

Ocena sygnałów procesowych z kotła energetycznego pod względem ich przydatności diagnostycznej

Anna Jankowska

Instytut Automatyki i Robotyki Politechniki Warszawskiej

Przedstawiono zastosowanie sztucznych sieci neuronowych do wczesnej detekcji stanu narastania nieszczelności parowych w obrębie komory spalania kotła energetycznego. Zestaw proponowanych w literaturze sygnałów wrażliwych na przeciek rozszerzono o dalsze zmienne pomiarowe osiągając znacznie lepszą jakość klasyfikacji niż przy minimalnym zestawie 3-4 zmiennych. Jako sieci klasyfikujące zbadano struktury radialne Radial Basis Function (RBF) oraz struktury wielowarstwowego perceptronu Multilayer Perceptron (MLP) o jednej lub dwu warstwach ukrytych, uczone metodami z nauczycielem. Redukcję rozważanego początkowo zbioru zmiennych wejściowych prowadzono poprzez analizę wrażliwości uzyskanych sieci, testując ich zdolności generalizacji na nieznanymi sytuacjach awarii tego samego typu. Uzyskano klasyfikację przekraczającą 90 % poprawnego przyporządkowania stanów procesu na nieznanymi na etapie uczenia przypadkach niesprawności. W niezależnych testach na 11 awariach potwierdzono większą przydatność w omawianym zadaniu struktur MLP niż RBF, mimo wyższej wrażliwości sieci RBF na sygnały wejściowe.

Słowa kluczowe: sztuczne sieci neuronowe, kotły fluidalne, wczesna detekcja awarii kotłów energetycznych, analiza wrażliwości

Coraż powszechniej stosowane w energetyce, ze względu na swoje zalety w porównaniu ze starszymi rozwiązaniami technologicznymi, kotły fluidalne są szczególnie podatne na uszkodzenia korozyjno-erozyjne instalacji [9]. Awarie kotłów parowych spowodowane przeciekami pary, ale także nieszczelnościami komory spalania (ekranów, naroży, rur), stanowią poważny problem techniczny i ekonomiczny. Często narastanie nieszczelności rozwija się początkowo dość wolno i np. przez kilka, kilkanaście dni obsługa techniczna nie zauważa uszkodzenia [9, 11]. Wczesna detekcja, w przypadku wolno narastających w kotle bloku energetycznego nieszczelności, umożliwia podjęcie racjonalnej decyzji o momencie wyłączeniu bloku. Prace nad metodami predykcyjnego, względem masywnych przecieków, wykrywania awarii w kotłach prowadzone są od dłuższego czasu [1, 6, 11]. Dotychczas w energetyce stosuje się specjalizowane rozwiązania w postaci czujników i systemów detekcji akustycznej, sprawdzania bilansu parowo-wodnego lub monitorowania wilgotności spalin. Każdą z tych metod cechują określone niedogodności, a zwłaszcza nieczułość na małe wartości przecieku.

Instytut Automatyki i Robotyki Politechniki Warszawskiej dysponuje wieloletnim archiwum sygnałów procesowych z kotłów energetycznych, zgromadzonym w czasie prowadzenia prac badawczych. Analiza stanów poprzedzających awarie stanowi podstawę modelowania i wykrywania rozwoju uszkodzenia.

Ostatnio zostały opracowane i wdrożone w wielu dziedzinach techniki systemy detekcji i lokalizacji uszkodzeń wykorzystujące metody i algorytmy sztucznej inteligencji (SI), w tym sztuczne sieci neuronowe (SSN), układy wnioskowania rozmytego, struktury neuronowo-rozmyte lub algorytmy ewolucyjne [1, 2, 5, 8, 10]. Często główną ideą tych rozwiązań jest ciągłe porównywanie sygnałów procesowych mierzonych w trybie on-line z wynikami numerycznego modelowania istotnych zmiennych procesu. Niezgodność między tymi sygnałami, nazywana residuum, stanowi informację o uszko-

dzeniu lub awarii monitorowanego procesu lub urządzenia. Ze względu na złożoność, nieliniowość lub pewne cechy niestacjonarności procesu, praktyczne rozwiązania dotyczące modeli obiektów a także identyfikacji ich opisu są dość często realizowane metodami SI lub rozszerzone o pewne funkcje wykorzystujące te techniki [2, 3, 4, 5, 8, 10].

Jakość i dokładność modeli opracowywanych metodami SI warunkowana jest oczywiście właściwym dla zadania modelem doborem sygnałów – wejść modelu. Skuteczny we wczesnej detekcji model przecieku wymaga określenia i przetestowania przydatności diagnostycznej wykorzystanych sygnałów procesowych. Jest to też warunek pożądanej przenośności uzyskanego rozwiązania na kolejne, podobne instalacje.

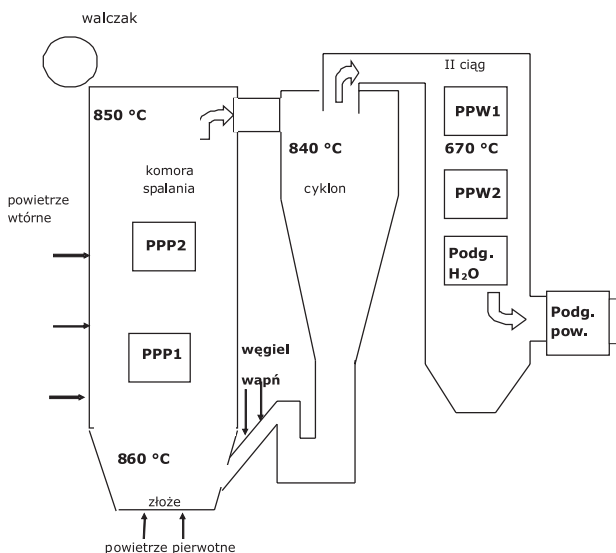
Badania prowadzono dla różnych typów nieszczelności kotłów fluidalnych i pyłowych, przy czym nacisk położono na detekcję awarii w kotłach fluidalnych. Określono trzy rodzaje – lokalizacje awarii i opracowano ich trzy oddzielne modele.

Krótki opis technologii spalania fluidalnego, dostępnych w kotle sygnałów procesowych oraz rodzajów nieszczelności przedstawiono w następnym punkcie. Następnie omówiono kryteria doboru sygnałów pomiarowych – wejściowych do modeli, a w części *Modele detekcji nieszczelności* zaprezentowano koncepcję modeli przecieku w strukturach SSN. Przydatność diagnostyczną zaproponowanych zestawów sygnałów przetestowano uruchamiając modele na danych archiwalnych obejmujących awarie tego samego typu niestosowane w procesie uczenia. Wyniki prac przedstawiono w punkcie *Ocena przydatności diagnostycznej sygnałów procesowych*. Wnioski i uwagi zebrane w ostatnim punkcie podsumowują wyniki przeprowadzonych prac.

Spalanie w kotle fluidalnym – dostępne sygnały pomiarowe

Kotły fluidalne z cyrkulującym złożem (CFB) [9, 13] składają się z komory spalania, cyklonów – kanałów nawrotu cyrkulu-

jącego złoża, II ciągu spalin – kanału konwekcyjnego (rys. 1). Spalanie w warstwie fluidalnego złoża zachodzi w dolnej części komory, dokąd dostarczane są także powietrze oraz rozdrobnione paliwo. Temperatura spalania wynosi ok. 860 °C. W kotłach typu CFB następuje ponowne zawrócenie większych niespalonych cząstek paliwa z górnych przestrzeni komory przez cyklony do obszaru złoża. Przeważają pary pierwotnej zachodzi w wymiennikach zamontowanych w komorze spalania, gdzie znajdują się przegrzewacze pary pierwotnej pierwszego (PPP1) i drugiego stopnia (PPP2). W drugim ciągu kotła zamontowane są przegrzewacze międzystopniowe, czyli przegrzewacze pary wtórnej wylotowej ze stopnia wysokoprężnego, podawanej po przejściu przez dwa stopnie przegrzewu (PPW1, PPW2) na średnioprężny stopień turbiny. W bilansie ciepła poszczególnych przegrzewaczy należy uwzględnić odbiór ciepła zachodzący w efekcie działania schładzaczy wtryskowych. W końcowym etapie przepływu spalin znajduje się podgrzewacz wody (Podg. H₂O) oraz powietrza (Podg. pow.).



Rys. 1. Schemat budowy kotła fluidalnego z cyrkulującym złożem

Fig. 1. Schematic diagram of circulating fluidized bed boiler

Warunki panujące w komorze spalania (intensywny ruch cząstek złoża, temperatura, zapylenie) wyznaczają bardzo wysokie wymagania wobec czujników pomiarowych. Z tego powodu w dużej przestrzeni komory spalania zamontowane są stosunkowo nieliczne czujniki temperatury i ciśnienia złoża fluidalnego oraz cyrkonowe sondy stężenia tlenu. O zachodzących w komorze spalania zjawiskach pośrednio informują parametry pary z pierwszego i drugiego stopnia przegrzewacza pary pierwotnej wprowadzanej następnie jako para przegrzana do wysokoprężnego stopnia turbiny. W II ciągu kotła spaliny pozbawione są cząstek stałych i narażenie instalacji na erozję i inne zjawiska zniszczenia jest tu znacznie mniejsze niż w komorze spalania. Jest tu zainstalowanych znacznie więcej czujników pomiarowych, mierzone są strumień, temperatura i ciśnienie w kanale spalin oddających ciepło w kolejnych przegrzewaczach pary, a następnie w podgrzewaczu wody i powietrza.

Jak wspomniano, kotły fluidalne są szczególnie podatne na uszkodzenia korozyjno-erozyjne instalacji [9]. Ten typ nie-

sprawności wpływa również ujemnie na warunki przekazywania ciepła oraz przyczynia się do częstej wymiany uszkodzonych elementów. W procesie rozwoju awarii można wyróżnić także inne niekorzystne, destrukcyjne zjawiska związane z wysoką temperaturą i ciśnieniem panującymi w instalacjach kotła. Zjawiska te są na ogół bardzo złożone i występują jednocześnie, nakładając się na siebie i przyspieszając proces niszczenia.

Przegląd podstawowych schematów technologicznych kotła fluidalnego: układów powietrza, paliwa, wody zasilającej, pary oraz spalin umożliwił wytypowanie ok. 120 sygnałów z każdego bloku do tworzenia archiwalnych zapisów definiujących procesy spalania w każdym z sześciu kotłów (trzech pyłowych i trzech fluidalnych CFB) z lat 2005–2009 r. Niektóre z wytypowanych sygnałów (np. strumienie wody do wtrysków, jak też stężenia składników spalin) mierzone są z bardzo zmienną w czasie dokładnością i wręcz nie zapewniają ilościowej reprezentacji mierzonych wielkości.

Dobór zmiennych procesowych

W budowie modeli procesów do celów diagnostyki i generacji residuum pożądane jest, by sygnały wejściowe modelu były możliwie mało wrażliwe na uszkodzenia procesu, tak by residuum między mierzoną zmienną procesową a wyjściem z modelu, traktowanym jako pewien wzorzec, wykazało jak największą wartość, gdy w procesie wystąpi uszkodzenie i mierzony sygnał będzie zmieniony wobec normalnego stanu procesu.

W przypadku, z jakim mamy do czynienia, nie występuje jedna zmienna (reprezentująca stan procesu), której wartość zmieniałaby się w sposób ciągły w sytuacji narastania awarii. Wymaganiem, jakie stawiamy tworzonemu modelowi, jest sygnalizacja stanu narastania przecieku. Uzasadnione jest więc opracowanie modelu awarii wypracowującego wyjście jako pewną funkcję wejść – zmiennych wrażliwych na przeciek. Wyznaczenie odpowiedniego zestawu sygnałów procesowych nie jest jednak oczywiste.

W patencie USA [1] proponowane jest tworzenie modeli przecieku parowego w postaci sztucznych sieci neuronowych oraz logiki rozmytej przy założeniu, że znana jest wartość przecieku odpowiednio ze znacznym wyprzedzeniem wobec chwili wyłączenia bloku, co (jak wspomniano w pierwszym punkcie) następuje zazwyczaj przy dość znacznej nieszczelności. Jednak w praktyce eksploatacji, początek rozwijania się awarii często nie jest zauważony przez obsługę techniczną [11, 12] i tym bardziej nie jest wtedy pomiarowo wyznaczony przeciek. W pracy [1] określono zmiennie wrażliwe na przeciek parowy, wyznaczając zestaw tzw. zmiennych uniwersalnych zapewniających detekcję przecieku, a także zestawy zmiennych tzw. lokalnych, pozwalających zlokalizować nieszczelności. Badano wrażliwość poszczególnej zmiennej procesowej q_i jako $w(q_i)$ z rekordów zarejestrowanych pomiarów, gdy rozwijał się przeciek i znana była jego wartość p :

$$w(q_i) = \left| \frac{\Delta q_i}{p} \right|, \quad (1)$$

gdzie: $\Delta q_i = q_i(t + \Delta t) - q_i(t)$, $\Delta t = 5$ min

Znaczna wartość wyznaczonej wrażliwości $w(q_i)$ musiała być zachowana w kilku (co najmniej 3 lub 4) kolejnych taktach obliczeń. W algorytmie określenia zestawu zmiennych procesowych, do wykorzystania we wczesnej detekcji nieszczelności kotła, niezbędne jest też określenie korelacji wzajemnej zmiennych o znacznej wrażliwości, w celu usunięcia sygnałów zbyt mocno skorelowanych ze sobą, czyli powtarzających w modelu informację. Ten etap eliminacji zmiennych należy prowadzić bardzo rozważnie z powodu dominującej w przebiegach zależności zmiennych procesowych od obciążenia – mocy bloku [7] (rys. 2).

Ostatecznie wyznaczono przykładowy zestaw uniwersalnych zmiennych wrażliwych [1], pozwalających wykryć przeciek (2 do 6 zmiennych):

- strumień wody zasilającej zimnej
- strumień powietrza do spalania
- ciśnienie na ssaniu wentylatorów spalin.

Zaproponowano też zestawy lokalnych zmiennych wrażliwych na przeciek w określonych punktach układu parowodnego. Należą do nich: poziom wody w walcu, strumień pulweryzowanego węgla, ciśnienia i wybrane temperatury za kolejnymi stopniami wymienników ciepła w przestrzeniach komory i II ciągu kotła, strumień kondensatu do odgazowacza, temperatura wody przed wtryskiem. Niektóre z ww. sygnałów nie są dostępne w archiwalnych zbiorach danych, w rejestracjach innych występuje wiele braków. Budowa i testy modeli neuronowych warunkowane są dostępnością przyjętych sygnałów zarówno w trybie off-line, jak i on-line, stąd ostatecznie analizowane zestawy sygnałów musiały być ograniczone do dostępnych w archiwalnych zapisach.

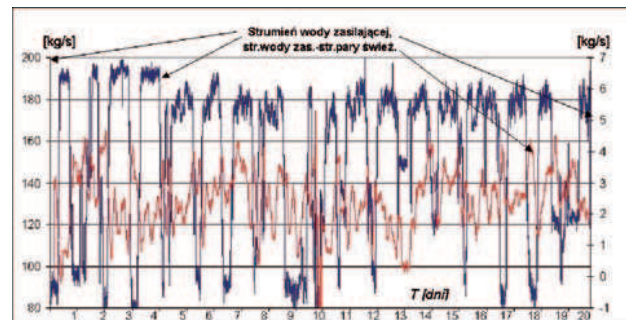
Modele detekcji nieszczelności

Podjęte wcześniej w Instytucie Automatyki i Robotyki Politechniki Warszawskiej prace nad wczesną detekcją nieszczelności kotła przez analizę podstawowych składników spalin (z analizatora), a następnie wyznaczenie residuum wilgotności spalin pozwoliły na wykrycie przecieku jedynie z wyprzedzeniem rzędu 3 h przed odstawieniem bloku [3, 7].

Poszukiwano więc modelu awarii nie znając liczbowej wartości przecieku i znacznika startu narastania nieszczelności, dysponując jednak wstępną wiedzą na temat zmiennych wrażliwych na przeciek parowy [1]. Takie zadanie można rozwiązywać stosując do klasyfikacji SSN. Sygnały wejściowe modeli neuronowych powinny wykazywać zmienność (wrażliwość) w sytuacji przecieku w kotle, tak aby wyjście modelu dokonywało podziału stanów pracy kotła na dwa podzbiory: stan poprawny (etykieta *poprawnie*) i przypisany sytuacji narastania przecieku (etykieta *awaria*). Najkorzystniej byłoby, gdyby uczenie sieci neuronowej wyróżniające stan poprawny i awaryjny można było zrealizować przez algorytm samoorganizacji danych, bez udziału eksperta narzucającego w zbiorze uczącym podział na dwie wyróżnione wyżej kategorie stanów procesu. Takie rozwiązanie mogłoby być dostępne w strukturze sieci Kohonena. Ponieważ jednak podjęte w tym względzie próby nie przyniosły spodziewanych efektów w przypadku sieci samoorganizujących się, okazało się konieczne wprowadzenie do zbioru danych uczących etykiet przyporządkowanych poszczególnym rekordom sygnałów. Rozróżnienie pracy poprawnej kotła od stanu powstającej awarii, na danych

off-line, do wykorzystania w fazie uczenia modelu, powinno być przeprowadzone przez technologa lub inżyniera-eksperta oceniającego analitycznie stan procesu. Jest to decydujący moment przygotowania danych i jego poprawne przeprowadzenie jest warunkiem skuteczności działania tworzonego modelu neuronowego.

Wśród awarii zarejestrowanych w archiwum znajdują się pojedyncze sytuacje widocznej skokowej zmiany w przebiegach czasowych zmiennych wrażliwych na przeciek. Wobec takich przypadków szczególnie łatwo jest przeprowadzić etykietowanie stanu procesu. Jednak w większości sytuacji przedawaryjnych (rys. 2) trudno zauważyć w przebiegach poszczególnych zmiennych oznaki awarii, a badanie residuum zmiennych przed wyłączeniem bloku nie uwidoczniło prostych zależności.




Rys. 2. Przebiegi czasowe przed wyłączeniem bloku z powodu przecieku w komorze spalania. Strumień wody zasilającej oraz uśredniona różnica strumieni wody zasilającej i pary świeżej

Fig. 2. Time signal series taken just before switching boiler off. Isolated fault: leaky combustion chamber. Signals: flow rates of the boiler supply water and averaged difference of the supply water and raw steam

Stąd założenie/oczekiwanie, że dyskretne symptomy rozwoju awarii z zestawu sygnałów wrażliwych na przeciek zostaną powiązane w działaniu SSN.

Dysponując przygotowanymi zbiorami danych (po niezbędnym preprocesingu [2, 7, 8] oraz przypisaniu etykiet) można byłoby przeprowadzić uczenie z nauczycielem i uzyskać sieci klasyfikujące stany pracy kotła. Zastosowane podejście jest próbą zautomatyzowania oceny stanu pracy kotła i rekurencyjnego poszerzania podzbiorów rekordów przypisanych stanom *awaria*. Wyjaśniono to na rys. 3. W pierwszym zbiorze uczącym stan poprawny reprezentowany był danymi sprzed ok. 3 tygodni od momentu wyłączenia bloku (próbkowanymi co 20 min) – etykieta *poprawnie*. Przyjęto założenie, że analizowana awaria wywiera, z dużym prawdopodobieństwem, wpływ na wybrane zmienne procesowe co najmniej 4 h przed odstawieniem bloku [11].



Rys. 3. Wstępny podział rekordów danych sprzed wyłączenia bloku

Fig. 3. Draft data records division just before power-unit switching off

Te rekordy opisano etykietą *awaria* (oznaczenie *awaria1* – próbkowane co 1 min). Na zbiorze uczącym złożonym z danych opatrzonych etykietami przeprowadzono trening sieci. Uzyskaną sieć uruchomiono na pełnym uporządkowanym zbiorze danych. Jeśli ustalony stan *awaria* był wskazywany na wyjściu modelu w sposób niezmienny, ciągle na dłuższym odcinku przed wyłączeniem bloku, do nauki włączono dane z całej doby przed odstawieniem bloku. Rozszerzenie zbioru uczącego o dane z co najmniej jednej doby pozwoli uzyskać generalizację tego stanu, niezależną od obciążenia bloku, zmiennego w cyklu dobowym (rys. 2). Należy zauważyć, że dla wielowymiarowego, złożonego oraz zmiennego w czasie procesu spalania w kotle (np. w skutek zmian składu paliwa czy trendów o długim horyzoncie) uzyskanie modeli w postaci sieci neuronowych zapewniających poprawną klasyfikację, wymaga użycia, na etapie uczenia modelu, danych cechujących wiele sytuacji poprawnej pracy bloku oraz danych z wielu stanów nasilania się awarii. Właściwości poprawnej generalizacji danych są niezbędną cechą utworzonej struktury różniącej stany obiektu.

W efekcie analizy danych archiwalnych z elektrowni opracowano zestawienie awarii 6 bloków energetycznych z 5 ostatnich lat eksploatacji, zawierające zapisy sygnałów pomiarowych z systemów DCS dla 26 awarii w obrębie układu para-woda oraz 35 awarii typu nieszczelność komory paleniskowej, ekranów, naroży itp. Większość publikacji dotyczących detekcji nieszczelności kotła koncentruje się na przeciekach w układzie parowo-wodnym, gdy w praktyce, co najmniej tak samo liczne okazują się nieszczelności pyłowe w obrębie komory spalania, której pomiarowe wyposażenie jest bardzo ograniczone. Przegląd zarejestrowanych w archiwum danych pozwolił wytypować 3 rodzaje awarii, których powtarzalność umożliwiła zastosowanie proponowanej metodyki budowy modeli oraz oceny przydatności diagnostycznej sygnałów mierzonych w procesie spalania. Są to nieszczelności w obrębie przegrzewacza pary wtórnej, podgrzewacza wody (obie awarie w II ciągu kotła) oraz nieszczelności typu erozyjnego w obszarze komory spalania (część miała przypisaną lokalizację, a część – nie). Przyjęto założenie, że zostaną opracowane modele awarii oddzielnie dla każdego z trzech ww. typów/lokalizacji nieszczelności.

Ocena przydatności diagnostycznej sygnałów procesowych

Ocenę przydatności diagnostycznej sygnałów przeprowadzono pośrednio. Z użyciem wytypowanych sygnałów wrażliwych na przeciek, opracowano modele detekcji trzech ww. typów awarii w postaci SSN, poprawnie klasyfikujące rozwój nieszczelności na przykładzie awarii użytej w uczeniu. W wyniku analizy wrażliwości sieci neuronowej względem sygnałów wejściowych [7, 8, 14] zredukowano liczbę wejść modeli, tak aby wskaźnik poprawnej klasyfikacji był $>0,95$. Następnie rozszerzono zbiór uczący o rekordy stanu normalnej pracy a także rozwoju awarii przed kilku awarii tego samego typu, rozłożonych w czasie. Po ponownym uczeniu sieć uruchomiono na zapisach niezależnych awarii testowych tego samego typu, nieznanymi w fazie uczenia i zbadano zdolność generalizacji struktur SSN. Jeśli poprawna klasyfikacja w teście osiągała jakość ok. 0,9, to przyjmowano, że to działanie jest satysfakcjonujące.

Zastosowana metoda oceny przydatności sygnałów wejściowych nie stanowi bezwzględnej miary istotności poszczególnych zmiennych w zadaniu rozróżnienia stanu poprawnego i stanu awarii. Jej wynik odnosi się do modeli SSN i może się w niewielkim stopniu różnić zależnie od metody uczenia i przygotowania plików uczących. Jako wynikowe podano zestawy zmiennych powtarzające się w wielu przebadanych strukturach SSN. Wprowadzono pewne zmienne różnicowe istotne w bilansowym ujęciu procesów cieplnych w kotle:

- Δp pary na stopniu WP turbiny
 - Δp pary na stopniu SP turbiny
 - Δ strumieni wody zasilającej i pary pierwotnej
 - Δ temperatury złoża i wejścia do cyklonu
 - Δ temperatury pary przegrzanej i pierwotnej,
- a także zmienne odpowiadające średnim wartościom:
- średnia temperatura inerty na wejściu do 2 cyklonów
 - średnie stężenie O_2 w komorze spalania.

Zastosowanie tak zdefiniowanych zmiennych wejściowych pozwoliło uzyskać bardziej wyrównane „wzmocnienia” modelu awarii względem poszczególnych wejść. Zmienne różnicowe są w mniejszym stopniu skorelowane z obciążeniem bloku i w tym względzie właściwe jest ich używanie w modelach.

Określono zestawy zmiennych dla modeli trzech awarii:

- nieszczelność komory spalania:
 - 1) strumień powietrza do spalania, 2) strumień wody zasilającej, 3) ciśnienie na ssaniu wentylatorów spalin, 4) temperatura złoża fluidalnego, 5) średnia temperatura inerty na wejściu do 2 cyklonów, 6) Δ temperatury złoża i wyjścia z cyklonu, 7) ciśnienie w komorze spalania, 8) O_2 w komorze spalania, 9) CO_2 przed elektrofiltrem, 10) Δ strumieni wody zasilającej i pary pierwotnej,
- nieszczelność przegrzewacza pary wtórnej:
 - 1) sygnały 1–5 jw., 6) Δp pary na stopniu SP turbiny, 7) Δ temperatury pary wtórnej na przegrzewaczu pary wtórnej,
- nieszczelność podgrzewacza wody:
 - 1) sygnały 1–5 jw., 6) Δ temperatury wody na podgrzewaczu wody.

Przeprowadzone testy działania modeli na sytuacjach awarii niestosowanych w uczeniu potwierdziły skuteczność detekcji nieszczelności z założonym współczynnikiem poprawnej klasyfikacji równym 0,9 dla awarii w II ciągu bloku, tzn. nieszczelności przegrzewacza pary wtórnej i podgrzewacza wody (badania na 5 sytuacjach przecieku). Sytuacje przecieku w komorze spalania badane były dla 6 awarii. Dla 4 z nich uzyskano detekcję ze współczynnikiem poprawnej klasyfikacji równym 0,9. Na dwu pozostałych awariach uzyskano poprawną klasyfikację ze współczynnikiem $>0,7$. Ten gorszy wynik jest efektem mało precyzyjnego opisu awarii w komorze spalania (brak precyzyjnej lokalizacji, także rozróżnienia awarii różnych typów w różnych fragmentach komory). Dostępność sygnałów pomiarowych w tym obszarze jest bardzo ograniczona i wczesne wykrywanie nieszczelności komory może okazać się dość trudne. Detekcja przecieków w przestrzeni komory spalania jest uwarunkowana generalizacją wiedzy z zapisów przebiegów zmiennych w sytuacjach przedawaryjnych w krytycznych lokalizacjach komory.

Wnioski

Uzyskane wyniki w zadaniu wczesnej detekcji awarii są obiecujące, zwłaszcza w odniesieniu do awarii w II ciągu kotła. Modele powinny jednak być przetestowane w długim horyzoncie czasu z powodu występujących w praktyce długookresowych trendów w procesie spalania [4].

Zestaw zmiennych podanych w pracy [1] jako zestaw uniwersalny okazał się niewystarczający w badanych przypadkach awarii.

Podjęta próba automatyzacji etykietowania rekordów archiwalnych dała pozytywne efekty.

Określenie zestawów zmiennych procesowych wrażliwych na przeciek umożliwiło dość łatwe opracowanie modeli dla kolejnych bloków o podobnej zasadzie działania.

Próby uzyskania klasyfikacji w strukturach sieci Kohonena, uczonych bez nauczyciela, nie dały rezultatu pozytywnego. W testach potwierdzono większą przydatność w omawianym zadaniu struktur MLP niż RBF, mimo wyższej wrażliwości sieci RBF na sygnały wejściowe.

Bibliografia

1. 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 20, 2001.
2. Jankowska A., Kornacki S.: *Artificial Neural Networks Approaches to Monitoring of Combustion In Fluid Boiler*. PAK, Vol. 55, 3/2009, s. 149–151.
3. Jankowska A.: *Approach to Early Boiler Leak Detection with Artificial Neural Networks*. Recent Advances in Mechatronics, Springer Verlag, 2007, p. 57–61.
4. Kornacki S.: *Neuronowe modele procesów o zmiennych właściwościach*. VII Krajowa Konferencja *Diagnostyka Procesów Przemysłowych*, Rajgród 12–14.09.2005. PAK 9/2005.
5. Kościelny J.M.: *Diagnostyka zautomatyzowanych procesów przemysłowych*. Akadem. Oficyna Wyd. EXIT, Warszawa, 2001.
6. Lang F.D., Rodgers D.A.T., Mayer L.E.: *Detection of Tube Leaks and their Location Using Input/Loss Methods*. Proc. of the Int. Joint Power Gener. Conf. Baltimore, Maryland, 03.30–04.01.2004 r., IJPGC2004-52027.
7. Olwert K.: *Opracowanie i analiza modelu wilgotności spalin w zadaniu wczesnej detekcji nieszczelności parowej kotła bloku energetycznego*, praca dyplomowa PW D-IAR-306, 2006, praca niepublikowana.
8. Osowski S.: *Sieci neuronowe do przetwarzania informacji*. Oficyna Wyd. PW, Warszawa 2006.
9. Pawlik M., Strzelczyk F.: *Elektrownie*. Wydanie 5, WNT, Warszawa 2009.
10. Patton R. J., Lopez-Toribio C.J., Uppa F.J.: *Artificial Intelligence Approaches to Fault Diagnosis*. Int. Journal of Applied Mathematics and Computer Science. Vol. 9, No 3. 471–518 (1999).
11. Xi Sun, Tongwen Chen, Marquez H. J.: *Efficient model-based leak detection in boiler steam-water system*. Computers and Chemical Engineering 26(2002), p. 1642–1647.
12. Xi Sun, Marquez H. J., Tongwen Chen: *An improved PCA method with application to boiler leak detection*. ISA Transactions 44 (2005), p. 379–397.
13. http://energetyka.wnp.pl/kotly-fluidalne,4552_2_0_0.html
14. *STATISTICA Neural Networks PL*, Przewodnik problemowy, StatSoft Polska Sp. z o.o., 2004, Kraków. ■

Evaluation of the power boiler process signals regarding their diagnostic applicability

An application of artificial neural networks for early detection of rising steam leaks and leaks within the combustion chamber of power unit, is presented. A set of signals sensitive to leakage proposed in the literature has been supplemented with further measuring variables enabling reaching significantly better classification quality than with the minimum set of 3-4 variables. As classification networks the Radial Basis Function (RBF) and Multilayer Perceptron (MLP) having one or two hidden layers trained with the teacher, were examined. Reduction of input variables belonging to the considered set was realised with sensitivity analysis of resulting networks, testing their generalisation ability on unknown failure situations of the same type.

Classification exceeding 90 % of proper process states attribution for unknown during the learning phase faults cases was obtained. The 11 independent test cases confirmed that for discussed tasks MLP structures were more useful than RBF ones, despite higher sensitivity of RBF networks to input signals.

Keywords: artificial neural network, fluidized bed boiler, early boiler fault detection, sensitivity analysis

dr inż. Anna Jankowska

Absolwentka i adiunkt Wydziału Mechatroniki, pracownik Instytutu Automatyki i Robotyki Politechniki Warszawskiej. Autorka ponad 40 publikacji z dziedziny modelowania złożonych procesów, modeli w strukturach sztucznych sieci neuronowych, diagnostyki z użyciem modeli neuronowych, przetwarzania sygnałów, automatyzacji badań maszyn.

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

