

METODA DETEKCCI WYCIEKÓW W SIECIACH WODOCIĄGOWYCH Z ZASTOSOWANIEM MODELI NLARX

Piotr Przystalka

Instytut Podstaw Konstrukcji Maszyn, Politechnika Śląska
e-mail: piotr.przystalka@polsl.pl

Streszczenie

W artykule zaprezentowano metodę detekcji wycieków w rozdzielczych sieciach wodociągowych z zastosowaniem klasycznego schematu diagnozowania bazującego na modelu monitorowanego obiektu. Omówiono sposób modelowania zależności pomiędzy zmianami przepływów wody z wykorzystaniem nieliniowych modeli autoregresyjnych z zewnętrznym wejściem oraz przedstawiono sposób ich użycia do detekcji wycieków. Poprawność proponowanego podejścia zilustrowano na podstawie eksperymentu dla wybranej dzielnicy miasta Rybnik.

LEAKAGE DETECTION METHOD IN WATER SUPPLY NETWORKS USING NLARX MODELS

Summary

The paper focuses on the leakage detection method in water supply networks with the use of the model-based fault detection approach. Non-linear autoregressive exogenous models are employed to find the relationship between water flow rates. These models are used to the leakage detection purpose. The merits and limits of the proposed method are illustrated for experiments dealing with the district management zone of Rybnik's water distribution network.

1. WSTĘP

Sieci wodociągowe to megaukłady techniczne o dużym znaczeniu dla odbiorców przemysłowych i indywidualnych. W sieciach tego typu dochodzi do niekontrolowanych wycieków. Następstwem takiego uszkodzenia jest bezpośrednie zagrożenie ludzkiego zdrowia i życia (np. w wyniku zanieczyszczenia wody) oraz straty ekonomiczne [2,3]. Przytoczone argumenty stanowią przesłanki do tego, że istnieje konieczność bieżącego monitorowania takich obiektów w celu detekcji i lokalizacji wycieków oraz skażenia wody. Ograniczając rozważania dotyczące przeglądu literatury do tematyki artykułu, można zauważyć, że najskuteczniejszą metodą detekcji wycieków, która doczekała się implementacji w systemach przemysłowych, jest analiza zmienności przepływu na zasilaniu sieci w godzinach nocnych [14]. Z drugiej

strony, coraz częściej sięga się do metod, które pozwalają na detekcję wycieków w sposób automatyczny na podstawie mierzonych zmiennych procesowych, takich jak np. wartości zmian przepływów oraz zmian ciśnień chwilowych wody w wybranych punktach sieci wodociągowej. Obecnie stosowane są metody diagnozowania bezpośredniego (diagnostyka symptomowa) oraz schematy diagnozowania na podstawie modelu sieci wodociągowej [2,6,9,10,14]. W dziedzinie diagnostyki technicznej szczególnie obiecujący jest intensywny rozwój metod diagnozowania odpornych na różne źródła niepewności [5,7,8]. Metody te mogą stanowić rozwiązanie problemu szybkiej detekcji oraz dokładnej lokalizacji wycieków już w początkowej fazie ich

występowania (szczególnie wtedy, gdy takie wycieki nie manifestują się na powierzchni gleby).

Głównym założeniem prezentowanych w artykule badań jest opracowanie takiego sposobu detekcji wycieków, który będzie umożliwiał ich wykrywanie nie tylko w godzinach nocnych (jak to się dzieje obecnie), ale również w ciągu całego dnia, kiedy zużycie wody ma charakter mocno niezdeterminowany. W niniejszym artykule przedstawiono metodę i wyniki detekcji wycieków w wybranej strefie sieci wodociągowej miasta Rybnik, uzyskane na podstawie proponowanego sposobu modelowania obiektu tej klasy. Szczegółowy opis problemu, o którym jest mowa z przykładowymi rozwiązaniami praktycznymi, można znaleźć w pracy [9]. Należy w tym miejscu zaznaczyć, że prezentowane tu badania są uzupełnieniem wyników rozważań zapoczątkowanych wspólnie z R. Wyczółkowskim i przedstawionych w [12].

2. METODA DETEKЦИИ WYCIEKÓW Z ZASTOSOWANIEM MODELI NLARX

2.1 MODELE NLARX

Rozdzielcze sieci wodociągowe to obiekty techniczne o p wejściach i q wyjściach, które mogą być modelowane za pomocą nieliniowych modeli autoregresyjnych z zewnętrznym wejściem (ang. *NonLinear Autoregressive model with Exogenous Inputs* - NLARX). Rozpatrywane modele są wynikiem rozwoju metod i środków ściśle związanych z modelowaniem eksperymentalnym. Identyfikacja takich modeli prowadzona jest w czterech głównych

określonych kryteriów. Modele tego typu można zapisać w sposób ogólny jako:

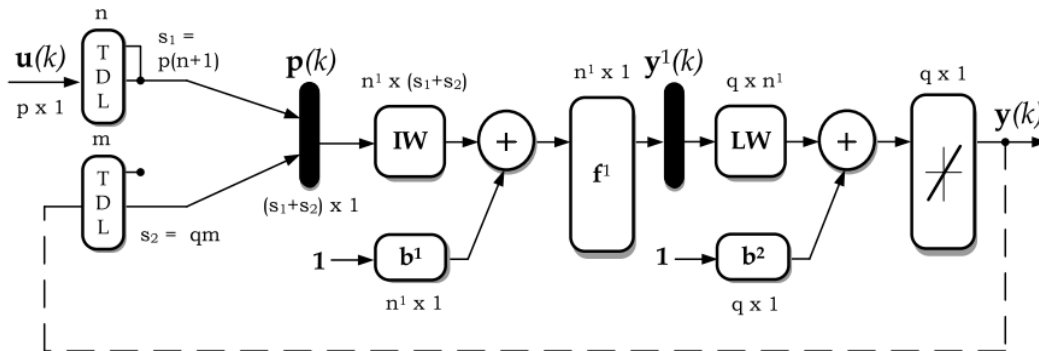
$$y(k) = f \left[\overbrace{u(k), u(k-1), \dots, u(k-n), y(k-1), y(k-2), \dots, y(k-m)}^{p(k)} \right] \quad (1)$$

gdzie n, m – rząd opóźnienia sygnału wejściowego i wyjściowego, f – nieliniowa zależność pomiędzy sygnałem wyjściowym $y(k)$ oraz odpowiednio sygnałem wejściowym $u(k)$ oraz opóźnionymi w czasie sygnałami $u(k)$ i $y(k)$. Jednym ze sposobów uzyskania nieliniowej funkcji f do odwzorowania zależności pomiędzy regresorami $p(k)$ i sygnałem wyjściowym jest zastosowanie w tym celu perceptronowej sieci neuronowej [7,16]. Umożliwia to uwzględnienie sygnałów zarówno wejściowych jak i wyjściowych identyfikowanego obiektu z aktualnej i poprzednich chwil czasu. W ten sposób do struktury jednokierunkowej wprowadza się sprzężenie zwrotne z wyjścia, przez co sieć statyczna jest w stanie odwzorować zależności rekurencyjne pomiędzy sygnałami (szeregowo - równoległy model identyfikacji). Struktura modelu NLARX może być przedstawiona jak na rys. 1.

Wyjście sieci pokazanej na rys. 1 w dyskretnej chwili k można wyznaczyć z równania:

$$y(k) = \mathbf{LW} \times \mathbf{f}^1 [\mathbf{IW} \times \mathbf{p}(k) + \mathbf{b}^1] + \mathbf{b}^2 \quad (2)$$

gdzie \mathbf{IW} – macierz wag warstwy wejściowej o wymiarze $n^1 \times (s_1 + s_2)$, \mathbf{LW} – macierz wag warstwy ukrytej o wymiarze $q \times n^1$, \mathbf{b}^{1-2} – wektory wartości progowych o wymiarach odpowiednio $n^1 \times 1$ i $q \times 1$, \mathbf{f}^1 – nieliniowy operator transformacji o wymiarze $n^1 \times 1$, n^1 – liczba neuronów w warstwie pierwszej, $\mathbf{p}(k)$ – sygnał wejściowy sieci o wymiarze $(s_1 + s_2) \times 1$, który powstaje w wyniku przetwarzania sygnału



Rys.1. Model NLARX zrealizowany w postaci sieci neuronowej

etapach polegających na [7]: zgromadzeniu danych, zdefiniowaniu struktury modelu, estymacji nieznanymi parametrów modelu na podstawie zgromadzonych danych, ocenie dokładności modelu w świetle

wejściowego $u(k)$ o wymiarze $p \times 1$ i wyjściowego $y(k)$ o wymiarze $q \times 1$ za pomocą bloków linii opóźniających. Ponadto zachodzą zależności: $s_1 = p(n+1)$ oraz $s_2 = qm$, gdzie n jest rzędem opóźnienia

sygnału wejściowego, m jest rzędem opóźnienia sygnału wyjściowego.

Podstawową zaletą tak zdefiniowanego modelu NLARX jest możliwość zastosowania sieci neuronowej o strukturze statycznej. Wielowarstwowe jednokierunkowe sieci neuronowe uważane są za uniwersalne aproksymatory zależności nieliniowych. Ich trenowanie możliwe jest za pomocą znanych technik optymalizacji z zastosowaniem metod opartych na gradiencie, jacobianie lub hesjanie funkcji celu zdefiniowanej np. w postaci błędu średniokwadratowego. Dodatkowo nie występuje tu problem stabilności podczas działania modelu i problem stabilizacji podczas jego strojenia. Bardzo ważnym zagadnieniem podczas modelowania neuronowego jest dobór odpowiedniej struktury modelu oraz ocena poprawności jego działania. W niniejszych badaniach problem ten rozwiązano, stosując kryterium informacyjne Schwarza do oceny modeli z uwzględnieniem ich złożoności oraz metodę izolacji kryterialnych [15]. Kryterium to można zapisać następująco:

$$BIC = n \ln(Q_G) + z \ln(n) \quad (3)$$

gdzie n – liczba próbek szeregu testowego, z – 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. Jako miarę jakości modelu przyjęto średni względny absolutny błąd procentowy:

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

gdzie y_{ij} – sygnał mierzony na monitorowanym obiekcie, \hat{y}_{ij} – wartość wyliczona za pomocą modelu NLARX, Y – zakres zmienności sygnału mierzonego, k – liczba wyjść modelu. Dodatkowo ocenę poprawności modelu wyznaczano na podstawie znormalizowanego pierwiastka z błędu średniokwadratowego:

$$NRMSE = \frac{1}{k} \sum_{j=1}^k \frac{1}{\sigma_Y} \sum_{i=1}^N \sqrt{\frac{1}{N} (y_{ij} - \hat{y}_{ij})^2} \quad (5)$$

gdzie σ_Y – odchylenie standardowe mierzonego sygnału wyjściowego.

Modele NLARX stosowane mogą być w celu odwzorowania zależności pomiędzy zmiennymi procesowymi, tj. przepływy wody, ciśnienia w wybranych punktach instalacji lub np. parametry meteorologiczne. Niemniej jednak wstępne badania przeprowadzone w zakresie przydatności tych modeli

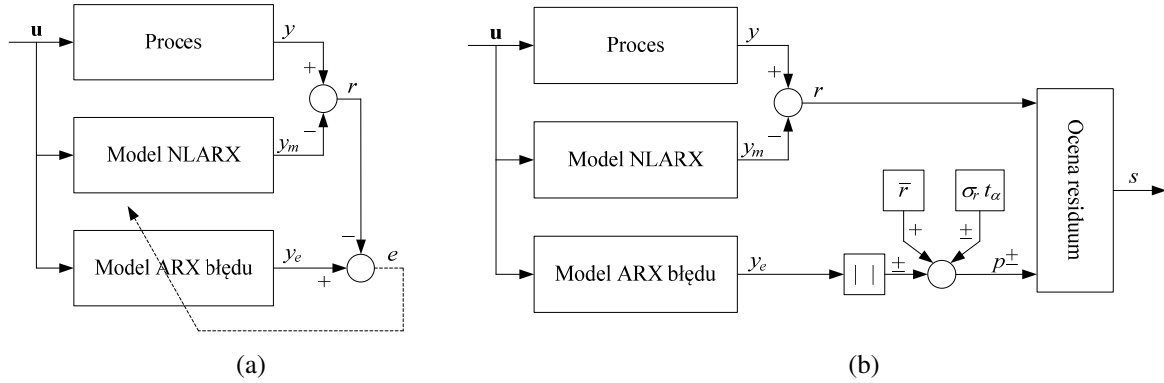
oraz analizy statystyczne danych, w tym, analizy korelacyjne, analizy informacji wzajemnej, analizy w dziedzinie częstotliwości oraz analizy wykładnika Hursta szeregów czasowych wyżej wymienionych zmiennych procesowych pokazują [9,12], że wystarczające jest poszukiwanie zależności wyłącznie pomiędzy zmianami przepływu wody.

W zastosowaniach praktycznych, niezależnie od przyjętej metody modelowania, utworzony model zawsze będzie w mniejszym lub większym stopniu odbiegał od rzeczywistości, co powoduje, że skutki te będą zauważalne podczas diagnozowania. Problemy takie nasilają się zwłaszcza wtedy, gdy rozpatruje się uszkodzenia drobne (ang. *soft faults*) lub uszkodzenia będące w początkowej fazie (ang. *incipient faults*). Na przykład przyjęcie zbyt małej wartości progów decyzyjnych służących do oceny wartości residuów prowadzi zazwyczaj do generacji dużej liczby fałszywych alarmów. Dla zbyt dużych wartości progów system detekcji będzie niewrażliwy na uszkodzenia drobne i narastające.

2.2 SCHEMAT DIAGNOZOWANIA

Jednym z możliwych rozwiązań problemu zasygnalizowanego w poprzednim podrozdziale jest zastosowanie tzw. odpornych algorytmów detekcyjnych [7,8]. W niniejszych badaniach zdecydowano, że detekcja uszkodzeń prowadzona będzie na podstawie klasycznego schematu diagnozowania z użyciem modelu obiektu [5,7] oraz zmiennych progów decyzyjnych zgodnie z podejściem opisanym w pracy [11]. Wartości tych progów wyliczane są na podstawie modelu błędu modelu (ang. *error model*). Idea identyfikacji modelu błędu modelu służącego do wyliczania chwilowych wartości progów decyzyjnych wg metody zaproponowanej w [11] pokazano na rys. 2(a). Dla modelu obiektu w stanie pełnej zdadności generuje się residua r dla bieżącego stanu bez wycieków (jednocześnie rejestrując wejścia modelu \mathbf{u}). Dla tak zgromadzonych danych tworzy się model $y_e = g(\mathbf{u})$ z wykorzystaniem wybranej metody identyfikacji parametrycznej, co prowadzi do utworzenia modelu błędu. Schemat zastosowania modelu błędu modelu w procesie diagnozowania przedstawiono na rys. 2(b). W pierwszej kolejności sygnał przepływu wody zmierzony w wybranym punkcie strefy porównywany jest z sygnałem przepływu wyliczonym za pomocą modelu NLARX. W wyniku tej operacji uzyskiwane jest residuum. Sygnały wejściowe, czyli przepływy z innych przepływomierzy tej strefy, na podstawie których wyznaczane jest wyjście 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 wyliczenie



Rys. 2. Schematy blokowe obrazujące sposób identyfikacji modelu błędu (a) i sposób detekcji wycieków w oparciu o zmienne progi decyzyjne (b)

sygnału diagnostycznego.

Detekcja wycieku realizowana jest poprzez ocenę residuum na podstawie zmiennych progów decyzyjnych wyliczanych na podstawie zależności:

$$p^\pm(k) = \bar{r} \pm t_\alpha \sigma_r \pm |y_e(k)| \quad (6)$$

gdzie \bar{r} , σ_r – średnia i odchylenie standardowe dla szeregu czasowego wartości residuum uzyskanego podczas testowania modelu NLARX, t_α – wartość krytyczna testu bloku decyzyjnego dla poziomu ufności równego $1-\alpha$ (wyznaczana dla uzyskiwanego rozkładu residuum np. w oparciu o tablice statystyczne), $y_e(k)$ – estymowana wartość błędu modelu. Binarny sygnał diagnostyczny generowany jest w przypadku, gdy:

$$s(k) = \begin{cases} 0 & \text{dla } p^+(k) \geq r(k) \geq p^-(k) \\ 1 & \text{dla } p^+(k) < r(k) < p^-(k) \end{cases} \quad (7)$$

gdzie $r(k)$ – chwilowa wartość residuum. Na podstawie odpowiedniej interpretacji wartości sygnałów diagnostycznych możliwa jest, poza detekcją, również lokalizacja wycieków pojawiających się w sieci wodociągowej.

Formalnie ocena merytoryczno-techniczna poprawności systemu detekcji wycieków działającego wg opracowanej metody może być zrealizowana poprzez określenie wartości estymaty sprawności części decyzyjnej tego systemu w odniesieniu do zbioru przykładów testowych. Zakłada się przy tym, że rozkład przykładów jest losowy i reprezentatywny dla oceny systemu. W celu obliczenia estymaty sprawności części decyzyjnej systemu detekcji wycieków zastosowano miary zdefiniowane w ramach problemu testowego projektu [1]. Pierwsza z nich to wskaźnik fałszywych alarmów (ang. *false detection rate*):

$$r_{fd} = \frac{\sum_i t_{fd}^i}{t_f - t_o} \quad (8)$$

Drugi wskaźnik dotyczy poprawnie generowanych alarmów (ang. *true detection rate*) i jest zdefiniowany jako:

$$r_{td} = \frac{\sum_i t_{td}^i}{t_h - t_f} \quad (9)$$

gdzie t_{td}^i jest okresem występowania poprawnie wskazanego alarmu, t_h jest punktem czasu oznaczającym koniec istotnego fragmentu strefy testu, t_{fd}^i jest okresem występowania fałszywego alarmu, t_f oznacza punkt czasu, w którym pojawiło się uszkodzenie, t_o oznacza punkt czasu, od którego rozpatrywany jest test.

3. WYNIKI BADAŃ WERYFIKACYJNYCH

Opracowana metoda weryfikowana była wstępnie z użyciem danych zarejestrowanych w jednej ze stref miasta Rybnik [12]. Uzyskano wtedy wyniki o charakterze jakościowym, które nie dały pełnej oceny potencjału zaproponowanej metody. Z tego powodu przeprowadzono dodatkowe badania weryfikacyjne mające na celu ilościową ocenę sprawności sposobu diagnozowania, na podstawie miar stosowanych w diagnostyce procesów przemysłowych [1]. Badania te dotyczyły trzech kolejnych stref Rybnika. Ze względu na podobny charakter rezultatów, jakie otrzymywano dla każdej ze stref, w niniejszym artykule zaprezentowano jedynie wyniki dla strefy Niewiadom.

Tworzenie modeli NLARX jak również bloków decyzyjnych dla danej sieci wodociągowej wymaga

przygotowania i przeprowadzenia eksperymentu umożliwiającego pozyskanie adekwatnych danych trenujących i testowych. Niniejsze badania były poprzedzone rozważaniami dotyczącymi rozmieszczenia urządzeń pomiarowych w takich punktach, które niosą najwięcej informacji o diagnozowanym obiekcie. Rozmieszczenie urządzeń zrealizowano z zastosowaniem genetycznej optymalizacji wielokryterialnej oraz metody optymalnego planowania eksperymentów. Wynikiem tych badań było określenie jedenastu punktów pomiarowych przepływu wody w rozważanej strefie. Szczegóły uzyskanych wyników można znaleźć w pracy [13]. W celu przeprowadzenia eksperymentu wykorzystano skalibrowany numeryczny model hydrauliczny rozpatrywanej sieci wodociągowej [9], który posłużył do wygenerowania przykładów trenujących i testowych. Przyjęto w sposób losowy 23 punkty wycieków, rozmieszczając je równomiernie w obrębie całej strefy. Założono niski poziom wycieku równy 4 m³/h oraz postanowiono, że prowadzone symulacje będą obejmowały czas pracy rozpatrywanego fragmentu sieci wodociągowej równy 4 tygodniom z okresem próbkowania $dt = 15$ min. Ze względu na główne założenie badań przyjęto, że wyciek pojawiać się będzie w środku 3. tygodnia o godz. 13:30. W ten sposób uzyskano jeden zestaw trenujący obejmujący 4 tygodnie pracy wodociągu w stanie pełnej zdadności oraz 23 zestawy testowe z wyciekami w końcowej fazie okresu symulacji. Bardziej szczegółowy opis modelu hydraulicznego i eksperymentu diagnostycznego można znaleźć w pracy zespołu badawczego [9].

Ze względu na fakt, że liczba wszystkich możliwych kombinacji zależności pomiędzy mierzonymi przepływami w rozpatrywanej strefie jest bardzo duża, to wybór istotnych wariantów wejść i wyjść modeli NLARX przeprowadzono na podstawie wyników analizy korelacyjnej. Najbardziej obiecujące okazały się warianty modeli, w których brane pod uwagę były wszystkie przepływomierze w danej strefie (mQ1, mQ2, ..., mQ11). Na przykład model mQ1 odwzorowuje zależność pomiędzy przepływem zarejestrowanym przez przepływomierz zainstalowany w punkcie 1 i przepływami zarejestrowanymi w pozostałych punktach strefy $q_1=f(q_2, q_3, \dots, q_{11})$, itd. Dane trenujące podzielono na dwa podzbiory: dane do strojenia i dane do walidacji modeli. Dla każdego przypadku strojenie modelu NLARX realizowano przy użyciu algorytmu Levenberga-Marquardta [4]. Przyjęto następujące wartości cech algorytmu: funkcja celu w postaci sumy kwadratów różnic; maksymalna liczba iteracji uczących równa 100; początkowa wartość czynnika regularizacyjnego $\lambda=1E-3$, mnożnik $\lambda_{dec}=0.1$ dla przypadku polepszenia wartości funkcji celu w danym kroku, mnożnik $\lambda_{inc}=10$ dla przypadku

pogorszenia wartości funkcji celu. Struktury modeli dla poszczególnych zależności dobierano stosując metodę izolacji dla kryterium Schwarzera oraz zasadę oszczędności. Wystarczające okazały się modele o strukturze $m=0$, $n=2$, $n^1=3$. Dokładność utworzonych modeli oceniono, używając standardowych miar jakości znanych z teorii identyfikacji systemów. Otrzymane wyniki walidacji modeli wytypowanych zależności pomiędzy wskazaniami przepływomierzy w rozważanej strefie przedstawiono w tab. 1.

Tab. 1. Wyniki ilościowej oceny modeli NLARX i modeli błędów tych modeli oraz parametry bloków decyzyjnych dla strefy Niewiadom


Id modelu	Oceny modelu NLARX			Ocena modelu błędu modelu	Parametry oceny residuum		
	MAPE	NRMSE	BIC	MSE	\bar{r}	σ_r	t_α
mQ1	0.53	2.32	33E3	5.43E-3	1.42E-4	0.12	3
mQ2	0.17	2.33	38E3	1.19E-3	1.79E-4	0.05	3
mQ3	0.09	2.34	50E3	2.04E-3	1.32E-6	0.07	3
mQ4	0.60	2.34	16E3	5.61E-4	6.11E-4	0.04	3
mQ5	0.20	2.33	38E3	4.53E-3	-3.08E-3	0.08	3
mQ6	0.80	2.34	31E2	1.43E-4	-2.65E-4	0.02	3
mQ7	1.50	2.33	-38E2	1.81E-4	1.04E-3	0.02	3
mQ8	2.17	2.32	9E2	8.18E-4	5.36E-4	0.04	3
mQ9	2.18	2.29	-16E3	6.75E-5	9.53E-4	0.01	3
mQ10	1.45	2.32	-14E3	4E-5	1.80E-5	0.01	3
mQ11	1.35	2.31	-5E3	1.19E-4	-2.38E-4	0.01	3

Dane do utworzenia modeli residuów pozyskano w wyniku symulacji modeli NLARX dla stanu pełnej zdadności obiektu. Modele residuów 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. Podczas badań zauważono, że niezależnie od tego, które z residuów jest modelowane, struktura $\mathbf{na}=[1]$, $\mathbf{nb}=[2,2,\dots,2]$ (modelu ARX) jest wystarczająca do jego odwzorowania (długość wektora \mathbf{nb} zależy od liczby wejść modelu, za pomocą którego generowane jest residuum). Uzyskane wyniki modelowania w postaci błędu średniokwadratowego (MSE) oraz parametry bloków decyzyjnych zestawiono w czterech ostatnich kolumnach tab. 1. Wartość krytyczną t_α dobrano, stosując regułę trzech sigm. Na rys. 3(a) pokazano wyniki działania modelu mQ2. Rysunek ten przedstawia wygenerowane residuum oraz odpowiadające mu przebiegi zmiennych progów decyzyjnych. Wartości chwilowe progów wyliczane były z zastosowaniem modelu błędu modelu mQ2. Wartości progowe tak uzyskane 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). Dodatkowo na rys. 3(b) zamieszczono histogram przedstawiający rozkład wartości residuum rozpatrywanego modelu - uzyskano normalny rozkład wartości residuum dla stanu bez uszkodzeń.

Ostatnim z etapów opisanych tu badań była weryfikacja przydatności opracowanych modeli w zadaniu detekcji wycieków. Ocenę sprawności przeprowadzono dla zbioru danych testowych przygotowanych w celu weryfikacji detektorów wycieku. Elementy tego zbioru stanowią przykłady, które nie były brane pod uwagę na etapach tworzenia modeli NLARX oraz podczas wyznaczania parametrów bloków decyzyjnych. Ocenę sprawności realizowano, stosując dwie miary: wskaźnik prawidłowych alarmów oraz wskaźnik fałszywych alarmów. Wyniki fazy testowania zaproponowanego sposobu detekcji wycieków w rozważanej strefie zamieszczono w tab. 2. Tablica przedstawia wskaźniki prawidłowych i fałszywych alarmów dla wszystkich utworzonych modeli. Wskaźniki te odnoszą się do miejsc wycieku rozlokowanych w różnych obszarach strefy Niewiadom. Można zauważyć, że uzyskano wysokie wartości wskaźników prawidłowych alarmów przy jednoczesnym braku fałszywych alarmów. Potwierdza to dużą odporność proponowanego sposobu diagnozowania na różnego rodzaju niepewności. Niemniej jednak można również

modeli. Na rys. 4 pokazano sposób działania dwóch wybranych modeli dla strefy Niewiadom. W górnej części rys. 4 pokazano przebiegi residuów uzyskane za pomocą modeli mQ3 i mQ5, które symulowano dla wycieku (emiter 4712) zlokalizowanego w losowo wybranym obszarze tej strefy. Na rysunkach naniesiono również przebiegi zmiennych progów decyzyjnych, które wyliczano na podstawie modeli błędów modeli mQ3 i mQ5. Dolna część rys. 4 przedstawia postacie sygnałów diagnostycznych uzyskanych za pomocą modeli mQ3 (a) i mQ5 (b).

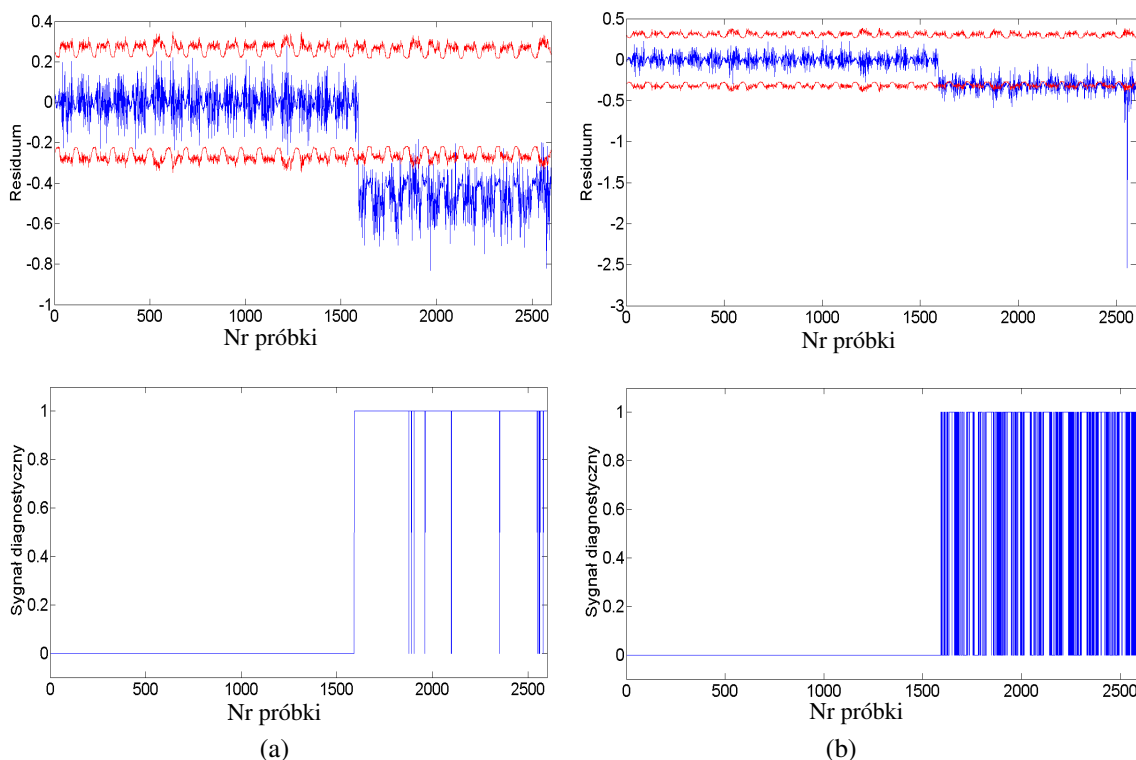


Rys. 3 Wyniki symulacji modelu mQ2 dla stanu pełnej zdatności sieci wodociągowej: (a) – przebieg residuum oraz wartości chwilowe progów decyzyjnych, (b) – histogram residuum

zauważyć duże zróżnicowanie czułości wszystkich

Tab. 2 Wskaźniki fałszywych i prawidłowych alarmów uzyskane dla losowo wybranych miejsc wycieku w strefie Niewiadom

Id emitera	mQ1		mQ2		mQ3		mQ4		mQ5		mQ6		...		Średnia	
	r_{fd}	r_{td}	r_{fd}	r_{td}	r_{fd}	r_{td}	r_{fd}	r_{td}	r_{fd}	r_{td}	r_{fd}	r_{td}	r_{fd}	r_{td}	r_{fd}	r_{td}
297	0.00	0.94	0.00	1.00	0.00	1.00	0.00	0.63	0.00	1.00	0.00	1.00	0.00	0.94
1356	0.00	0.93	0.00	0.99	0.00	1.00	0.00	0.86	0.00	0.32	0.00	1.00	0.00	0.91
768	0.00	0.83	0.00	1.00	0.00	1.00	0.00	0.41	0.00	0.99	0.00	1.00	0.00	0.92
1083	0.00	0.01	0.00	0.98	0.00	0.99	0.00	0.00	0.00	0.99	0.00	0.95	0.00	0.81
1669	0.00	1.00	0.00	1.00	0.00	1.00	0.00	0.88	0.00	1.00	0.00	1.00	0.00	0.98
864	0.00	0.61	0.00	0.99	0.00	1.00	0.00	0.29	0.00	0.99	0.00	0.99	0.00	0.89
4712	0.00	1.00	0.00	1.00	0.00	0.98	0.99	0.25	0.00	0.60	0.00	0.00	0.00	0.55
4730	0.00	0.80	0.00	1.00	0.00	1.00	0.00	1.00	0.00	1.00	0.00	0.02	0.00	0.79
4848	0.00	1.00	0.00	0.00	0.00	0.04	0.00	1.00	0.00	0.00	0.00	0.36	0.00	0.63
4024	0.00	0.79	0.00	1.00	0.00	1.00	0.00	1.00	0.00	0.99	0.00	0.02	0.00	0.79
3774	0.00	0.07	0.00	0.01	0.00	0.00	0.00	0.06	0.00	0.22	0.00	1.00	0.00	0.32
3660	0.00	0.04	0.00	0.01	0.00	0.00	0.00	0.09	0.00	0.23	0.00	1.00	0.00	0.33
3450	0.00	0.88	0.00	0.18	0.00	0.96	0.00	0.85	0.00	0.99	0.00	1.00	0.00	0.87
2324	0.00	1.00	0.00	0.15	0.00	0.99	0.00	0.96	0.00	0.07	0.00	1.00	0.00	0.78
1602	0.00	1.00	0.00	0.13	0.00	0.99	0.00	0.95	0.00	0.11	0.00	1.00	0.00	0.78
2474	0.00	0.10	0.00	0.03	0.00	0.01	0.00	0.11	0.00	0.31	0.00	0.08	0.00	0.31
2435	0.00	0.09	0.00	0.07	0.00	0.06	0.00	0.13	0.00	0.31	0.00	0.13	0.00	0.36
2937	0.00	0.09	0.00	0.03	0.00	0.01	0.00	0.10	0.00	0.29	0.00	0.06	0.00	0.30
3357	0.00	0.18	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.19	0.00	0.15	0.00	0.20
3286	0.00	0.61	0.00	0.02	0.00	0.00	0.00	0.00	0.00	0.42	0.00	0.39	0.00	0.26
2757	0.00	0.04	0.00	0.86	0.00	0.40	0.00	0.95	0.00	0.30	0.00	0.84	0.00	0.71
3369	0.00	0.04	0.00	0.00	0.00	0.00	0.00	0.05	0.00	0.20	0.00	1.00	0.00	0.31
3007	0.00	0.06	0.00	0.08	0.00	0.04	0.00	0.14	0.00	0.31	0.00	0.01	0.00	0.36



Rys. 4 Przykładowe rezultaty detekcji wycieków na podstawie modelu mQ3 (a) mQ5 (b) dla wycieku zlokalizowanego w obszarze (emiter 4712) strefy Niewiadom

Na podstawie sygnałów diagnostycznych podejmowana jest decyzja o występującym w sieci wodociągowej wycieku. Przykład ten dobrze ilustruje sytuację przedstawiającą różną czułość poszczególnych modeli na pojawiające się w tym punkcie wycieki (Id

emitera 4712). Oba modele nie generują fałszywych alarmów, jednak pierwszy z nich charakteryzuje się dużo większą czułością na wyciek w tym miejscu, co przekłada się na jakość sygnału diagnostycznego. Istnieją jednak takie sytuacje dla pary tych modeli,

jak na przykład wyciek w punkcie 3286 (tab. 2), że pierwszy z nich nie reaguje zupełnie na wyciek, a drugi umożliwia jego wykrycie.

Duża różnorodność wartości wskaźnika prawidłowych alarmów, którą uzyskano dla rozpatrywanych modeli, jest zjawiskiem niekorzystnym. Niemniej jednak, jednocześnie uzyskiwano odpowiedzi bloków decyzyjnych charakteryzujące się powtarzalnymi niskimi wartościami wskaźnika fałszywych alarmów. Takie działanie pozwala na połączenie wyników klasyfikacji w celu wygenerowania wypadkowej diagnozy. Podczas badań okazało się, że użycie agregacji z zastosowaniem sumy logicznej pozwala połączyć wyjścia modeli i uzyskać wynik, dla którego średnia wartość wskaźnika prawidłowych alarmów przekracza wartość 0.98 przy średniej wartości wskaźnika fałszywych alarmów mniejszego od 0.01.

4. PODSUMOWANIE I WNIOSKI

W artykule zaprezentowano metodę detekcji wycieków w rozdzielczych sieciach wodociągowych z zastosowaniem modeli NLARX. Detekcję wycieków realizowano z zastosowaniem klasycznego schematu diagnozowania na podstawie modelu obiektu oraz

znanej metody modelowania niepewności. Modele NLARX pozwalają na dokładne odwzorowanie zależności pomiędzy zmianami przepływów wody, które rejestrowane są w obrębie wydzielonej strefy sieci wodociągowej. W artykule pokazano, że zastosowanie modeli NLARX w połączeniu z wykorzystaną metodą generowania zmiennych progów decyzyjnych umożliwia prowadzenie detekcji wycieków w ciągu całej doby. Ponadto detekcja realizowana jest z bardzo niskim wskaźnikiem fałszywych alarmów przy jednoczesnym bardzo wysokim wskaźniku prawidłowych alarmów. Moduł detekcji wycieków opracowany na podstawie zaproponowanej metody został zaimplementowany w PWiK w Rybniku i obecnie służy do sygnalizowania alarmów dozorowi technicznemu sieci wodociągowej w tym mieście.

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 Instytucie Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach.

Literatura

1. Bartyś M., Patton R., Syfert M., de las Heras S., Quevedo J.: Introduction to the DAMADICS actuator FDI benchmark study. "Control Engineering Practice" 2006, Vol. 14, No. 6, p. 577-596.
2. Eliades D. and Polycarpou M.: A fault diagnosis and security framework for water systems, "IEEE Transactions on Control Systems Technology" 2010, Vol. 18, No. 6, p. 1254-1265.
3. Geiger G., Werner T. and Matko D.: Leak detection and locating – A survey, "35th Annual PSIG Meeting", 2003.
4. Hagan M.T., Menhaj M.B.: Training feedforward networks with the Marquardt algorithm. „IEEE Transactions on Neural Networks”, 1994, Vol. 8, No. 6, p. 989-993.
5. Isermann R.: Fault-diagnosis systems: an introduction from fault detection to fault tolerance. Springer, 2006.
6. Jezior K., Mazur K., Borowa A., Grochowski M. i Brdys M.: 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" 2007, Academic Publishing House EXIT, p. 303-310.
7. Korbicz J., Kościelny J.M., Kowalczyk Z. and Cholewa W. (red.): Fault diagnosis: models, artificial intelligence, applications. Berlin/Heidelberg: Springer, 2004.
8. Korbicz J.: Robust fault detection using analytical and soft computing methods. Bulletin of the Polish Academy of Sciences "Technical Sciences" 2006, Vol. 54, No. 1, p. 75-88.
9. Moczulski M., Ciupke K., Przyszałka P., Tomasik P., Wachla D., Wiglenda R., Wyczółkowski R.: Metodyka budowy systemu monitorowania wycieków w sieciach wodociągowych. W: „Diagnostyka procesów i systemów”, X Międzynarodowa konferencja naukowo-techniczna, Zamość 2011, s. 409 – 420. (pamięć USB).
10. Nowicki A., Grochowski M., Duzinkiewicz K.: Data-driven models for fault detection using kernel PCA - water distribution system case study. "International Journal of Applied Mathematics and Computer Science", 2012, Vol. 22, No. 4, p. 939-949.
11. Patan K.: 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 (eds.) "Fault diagnosis and fault tolerant control". Warsaw: Academic Publishing House EXIT, 2007, p. 337-346.

12. Przystałka P., Wyczółkowski R.: Detekcja małych wycieków w sieciach wodociągowych z zastosowaniem metody modelowania niepewności. „Pomiary Automatyka Kontrola” 2011 vol. 57, nr 11, s. 1307-1310.
13. Przystałka P., Moczulski W.: Optimal placement of sensors and actuators for leakage detection and localization. Preprints of the 8th “IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes” (SAFEPROCESS), p. 666-671, August 29-31, 2012. Mexico City, Mexico.
14. Puust R., Kapelan Z., Savic D. and Koppel T.: A review of methods for leakage management in pipe networks. “Urban Water Journal” 2010, Vol. 7, No. 1, p. 25–45.
15. Rutkowski L.: Metody i techniki sztucznej inteligencji. Warszawa: Wyd. Nauk. PWN, 2005.
16. Tsung-Nan Lin, Giles C. L., Bill G. i Kung S.: A delay damage model selection algorithm for NARX neural networks. “IEEE Transactions on Signal Processing” 1999, t. 45, p. 2719–2730.

Proszę cytować ten artykuł jako:

Przystałka P.: Metoda detekcji wycieków w sieciach wodociągowych z zastosowaniem modeli NLARX. „Modelowanie Inżynierskie” 2013, nr 46, t. 15, s. 94 – 102.