

METODA OSZACOWANIA NIEPEWNOŚCI ADDYTYWNEGO MODELU REGRESJI NA POTRZEBY UKŁADU DETEKЦИИ INSTALACJI GAZOCIĄGOWEJ

Zofia Magdalena ŁABĘDA-GRUDZIAK

Streszczenie: W artykule przedstawiono metodę oszacowania niepewności 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 na podstawie danych z modelu analitycznego symulatora sieci, który dostrojony jest to rzeczywistej instalacji przesyłowej gazu.

Słowa kluczowe: model addytywny, sieci przesyłowe gazu, przewidywanie ciśnienia, modelowanie niepewności modelu, odporna detekcja uszkodzeń, eksploracja danych.

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 [1,2].

Systemy detekcji uszkodzeń rurociągów odgrywają kluczową rolę w zadaniu zminimalizowania występowania wycieków oraz ograniczenia ich skutków. Zagadnienie detekcji nieszczelności jest szeroko prezentowane w literaturze [3,4,5], jednak nie opracowano do tej pory całkowicie skutecznego systemu działającego dla każdej konfiguracji rurociągu.

Ze względu na wysokie koszty budowy rurociągów gazu, które są prowadzone przeważnie w ziemi, okres eksploatacji rurociągów powinien być długi (do ok. 50 lat) i to przy minimalnym ryzyku wystąpienia awarii. Trudne warunki eksploatacji stawiają coraz większe wymagania dotyczące długotrwałości i wysokiego stopnia bezawaryjności systemów sterowania. Ze względu na łatwopalność i szkodliwość ekologiczną gazu, awarie powodujące rozszczelnienie instalacji i uchodzenie gazu stwarzają silne zagrożenie wystąpienia wybuchu i skażenia środowiska. Zagrożenia te wyeliminować można poprzez bieżącą detekcję [3,4,5] pozwalającą przewidzieć ewentualną konieczność wyłączenia tłoczenia lub odcięcia nieszczelnego odcinka rurociągu.

Metody i systemy detekcji dzieli się na bezpośrednie (zewnętrzne), kiedy obserwacja zachodzi na zewnątrz rurociągu – z użyciem specjalnych czujników lub pośrednie (analityczne, wewnętrzne), gdy wykorzystuje się w detekcji analizę stanu instalacji

wyrażonego przez pomiary ciśnień i strumieni/prędkości płynu. Wraz z rozwojem metod eksploracji danych oraz algorytmów sztucznej inteligencji prowadzone są badania nad wykorzystaniem modeli cząstkowych w detekcji uszkodzeń gazociągów.

Praca niniejsza podejmuje zagadnienie opracowania modeli cząstkowych odtwarzających wartości ciśnień w sieci gazociągowej za pomocą addytywnego modelu regresji dla potrzeb detekcji uszkodzeń gazociągów. Diagnostyka z użyciem cząstkowych modeli wymaga opracowania modeli niewielkich fragmentów instalacji, reagujących lokalnie na uszkodzenia i pokrywających w sumie zasięgiem cały modelowany obiekt. Modele takie identyfikowane są w trybie off-line w wyniku eksploracyjnej analizy archiwalnych danych pomiarowych. Następnie, w trybie bieżącego monitoringu, obliczane są klasyczne residua jako różnica pomiędzy zmienną procesową i odpowiadającą jej wielkością odtwarzaną przez model.

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 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.

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. Identyfikacja modeli cząstkowych metodą błędu predykcji

Opis działań mających na celu opracowanie modelu statystycznego 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*) [7], a jakość danych decyduje o powodzeniu obliczeń i jakości wynikowego modelu.

Korzystając z coraz większych możliwości opomiarowania systemów nadzoru stacje operatorskie mogą realizować zadania archiwizacji danych, ponieważ w sieciach przesyłowych odbiorcy gazu są precyzyjnie zlokalizowani poprzez stacje redukcyjno-pomiarowe. Z części tych stacji można uzyskać bardzo dokładne dane dotyczące chwilowych poborów gazu. To stwarza możliwość budowy addytywnych modeli cząstkowych na podstawie danych pomiarowych z sieci oraz wiedzy o ich strukturze.

2.1. Addytywny model regresji

Metoda identyfikacji oparta na addytywnym modelu regresji jest nowym podejściem w diagnostyce procesów przemysłowych i została przedstawiona w pracach autora, opublikowanych w pozycjach [8,9,10,11] spisu literatury. Poniżej omówiono pokrótce tylko 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 , zdefiniujmy model addytywny w postaci:

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

gdzie α jest pewną stałą, błąd ε jest niezależny od (X_1, X_2, \dots, X_p) , $E(\varepsilon) = 0$, $\text{Var}(\varepsilon) = \sigma^2$ oraz φ_j są jednowymiarowymi funkcjami zmiennej X_j niekoniecznie liniowymi, szacowanymi na podstawie danych. 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 [8,9], fakt ten wykorzystamy dalej. Wiążąc wielkości fizyczne w procesie oraz czas, model ten może posłużyć do opisu zachowania się procesu przemysłowego i może naśladować jego działanie.

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

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

które oznacza znalezienie stałej α , równej $\hat{\alpha}$ oraz p funkcji jednej zmiennej $\hat{\varphi}_j(\cdot)$. Estymatory funkcji φ_j są znajdowane przez zastosowanie ustalonych funkcji wygładzających, takich jak funkcje lokalnie wielomianowe oraz wielomianowe funkcje sklejjane. Odpowiednie funkcje wygładzające w modelu addytywnym są znajdowane za pomocą iteracyjnego algorytmu dopasowania wstecznego (ang. *Backfitting Algorithm*). Można udowodnić, że przy spełnieniu pewnych założeń, algorytm zbiega do jednoznacznego rozwiązania, startując z dowolnych wartości początkowych [8,9].

2.2. Wybór 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 i określenia rzędu modelu.

Ponieważ model procesu przemysłowego powinien jak najlepiej odwzorowywać przebieg rzeczywistych zmian stanu procesu, konieczne jest określenie zbioru sygnałów wejściowych - oddziałujących na proces i wyjściowych, będących wynikiem jego działania. Model addytywny (1) jest modelem wielowejsciowym MISO, stąd w procesie identyfikacji należy wybrać zbiór sygnałów wejściowych oraz jeden sygnał wyjściowy, który będzie modelowany. Bardzo istotna jest w tym etapie postępowania wiedza *a priori* o procesie.

Należy rozpoznać mechanizmy działania procesu i kierować się zamierzonym celem budowy modelu. Ponieważ wykorzystywany model będzie służył do predykcji, zasadą będzie wykorzystanie jako wejść tych wielkości, które w sensie przyczynowym są najbliższej powiązane z modelowaną wielkością. Optymalna struktura modelu powinna uwzględniać wszystkie sygnały. Niestety, nie jest możliwe zmierzenie każdego działającego zakłócenia, dlatego też przygotowujemy model będzie zawsze w pewnym stopniu uproszczeniem.

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 i wyjściowe [9].

Prostotę modelu można mierzyć za pomocą liczby parametrów, które się w nim pojawiają. Na ogół model o większej liczbie predyktorów daje dokładniejsze przewidywania, jednak ma też większą skłonność do przeuczenia. W celu porównania jakości dwóch lub więcej modeli opisujących zmienność danej zmiennej zależnej, w pracy wybrano test końcowego błędu prognozy FPE (ang. *Final Prediction Error*) i kryterium informacyjne Akaike AIC (ang. *Akaike Information Criteria*).

2.3. Wstępne przetwarzanie danych

Podczas pracy komputerowego systemu sterowania dane pobierane z czujników pomiarowych są rejestrowane i przekazywane dalej do bazy danych archiwalnych procesu. Większość surowych danych przechowywanych w archiwalnych bazach danych jest nieobrobiona, niekompletna i zaszumiona. Aby baza danych była przydatna do celów identyfikacji musi przejść przez wstępną obróbkę danych w formie czyszczenia i przekształcania danych. Należy również pamiętać o możliwości pojawienia się błędów wynikających z ograniczeń zakresów czujników pomiarowych.

Dodatkowo, w przypadku podejrzenia udziału szumu pomiarowego można rozważyć wprowadzenie filtracji. Jest to operacja, której celem jest zazwyczaj usunięcie z sygnału zniekształceń pomiarowych. Filtracji można dokonać w dziedzinie czasu lub częstotliwości. W praktyce przy algorytmach odtwarzania lub predykcji zadawalające efekty zmniejszenia wpływu szumów pomiarowych daje zastosowanie uśredniającego okna czasowego lub zastosowanie filtracji jako wygładzania sygnału.

2.4. Ocena jakości identyfikacji modelu

Model obiektu opisuje jego właściwości i zachowanie tylko w przybliżeniu, jest uproszczonym opisem rzeczywistości. Spowodowane jest to niedokładnością wyznaczenia parametrów modelu oraz nieadekwatnością struktury modelu. Na niedokładność wyznaczenia parametrów modelu mają wpływ błędy przyjętej metody identyfikacji parametrów modelu, błędy obliczeń numerycznych, błędy danych użytych do identyfikacji parametrów modelu. Natomiast nieadekwatność struktury modelu może wynikać z pominięcia wśród wielkości modelujących obiekt, czynników istotnych dla przebiegu zjawisk w obiekcie lub niewłaściwej specyfikacji wielkości modelujących obiekt.

Obiektywną oceną modelu procesu jest wykorzystanie wyznaczonego modelu do symulacji wyjścia dla zbioru danych testowych. W celu sprawdzenia jakości oszacowanego modelu, wyznaczono wartości miar dopasowania, takich jak: średni kwadrat błędów (MSE), średni moduł błędów (MADE), średni bezwzględny błąd procentowy wyrażony w zakresie pomiarowym wyjścia (MAPE), wariancja błędów (VAR).

3. Modelowanie niepewności modelu addytywnego

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.

Procedurę formowania obwiedni niepewności w dziedzinie czasu, przeznaczonej 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

- i. Uformułuj zbiór danych $\{(x_t, y_t)\}_{t=1}^n$ gdzie $x_t = \{x_{tj}\}_{j=1}^p$ 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.
- ii. Uformułuj zbiór danych $\{(x_t, r_t)\}_{t=1}^n$ i przeprowadź procedurę modelowania modelu błędu przy wykorzystaniu addytywnego modelu regresji. Otrzymany model jest estymatą błędu modelu procesu w stosunku do niezamodelowanej dynamiki procesu czy szumów.
- iii. Wyznacz środek obszaru niepewności jako $\hat{y}_t + \hat{r}_t$, gdzie \hat{r}_t jest odpowiedzią modelu błędu.
- iv. 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 $T_{d,t}$.

Progi adaptacyjne, które określają obszar niepewności, są następujące:

$$\begin{aligned} T_{g,t} &= \hat{y}_t + \hat{r}_t + u_\alpha \cdot \hat{\sigma}_{\hat{r}_t} \\ T_{d,t} &= \hat{y}_t + \hat{r}_t - u_\alpha \cdot \hat{\sigma}_{\hat{r}_t} \end{aligned} \quad (3)$$

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 (3) będą dobrze określać obszar niepewności tylko wtedy, kiedy sygnał \hat{r}_t będzie posiadał rozkład prawdopodobieństwa zgodny z rozkładem normalnym.

3.1. 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.

4. Przykład

W niniejszym rozdziale przedstawiono wyniki wykorzystania addytywnego modelu regresji do identyfikacji modelu rozkładu ciśnienia w sieci gazociągowej oraz jego niepewności dla potrzeb detekcji uszkodzeń. Badania przeprowadzono na podstawie danych pochodzących z symulatora sieci gazociągowej, dostrojonego do rzeczywistej instalacji znajdującej się na dużym obszarze Polski. Symulator został opracowany na podstawie modeli analitycznych, w systemie zaawansowanego monitorowania i diagnostyki *AMandD* [12] w Instytucie Automatyki i Robotyki Politechniki Warszawskiej. Badania przeprowadzono przy użyciu programu R-project [13], przeznaczonego do zaawansowanych obliczeń statystycznych.

4.1. Opis obiektu diagnozowania

Odcinek sieci gazowej wykorzystany w prezentowanych badaniach obejmował fragment rzeczywistego gazociągu zasilanego ze stacji w Wólce Radzywińskiej wraz z całą siecią stacji poborów. Żaden z odcinków analizowanej sieci nie wyprowadza gazu poza monitorowany obszar [12]. W większości stacji, odległych od głównej linii gazociągu od

stacji znajdujących się za analizowanym odcinkiem z uwzględnieniem dynamiki zmiany objętości gazu skumulowanego w gazociągu [12]. Tak wyliczane sygnały mogą być wykorzystywane jako dodatkowe wejścia modeli cząstkowych.

4.2. Eksploracyjna analiza danych pomiarowych

Addytywne modele cząstkowe odzwierciedlające funkcjonowanie określonych fragmentów instalacji zostały pozyskiwane z zastosowania technik eksploracji danych pomiarowych. W ramach badań dokonano: wyboru sygnałów wejściowych dla poszczególnych modeli na podstawie analizy wrażliwości oraz znajomości struktury sieci gazociągowej, wykorzystując przede wszystkim ciśnienia i przepływy skumulowane z węzłów bezpośrednio sąsiadujących z węzłem modelowanym; wstępnej obróbki danych. Opis wykorzystywanych sygnałów pomiarowych zamieszczono w tab. 1.

Tab. 1. Zmienne pomiarowe gazu użyte w modelowaniu

Ciśnienie	Przepływ skumulowany	Stacja poboru gazu
P_{Troj}	$Qn(n)_{Troj}$	Trojany
P_{Nieg}	$Qn(n)_{Nieg}$	Niegów
P_{Drog}	$Qn(n)_{Drog}$	Drogoszewo

W celu prawidłowego odzwierciedlenia dynamiki obiektu oraz zwiększenia odporności detekcji uszkodzeń na wpływ impulsowych zakłóceń oddziałujących na sygnały pomiarowe, zaproponowano model addytywny o strukturze FIR (ang. *finite impulse response model*) rzędu 2. Zwiększenie rzędu modelu nie skutkowało znaczną poprawą wyników modelowania w stosunku do wzrostu złożoności modelu.

4.3. Model cząstkowy obiektu diagnozowania

W niniejszym rozdziale przedstawiono wyniki dla wybranego węzła sieci – Niegów. Zaproponowano następujący model:

$$\begin{aligned}
 P_{Nieg,t} = & \alpha + \varphi_1(P_{Troj,t-1}) + \varphi_2(P_{Troj,t-2}) + \varphi_3(Qn(n)_{Troj,t-1}) + \varphi_4(Qn(n)_{Troj,t-2}) \\
 & + \varphi_5(Qn(n)_{Nieg,t-1}) + \varphi_6(Qn(n)_{Nieg,t-2}) + \varphi_7(P_{Drog,t-1}) + \varphi_8(P_{Drog,t-2}) \\
 & + \varphi_9(Qn(n)_{Drog,t-1}) + \varphi_{10}(Qn(n)_{Drog,t-2}) + \varepsilon_t,
 \end{aligned} \quad (4)$$

gdzie ε_t , dla $t = 3, \dots, n$ są niezależnymi zakłóceniami losowymi oraz $\varphi_1, \dots, \varphi_{10}$ są pewnymi jednowymiarowymi funkcjami rzeczywistymi.

4.4. Wyniki jakości identyfikacji modelu rozkładu ciśnienia

W celu estymacji modelu addytywnego (4) wybrano algorytm dopasowania wstecznego z naturalną kubieczną funkcją sklejaną. Dla danych uczących, pochodzących ze stanu zdadności procesu, otrzymano estymowane wartości ciśnienia wraz z rzeczywistymi

wartościami ciśnienia danymi z procesu. Wskaźniki jakości identyfikacji modelu (4) przedstawiono w tab. 2.

Tab. 2. Wyniki jakości identyfikacji modelu rozkładu ciśnienia

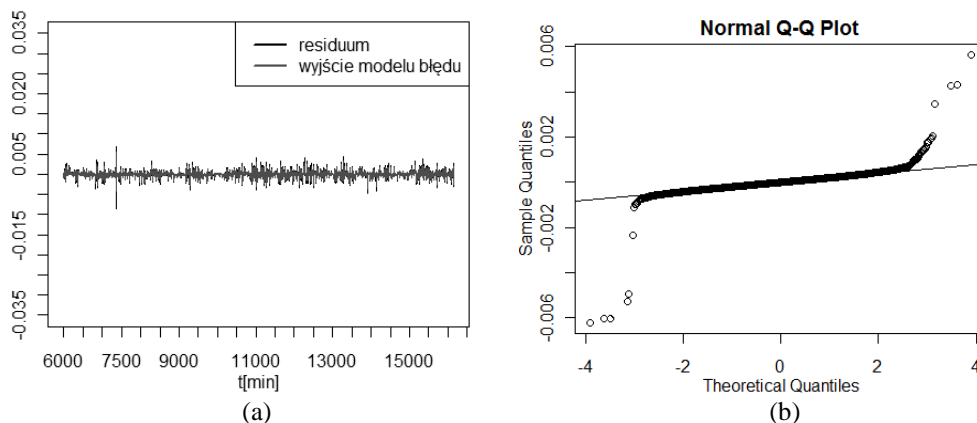
MSE	MADE	MAPE	VAR
2e-06	3e-05	0.0873%	1e-06

Uzyskano jakość modelowania rzędu 0.1% zakresu zmienności sygnału wyjściowego. Otrzymane wyniki badań są zadowalające, gdyż na podstawie danych pochodzących z symulatora sieci, zaprezentowane metody pozwoliły na skonstruowanie modelu dobrze odzwierciedlającego dynamikę procesu.

4.5. Wyniki modelowania niepewności modelu addytywnego

Na podstawie modelu (4) można wyznaczyć residua $r_t = P_{Nieg,t} - \hat{P}_{Nieg,t}$, a następnie wyznaczyć odporną estymatę niepewności związanej z modelem (4). W tym celu zastosowano addytywny model błędu o strukturze rzędu 4, z pięcioma sygnałami wejściowymi ($P_{Troj}, P_{Drog}, Qn(n)_{Troj}, Qn(n)_{Nieg}, Qn(n)_{Drog}$) i sygnałem wyjściowym stanowiącym sygnał residuum r_t . Wybór wysokiego rzędu modelu był podyktowany jakością odwzorowania dynamiki sygnału residuum.

Na rys. 2 (a) przedstawiono sygnał residuum oraz estymowane wyjście modelu błędu. Na podstawie wykresu kwantylowego przedstawionego na rys. 2 (b) można wnioskować o tym, że estymowane wyjście modelu błędu posiada rozkład normalny.



Rys. 2. Residua i wyjścia modelu błędów dla procesu w stanie zdatności (a) oraz wykresy kwantylowe dla rozkładu normalnego (b)

Błędy MADE i MAPE identyfikacji modelu błędu były rzędu 0.9%. Do określenia obszaru niepewności założono poziom ufności o wartości 95% i wygenerowano dwa progi adaptacyjne, górny $T_{g,t}$ i dolny $T_{d,t}$ zgodnie z zależnością (3).

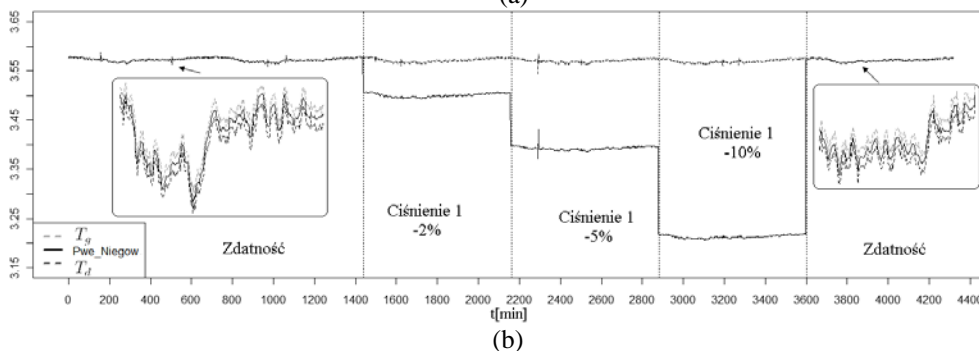
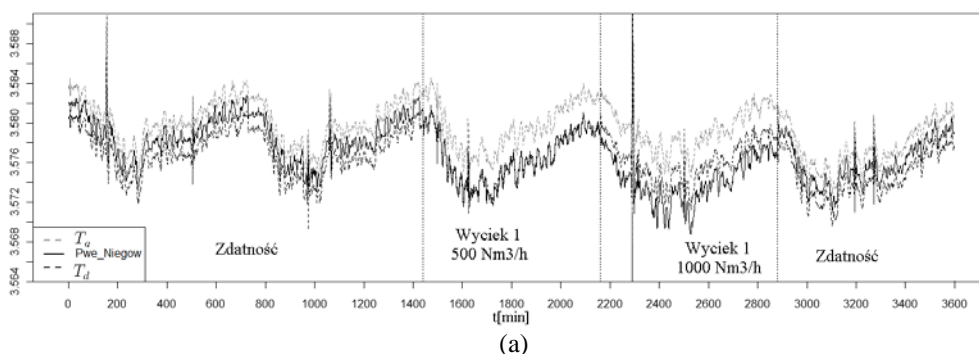
4.6. Wyniki wrażliwości modelu na zasymulowane uszkodzenia

Do badania algorytmów detekcyjnych, bazujących na metodzie modelowania niepewności modelu addytywnego, wykorzystano próbę testową składającą się z danych pomiarowych pochodzących zarówno ze stanu zdatności, jak i ze sztucznie wprowadzonymi uszkodzeniami, których opis przedstawiono w tab. 3.

Tab. 3. Lista uszkodzeń wybranych do testów

Nazwa	Opis	Wartość
Wyciek 1	W połowie pomiędzy Trojanami a Niegowem (przepływ nominalny około 6000 m ³ /h)	500 Nm ³ /h 1000 Nm ³ /h
Ciśnienie 1	Stacja Niegów (wartości aktualnej)	-2 % -5 % -10 %

Na rys. 3a i 3b 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, dzięki czemu może zostać wykorzystany jako adaptacyjny próg decyzyjny.



Rys. 3. Obszar niepewności i wyjście procesu w warunkach nominalnych (zdatność) i wystąpienia uszkodzenia: wyciek 1 (a), ciśnienie 1 (b)

Wyniki wskaźników jakości detekcji poszczególnych uszkodzeń przedstawiono w tab. 4.

Tab. 4. Wyniki jakości identyfikacji modelu rozkładu ciśnienia

Miara	Wyciek 1		Ciśnienie 1		
	500 Nm ³ /h	1000 Nm ³ /h	--2%	-5%	-10%
θ_{fd} [%]	71.73	98.91	99.58	100	99.98
t_{dt} [min]	10	6	3	1	1

Ponadto, najwyższe wartości wskaźnika fałszywej detekcji θ_{fd} w poszczególnych próbach testowych (w trakcie 2157 minut symulacji procesu w warunkach nominalnych) zanotowano na poziomie 2.6%. Wynika to głównie z pewnej wady metody progowania - jeśli w sygnale wyjściowym obserwuje się nagle zmiany wartości, obszar niepewności jest dosyć wąski i sygnał wyjściowy procesu wykracza poza obszar niepewności, powodując fałszywe alarmy.

5. Wnioski

W artykule zaprezentowano efektywne rozwiązanie umożliwiające identyfikację zarówno modelu rozkładu ciśnienia w ściśle określonym węzle sieci gazociągowej, jak i 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. Dokładność odtwarzanych wartości ciśnień waha się w granicach do około 0,015 MPa, przy średniej wartości ciśnień równej ok. 3.6 MPa, tj. 0.5% błędu względnego. Stąd zaprezentowana metoda pozwoliła na skonstruowanie modelu dobrze odzwierciedlającego dynamikę procesu. Wykorzystanie niepewności skonstruowanego modelu umożliwiło otrzymanie wyników detekcji zdecydowanie lepszych niż przy zastosowaniu algorytmu detekcji o stałych wartościach progowych (por. [11]).

Podziękowania

Niniejsza praca była częściowo finansowana w ramach grantu promotorskiego KBN „Wykorzystanie addytywnego modelu regresji do generacji residuów dla potrzeb detekcji uszkodzeń”, nr N N514 238337 oraz projektu badawczego „Metody rozwiązania podstawowych problemów rozpoznawania uszkodzeń w złożonych obiektach dynamicznych”, nr 2011/01/B/ST7/06183.

Literatura

1. Kościelny J.M.: Diagnostyka procesów przemysłowych. EXIT, Warszawa 2001.
2. Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W. (red): Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania. WNT, Warszawa 2002.
3. Bilman L. Isermann R.: Leak detections methods for pipelines, Automatica, vol. 23, no. 3, 1987, s. 381-385.

4. Verde C.: Multi-leak detection and isolation in fluid pipelines, Control Engineering Practice, vol.9, 2001.
5. Hauge E., Aamo O.M., Godhavn J-M.: Model based pipeline monitoring with leak detection, SPE Projects, Facilities & Construction, vol. 4, No.3, 2009.
6. Korbicz J., Kościelny J.M.: Modelowanie, diagnostyka i sterowanie nadrzędne procesami. Implementacja w systemie DiaSter. WNT, Warszawa, 2009.
7. Larose D.T.: Discovering Knowledge in Data: An Introduction to DATA MINING. Wiley, 2005.
8. Hastie T., Tibshirani R.: Generalized additive models. Chapman and Hall, 1990.
9. Łabęda-Grudziak Z.M.: Identification of dynamic system additive models by KDD methods. Pomiary-Automatyka-Kontrola PAK, nr 3, 2011, 2011, s. 249-252.
10. Łabęda-Grudziak Z.M.: Identyfikacja i symulacja rozkładu ciśnienia w sieciach gazowych z wykorzystaniem addytywnego modelu regresji. Pomiary-Automatyka-Robotyka PAR, nr 11, 2010, s. 60-64.
11. Łabęda-Grudziak Z.M.: Monitorowanie stanu instalacji gazociągowej w oparciu o addytywny model regresji, XIV Konferencja Komputerowo Zintegrowane Zarządzanie, Zakopane, materiały konferencyjne, t.2, 2010, s. 59-70.
12. Stachura M. i Syfert M.: Model sieci gazowej w systemie monitorowania i diagnostyki AMandD. Pomiary-Automatyka-Robotyka PAR, nr 11, 2010, s. 110-115.
13. Good P.I. Introduction to statistics through reasampling methods and R/S-PLUS. Wiley, 2005.

Mgr Zofia M. ŁABĘDA-GRUDZIAK
Instytut Automatyki i Robotyki
Wydział Mechatroniki Politechniki Warszawskiej
02-525 Warszawa, ul. Św. Andrzeja Boboli 8
tel.: (22) 849 96 16
e-mail: z.labeda@mchtr.pw.edu.pl