

# Identyfikacja i symulacja rozkładu ciśnienia w sieciach gazowych z wykorzystaniem addytywnego modelu regresji

Zofia Magdalena Łabęda-Grudziak

Instytut Automatyki i Robotyki Politechniki Warszawskiej

W artykule przedstawiono identyfikację i symulację pracy sieci przesyłowej gazu za pomocą modeli addytywnych w celu oszacowania wartości ciśnienia w określonych punktach węzłowych oraz zbadania zachowania się sieci. Modele cząstkowe odzwierciedlające funkcjonowanie określonych fragmentów instalacji zostały pozyskiwane z zastosowania technik eksploracji danych pomiarowych. Do wyznaczenia parametrów modeli addytywnych zastosowano algorytm dopasowania wstecznego i nieparametryczne techniki estymacji. Badania przeprowadzono dla wybranego fragmentu rzeczywistej sieci przesyłowej gazu.

**Słowa kluczowe:** model addytywny, sieci przesyłowe gazu, symulacja, przewidywanie ciśnienia, eksploracja danych

**S**ieci przesyłowe służą do transportowania dużych ilości gazu pod wysokim ciśnieniem na znaczne odległości. Wysokie koszty budowy rurociągów gazu, które są prowadzone przeważnie w ziemi oraz trudne warunki eksploatacji stawiają coraz większe wymagania dotyczące długotrwałości i wysokiego stopnia bezawaryjności systemów sterowania. Dlatego też metody poprawiające jakość nadzoru i monitorowania procesów odgrywają kluczową rolę w zadaniu zminimalizowania występowania uszkodzeń oraz ograniczenia ich skutków.

W sieciach przesyłowych odbiorcy gazu są precyzyjnie zlokalizowani przez stacje redukcyjno-pomiarowe. Z części tych stacji można uzyskać, przez różne systemy telemetrii, bardzo dokładne dane dotyczące chwilowych poborów gazu, z czasem próbkowania rzędu nawet kilku minut. To stwarza możliwość budowy modeli cząstkowych na podstawie danych pomiarowych z sieci oraz wiedzy eksperckiej o jej strukturze.

Podczas modelowania pracy sieci przesyłowych należy uwzględnić zmiany, jakie zachodzą w procesie przesyłania. Stąd konieczne jest stosowanie modeli dynamicznych, gdyż w przeciwnym przypadku prowadziłyby to do dużych błędów. Gaz ziemny jest gazem lepkiem i ściśliwym, którego wszystkie parametry fizykochemiczne silnie zależą od warunków ciśnieniowo-temperaturowych. Do opisu takiego medium konieczne jest zastosowanie skomplikowanych równań stanu, np. wirtualnych lub kubicznych równań stanu gazu (Berthelota, Beattie-Bridgmana, Penga-Robinsona, Redlica-Kwonga) [1, 2]. Dynamikę elementarnego odcinka rurociągu gazu można wyrazić również za pomocą układu różniczkowych równań cząstkowych, które można wyprowadzić z zasady zachowania masy oraz zasady zachowania pędu i rozwiązywać metodami jawnymi (metoda DuForta-Frankela) oraz ukrytymi (metoda Crank-Nicholsona) [3]. Do analizy pracy fragmentów systemu przesyłowego wykorzystywane były także techniki sztucznej inteligencji [4, 5].

Ze względu na rozbudowany i skomplikowany charakter układu rurociągów, a także złożony opis właściwości fizykochemicznych samego gazu oraz uwzględnienie wielu zjawisk zachodzących podczas przepływu gazu rurociągiem, opracowanie modelu na podstawie równań fizycznych jest bardzo trudne, a identyfikacja jego parametrów sprawia dodatkowe trudności. Ponadto zwiększenie liczby wejść procesu gwałtownie

zwiększa nakłady obliczeniowe w modelowaniu neuronowym i liczbę reguł w modelowaniu rozmytym.

W pracy przedstawiono alternatywną technikę, która przewyższa ograniczenia związane z nieliniowym modelowaniem wielowymiarowym. Są to modele addytywne (ang. *additive models*) [6], które posłużyły do identyfikacji i symulacji procesu zmian ciśnień w sieci gazociągowej. Skuteczność skonstruowanych modeli została zweryfikowana na podstawie danych testowych pochodzących ze stanu normalnej eksploatacji gazociągu. W przyszłości kontynuacją tych badań będzie wykorzystanie uzyskanych modeli dla potrzeb detekcji niebezpieczeństwa instalacji gazociągowych.

## Eksploracja danych

W instalacjach przemysłowych, jakimi są sieci gazociągowe, dostępne są wartości archiwizowanych zmiennych procesowych. Dane te mogą być niekompletne, sprzeczne, niedokładne czy obciążone niepewnością. W związku z tym powstało zapotrzebowanie na nowe metody i narzędzia informatyczne, które mogą wspomóc człowieka w odkrywaniu wiedzy z danych. Jest to obszar zainteresowania nowej dziedziny nazywanej eksploracją danych (ang. *data mining*) [7]. Metody odkrywania wiedzy z danych polegają na analizie statystycznej wyników pomiarów parametrów istotnych z punktu widzenia funkcjonowania rurociągu (ciśnienia, przepływy, temperatury), tak aby szybko i trafnie rozpoznać zmiany stanu procesu w trakcie jego eksploatacji, oraz nie wymagają istotnej wiedzy na temat rurociągu ani zjawisk w nim zachodzących. W procesie odkrywania wiedzy wyróżniamy następujące ogólne etapy: zrozumienie uwarunkowań badawczych, zrozumienie danych, przygotowanie danych, modelowanie, ewaluacja i wdrożenie [7].

Na wstępie procesu odkrywania wiedzy z danych należy jasno sformułować cele i wymagania projektu w terminologii rozważanego procesu. Ponieważ model procesu zmian ciśnienia w sieci gazowej powinien jak najlepiej odwzorowywać przebieg rzeczywistych zmian stanu procesu, konieczne jest określenie zbioru sygnałów wejściowych, oddziałujących na proces i wyjściowych, będących wynikiem jego działania. 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.

Aby baza danych była przydatna do celów eksploracji danych, musi przejść przez wstępną obróbkę danych w formie czyszczenia i przekształcania danych. Dlatego należy zweryfikować, czy występują pola, które są przestarzałe lub zbędne, rekordy z brakującymi wartościami, dane znajdujące się w formacie nieodpowiednim dla modeli eksploracji danych i wartości niezgodne z zasadami lub zdrowym rozsądkiem. Kolejnym etapem jest zrozumienie danych i dokonanie wstępnej analizy danych, mającej na celu odkrycie pierwszych zależności. Na koniec należy wybrać technikę estymacji i predykcji zastosowanego modelu, pamiętając jednocześnie o dostosowaniu parametrów modelu (kalibracja modelu) oraz ocenie wyników symulacji na skalibrowanym modelu w odniesieniu do postawionych wymagań. Jeśli wyniki symulacji są niezadowalające, należy powtarzać powyższe czynności aż do momentu uzyskania poprawnych wyników.

## Addytywny model regresji


Metoda identyfikacji i symulacji oparta na addytywnym modelu regresji jest nowym podejściem w diagnostyce procesów przemysłowych i została przedstawiona w licznych publikacjach [8, 9, 10, 11, 12]. Istotę metody omówiono poniżej, w odniesieniu do sieci gazociągowej.

Dla potrzeb eksploracyjnej analizy danych z sieci gazociągowej w pracy wykorzystano modele addytywne, w następującej postaci:

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

gdzie:  $Y$  jest sygnałem wyjściowym procesu,  $X_1, X_2, \dots, X_p$  są sygnałami wejściowymi procesu dla  $p > 1$ , błąd  $\varepsilon$  jest niezależny od  $(X_1, X_2, \dots, X_p)$ ,  $E(\varepsilon) = 0$ ,  $\text{Var}(\varepsilon) = \sigma^2$  oraz  $\phi_j$  są jednowymiarowymi funkcjami zmiennej  $X_j$ , niekoniecznie liniowymi, szacowanymi na podstawie danych za pomocą nieparametrycznych technik estymacji, takich jak estymatory lokalnie wielomianowe (ang. *locally polynomial smoothers*) lub naturalne kubyczne funkcje sklepane (ang. *natural cubic splines*) [6, 8]. Metody te mają pojedyncze parametry wygładzające, które kontrolują „gładkość” estymatora funkcji regresji i zwykle ich wartości wybierane są przez optymalizację kryterium uogólnionej krosvalidacji (ang. *generalized cross-validation*) [6, 8, 12]. Podkreślimy, że nie zakładamy, że sygnały  $X_j$  są niezależne. W celu estymacji modelu addytywnego funkcje  $\phi_j$  są znajdowane za pomocą iteracyjnego algorytmu dopasowania wstecznego (ang. *backfitting algorithm*) [6, 11], dla którego udowodniono zbieżność do jednoznacznego rozwiązania [8, 11].

Model addytywny jest matematycznym modelem procesu, który wiążąc wielkości fizyczne w procesie oraz czas może posłużyć do opisu zachowania się procesu i może naśladować jego działanie. Stąd w oparciu o skonstruowany addytywny model regresji można obliczyć rozkład ciśnień w sieci na podstawie znanych, zmierzonych w rzeczywistej sieci wartości dostępnych zmiennych pomiarowych, a następnie monitorować różnice (tzw. residua  $r = y - y_m$ ) między wartościami ciśnienia  $y$  zmierzonymi w rzeczywistej sieci a wartościami ciśnienia  $y_m$  estymowanymi za pomocą modelu addytywnego. Dla większo-



Rys. 1. Schemat generowania residuów z wykorzystaniem modelu addytywnego

Fig. 1. The diagram of residuals generates based on the additive model

ści prawidłowych stanów pracy sieci gazociągowej, przy założeniu prawdziwości modelu, residua powinny być bliskie bądź równe zeru. Schemat przedstawiający generowanie residuów za pomocą modelu addytywnego przedstawiono na rys. 1.

## Weryfikacja kalibracji modelu

Zastosowanie addytywnego modelu rozkładu ciśnienia w sieci gazowej w symulacji pracy obiektu rzeczywistego wymaga jego kalibracji. Poprawnie skalibrowany model ma zdolności prognostyczne pozwalające uzyskać dostatecznie zbliżone odwzorowanie zachowania rzeczywistego systemu w zmiennych warunkach prowadzenia procesu. Stąd celem kalibracji jest uzyskanie jak najmniejszych rozbieżności między wynikami symulacji a danymi pomiarowymi. Jednocześnie należy pamiętać, iż modelowanie nie uwzględnia pewnych procesów zachodzących w świecie rzeczywistym.

Weryfikacja kalibracji modelu stanowi procedurę mającą na celu sprawdzenie jakości oszacowanego modelu, co sprowadza się do określenia, z jakim błędem model naśladowuje zachowanie się rzeczywistego procesu. Dla danych pomiarowych  $\{(x_t, y_t)\}_{t=1}^n$ , gdzie  $x_t = \{x_{tj}\}_{j=1}^p$ , rejestrowanych w trakcie eksploatacji instalacji gazociągowej przyjęto następujące wskaźniki jakości modelowania:

- średni kwadrat błędów (ang. *mean square error*)

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

- średni moduł błędów (ang. *mean-absolute deviation error*)

$$\text{MADE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (3)$$

- średni bezwzględny błąd procentowy wyrażony w zakresie pomiarowym wartości wyjścia (ang. *mean-absolute percentage error*)

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{(y_{t,\max} - y_{t,\min})} \cdot 100\% \quad (4)$$

- wariancja błędów (ang. *variance error*)

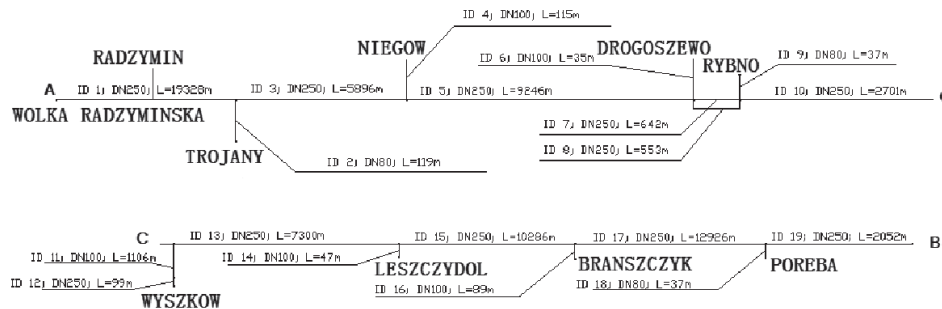
$$\text{VAR} = \frac{1}{n} \sum_{t=1}^n (y_t - \bar{\hat{y}}_t)^2 \quad (5)$$

gdzie  $y_t$  oznacza wartość zmiennej wyjściowej procesu,  $\hat{y}_t$  oznacza estymowaną wartość zmiennej wyjściowej procesu,  $y_{t,\min}$  i  $y_{t,\max}$  oznaczają odpowiednio najmniejszą i największą wartość zmiennej wyjściowej procesu,  $\bar{\hat{y}}_t$  oznacza średnią wartość estymowanej zmiennej wyjściowej procesu oraz  $n$  jest liczno-

ścią próby. Dane pomiarowe wykorzystywane podczas weryfikacji powinny pochodzić z niezależnej próby testowej, tzn. z okresu odmiennego od użytego podczas kalibracji.

### Przykład – addytywny model gazociągu

Badania przeprowadzono dla fragmentu rzeczywistej sieci przesyłowej gazu znajdującej się na dużym obszarze Polski. Wytypowany fragment sieci składa się z rurociągu głównego wraz z odnogami, które są zakończone osiemnastoma stacjami redukcyjno-pomiarowymi. W pracy podjęto próbę oszacowania modeli procesu zmian ciśnień w sieci gazociągowej dla sześciu stacji poboru gazu, odpowiednio w miejscowościach: Radzymin, Trojany, Niegów, Drogoszewo, Rybno, Leszczydół. Fragment schematu instalacji przedstawiono na rys. 2.



Rys. 2. Fragment schematu instalacji sieci gazowej  
Fig. 2. The fragment of schematic diagram of gas network

### Eksploracyjna analiza danych

Identyfikację i symulację modeli przeprowadzono przy użyciu programu R-project [13], przeznaczonego do zaawansowanych obliczeń statystycznych. Ponieważ model procesu do poprawnego działania wymaga uprzedniego nauczania, tzn. dostarczenia wiedzy o prawidłowym działaniu procesu, wybrano z bazy danych zbiór uczący, na podstawie którego szacowane będą modele cząstkowe i zbiór testowy, na podstawie którego weryfikowana będzie jakość i zdolność predykcji oszacowanych modeli. Kryterium doboru danych była jak największa zmienność sygnałów wejściowych i wyjściowych, reprezentująca najbardziej skrajne stany.

Zbrane w obiekcie surowe dane poddano wstępnej obróbce. Eksploracyjna analiza danych wykazała istnienie brakujących danych oraz obserwacji odstających. Rekordy z takimi danymi pominięto podczas analizy. Operacja ta nie doprowadziła do analizy obciążonego zbioru danych ani utraty informacji o zachowaniu się procesu.

W przypadku analizy danych pomiarowych pojawia się problem uwzględniania szumów pomiarowych, które mogą prowadzić do błędnych interpretacji zjawisk zachodzących w badanym procesie. Aby wyeliminować takie sygnały, zastosowano filtr FIR (ang. *finite impulse response filter*) lub alternatywnie filtr ARMA (ang. *autoregressive moving average filter*). Po wnikliwej analizie wywnioskowano, że do prawidłowego zamodelowania dynamiki sieci wystarczy zastosować filtry rzędu drugiego. Zwiększenie rzędu filtru nie skutkowało znaczną poprawą wyników modelowania w stosunku do wzrostu złożoności modelu.

Tab. 1. Zmienne użyte w modelowaniu  
Tab. 1. Variables used in the modelling

Ciśnienie	Stacja poboru gazu
Pwe_WolkaRadz	Wólka Radzyńska
Pwe_Radzymin	Radzymin
Pwe_Trojany	Trojany
Pwe_Niegow	Niegów
Pwe_Drogoszewo	Drogoszewo
Pwe_Rybno	Rybno
Pwe_Leszczydol	Leszczydół
Pwe_Branszczyk	Brańszczyk

Dla tak przygotowanych danych, za pomocą cząstkowych modeli addytywnych obliczany jest rozkład ciśnień w sieci na podstawie znanych, zmierzonych w rzeczywistej sieci wartości ciśnienia w sąsiednich stacjach poboru. Po uwzględnieniu braków sygnałowych (w stacjach Wyszkiw i Poręba pomiar ciśnienia nie był realizowany), do budowy modeli cząstkowych wykorzystano zmienne, których wykaz przedstawiono w tab. 1.

Poniżej zaprezentowano modele zmian ciśnień w sieci dla wybranych punktów poboru, odpowiednio dla Radzymina, Drogoszewa i Leszczydołu:

$$Pwe\_Radzymin_t = \phi_1(Pwe\_Radzymin_{t-1}) + \phi_2(Pwe\_Radzymin_{t-2}) + \phi_3(Pwe\_WolkaRadz_{t-1}) + \phi_4(Pwe\_WolkaRadz_{t-2}) + \varepsilon_t, \quad (6)$$

$$Pwe\_Drogoszewo_t = \psi_1(Pwe\_Niegow_{t-1}) + \psi_2(Pwe\_Niegow_{t-2}) + \psi_3(Pwe\_Rybno_{t-1}) + \psi_4(Pwe\_Rybno_{t-2}) + \varepsilon_t, \quad (7)$$

$$Pwe\_Leszczydol_t = \chi_1(Pwe\_Trojany_{t-1}) + \chi_2(Pwe\_Trojany_{t-2}) + \chi_3(Pwe\_Rybno_{t-1}) + \chi_4(Pwe\_Rybno_{t-2}) + \chi_5(Pwe\_Drogoszewo_{t-2}) + \chi_6(Pwe\_Drogoszewo_{t-2}) + \varepsilon_t, \quad (10)$$

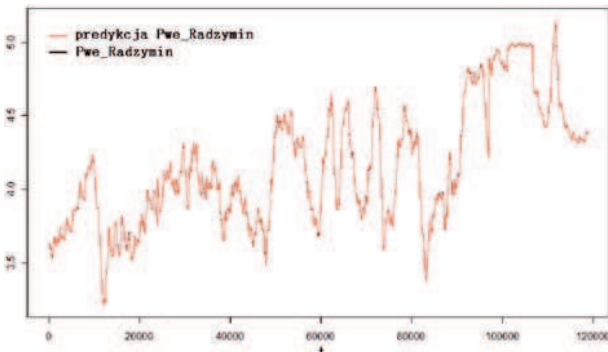
gdzie  $\phi_1, \dots, \phi_4, \psi_1, \dots, \psi_4, \chi_1, \dots, \chi_6$  są jednowymiarowymi funkcjami poszczególnych sygnałów oraz  $\varepsilon_t$  dla  $t=3, \dots, n$  są niezależnymi zakłóceniami losowymi.

Na podstawie modeli (6)–(8) można wyznaczyć residua  $r_t = Pwe_t - \hat{Pwe}_t$  które są przybliżeniem błędów  $\varepsilon_t$ .

### Wyniki modelowania

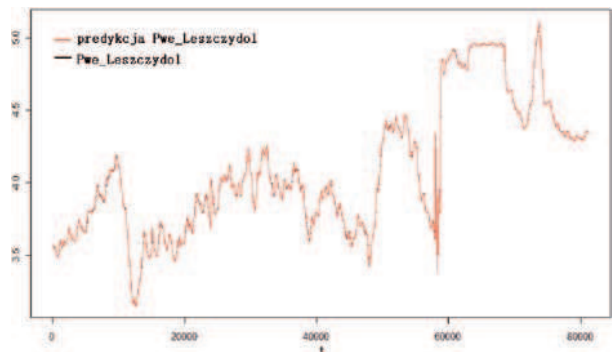
W celu estymacji modeli addytywnych (6) – (8) wybrano algorytm dopasowania wstecznego z naturalną kubiczną funkcją sklejaną z parametrem wygładzającym  $df = 4$ , utożsamianym z liczbą stopni swobody [6, 12]. Na podstawie danych uczących i testowych, pochodzących ze stanu zdatności procesu, otrzymano estymowane wartości ciśnienia gazu (predykcja Pwe\_) wraz z rzeczywistymi wartościami ciśnienia gazu danymi z procesu (Pwe\_), których wykresy przedstawiono na rys. 3–8.

Przebiegi wyników modelowania niemalże idealnie nadążają za rzeczywistym procesem.



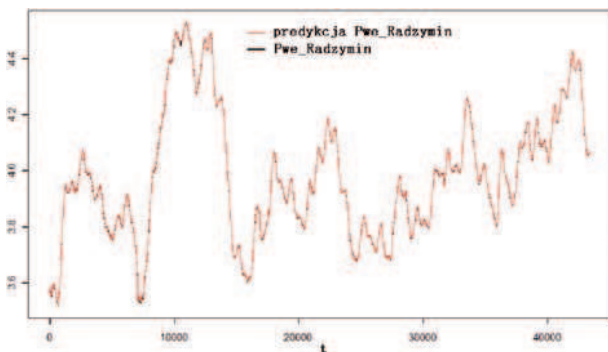
**Rys. 3.** Przebieg ciśnienia pomierzonego i modelowanego w Radzyminie dla próby uczącej

**Fig. 3.** The process of pressure measured and modelled in Radzymin for the learning sample



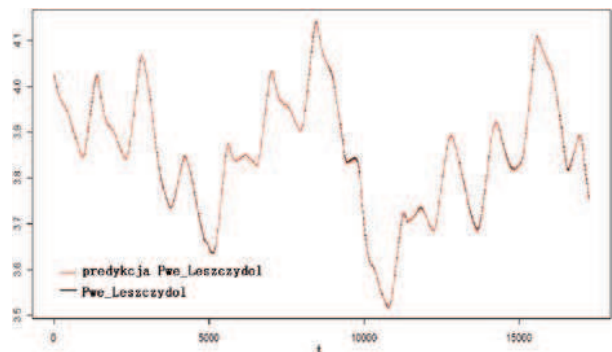
**Rys. 7.** Przebieg ciśnienia pomierzonego i modelowanego w Leszczynie dla próby uczącej

**Fig. 7.** The process of pressure measured and modelled in Leszczyno for the learning sample



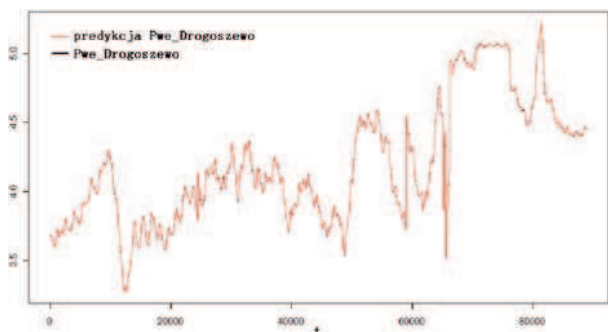
**Rys. 4.** Przebieg ciśnienia pomierzonego i modelowanego w Radzyminie dla próby testowej

**Fig. 4.** The process of pressure measured and modelled in Radzymin for the training sample



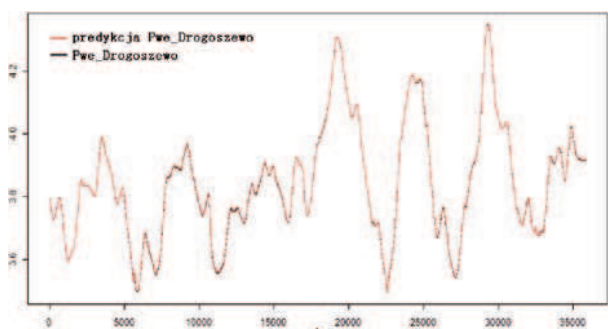
**Rys. 8.** Przebieg ciśnienia pomierzonego i modelowanego w Leszczynie dla próby testowej

**Fig. 8.** The process of pressure measured and modelled in Leszczyno for the training sample



**Rys. 5.** Przebieg ciśnienia pomierzonego i modelowanego w Drogoszewie dla próby uczącej

**Fig. 5.** The process of pressure measured and modelled in Drogoszewo for the learning sample



**Rys. 6.** Przebieg ciśnienia pomierzonego i modelowanego w Drogoszewie dla próby testowej

**Fig. 6.** The process of pressure measured and modelled in Drogoszewo for the training sample

### Wyniki jakości modelowania

W celu dokonania oceny pracy zaproponowanych modeli obliczono wartości miar dopasowania (4) – (7), a także minimalne i maksymalne wartości otrzymanych residuów. Wyniki zostały przedstawione w tab. 2.

**Tab. 2.** Wskaźniki jakości dopasowania dla poszczególnych modeli addytywnych

**Tab. 2.** Criteria of the individual additive models fitting

Miara	Próba ucząca			Próba testowa		
	Radz.	Drog.	Leszcz.	Radz.	Drog.	Leszcz.
MSE	2e-06	1e-06	1e-06	1e-06	2e-06	1e-06
MADE	9e-04	8e-04	0,001	0,001	0,002	0,001
MAPE (%)	0,045	0,047	0,066	0,116	0,173	0,212
VAR	1e-06	1e-06	1e-06	1e-06	1e-06	1e-06
Min. residuum	-0,02	-0,01	-0,01	-0,05	-0,01	-0,008
Max. residuum	0,022	0,01	0,007	0,027	0,02	0,012



## Podsumowanie

Dokładność identyfikacji i symulacji, a w konsekwencji poprawne działanie systemu monitorującego 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 rozkładu ciśnienia w ściśle określonym węzle sieci gazociągowej za pomocą addytywnego modelu regresji. 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 jednoznacznego rozwiązania i nie wymaga dużych nakładów obliczeniowych.

Otrzymane wyniki badań są zadowalające, gdyż zaprezentowane metody pozwoliły na skonstruowanie modeli dobrze odzwierciedlających dynamikę procesu, co pozwoli w dalszym etapie badań na ich wykorzystanie w celach detekcji uszkodzeń.

## Podziękowania

Przedstawione badania zostały częściowo przeprowadzone w ramach projektu rozwojowego pt. *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.

## Bibliografia

- Grygorowicz J., Warowny W.: *Równania stanu w przemyśle naftowym i gazowniczym*, Nafta – Gaz, 54, 1998, s. 15–23.
- Warowny W.: *Kubiczne równania stanu i ich wykorzystanie w gazownictwie ziemnym*, Nafta – Gaz, 10, 2007, s. 613–623.
- Osiadacz A.J.: *Simulation and Analysis of Gas Networks*, Gulf Publishing Company, 1987.
- Neuroth M., MacConnell P., Stronach F., Vamplle P.: *Improved modeling and control of oil and gas transport facility operations using artificial intelligence*, Knowledge-Based Systems, 13, 2000, s. 81–92.
- Kogut K.: *Możliwości wykorzystania sztucznych sieci neuronowych w analizie pracy sieci przesyłowej gazu ziemnego*, Nowoczesne Gazownictwo, 3, 2004, s. 1–4.
- Hastie T., Tibshirani R.: *Generalized additive models*, Chapman and Hall, 1990.
- Larose D.T.: *Discovering Knowledge in Data: An Introduction to DATA MINING*, Wiley, 2005.
- Łabęda Z.M.: *Wykorzystanie addytywnego modelu regresji w eksploracyjnej analizie danych*. VI Sympozjum Modelowanie i Symulacja Komputerowa w Technice, Łódź 2008.
- Łabęda Z.M.: *Additive model applications for the fault detection of actuators*, Pomiary Automatyka Kontrola, Vol.55, s. 152–155, (3)2009.
- Łabęda Z.M.: *Modele addytywne w układzie detekcji uszkodzeń w stacji wyparnej*. IX Międzynarodowa Konferencja Diagnostyka Procesów i Systemów, Gdańsk 2009, „Systemy wykrywające, analizujące i tolerujące usterki. Automatyka i Informatyka”, Pomorskie Wydawnictwo Naukowo-Techniczne, rozdział 13, s. 113–120.
- Łabęda Z.M.: *The backfitting and marginal integration estimators for additive models*. IV Konferencja Naukowo-Techniczna Doktorantów i Młodych Naukowców, Warszawa, 2009, materiały konferencyjne, s. 307–314.
- Łabęda Z.M.: *Smoothing parameters selection in the additive regression models approach for the fault detection scheme*, IV Konferencja Naukowo-Techniczna Doktorantów i Młodych Naukowców, Warszawa, 2009, materiały konferencyjne, s. 299–306.
- Good P.I.: *Introduction to statistics through resampling methods and R/S-PLUS*, Wiley, 2005. ■

### The identification and simulation of pressure decomposition in gas network using additive regression model

In this paper identification and simulation methods to predict pressure values at determined nodes and to analyse the operation of gas network is presented. The proposed method is based on additive models and knowledge discovery data application. The backfitting algorithm with nonparametric smoothness techniques has been used for estimating the additive model. The results of modeling has been presented. All research has been carried out based on the part of long range gas pipelines. Received results are satisfactory because the proposed method is very suitable for the multivariate dynamical process fitting in the analyzed structures.

**Keywords:** additive model, gas pipelines, simulation, pressure prediction, data mining

#### mgr Zofia Magdalena 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