

Piotr PRZYSTAŁKA, Ryszard WYCZÓŁKOWSKI
KATEDRA PODSTAW KONSTRUKCJI MASZYN, POLITECHNIKA ŚLĄSKA,
ul. Konarskiego 18a, 44-100 Gliwice

Detekcja małych wycieków w sieciach wodociągowych z zastosowaniem metody modelowania niepewności

Dr inż. Piotr PRZYSTAŁKA

Jest adiunktem w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej. Obszar zainteresowań naukowo-badawczych autora obejmuje: mechatronikę, automatykę i robotykę, diagnostykę techniczną, informatykę stosowaną. Głównym przedmiotem jego działalności naukowej jest zagadnienie stosowania metod i technik sztucznej inteligencji w sterowaniu i diagnozowaniu różnych klas obiektów technicznych.



e-mail: piotr.przystalka@polsl.pl

Dr inż. Ryszard WYCZÓŁKOWSKI

Jest zatrudniony na stanowisku adiunkta w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej. Zainteresowania naukowe: metodologia projektowania, diagnostyka techniczna a w szczególności zastosowanie metod sztucznej inteligencji w tych dziedzinach.



e-mail: ryszard.wyczolkowski@polsl.pl

Streszczenie

W artykule przedstawiono badania dotyczące detekcji małych wycieków pojawiających się w sieciach wodociągowych. W celu detekcji uszkodzeń zastosowano schemat diagnozowania w oparciu o residua wygenerowane za pomocą przybliżonych modeli obiektu. Część decyzyjną realizującą ocenę wartości chwilowych residuów opracowano na podstawie metody modelowania niepewności. Uzyskane wyniki badań potwierdzają poprawność zastosowanego rozwiązania.

Słowa kluczowe: sieci wodociągowe, detekcja wycieków bazująca na modelu, odporna detekcja wycieków, modelowanie niepewności.

Small leakage detection in water distribution systems with use of the model error modelling method

Abstract

This paper considers the problem of small leakage detection in urban water supply networks. In order to detect leakage, the model-based fault diagnosis scheme was used. Nonlinear autoregressive exogenous models were applied to residual generation. A nonlinear part of the model was worked out with use of a multilayer perceptron neural network. Residual evaluation was realised basing on the model error modelling method. This method was modified to obtain a new scheme for adaptive threshold generation. In the case study reported in this paper the authors present the fault detection experiments with use of the industrial data set. The obtained results of small leakage detection in the considered water supply network confirm the effectiveness of the proposed approach. The paper is organized as follows. The first section deals with the introduction to the study. The second one includes a description of the proposed method. In the next section there are presented the results that were obtained by the authors. Finally, the paper ends with the conclusions.

Keywords: urban water supply networks, model-based leakage detection, robust leakage detection, uncertainty modelling.

1. Wprowadzenie

Sieci wodociągowe pełnią bardzo ważną rolę zarówno dla obiektów przemysłowych jak również dla odbiorców indywidualnych. W sieciach wodociągowych zdarzają się niekontrolowane wycieki o różnym nasileniu i lokalizacji. Istnieją dwa poważne następstwa tego typu uszkodzenia. Pierwsze z nich to straty ekonomiczne, drugie to bezpośrednie zagrożenie ludzkiego życia w wyniku skażenia wody poprzez wprowadzenie zanieczyszczenia do sieci pracującej w stanie obniżonego ciśnienia roboczego [3, 14]. Takie warunki pracy obiektu powodują konieczność bieżącego monitoringu w celach detekcji i lokalizacji wycieków oraz skażenia wody. Istnieje wiele metod umożliwiających rozwiązanie przytoczonych problemów. Do najważniejszych metod detekcji i lokalizacji wycieków, które doczekały się implementacji w systemach przemysłowych, można zaliczyć [4, 14]: analizę

zmienności przepływu na wejściu sieci w godzinach nocnych, krokowe testowanie (ang. step testing), badanie korelacji szumu wycieku (ang. leak noise correlators), inspekcja z zastosowaniem georadaru (ang. ground penetrating radar inspection). Z drugiej strony, jednym z podstawowych sposobów diagnozowania przyczyn skażenia wody jest monitorowanie sieci wodociągowej w strategicznych punktach z zastosowaniem specjalistycznych czujników jakości wody [3]. Głównymi wadami tego typu podejść do diagnozowania sieci wodociągowej są: konieczność stosowania specjalistycznego oprzyrządowania pomiarowego, konieczność przeprowadzenia eksperymentów czynnych na obiekcie, potrzeba dużego doświadczenia osoby nadzorującej proces diagnozowania, brak możliwości diagnozowania w sposób automatyczny, długi czas diagnozowania oraz brak sprzężenia zwrotnego.

Obecnie zauważalny jest rozwój metod i środków, które pozwalają diagnozować on-line w sposób automatyczny na podstawie mierzonych zmiennych procesowych takich jak np. wartości przepływów i/lub ciśnień chwilowych w wybranych punktach sieci wodociągowej. Przykłady takiego sposobu diagnozowania obiektu tego typu można znaleźć w pracach [1, 3, 5, 7, 15]. Jak można zauważyć, stosowane są zarówno metody bazujące na modelu obiektu jak również metody, w których wykorzystywane są zmienne procesowe w sposób bezpośredni. Biorąc pod uwagę szybki rozwój metodologii diagnostyki procesów [6, 10], a w szczególności koncepcji diagnozowania odpornego na różne źródła niepewności [2, 9] można spodziewać się, że zastosowanie tych metod pozwoli rozwiązać problem szybkiej detekcji i lokalizacji wycieków już w początkowej fazie ich rozwoju.

W niniejszym artykule przedstawiono wyniki detekcji małych wycieków w wybranej strefie sieci wodociągowej miasta Rybnik uzyskane w oparciu o klasyczny schemat diagnozowania z zastosowaniem modelu przybliżonego obiektu. Modele utworzono dla stanu pełnej zdatności i na ich podstawie generowano residua, które oceniano za pomocą zmiennych progów decyzyjnych. Wartości chwilowe progów decyzyjnych wyliczono na podstawie modeli błędów modeli przybliżonych. Szczegółowy opis zastosowanej tu metodyki z przykładowymi aplikacjami praktycznymi można znaleźć w pracach [11] i [12].

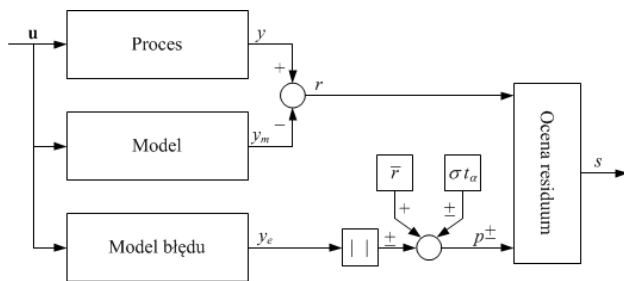
2. Opis metody

Na rys. 1 zilustrowano ideę metody detekcji wycieków w oparciu o przybliżone modele wejściowo-wyjściowe oraz odpowiadające im modele błędów. Podejście to jest zgodne z ogólną koncepcją opisaną w pracy [13], przy czym zastosowano tu oryginalny sposób oceny residuum. Sposób diagnozowania przedstawiony na rysunku jest następujący. W pierwszej kolejności sygnał zmiennej procesowej mierzonej w wybranym punkcie strefy (przepływ z wybranego przepływomierza) porównywany jest z sygnałem wyliczonym za pomocą przybliżonego modelu obiektu. W wyniku tej operacji uzyskiwane jest residuum. Sygnały wejściowe (prze-

plywy z innych przepływomierzy tej strefy), na podstawie których wyznaczane jest wyjście przybliżonego modelu obiektu stanowią jednocześnie wejścia modelu błędu modelu (modelu residuum). Na tej podstawie wyznaczana jest estymowana wartość błędu modelu w danej chwili. Wygenerowane sygnały przekazywane są do bloku oceniającego, którego zadaniem jest wygenerowanie sygnału diagnostycznego. W celu detekcji ocena ta przebiega w oparciu o zmienne progi decyzyjne wyliczane na podstawie zależności:

$$p_{\pm}(k) = \bar{r} \pm t_{\alpha} \sigma_r \pm |y_e(k)|, \quad (1)$$

gdzie \bar{r} – średnia wartość residuum uzyskana podczas testowania przybliżonego modelu wejściowo-wyjściowego, σ_r – odchylenie standardowe uzyskane dla residuum podczas testowania przybliżonego modelu wejściowo-wyjściowego, t_{α} – poziom istotności testu bloku decyzyjnego, $y_e(k)$ – estymowana wartość błędu przybliżonego modelu wejściowo-wyjściowego.



Rys. 1. Schemat detekcji wycieków w oparciu o zmienne progi decyzyjne
Fig. 1. Leakage detection with use of adaptive thresholds

Binarny sygnał diagnostyczny generowany jest w przypadku, gdy:

$$s(k) = \begin{cases} 0 & \text{dla } p_+(k) \geq r(k) \geq p_-(k) \\ 1 & \text{dla } p_+(k) < r(k) < p_-(k) \end{cases} \quad (2)$$

gdzie $r(k)$ – chwilowa wartość residuum.

Istnieje wiele różnych klas modeli przybliżonych, które można zastosować w celu realizacji podstawowych konfiguracji zależności pomiędzy zmiennymi procesowymi (modelu obiektu). W badaniach ograniczono się do modeli NARX (ang. nonlinear autoregressive exogenous model), w których część nieliniową realizowano z zastosowaniem jednokierunkowej sieci neuronowej. Identyfikacja takich modeli prowadzona jest w czterech głównych etapach polegających na: zgromadzeniu danych, zdefiniowaniu struktury modelu, estymacji nieznanymi parametrów modelu na podstawie zgromadzonych danych, ocenie dokładności modelu w świetle określonych kryteriów. W celu zgromadzenia danych wykorzystywany jest model hydrauliczny sieci wodociągowej. Ponadto wykorzystuje się dane z obiektu rzeczywistego zgromadzone w bazie danych systemu pomiarowego. Swobodne parametry modelu NARX dostraja się przy użyciu metody Levenberga-Marquardta. W niniejszych badaniach konfiguracje wejść i wyjść modeli wskazywano na podstawie analizy statystycznej (np. na podstawie analizy współczynnika korelacji Pearsona lub miary informacji wzajemnej pomiędzy zmiennymi procesowymi). Ponadto podczas budowy modelu procesu istniał dostęp do wiedzy eksperckiej, co umożliwiło ograniczenie zbioru wszystkich możliwych kombinacji zmiennych procesowych. Zadanie doboru struktury modelu NARX rozwiązano stosując zasadę oszczędności i kryterium informacyjne Schwarza w postaci [8]:

$$\text{BIC} = N \ln(Q_G) + p \ln(N), \quad (3)$$

gdzie N – liczba próbek szeregu testowego, p – złożoność modelu (liczba swobodnych parametrów modelu pomnożona przez liczbę wejść modelu), Q_G jest wybraną miarą jakości odwzorowania dynamiki procesu wyznaczoną dla zbioru danych testowych.

W celu oceny jakości odwzorowania posłużono się średnim bezwzględnym błędem procentowym wyliczonym z zależności:

$$\text{MAPE} = \frac{100\%}{kN} \sum_{j=1}^k \sum_{i=1}^N \frac{y_{ij} - \hat{y}_{ij}}{Y}, \quad (4)$$

gdzie y_{ij} – sygnał mierzony na monitorowanym obiekcie, \hat{y}_{ij} – wartość wyliczona za pomocą modelu przybliżonego, Y – zakres zmienności sygnału mierzonego, k – liczba wyjść modelu.

Jak było wspomniane wcześniej wartości progów decyzyjnych wyliczane są na podstawie modelu błędu modelu (ang. error model). Sposób wyznaczenia modelu błędu jest następujący (wg [13]). Dla utworzonego przybliżonego modelu obiektu w stanie pełnej zdadności generuje się residua r dla bieżącego stanu bez wycieków jednocześnie rejestrując wejścia u modelu obiektu. Dla tak zgromadzonych danych tworzy się model zależności $y_e=f(u)$ z wykorzystaniem wybranej metody identyfikacji parametrycznej, co prowadzi do utworzenia modelu błędu.

3. Badania weryfikacyjne

W celu praktycznej weryfikacji metody detekcji małych wycieków pojawiających się w sieciach wodociągowych wykorzystano dane historyczne zgromadzone na obiekcie rzeczywistym. Dane te obejmowały kilka miesięcy pracy sieci wodociągowej i dotyczyły pomiarów przepływów w wybranych punktach strefy Kamień miasta Rybnik. Biorąc pod uwagę przytoczone warunki eksploatacyjne wytypowano dwa eksperymenty diagnostyczne:

1. Przykład pierwszy dotyczy testu, w którym rozpatruje się uszkodzenia FAULT1 oznaczające niesklasyfikowany wyciek w wyniku uszkodzenia rurociągu o średnicy $\varnothing 32$, oraz FAULT2 - niesklasyfikowany wyciek w wyniku uszkodzenia rurociągu o średnicy $\varnothing 50$.
2. Drugi przykład dotyczy testu, w którym rozpatruje się uszkodzenie FAULT4 oznaczające mały wyciek spowodowany urwaniem rurociągu o średnicy $\varnothing 40$.

Na Rys. 2 przyjęto następujące oznaczenia: FAULT1_DETECTION_TIME - moment zgłoszenia uszkodzenia przez dozór techniczny, FAULT1_FLOW_STOP - moment odcięcia wody w celu usunięcia uszkodzenia, FAULT1_FLOW_START - moment przywrócenia dostaw wody.

W celu utworzenia przybliżonych modeli wejściowo-wyjściowych wytypowano dwie zależności, które zamieszczono w tab. 1. Dane trenujące niezbędne do identyfikacji modelu mQ1 obejmowały okres od 2008-02-01 do 2008-02-26. Dane z przedziału czasu od 2008-02-27 do 2008-03-11 wykorzystano na etapie weryfikacji klasyfikatora KkmQ1 działającego w oparciu o model mQ1. Podobnego podziału dokonano dla drugiego eksperymentu diagnostycznego. Zbiór trenujący dla modelu mQ2 obejmował okres od 2008-09-03 do 2008-10-11. Dane weryfikacyjne do testowania klasyfikatora KkmQ2 pochodziły z okresu od 2008-10-12 do 2008-10-24.

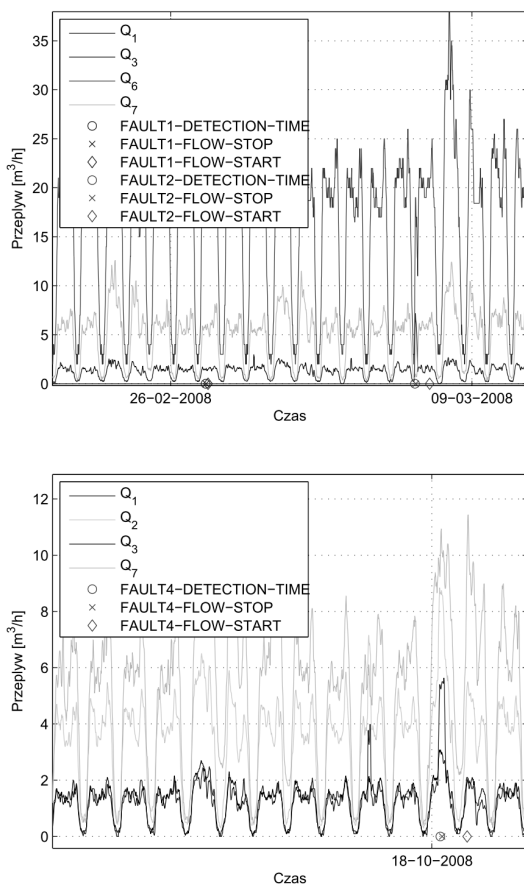
Tab. 1. Wykaz wejść i wyjść przybliżonych modeli zmian przepływu wody dla wytypowanych zależności

Tab. 1. Inputs and outputs of water flow models for the selected relations

Id zal.	Id m.	Identyfikatory przepływomierzy						
		Q1	Q2	Q3	Q4	Q5	Q6	Q7
1	mQ1	-	-	-	-	-	WE	WY
2	mQ2	-	WE	WY	-	-	-	WE

Wskazane w tab. 1 zależności pomiędzy wytypowanymi zmiennymi procesowymi odwzorowano z zastosowaniem modeli klasy NARX. W modelach tych część nieliniową realizowano z zastosowaniem wielowarstwowych sieci neuronowych typu perceptronowego. Zastosowano sieć z jedną warstwą ukrytą wyposażoną w sześć jednostek, które posiadały tangensoidalną funk-

cję wyjścia. Dla każdego przypadku swobodne parametry modelu neuronowego wyznaczano przy użyciu algorytmu Levenberga-Marquardta (100 epok, $\lambda=1E-3$, $\text{dec}=0.1$, $\text{inc}=10$). Struktury modeli dla poszczególnych zależności dobierano stosując kryterium Schwarza (BIC) oraz zasadę oszczędności ($n_{a1}=[0]$, $n_{b1}=[2]$, $n_1=6$; $n_{a2}=[0]$, $n_{b2}=[2\ 2]$, $n_2=6$). Dokładność utworzonych modeli oceniono używając miary MAPE. Otrzymane wyniki testowania przybliżonych modeli wytypowanych zależności pomiędzy zmiennymi procesowymi zestawiono w tab. 2.



Rys. 2. Wizualizacja zmiennych procesowych
Fig. 2. Visualization of the process variables

Następnie opracowano modele błędów modeli mQ1 i mQ2. Dane trenujące i testowe do tego celu pozyskano w wyniku symulacji modeli wejściowo-wyjściowych dla stanu pełnej zdadności obiektu. Modele błędów modeli zostały utworzone z zastosowaniem parametrycznych modeli ARX. Podczas badań swobodne parametry tych modeli wyznaczano za pomocą metody najmniejszych kwadratów a ich struktury dobierano z zastosowaniem zasady oszczędności. Najlepsze wyniki uzyskano dla struktury $n_a=[1]$, $n_b=[1]$ (model błędu dla mQ1) i $n_a=[1]$, $n_b=[1,1]$ (model błędu dla mQ2). Uzyskane oceny w postaci błędu średniokwadratowego (MSE) zamieszczono w ostatnich kolumnach tab. 2.

Tab. 2. Wyniki ilościowej oceny modeli
Tab. 2. Quality measures of the models

Id m.	M. procesu		M. błędu
	MAPE	BIC	MSE
mQ1	3.96	4335.98	8.23E-3
mQ2	4.07	1522.22	6.19E-3

Parametry bloków decyzyjnych klasyfikatorów KKmQ1 i KKmQ2 wyznaczono przy użyciu danych testowych z etapu


tworzenia przybliżonych modeli wejściowo-wyjściowych. Wartości wyznaczonych parametrów zamieszczone są w tab. 3.


Tab. 3. Wartości parametrów bloków decyzyjnych opracowanych klasyfikatorów
Tab. 3. Coefficient values of decision making blocks of the elaborated classifiers

Id	\bar{r}	σ_r	t_α
KKmQ1	-0.97	1.29	3
KKmQ2	0.03	0.13	3

Odpowiedzi modeli mQ1 i mQ2 w wyniku symulacji przy użyciu danych weryfikacyjnych przedstawiono na rys. 3. Na rysunku tym można zaobserwować miejsca przekroczenia progów decyzyjnych przez generowane residua.

Jak można zauważyć wartości progowe charakteryzują się pewną okresowością wynikającą z charakteru zmienności profilu zużycia wody przez użytkowników sieci wodociągowej (wyższa wartość progów dla okresu dziennego i wieczornego, niższa dla okresu nocnego). Pierwsze dwa wykresy przedstawiają działanie klasyfikatora KKmQ1, z kolei następne dwa obrazują odpowiedzi klasyfikatora KKmQ2. Jak można zauważyć jedynie uszkodzenie FAULT1 nie zostało wykryte co jest prawdopodobnie spowodowane tym, że amplituda wycieku mieściła się w zakresie błędów pomiarowych przepływomierzy. Należy również podkreślić, że uzyskano bardzo małą liczbę fałszywych alarmów. W przedstawionych badaniach weryfikacyjnych nie wyznaczono ocen sprawności klasyfikatorów ze względu na brak precyzyjnej informacji o czasie występowania wycieku.





Rys. 3. Wyniki testowania klasyfikatorów KKMq1 i KKMq2
Fig. 3. The verification results of KKMq1 and KKMq2 classifiers

4. Wnioski i podsumowanie

W artykule pokazano, że możliwe jest praktyczne zastosowanie schematu diagnozowania w oparciu o model obiektu w celu wykrywania małych wycieków w sieciach wodociągowych. Zastosowanie przybliżonych modeli obiektu klasy NARX w celu generowania residuów oraz metody modelowania niepewności zaproponowanej w pracy [13] do oceny tak generowanych residuów pozwala na uzyskanie wysokiej sprawności systemu detekcji małych wycieków. Opracowane podejście do wykrywania tego typu uszkodzeń może być zastosowane zarówno podczas pracy obiektu w godzinach nocnych jak również dziennych. W przebiegach wyliczanych progów decyzyjnych można zauważyć, że ich wartości zależą od pory dnia. Niskie wartości progów uzyskuje się podczas pracy obiektu w nocy oraz wysokie dla godzin dziennych. Ponadto wartości zmiennych progów decyzyjnych zróżnicowane są pod względem dnia tygodnia przez co dodatkowo uwzględnione są czynniki wynikające z różnego obciążenia sieci w skali czasu makro (zróżnicowanie zapotrzebowania na wodę przez odbiorców ze względu na dzień tygodnia).

Podczas prowadzenia badań weryfikacyjnych nasunęło się pytanie co do wpływu niepewności modelu błędu modelu na przebieg procesu diagnozowania. Analiza tego czynnika wydaje się problemem ciekawym do rozważenia w dalszych badaniach. Ponadto przewiduje się zastosowanie innych klas modeli przybliżonych oraz metod estymowania niepewności w celu wyliczania zmiennych progów decyzyjnych.

Badania finansowane częściowo ze środków projektu POIG 01.04.00-24-027 pt. "Zintegrowany, inteligentny system monitorowania i zarządzania siecią wodociągów na terenie działalności PWiK Sp. z o.o. w Rybniku" oraz częściowo ze środków przeznaczonych na badania statutowe w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach.

5. Literatura

- [1] Blesa, J., Puig, V., Saludes, J. and Vento, J. (2010). Leak detection, isolation and estimation in pressurized water pipe networks using LPV models and zonotopes, The 8th IFAC Symposium on Nonlinear Control Systems, pp. 36–41.
- [2] Chen, J. and Patton, R. J. (1998). Robust Model-Based Fault Diagnosis for Dynamic Systems, Kluwer Academic Publishers, Norwell, MA, USA.
- [3] Eliades, D. and Polycarpou, M. (2010). A fault diagnosis and security framework for water systems, IEEE Transactions on Control Systems Technology 18/6: 1254–1265.
- [4] Geiger, G., Werner, T. and Matko, D. (2003). Leak detection and locating – A survey, 35th Annual PSIG Meeting.
- [5] Gertler, J., Romera, J., Puig, V. and Quevedo, J. (2010). Leak detection and isolation in water distribution networks using PCA and structured residuals, Control and Fault-Tolerant Systems (SysTol), pp. 191–196.
- [6] Isermann, R. (2006). Fault-Diagnosis Systems. An Introduction from Fault Detection to Fault Tolerance, Springer.
- [7] Jezior, K., Mazur, K., Borowa, A., Grochowski, M. i Brdyś, M. (2007). Multiregional PCA for leakage detection and localisation in DWDS - Chojnice case study, in J. Korbicz, K. Patan and M. Kowal (Eds), Fault Diagnosis and Fault Tolerant Control, Academic Publishing House EXIT, pp. 303–310.
- [8] Konishi, S. and Kitagawa, G. (2008). Information Criteria and Statistical Modeling, Springer Science+Business Media, LLC.
- [9] Korbicz, J. (2006). Robust fault detection using analytical and soft computing methods, Bulletin of the Polish Academy of Sciences: Technical Sciences 54(1): 75–88.
- [10] Korbicz, J., Kościelny, J. M., Kowalczyk, Z. and Cholewa, W. (Red.) (2004). Fault diagnosis. Models, artificial intelligence, applications, Springer Berlin/Heidelberg.
- [11] Moczulski, W., Wyczółkowski, R., Ciupke, K., Tomasik, P., Wachla, D., Przystałka, P. i Wiglenda, R. (2011). Metodyka budowy systemu monitorowania wycieków w sieciach wodociągowych, Diagnostics of Processes and Systems, Zamość.
- [12] Moczulski, W., Wyczółkowski, R., Ciupke, K., Tomasik, P., Wachla, D., Przystałka, P. i Wiglenda, R. (2011). Metodyka budowy systemu monitorowania wycieków w sieciach wodociągowych - przykład zastosowania, Diagnostics of Processes and Systems, Zamość.
- [13] Patan, K. (2007). Robust fault diagnosis in a DC motor by means of artificial neural networks and model error modelling, in M. K. ed. by J. Korbicz, K. Patan (Ed.), Fault diagnosis and fault tolerant control, Academic Publishing House EXIT, Warsaw, pp. 337–346.
- [14] Puust, R., Kapelan, Z., Savic, D. and Koppel, T. (2010). A review of methods for leakage management in pipe networks, Urban Water Journal 7/1: 25–45.
- [15] Tetzner, R. (2003). Model-based pipeline leak detection and location 3R International [42] Heft 7/2003.