

Michał SYFERT, Anna JANKOWSKA, Zofia M. ŁABĘDA– GRUDZIAK, Łukasz TABOR
 INSTYTUT AUTOMATYKI I ROBOTYKI POLITECHNIKI WARSZAWSKIEJ,
 ul. Św. A. Boboli 8, pok 255, 02-525 Warszawa

Porównanie cząstkowych modeli parametrycznych w zadaniu detekcji uszkodzeń sieci gazowej

Dr inż. Michał SYFERT

Zatrudniony w Instytucie Automatyki i Robotyki, Politechniki Warszawskiej. Zajmuje się badaniami w dziedzinie diagnostyki procesów przemysłowych oraz zastosowań logiki rozmytej. Jest głównym autorem systemu diagnostycznego DIAG oraz jednym z głównych autorów zaawansowanego systemu monitorowania i diagnostyki A MandD a także platformy programowej inteligentnego systemu diagnostyki i wspomagania sterowania procesów przemysłowych DiaSter.

e-mail: m.syfert@mchtr.pw.edu.pl



Dr inż. Anna JANKOWSKA

Adiunkt Wydziału Mechatroniki, pracownik Instytutu Automatyki i Robotyki Politechniki Warszawskiej. Autorka wdrożeń przemysłowych z zakresu automatyzacji badań maszyn i monitorowania procesów oraz ponad 40 publikacji z dziedziny przetwarzania sygnałów, modelowania złożonych procesów, modeli w strukturach sztucznych sieci neuronowych, diagnostyki z użyciem modeli neuronowych i rozmyto-neuronowych.

e-mail: a.jankowska@mchtr.pw.edu.pl



Mgr inż. 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



Mgr inż. Łukasz TABOR

Doktorant w Instytucie Automatyki i Robotyki na Wydziale Mechatroniki Politechniki Warszawskiej. Ukończył studia na kierunku Automatyka i Robotyka. W ramach prac naukowo-badawczych zajmuje się modelowaniem i diagnostyką procesów przemysłowych w szczególności interesują go metody odkrywania wiedzy w przemysłowych bazach danych.

e-mail: tabor.lukasz@gmail.com



Streszczenie

Zreferowano badania detekcji uszkodzeń gazociągu z użyciem cząstkowych modeli parametrycznych. Stosując trzy metody modelowania: addytywne modele regresyjne (najnowszą z badanych technik), sztuczne sieci neuronowe oraz układy rozmyte typu TSK opracowano aproksymacje ciśnień w węzłach sieci. Modele testowano w zadaniu detekcji wycieku oraz uszkodzenia czujnika pomiarowego. Wszystkie modele zapewniały dużą dokładność aproksymacji ciśnienia w poprawnych stanach pracy, wykazując także bardzo skuteczną detekcję uszkodzeń czujników pomiarowych ciśnień, natomiast w sytuacji symulowanych wycieków ich przydatność w detekcji była znacznie mniejsza.

Słowa kluczowe: detekcja uszkodzeń, modele cząstkowe, modele parametryczne, addytywne modele regresyjne, sztuczne sieci neuronowe, systemy rozmyte.

Comparison of particular parametric models for faults detection in gas pipeline

Abstract

The results of faults detection [1, 2, 3, 4, 5] in a gas system network (Fig. 1) with use of parametric partial models [6, 7, 8] are presented in the paper. This is a new approach to the task with use of exploratory data analysis [10, 11, 17] and partial models. Three techniques were used to build models of pressure in network nodes: additive regression (ADD – new method of modelling [10, 11, 12, 13, 14, 15]), artificial neural networks (ANN) [16, 17, 18] and TSK fuzzy logic modelling [8, 16, 17]. The measured pressures in adjacent nodes as well cumulative flows in the main line (from global analytical model [9]) of gasoline were the inputs of the models. For the analysed stations (in parts A and B marked in Fig. 1) a set of test failures in the form of leaks and damage of pressure sensors is given in Tab. 1. Using trial and error method, by evaluating the effectiveness of fault detection, there were obtained structures of models of different complexity for individual modelling techniques: ADD – presented by equations (1) and (2), ANN- (3) and (4), TSK- (5) and (6). The model order is not greater than 2. The exemplary results of leak detection with use of particular models are shown in Figs. 3, 5, 7 and of sensor fault detection in Figs. 4, 6, 8. In the conclusions there is summarised the relative accuracy of models (in Table 2), the relative normalized values of the studied residues of leaks – Tab.3 and the pressure sensor failures – Tab. 4.

All models provided highly precise pressure approximation in non-fault states, but TSK and ADD models turned out to be the more accurate. Additionally, all of them were effective in case of pressure sensor fault detection, however, in case of simulated leakages their usefulness was much lower.

Keywords: faults detection, particular models, parametric models, additive regression models, artificial neural networks, fuzzy systems.

1. Wprowadzenie

Zagadnienie detekcji nieuszczelnności, ważne w eksploatacji sieci przesyłu płynnych mediów, jest szeroko prezentowane w literaturze [1, 2, 3, 4, 5]. Metody i systemy detekcji dzieli się na bezpośrednie (zewnątrzne), 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 [4]. Wraz z rozwojem metod eksploracji danych oraz algorytmów sztucznej inteligencji prowadzone są badania nad ich wykorzystaniem w detekcji uszkodzeń gazociągów.

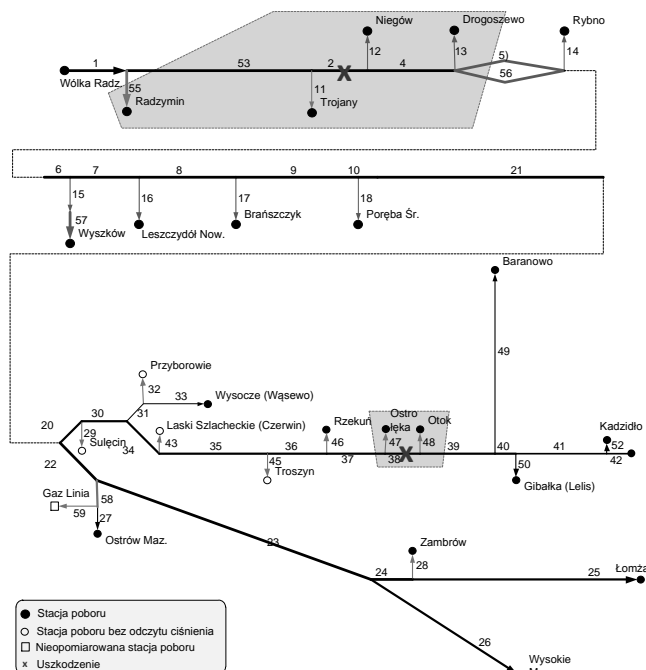
Prezentowane w pracy badania porównawcze zostały częściowo wykonane w ramach projektu rozwojowego, którego celem było opracowanie algorytmów oraz modułów systemu diagnostycznego sieci gazociągowej, w tym - wykorzystanie zbioru parametrycznych modeli cząstkowych odtwarzających wartości określonych sygnałów procesowych. Diagnostyka z użyciem cząstkowych modeli wymaga opracowania modeli niewielkich fragmentów instalacji, reagujących lokalnie na uszkodzenia i pokrywających w sumie zasięgiem cały modelowany obiekt [6, 7, 8]. 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. Fizyczne wielkości podległe ocenie w instalacji, to – ciśnienia w kolejnych węzłach gazociągu.

W pracy rozważano trzy różne rodzaje odwzorowań: modele addytywne regresji (ADD) – nową technikę aproksymacji, sztuczne sieci neuronowe (SSN) oraz modele rozmyte typu Takagi-

Sugeno-Kanga (TSK). Wszystkie badane techniki modelowania znajdują zastosowanie w aproksymacji nieliniowych zależności między rozpatrywanymi wielkościami, gdy trudno jest uzyskać jawny opis matematyczny oraz wykorzystują proces uczenia modeli. Aby ocenić przydatność ww. modeli w detekcji uszkodzeń gazociągu zasymulowano uszkodzenia typu wyciek i niesprawność czujnika pomiaru ciśnienia w dwu wybranych lokalizacjach instalacji.

2. Opis obiektu

Odcinek sieci gazowej wykorzystany w prezentowanych badaniach obejmował fragment rzeczywistego gazociągu zasilanego ze stacji w Wólce Radzyńskiej wraz z całą siecią stacji poborów. Żaden z odcinków analizowanej sieci nie wyprowadza gazu poza monitorowany obszar [9]. W większości stacji, odległych od głównej linii gazociągu od kilkuset metrów do kilkunastu kilometrów, dostępne są pomiary strumieni pobieranego gazu (ozn. F_{nazwa_stacji}) oraz wartości ciśnień w rurociągu zasilającym w części wysokociśnieniowej (ozn. P_{nazwa_stacji}). Węzły, w których nie ma dostępnych pomiarów przepływów oraz ciśnień wskazano na tle schematu na rys. 1. Na wejściu analizowanego odcinka dostępny jest pomiar strumienia gazu ($F_{WólkaRadz.}$) jak i ciśnienia zasilania ($P_{WólkaRadz.}$). Wartość ciśnienia na wejściu (Wólka Radzyńska) utrzymywana jest na stałym poziomie poprzez układ regulacji, co ułatwia identyfikację cząstkowych modeli parametrycznych oraz ich wykorzystanie w detekcji uszkodzeń.



Rys. 1. Fragmenty gazociągu wybrane do badań porównawczych. Krzyżykami symbolicznie oznaczono uszkodzenia przewidziane do symulacji w czasie testów

Fig. 1. Gas-line fragments chosen to comparison investigations. Crosses indicate simulated faults locations during tests

W przeprowadzonych badaniach analizowano możliwość wykorzystania modeli o różnej strukturze odtwarzających wartości ciśnień w poszczególnych stacjach lub wartości spadków ciśnień na poszczególnych fragmentach gazociągu. Z zależności fizycznych opisujących przepływ gazu wynika, że wielkości te zależne są od ciśnień w stacjach sąsiednich oraz strumienia przepływu gazu w danym odcinku gazociągu. Niestety, pomiar strumienia w głównej linii instalacji nie jest dostępny, dostępne są jedynie pomiary strumieni poborów w poszczególnych stacjach. Aby umożliwić budowę modeli cząstkowych zdecydowano się zatem na wykorzystanie szacowanego strumienia gazu (ozn. $Q(n)_{nazwa_stacji}$), wyliczanego na podstawie skumulowanej sumy

poborów ze stacji znajdujących się za analizowanym odcinkiem z uwzględnieniem dynamiki zmiany objętości gazu skumulowanego w gazociągu [9]. Tak wyliczane sygnały mogą być wykorzystywane jako dodatkowe wejścia modeli cząstkowych.

Brak sygnału pomiarowego ciśnienia w konkretnym węźle sieci ogranicza jedynie możliwość zastosowania modeli odtwarzających tę wielkość. Natomiast brak pomiaru strumienia pobieranego gazu w danej stacji musi być traktowany jako niemierzalne zakłócenie (z punktu widzenia działania zbioru modeli cząstkowych).

Wszystkie dane pomiarowe dostępne były z okresem próbkowania równym 60s.

3. Plan badań

Aby umożliwić wykonanie badań porównawczych różnych technik i metod budowy modeli cząstkowych konieczne było opracowanie odpowiedniego planu badań. Każda z technik modelowania musi być użyta do modelowania tych samych fragmentów instalacji przy wykorzystaniu tych samych archiwalnych zbiorów danych. W ramach planu badań: wybrano fragment instalacji, dla którego budowane będą modele cząstkowe, określono wzorcowe uszkodzenia, wykorzystane następnie do testowania algorytmów detekcji, przygotowano zbiory danych uczących oraz testowych uwzględniających symulację wybranych uszkodzeń oraz opracowano formę prezentacji wyników.

Do badań wybrano dwa fragmenty instalacji (rys. 1):

- obszar A: od stacji Radzymin do Drogoszewa - w początkowym fragmencie gazociągu, cechujący się znacznym przepływem gazu,
- obszar B: stacje Ostrołęka oraz Otok - w końcowym fragmencie gazociągu, gdzie obserwowany jest mniejszy przepływ medium.

Budowane modele miały za zadanie odtwarzać ciśnienia w stacjach ze wskazanych obszarów oraz dodatkowo modelować spadek ciśnienia na fragmentach rurociągu, dla których przewidziano scenariusze nieszczelności.

Do eksperymentu numerycznego wybrano dwie nieszczelności oraz dwa uszkodzenia czujników ciśnienia (w obszarze A i B) przy czym wykorzystano kilka poziomów „wielkości uszkodzenia”, aby sprawdzić ogólną zmianę wrażliwości modeli w projektowanych testach. W wyniku analizy wstępnych wyników przyjęto znaczne wartości testowych zakłóceń - tabela 1.

Tab. 1. Lista uszkodzeń wybranych do eksperymentu numerycznego
Tab. 1. The list of faults chosen for numerical experiments

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
Wyciek 2	W połowie pomiędzy Ostrołęką a Otokiem (przepływ nominalny około 600 m ³ /h)	150 Nm ³ /h
		300 Nm ³ /h
Ciśnienie 1	Stacja Niegów (wartości aktualnej)	-2 %
		-5 %
		-10 %
Ciśnienie 2	Stacja Ostrołęka (wartości aktualnej)	-2 %
		-5 %
		-10 %

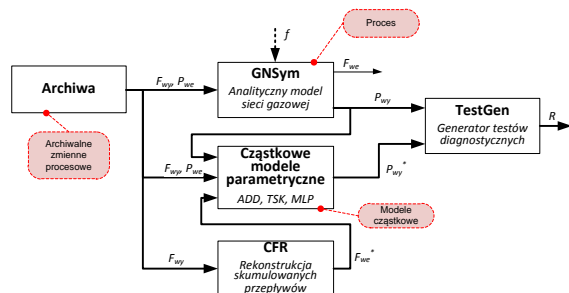
Dostępne dane pomiarowe z rzeczywistego procesu zawierały jedynie okres pracy bez uszkodzeń. Pozwalały więc na identyfikację modeli oraz weryfikację dokładności odtwarzania modelowanych sygnałów w poprawnym stanie pracy.

Nie dawały jednak możliwości przeprowadzenia pełnych testów w zakresie przydatności modeli do detekcji uszkodzeń. Zdecydowano się na realizację badań w dwóch etapach:

- 1) wzorcowe dane wygenerowano przy wykorzystaniu analitycznego symulatora sieci [9] pełniącego rolę wzorcowego procesu. W tym przypadku istniała możliwość symulacji nieszczelności oraz uszkodzeń torów pomiarowych ciśnienia. Podczas generowania danych z symulatora na jego wejścia podawano wartości rzeczywiste sygnałów procesowych. Modele utworzone

w tym etapie oznaczono (GAM), jako uczone na danych globalnego modelu analitycznego,

- 2) wykorzystano jako uczące rzeczywiste dane procesowe. W tym przypadku możliwe było przeprowadzenie symulacji jedynie uszkodzenia torów pomiarowych ciśnienia. Modele oznaczono (PV).



Rys. 2. Sposób generacji residuów na podstawie zbioru modeli cząstkowych obliczanych po podaniu na wejściu danych procesowych

Fig. 2. The way of residue generation based on the set of partial models fed with process data

Wygenerowane zbiory danych uczących i testowych obejmowały około 2-tygodniowy okres pracy instalacji. Pełny plan badań dla każdej z technik modelowania zawierał:

- wybór możliwie najlepszej struktury modelu (metodą prób i błędów) i przeprowadzenie identyfikacji, w razie konieczności należało zastosować dodatkowe przetwarzanie zmiennych,
- sprawdzenie wrażliwości modelu na skokowe zmiany sygnałów wejściowych przy ściśle określonych warunkach,
- uruchomienie modelu – symulację procesu dla testowego zbioru danych bez uszkodzeń oraz określenie podstawowych parametrów statystycznych przebiegu residuum w tym stanie,
- symulację procesu dla wszystkich zdefiniowanych uszkodzeń oraz prezentację wyników w standardowej formie.

W kolejnych rozdziałach pracy przedstawiono struktury modeli cząstkowych uzyskanych dla każdej z metod oraz efekty osiągnięte w detekcji uszkodzeń dla dwóch wybranych węzłów sieci (Trojany – w obszarze A i Otok - ostatnia z rozważanych stacji - obszar B - rys. 1). Pokazano też przykładowe przebiegi residuum we wszystkich technikach modelowania dla badań etapu 1. Na wszystkich wykresach wyjść modeli i residuów (rys. 3 do 8) oś x podana jest w numerach próbek odległych co 1 minutę, na osiach y wykresów przedstawione jest ciśnienie [MPa]. Dokonano również ogólnej oceny dokładności odtwarzania przebiegów procesowych oraz jakości detekcji uszkodzeń czujników ciśnienia z użyciem modeli uczonych na danych bezpośrednio z procesu – w etapie 2 prac. W rozdziale 7 zestawiono dokładność modelowania ciśnienia dla trzech badanych technik w stanie zdadności instalacji a następnie podano średnie wartości residuum dla symulowanych uszkodzeń. Podsumowano uzyskane wyniki modelowania i detekcji uszkodzeń.

4. Wykorzystanie modeli addytywnych

Dla modeli addytywnych, problem poprawnego wyboru struktury modelu sprowadza się przede wszystkim do ustalenia wielkości charakteryzujących obiekt badań oraz określenia rzędu modelu. Wyboru sygnałów wejściowych dla poszczególnych modeli dokonywano na podstawie analizy wrażliwości oraz znajomości struktury sieci gazociągowej, wykorzystując przede wszystkim ciśnienia i przepływy skumulowane z węzłów bezpośrednio sąsiadujących z węzłem modelowanym. Dodatkowo, w celu polepszenia jakości modelowania dla stanu procesu z uszkodzeniami, w niektórych modelach wykorzystywano przepływy skumulowane w stacji modelowanego ciśnienia.

W celu poprawnego odzwierciedlenia dynamiki procesu, w badaniach wykorzystano modele o sygnałach wejściowych z chwili bieżącej oraz opóźnionych – z poprzednich chwil czasu. Są to modele o strukturze FIR (ang. Finite Impulse Response Models).

Modele te zmniejszają także wpływ szumów pomiarowych na jakość modelowania. Modele o strukturze ARMA (ang. Autoregressive Moving Average Models), w których wykorzystuje się na wejściach również opóźnione sygnały wyjściowe, poza bardziej rozbudowaną strukturą i z reguły większą dokładnością modelowania, cechuje duża wrażliwość na wpływ impulsowych zakłóceń oddziałujących na sygnały pomiarowe i mniejsza przydatność w detekcji stanów awaryjnych. Wybór rzędów poszczególnych modeli został dokonany metodą prób i błędów. Brano pod uwagę nie tylko złożoność struktury modelu addytywnego, ale także jakość detekcji. Zwiększenie rzędów modeli nie polepszało istotnie jakości modelowania dla stanu zdadności, zaś w przypadku stanu z zasymulowanymi uszkodzeniami wyraźnie zwiększało wartości uzyskiwanych residuów. W badaniach najlepiej wypadły modele addytywne o bardziej złożonej strukturze - rzędu 2.

Poniżej przedstawiono struktury modeli addytywnych dla dwóch wybranych węzłów sieci - Trojany i Otoku. Wyjściami modeli są odpowiednio ciśnienia w Trojanach i Otoku w chwili t .


$$\begin{aligned} P_{Troj,t} \sim & \varphi_1(P_{Radz,t-1}) + \varphi_2(P_{Radz,t-2}) \\ & + \varphi_3(Q(n)_{Radz,t-1}) + \varphi_4(Q(n)_{Radz,t-2}) \\ & + \varphi_5(Q(n)_{Troj,t-1}) + \varphi_6(Q(n)_{Troj,t-2}) \\ & + \varphi_7(P_{Nieg,t-1}) + \varphi_8(P_{Nieg,t-2}) \\ & + \varphi_9(Q(n)_{Nieg,t-1}) + \varphi_{10}(Q(n)_{Nieg,t-2}) \end{aligned} \quad (1)$$

Wejściami modelu są: ciśnienia w poprzedniej i następnej stacji, a także przepływy skumulowane w tych stacjach oraz w stacji Trojany. Wartości tych sygnałów dla $t > 2$ brane są z chwil $t-1$ i $t-2$.

$$\begin{aligned} P_{Otok,t} \sim & \varphi_1(P_{Ostr,t-1}) + \varphi_2(P_{Ostr,t-2}) \\ & + \varphi_3(Q(n)_{Ostr,t-1}) + \varphi_4(Q(n)_{Ostr,t-2}) \\ & + \varphi_5(P_{Baran,t-1}) + \varphi_6(P_{Baran,t-2}) \\ & + \varphi_7(Q(n)_{Baran,t-1}) + \varphi_8(Q(n)_{Baran,t-2}) \end{aligned} \quad (2)$$

Wejścia modelu jw. bez strumienia skumulowanego w stacji Otok.

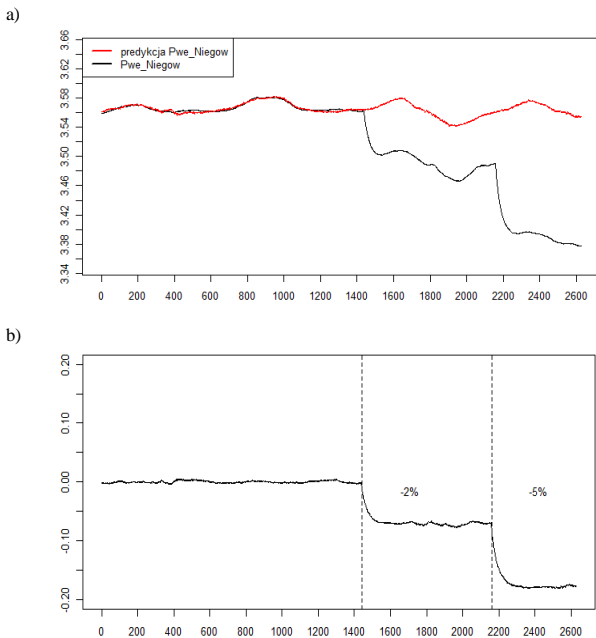
- Etap 1, przykład detekcji wycieku 1 - stacja Trojany



Rys. 3. a) Przebieg wielkości wzorcowej oraz wyjścia modelu PPM^{ADD(GAM)} TROJANY: wyciek 1; b) przebieg residuum

Fig. 3. a) Pattern variable and output of model PPM^{ADD(GAM)} TROJANY: leakage; b) residuum

- Etap 2, przykład detekcji uszkodzenia czujnika pomiarowego z wykorzystaniem modelu ciśnienia Trojany uczonego na danych z procesu (PV).



Rys. 4. a) Przebieg wielkości wzorcowej oraz wyjścia dla modelu $PPM^{ADD(PV)}$ NIEGÓW: ciśnienie 1; b) przebieg residuum

Fig. 4. a) Pattern variable and model $PPM^{ADD(PV)}$ NIEGÓW output: pressure 1; b) residuum

5. Wykorzystanie wielowarstwowych sieci neuronowych

Modele neuronowe [16, 17] opracowano w pakiecie Neural Network Statistica [18], który umożliwia opracowanie SSN w strukturach liniowej, radialnej (RBF), wielowarstwowego perceptronu (*MultiLayer Perceptron* - MLP) o jednej lub 2 warstwach ukrytych. Tworzone struktury SSN miały jedno wyjście – ciśnienie w węzle gazociągu. Ze względu na nieliniowy charakter zależności między modelowanymi zmiennymi wykluczono z rozważań sieci liniowe, natomiast ciągły charakter przekształceń przesądził, że badane były sieci o jednej warstwie ukrytej jednokierunkowe: perceptronowe i radialne. W warstwie wejściowej badanych SSN zachodzi jedynie normalizacja sygnałów. Neurony stosowane w sieciach MLP cechowała sigmoidalna funkcja aktywacji, natomiast w sieciach RBF neurony radialne opisane były funkcją Gaussa.

Wpływ poszczególnych zmiennych wejściowych na wyjście sieci oceniano stosując analizę wrażliwości a także oceniając wartości uzyskanych residuów, gdy symulowano uszkodzenia. Sieci radialne RBF wykazywały dobrą dokładność odwzorowań dla stanu poprawnego, jednak cechowała je mniejsza skuteczność detekcji uszkodzeń. Ostatecznie wybrano sieci perceptronowe MLP. W wyniku przeprowadzonych badań przyjęto następujące postaci modeli:

- ciśnienie w stacji Trojany w chwili t :

$$P_{Troj,t} = f(P_{Nieg,t}, P_{Nieg,t-1}, P_{Nieg,t-2}, Q(n)_{Troj,t-2}) \quad (3)$$

Wejściami są ciśnienie w stacji następnej w chwilach t , $t-1$ i $t-2$, (dla $t > 2$) oraz przepływ skumulowany z chwili $t-2$. Najlepszy model ma strukturę sieci MLP o 4 wejściach, 7 neuronach ukrytych oraz 1 wyjściu (MLP 4-7-1).

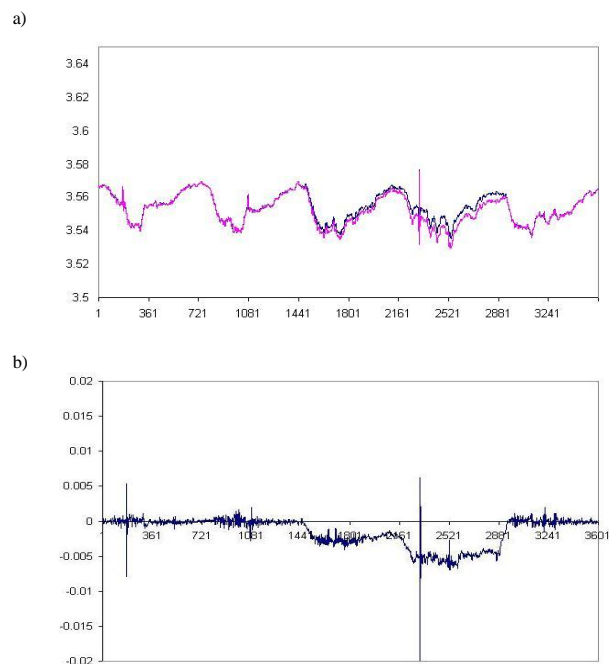
- ciśnienie w stacji Otok w chwili t :

$$P_{Otok,t} = f(P_{Ostrol,t}, P_{Ostrol,t-1}, P_{Ostrol,t-2}, Q(n)_{Otok,t-2}) \quad (4)$$

Wejściami są ciśnienie w poprzedniej stacji dla chwil t , $t-1$ i $t-2$, oraz przepływ skumulowany z chwili $t-2$, dla $t > 2$. Model o strukturze MLP 4-8-1.

Przykładowe wyniki modelowania i detekcji uszkodzeń


- Etap 1 – przykład detekcji wycieku 2, stacja Otok



Rys. 5. a) Przebieg wielkości wzorcowej oraz wyjścia dla modelu $PPM^{MLP(GAM)}$ OTOK: wyciek 2, b) przebieg residuum, zakres (-0.02, 0.02) [MPa]

Fig. 5. a) Pattern variable and output of model $PPM^{MLP(GAM)}$ OTOK: pressure 1; b) residuum

- Etap 2. Sygnały bezpośrednio z archiwum procesu wymagały wygładzenia algorytmem *moving average*. Przykładowy przebieg residuum w przypadku uszkodzenia – ciśnienie 1 dla stacji Niegów podano na rys. 6.



Rys. 6. Przebieg residuum dla modelu $PPM^{MLP(PV)}$ NIEGÓW: ciśnienie 1

Fig. 6. Residuum Of model $PPM^{MLP(PV)}$ NIEGÓW: pressure 1

6. Wykorzystanie modeli rozmytych typu TSK

Modele rozmyte typu TSK zostały opracowane w środowisku DiaSter [8], które dla zadanej struktury (wskazane wejścia i możliwe opóźnienia sygnałów, wskazanie wejść rozmywających) w procesie uczenia automatycznie dobierało liczbę i rozmieszczenie funkcji przynależności i postać wielomianów konkluzji. Dodatkowo możliwe było określenie stopnia tych wielomianów a co za tym idzie otrzymanie funkcji nieliniowych względem wejść.

Struktury uzyskanych modeli:

- ciśnienie w stacji Trojany w chwili t :

$$P_{Troj, t} = f(P_{Radz, t}, P_{Radz, t-1}, P_{Radz, t-2}, P_{Nieg, t}, P_{Nieg, t-1}, P_{Nieg, t-2}, Q(n)_{Troj, t}, Q(n)_{Troj, t-1}, Q(n)_{Troj, t-2}) \quad (5)$$

Wejściami modelu są: ciśnienia w poprzedniej i następnej stacji w chwilach $t, t-1$ i $t-2$, dla $t > 2$, a także strumień skumulowany z tych samych chwil czasu.


- ciśnienie w stacji Otok w chwili t :

$$P_{Otok, t} = f(P_{Ostrol, t}, P_{Ostrol, t-1}, P_{Ostrol, t-2}, P_{Lelis, t}, P_{Lelis, t-1}, P_{Lelis, t-2}, Q(n)_{Otok, t}, Q(n)_{Otok, t-1}, Q(n)_{Otok, t-2}) \quad (6)$$


Zestaw wejść jak powyżej.

Przykładowe wyniki modelowania i detekcji uszkodzeń:

- Etap 1- przykład detekcji wycieku 1 w stacji Trojany



Rys. 7. a) Przebieg wielkości wzorcowej oraz wyjścia dla modelu $PPM^{TSK(GAM)}$ TROJANY: wyciek 1; b) przebieg residuum dla próby testowej
 Fig. 7. a) Pattern variable and output of model $PPM^{TSK(GAM)}$ TROJANY: leakage 1; b) residuum for test



Rys. 8. Residuum dla modelu $PPM^{TSK(GAM)}$ OTOK - ciśnienie 2, zakres (-0.5, 0.5) MPa
 Fig. 8. Residuum of model $PPM^{TSK(GAM)}$ OTOK - pressure 2, scope (-0.5, 0.5) MPa

- Etap 2. Modele uzyskane w etapie 2 cechowała bardzo niska jakość w porównaniu z otrzymanymi w etapie 1. Okazały się one także mało przydatne w zadaniu detekcji uszkodzeń.

7. Podsumowanie

- Etap 1

Dokładność uzyskanych modeli wyrażoną przez znormalizowane odchylenia standardowe błędu odtwarzania ciśnienia w stanie poprawnej pracy instalacji zaprezentowano w tabeli 2.

Tab. 2. Odchylenia standardowe błędu modelowania znormalizowane odpowiednimi zakresami ciśnienia w stacjach Trojany i Otok w 3 typach modeli - stan poprawny
 Tab. 2. Standard deviations of modeling errors normalised by proper scope of pressure in Trojany and Otok stations in 3 models types - correct state

stacja	ADD	TSK	SSN
Trojany	1.50%	0.44%	4.50%
Otok	0.15%	0.06%	1.30%

Najwyższą dokładność modelowania w stanie poprawnym zapewniają modele TSK, niższą - ADD a najniższą modele w strukturach SSN (tab. 2). Jednocześnie liczba wejść jest najwyższa dla modeli ADD, mniejsza dla TSK i najniższa dla modeli SSN.

Ocenę uzyskanych residuów dla uszkodzeń – nieszczelności oznaczonych jako wyciek 1 i wyciek 2 (uśredniona wartość dla kolejnych wartości uszkodzenia w pojedynczej próbie - wyrażona w procentach zakresu zmienności ciśnienia w poszczególnych stacjach) przedstawiono w tab. 3. Zaciemnione pola wskazują na detekcję uszkodzenia, średnia wartość residuum jest wtedy co najmniej kilkakrotnie (≥ 5 razy) większa niż odchylenie standardowe błędu modelu dla stanu poprawnej pracy instalacji (tab. 2).

Dynamika procesu jest dobrze odtworzona dzięki użyciu wejść opóźnionych o jeden i dwa takty próbkowania. Dobór rzędu modeli należy w przyszłości prowadzić z użyciem metod optymalizacji w bardziej usystematyzowany sposób.

Residua uzyskane dla uszkodzeń czujników ciśnienia znormalizowane aktualną wartością ciśnienia zestawiono w tabeli 4.

Tab. 3. Średnie znormalizowane wartości residuum dla uszkodzeń typu wyciek uzyskane w dwu stacjach Trojany i Otok w trzech typach modeli
 Tab. 3. Mean normalised residuum values of leakage for Trojany and Otok

Uszkodzenie	ADD	SSN	TSK
Trojany			
Wyciek 1	-7.25%	0.00%	-4.25%
Wyciek 2	-0.95%	0.00%	-0.25%
Otok			
Wyciek 1	-0.02%	0.0	0.00
Wyciek 2	0.01E-4	-9.25%	0.00

Tab. 4. Znormalizowane wartości residuum dla uszkodzeń czujników ciśnienia uzyskane w dwu stacjach Trojany i Otok
 Tab. 4. Normalised values of residuum for pressure sensor faults: Trojany and Otok

Model	Wartość uszkodzenia		
	-2%	-5%	-10%
Ciśnienie 1 Trojany			
ADD	0.00%	0.00%	0.00%
SNN	0.05%	0.13%	0.30%
TSK	0.23%	0.61%	1.26%
Ciśnienie 2 Otok			
ADD	0.06%	0.13%	0.30%
SNN	0.27%	0.61%	1.29%
TSK	0.83%	2.06%	4.14%

Uszkodzenia czujnika ciśnienia w obszarze B instalacji nie były praktycznie widoczne w residuach dla stacji w obszarze A i odwrotnie.

Opracowane modele mogą być zastosowane do predykcji rozkładu ciśnienia w węzłach sieci.

Większość modeli cechuje się dużą wrażliwością wobec uszkodzeń toru pomiarowego ciśnienia. Uszkodzenia rzędu 2% wielkości mierzonej mogą być skutecznie wykrywane.

Przydatność cząstkowych modeli do detekcji wycieków jest mniejsza niż wobec usterek torów pomiaru ciśnienia. Znaczna ścisłość medium gazowego sprawia, że ciśnienia w gazociągu są słabo wrażliwe na wycieki gazu (zmiennosc ciśnień w sytuacji nieszczelności jest niewielka). Natomiast lokalne sygnały wejściowe modeli są mocno skorelowane z odtwarzanym ciśnieniem i jest to niekorzystne w detekcji nieszczelności z użyciem modeli cząstkowych bazujących właśnie na lokalnych zmiennych procesowych. Wycieki (odpowiadające nawet dużym ubytkom $\sim 1000 \text{ Nm}^3/\text{h}$), jeśli występują w początkowym obszarze instalacji generują dla przykładowej stacji Trojany residuum rzędu kilku wartości odchylenia standardowego w stanie poprawnym (zarówno w modelu ADD jak i TSK). Dla obszaru końcowego gazociągu uzyskano wyraźną detekcję wycieku 2 w modelu SSN. Jednak nie wszystkie zbudowane modele umożliwiały detekcję wycieków. Wrażliwość modeli była znacznie wyższa wobec ciśnień na wejściach niż wobec skumulowanych strumieni gazu.

Rozważane modele spadku ciśnienia między kolejnymi węzłami sieci nie poprawiły detekcji wobec modeli ciśnień w poszczególnych stacjach.

• Etap 2

Modele (PV) uczone na danych z procesu wykazywały w stanie poprawnej pracy znacznie większe odchylenia standardowe od zadanego wzorca (rzędu kilku razy) niż uzyskane w modelach etapu 1. Przy niewielkiej wrażliwości modeli na przecieki w etapie 1, zapewne także modele etapu 2 nie byłyby w sposób dostateczny skuteczne w detekcji nieszczelności.

Większość modeli wykrywała niesprawności czujników ciśnienia.

Celowe było wykorzystanie filtrów uśredniających zarówno wobec wejść jak i wyjść tych modeli.

Uruchomienie modeli uzyskanych w etapie 1 na danych procesowych wykazało istotną zależność wyników od zmian kalibracji torów pomiarowych. Mechanizm korekty przesunięć składowych stałych, powstałych w długim horyzoncie czasu lub w wyniku zmiany kalibracji torów pomiarowych, wprowadzony do modelu globalnego [9] stanowi inżynierskie rozwiązanie praktycznie ważnego problemu eksploatacyjnych dryftów wskazań przyrządów pomiarowych.

• Uwagi końcowe

Badania wykazały niezbyt wielką skuteczność detekcji wycieków z użyciem badanych modeli cząstkowych, na których wejścia podawano ciśnienia w pobliskich stacjach i skumulowane strumienie gazu w głównej linii instalacji.

Natomiast zbadane modele są skuteczne w wykrywaniu niesprawności torów pomiarowych ciśnień.

Wszystkie typy utworzonych modeli wymagają starannego przygotowania zestawów danych uczących obejmującego pełny zakres zmienności sygnałów z pracy gazociągu z uwzględnieniem zmienności np. pór roku.

Addytywne modele regresyjne, to - technika dotychczas niestosowana dla potrzeb detekcji uszkodzeń. Stosunkowo niewielkie nakłady obliczeniowe, jakich wymaga, stwarzają dobre perspektywy przyszłych aplikacji tej metody w diagnostyce procesów. Obecnie wykorzystanie tej techniki umożliwia zaawansowany

pakiet statystyczny R-project [15] wymagający samodzielnego przygotowywania struktur modeli lub gotowa platforma Statistica Data Miner. Z kolei metody tworzenia modeli TSK i SSN są dostępne w zaawansowanych pakietach, takich jak: Matlab, Statistica, DiaSter [8].

Niniejsza praca była częściowo finansowana w ramach projektu badawczego rozwojowego „Badania nad systemami detekcji i lokalizacji nieszczelności rurociągów”, nr O R00 0013 06 oraz grantu promotorskiego KBN pt. „Zastosowanie addytywnego modelu regresji do generacji residuów dla potrzeb detekcji uszkodzeń”, nr N N514 238337.

8. Literatura

- [1] Bilman L. Isermann R.: Leak detections methods for pipelines, *Automatica*, vol. 23, no. 3, s. 381-385, 1987.
- [2] Verde C.: Multi-leak detection and isolation in fluid pipelines, *Control Engineering Practice*, vol.9, 2001.
- [3] Hauge E., Aamo O.M., Godhavn J.-M.: Model based pipeline monitoring with leak detection, *SPE Projects, Facilities & Construction*, vol. 4, No.3, 2009.
- [4] Sobczak R., Turkowski M., Bratek A., Słowikowski M., Bogucki A.: Metody i systemy detekcji nieszczelności rurociągów dalekosiężnych, *Pomiary Automatyka Robotyka*, 4/2007.
- [5] Turkowski M., Bratek A., Słowikowski M., Bogucki A.: Postępy i problemy realizacji systemów detekcji i lokalizacji rurociągów, *Pomiary Automatyka Robotyka*, R 13-2009.
- [6] Kościelny, J. M.: Diagnostyka zautomatyzowanych procesów przemysłowych, *Akadem. Oficyna Wyd. EXIT, Warszawa*, 2001.
- [7] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W. (red): Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania, (1-828), *WNT, Warszawa*, 2002.
- [8] Korbicz J., Kościelny J.M. (red): Modelowanie, diagnostyka, i sterowanie nadrzędne procesami. Implementacja w systemie DiaSter. *WNT*, (1-443), *Warszawa*, 2009.
- [9] Stachura M. i Syfert M.: Model sieci gazowej w systemie monitorowania i diagnostyki AMandD. *Pomiary Automatyka Robotyka PAR*, str. 110-115, nr 11/2010.
- [10] Larose D.T.: *Discovering Knowledge in Data: An Introduction to DATA MINING*, Wiley, 2005.
- [11] Hastie T. i Tibshirani R.: *Generalized additive models*, Chapman and Hall, 1990.
- [12] Labęda-Grudziak Z.M.: Identyfikacja i symulacja rozkładu ciśnienia w sieciach gazowych z wykorzystaniem addytywnego modelu regresji. *Pomiary Automatyka Robotyka PAR*, nr 11/2010, str. 60-64, 2010.
- [13] Labęda-Grudziak Z.M.: Smoothing parameters selection in the additive regression models approach for the fault detection scheme. *Pomiary Automatyka Kontrola PAK*, nr 2/2011, str. 197-200, 2011.
- [14] Labęda-Grudziak Z.M.: Identification of dynamic system additive models by KDD methods. *Pomiary Automatyka Kontrola PAK*, nr 3/2011, str. 249-252, 2011.
- [15] Good P.I.: *Introduction to statistics through resampling methods and R/S-PLUS*, Wiley, 2005.
- [16] Osowski, S.: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wyd. PW, *Warszawa*, 2006.
- [17] Rutkowski, L.: *Metody i techniki sztucznej inteligencji*, PWN, *Warszawa*, 2005.
- [18] STATISTICA Neural Networks PL, *Przewodnik problemowy*, StatSoft, *Polska Sp. z o.o., Kraków*, 2004.

otrzymano / received: 19.07.2011

przyjęto do druku / accepted: 01.12.2011

artykuł recenzowany / revised paper