

**Bożydar SZADKOWSKI**

Emerson Process Management Power & Water Solutions, Warszawa

**Anna JANKOWSKA**

Instytut Automatyki i Robotyki Wydział Mechatroniki PW, Warszawa

## **DETEKCJA NIESZCZELNOŚCI KOTŁA FLUIDALNEGO Z UŻYCIEM MODELI ROZMYTO-NEURONOWYCH**

### **Słowa kluczowe**

Detekcja awarii, systemy rozmyto-neuronowe, kocioł fluidalny, modelowanie.

### **Streszczenie**

Zreferowano badania modelowe nad detekcją nieszczelności kotłów fluidalnych z wykorzystaniem danych z archiwum. Modelowanie prowadzono w przyborniku Fuzzy Logic pakietu Matlab. Omówiono dwa podejścia do rozwiązania problemu. W pierwszym – opracowano modele rozmyto-neuronowe typu Takagi-Sugeno-Kanga (TSK) 4 zmiennych procesowych o dużej wrażliwości na przeciek. Uśrednione residua tych zmiennych, w przesuwym oknie czasowym, pozwoliły wykryć 7 z 8 rozważanych przypadków nieszczelności. Oceniono długość okna i uzyskane wyprzedzenie detekcji względem wyłączenia bloku. Następnie opracowano i przetestowano model awarii o binarnym wyjściu. Równoległe wykorzystanie opracowanych modeli pozwoliło na wykrycie z kilkudniowym wyprzedzeniem wszystkich analizowanych awarii, potwierdzając przydatność modeli TSK w ważnym zadaniu eksploatacyjnym. Wskazano dalsze kierunki prac.

## Wprowadzenie

Prowadzona on-line detekcja awarii – nieszczelności jest ważnym zadaniem eksploatacyjnym w monitorowaniu i nadzorowaniu pracy kotłów energetycznych. Dotyczy to zwłaszcza nowoczesnych kotłów fluidalnych, istotnie podatnych na awarie [1]. Wiele nieszczelności rozwija się powoli i są one niewidoczne dla operatorów, wyłączenie bloku następuje dopiero po kilku–kilkunastu dobach od wystąpienia pierwszych symptomów awarii. Grozi to oczywiście rozwijaniem się innych uszkodzeń i kosztownymi naprawami. Zadanie wczesnej detekcji nieszczelności kotła stanowi przedmiot wielu prac, np. [2, 3, 4, 5]. Reprezentowane jest w nich zarówno podejście systematyczne modelowania procesu spalania, często z wykorzystaniem rozkładu na czynniki główne (Principal Component Analysis – PCA) i ocena residuum modelu w sytuacji powstawania awarii, jak i metody wydobywania wiedzy z danych pomiarowych z użyciem inteligentnych algorytmów obliczeniowych, bez wykorzystania jawnej postaci modelu procesu.

Modele matematyczne procesu spalania tworzą układ różniczkowych równań ze sprzężeniami skrośnymi, trudnych w identyfikacji także z powodu nieliniowości zjawisk oraz zmiennych w czasie obciążeń bloku i znacznego rozrzutu cieplnych właściwości paliwa. Modelowanie procesu spalania metodą PCA dotyczy najczęściej jedynie bilansu parowo-wodnego w układzie ciśnieniowym bloku. I do tego układu na ogół ograniczają się prace literaturowe [2, 4, 5]. W pracy [5] wskazano na 3 zmienne procesowe wrażliwe na parowe przecieki. Są to strumienie wody zasilającej i powietrza do spalania oraz ciśnienie na ssaniu wentylatorów spalin.

Analiza danych archiwalnych z systemu DCS profesjonalnej elektrowni z lat 2005–2008 wykazała, że co najmniej tak samo liczne, jak awarie typu przeciek w układzie ciśnieniowym pary, były nieszczelności powstające w wyniku erozyjnego działania przemieszczających się w obrębie kotła strumieni złoża fluidalnego i powietrza poza tym układem. Jako sygnały przydatne w diagnostyce dla rozszerzonego zestawu awarii wytypowano [6], np.: stężenie  $\text{CO}_2$  w spalinach, strumień spalin, a także różnicę temperatur między górną przestrzenią komory a wejściem do cyklonu nawrotnego.

Podjęmowane obecnie w Instytucie Automatyki i Robotyki PW prace nad wykrywaniem nieszczelności dotyczą obu ww. rodzajów przecieków pojawiających się zarówno w komorze spalania, jak i w drugim ciągu kotła fluidalnego [6].

W artykule przedstawiono dwa etapy badań nad detekcją nieszczelności. Na pierwszym opracowano modele poszczególnych zmiennych wrażliwych na przeciek, aby wyznaczyć ich residua w sytuacjach powstawania awarii. Modele te były uczone na danych pomiarowych z poprawnego działania kotła. Uzyskane, uśrednione w oknie czasowym, wartości residuum dla stanu poprawnego i następnie w sytuacjach narastania awarii zestawiono w p. 2 pracy. Przedysku-

towano także zależność residuum od długości okna obliczeniowego i jego wyprzedzenia w czasie względem momentu wyłączenia bloku.

Następnie podjęto próbę opracowania układu detekcji nieszczelności poprzez model awarii o wyjściu dwustanowym: wartość 0 przypisano działaniu sprawnego kotła, wartość 1 – awarii. Uczenie takiego modelu wymagało zaprezentowania danych z poprawnej pracy, jak i z przedziału czasu narastania awarii. Uzyskane wyniki przedstawiono w p. 3 pracy.

Modele wykorzystujące metody sztucznej inteligencji [7, 8], dobrze nadając się do aproksymacji nieliniowych zależności są coraz szerzej stosowane w różnych zadaniach praktycznych, w tym – w diagnostyce [5, 6, 7, 8, 10]. Chcąc połączyć zalety sieci neuronowych [3, 7, 8] z możliwością eksperckiego wpływu i analizy działania modeli, w pracy tworzono i testowano rozmyte sieci neuronowe (nazywane też systemami rozmyto-neuronowymi) [7, 8].

## 1. Środowisko modelowania, dobór zestawu sygnałów wejściowych sieci rozmyto-neuronowych

Badania przeprowadzono w pakiecie Matlab, w przyborniku *Fuzzy Logic Toolbox* [9], który umożliwia projektowanie 2 podstawowych typów systemów rozmytych, tj. Mamdaniego i Takagi-Sugeno-Kanga (TSK), nazywanych też Sugeno lub Takagi-Sugeno) [7, 8]. Wykorzystano ANFIS Editor GUI – narzędzie do strojenia modeli typu TSK; tylko takie modele (cechujące się jawnymi zasadami wnioskowania i wyostrzania o funkcji konkluzji w postaci wielomianu pierwszego stopnia) były badane w niniejszej pracy.

Parametry funkcji przynależności na wejściach modeli oraz parametry trzech pierwszych warstw ukrytych struktury modelu wyznaczane są z użyciem algorytmu propagacji wstecznej i gradientowej metody największego spadku [9]. Natomiast współczynniki wielomianów wyjściowych dobierane są metodą najmniejszych kwadratów. W bazie reguł modeli ANFIS stosowano metodę klasteryzacji (*ang. Subtractive clustering*). W wyniku przeprowadzonych badań przyjęto domyślne wartości parametrów metody klasteryzacji poza jednym, *range of influence*, uzmiennianym w poszczególnych modelach.

Założono, że już 3 tygodnie przed awaryjnym wyłączeniem bloku mogą występować niewidoczne z zewnątrz symptomy awarii, więc jako dane stanu poprawnego stosowano rekordy wyprzedzające wyłączenie bloku co najmniej o 21 dni. Zakresy zmienności sygnałów ograniczono w wyniku analizy histogramów. Ocenie poddano tablice korelacji wzajemnej sygnałów – współczynników Pearsona [10].

W analizie już wstępnie ograniczonego zestawu sygnałów wejściowych modeli [6] opierano się na elementarnych związkach przyczynowo-skutkowych, weryfikując zależności między sygnałami wejściowymi i wyjściowymi modeli z użyciem funkcji *seqsrch* (*forward sequential search*) pakietu Matlab [9]. Sygna-

ły wejściowe, wobec których wyjście modelu cechuje się znaczną wrażliwością, wyznaczone były poprzez iteracyjną ocenę błędu RMS modeli ANFIS, budowanych i uczonych dla kolejno rozpatrywanych zestawów sygnałów wejściowych.

W zestawie danych pomiarowych z archiwum znajdują się zarówno sytuacje przecieku z układu ciśnieniowego, jak i uszkodzenia wywołane erozją pyłowo-popiołową poza tym układem, co stanowi właściwy materiał wyjściowy dla badań detekcji awarii – nieszczelności o różnym charakterze.

## 2. Modele zmiennych wrażliwych na przeciek kotła

Opracowano 4 modele zmiennych wrażliwych na przecieki [10]:

- strumień wody zasilającej,
- strumień powietrza do spalania,
- ciśnienie na ssaniu wentylatorów spalin,
- stężenie CO<sub>2</sub> w spalinach.

Efekty modelowania zostaną zreferowane na przykładzie strumienia wody zasilającej, podstawowej zmiennej służącej do oceny bilansu materiałowego kotła. Uczenie prowadzono na danych ze stanu poprawnej pracy bloku. W wyniku wielu prób rozbudowy i redukcji zestawu sygnałów wejściowych najlepszy z uzyskanych modeli wykorzystuje 6 sygnałów wejściowych o 6 zbiorach rozmytych każdego z wejść. Pozostałe modele zmiennych wrażliwych na przeciek opracowano i przedstawiono w pracy [10].


Kolejno zilustrowano przebiegi zmiennej wyjściowej modelu dla wybranego fragmentu zbioru testowego w stanie poprawnej pracy kotła (4 doby) – rys. 1a oraz na rys. 1b fragment (3 doby) przebiegu od 8 dni poprzedzających wyłączenie kotła dla jednej z rozważanych awarii.

Wyznaczano residuum – błąd uśredniony w oknie czasu 3 dni dla obu prezentowanych sytuacji. Analogicznie oceniono residua wszystkich opracowanych modeli zmiennych wrażliwych na przeciek w dniach poprzedzających kolejne awaryjne wyłączenia bloku.

Modele trzech zmiennych wrażliwych na przeciek potwierdziły swoją skuteczność w wykrywaniu trzech awarii opisanych jako nieszczelność kotła i nieszczelność komory paleniskowej. Jednak nie wykazały one residuum we wszystkich awariach tego typu.

Dla 3 z 8 analizowanych awarii, przecieków z układu ciśnieniowego, residua wszystkich badanych zmiennych wygenerowane zostały jednocześnie. Największą skuteczność wykazał model stężenia CO<sub>2</sub>, pozwalając na detekcję 7 z 8 awarii. Tylko ten model wykazał residuum dla awarii nr 5 i 6.

W tab. 1 przedstawiono wyniki uzyskane dla czterech zbadanych modeli dla wszystkich analizowanych awarii. Podano stosunek wartości residuum w czasie rozwijania się awarii do jego miary w stanie poprawnej pracy kotła dla tych sytuacji narastania nieszczelności, dla których wartość tego ilorazu przekroczyła 1,0. Awarię nr 2 cechują stosunkowo niewielkie wartości residuów.



Rys. 1. Strumień wody zasilającej – przebieg rzeczywisty – mierzony u wyjścia modelu: a) stan poprawny, b) w przedziale czasu (8, 5) dni przed awarią

Tabela 1. Iloraz średniej miary residuum narastania awarii względem residuum stanu poprawnego (\* wyznaczony w krótszym oknie czasowym 2 dni)

Nr aw.	opis awarii	strumień wody zasilającej	strumień powietrza do spal.	ciśnienie na ssaniu went. spalin	stężenie CO <sub>2</sub> w spalinach
1	nieszczelność kotła	2,5	6	5	2,8
2	nieszczelność kotła		1,2	1,2	1,5
3	nieszczeln. ekr., naroże	1,25	4,5		7
4	nieszczeln. komor. palenisk.	13	4,5	2,5	4
5	nieszczeln. komor. palenisk.				2,8*
6	nieszczelność płaszczka komory palenisk				3,4
7	nieszczelność na odwodzie zimnej szyny				
8	nieszczelności komory paleniskowej – ekrany	10	2,2	10	1,02

Zależność residuum od położenia okna czasowego zbadano, przesuując okno o długości 3 dni w przedziale czasu od 8 dni względem wyłączenia bloku do chwili wyłączenia. Dla większości modeli największe wartości residuum wystąpiły dla okna w zakresie 6 do 3 lub 7 do 4 dni przed wyłączeniem bloku. Jednak zakres zmienności residuum przy przesuwaniu okna czasowego był niewielki (rzędu kilkunastu % wartości maksymalnej). Jest to wskazanie do stosowania krótszego okna czasowego rzędu 1 do 2 dni. Dalsze skracanie okna może jednak doprowadzić do wykrywania krótkotrwałych zakłóceń parametrów procesu spalania, a tym samym stanowi zagrożenie fałszywymi alarmami.

### 3. Model awarii

Opracowano model awarii o dwustanowym wyjściu, które ma dawać bezpośrednie wskazanie o poprawnej pracy kotła, wtedy – wyjście ma być równe 0 lub o narastaniu awarii – wyjście równe 1. Wejściami modelu są residua opracowanych poprzednio zmiennych wrażliwych na przeciek oraz wybrane inne [6, 7] sygnały procesowe.

Uczenie modelu awarii wymaga szczególnej staranności w przygotowaniu danych uczących i testujących model. Plik danych uczących skomponowano, wykorzystując rejestracje wielu stanów poprawnych oraz wybranych fragmentów z powstawania trzech różnych typów awarii (nr 2, 3 i 6 wg tab. 1). Chodziło o zaprezentowanie możliwie szerokiego zestawu symptomów nieszczelności w celu generalizacji w modelu wiedzy diagnostycznej. W doborze zestawu sygnałów wejściowych modelu ponownie zastosowano funkcję *seqsrch*. Model wykorzystuje na wejściu 9 zmiennych o 8 funkcjach przynależności.

Uruchomienie modelu awarii na niestosowanych w uczeniu danych z rozwoju pięciu nieszczelności spowodowało detekcję trzech z nich. Były to awarie (nr 1, 7 i 8 wg tab. 1). Awaria nr 7 – nieszczelność na odwodzie zimnej szyny nie była dotychczas sygnalizowana przez żaden badany model. Jej wykrycie świadczy o generalizacyjnych właściwościach modeli TSK.

### Podsumowanie

Wykorzystując dane off-line z elektrowni, opracowano modele TSK zastosowane następnie do detekcji nieszczelności. Zbadano dwa podejścia do tego zadania: 1) poprzez ocenę residuum 4 zmiennych procesowych wrażliwych na przeciek, 2) przez generację stanu procesu w modelu awarii. W obu rozwiązaniach uzyskano znaczną skuteczność wykrywania awarii ze sporym, bo aż kilkudniowym wyprzedzeniem w stosunku do chwili wyłączenia bloku. Wydaje się, że właściwa do detekcji residuum długość przesuwanego okna czasowego to przedział rzędu jednego lub dwu dni. W prowadzonych pracach nie podjęto zagadnienia lokalizacji nieszczelności z powodu braku w posiadanych archiwach niezbędnych w tym celu sygnałów pomiarowych.

Konieczne są jednak dalsze prace: np. należy rozważyć zautomatyzowany tryb korekcji długofalowych trendów procesu dla zmiennych wrażliwych na przeciek [11], zbadać bardziej szczegółowo długość okna czasowego do oceny residuum, przeanalizować celowość wskaźnika operującego na opracowanych residuach poszczególnych zmiennych. Natomiast budowa pewnego w działaniu i skutecznego modelu awarii (dla rozważanych dwu typów nieszczelności) wymaga dalszego rozszerzenia bazy danych o kolejne sytuacje opisujące rodzaje i lokalizacje awarii nieuwzględnione w dotychczasowych badaniach.

### **Bibliografia**

1. Pawlik M., Strzelczyk F.: *Elektrownie*, wydanie 5, WNT, Warszawa 2009.
2. Xi Sun, Marquez H. J., Tongwen Chen.: An improved PCA method with application to boiler leak detection, *ISA Transactions* 44, 2005, 379–397.
3. Jankowska A.: Approach to Early Boiler Leak Detection with Artificial Neural Networks. *Recent Advances in Mechatronics*, Springer Verlag, 2007, pp. 57–61.
4. Lang F.D., Rodgers, D.A.T., Mayer, L.E.: Detection of Tube Leaks and their Location Using Input/Loss Methods, *Proc. of the International Joint Power Generation. Conference Baltimore, Maryland, 03.30–04.01.2004 r., IJPGC2004-52027*.
5. Alouani A. T., Shih -Yung Chang P.: Artificial Neural Network and Fuzzy Logic Based Boiler Tube Leak Detection Systems, USA Patent No: 6,192,352 B1, Feb 2001.
6. Jankowska A.: Ocena sygnałów procesowych z kotła energetycznego pod względem ich przydatności diagnostycznej. *Pomiary, Automatyka, Robotyka*. 11/2010, s. 79–83.
7. Piegat A.: *Modelowanie i sterowanie rozmyte*. Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999.
8. Rutkowski L.: *Metody i techniki sztucznej inteligencji*, PWN Warszawa 2005.
9. Matlab, <http://www.mathworks.com/help/toolbox/fuzzy/fp715dup12.html>. Dokumentacja online do pakietu Matlab, 2011.
10. Szadkowski B.: *Analiza wczesnej detekcji nieszczelności w kotle energetycznym z wykorzystaniem modeli rozmyto-neuronowych*. Niepublikowana praca dyplomowa magisterska, PW D-IAiR-458, Warszawa 2010.
11. Kornacki S.: Neuronowe modele procesów o zmiennych właściwościach. 12–14.09.2005, *Pomiary Automatyka Kontrola* nr 9/2005, s. 112–114.

Recenzenci:

**Jacek KLUSKA**  
**Andrzej PIECZYŃSKI**

## **Approach to boiler leak detection with fuzzy neural models**

### **Key words**

Detection of outage, fuzzy-neural system, fluidised bed boiler, modelling.

### **Summary**

The research results into leak detection in a fluidised bed boiler are presented. The studies took advantage of the historical data from DCS in the professional power plant. Models of neuro-fuzzy Takagi-Sugeno-Kanga (TSK) type were built and tested in the Fuzzy Toolbox of Matlab. The roots of boiler outage (in water-steam pressure system and aside from this system) are indicated. The two approaches to leak detection task are described. In the first, the models of the 4 process variables sensitive to leakage were built. The residues of these models were evaluated in a moving time window. The length of the time window and the advance of leakage detection are discussed.

Next, the model the TSK of the boiler faults with binary output was built and tested. Training data was collected for 3 cases of raised outage (models output – 1) and the normal work of installation (models output – 0). The parallel usage of proposed TSK models provided a successful detection of all studied fault cases a few days in advance. This has confirmed the suitability of the fuzzy neural models in an important exploitation task.