin Sugar Factory S.A.