

Mariusz PAWLAK

Instytut Techniki Ciepłej, Łódź

ROZMYTE SIECI NEURONOWE JAKO MODELE DIAGNOSTYCZNE W UKŁADZIE REGULACJI TURBINY KONDENSACYJNEJ

Słowa kluczowe

Układ regulacji, modelowanie rozmyte, sieci neuronowe, diagnostyka, tory pomiarowe.

Streszczenie

W artykule przedstawiono wykorzystanie modelowania w układzie regulacji turbiny kondensacyjnej do celów diagnostycznych. Diagnostyce podlegają tory pomiarowe doprowadzone do systemu sterowania. Opisano sposób budowy modeli cząstkowych wykorzystywanych do detekcji uszkodzeń, które wykorzystują technikę rozmytych sieci neuronowych.

Wprowadzenie

Znane dzisiaj metody i techniki pozwalające na zwiększenie niezawodności systemów regulacji można podzielić na metody redundancji sprzętowej i informacyjnej. Redundancja informacyjna toru pomiarowego występuje wówczas, gdy dodatkowa wartość zmiennej procesowej jest wyliczana z modelu matematycznego wiążącego wyliczaną zmienną z innymi mierzonymi sygnałami. Zamiast stosowania nadmiarowych urządzeń pomiarowych w strukturze systemu, jak to ma miejsce w redundancji sprzętowej, wykorzystywane są modele matematyczne do wyliczania wartości zmiennych procesowych. W Instytucie Techniki Ciepłej w Łodzi podjęto prace zmierzające do zastosowania redundancji

analitycznej w cyfrowych układach regulacji turbin [3]. Zasada działania układu wykorzystującego model do detekcji uszkodzenia polega na analizie różnicy (residuum) porównywanych sygnałów: modelowego z rzeczywistym.

Jednym ze sposobów opracowania modeli do celów diagnostycznych jest użycie struktury opartej na podstawie rozmytych sieci neuronowych.

Rozmyte sieci neuronowe są połączeniem modelowania rozmytego ze strukturą sztucznych sieci neuronowych. Tworząc rozmytą sieć neuronową wykorzystuje się wiedzę eksperta do określenia liczby reguł oraz wstępnego rozmieszczenia funkcji przynależności. Na podstawie danych zebranych z rzeczywistego obiektu można przeprowadzić proces uczenia sieci.

1. Struktury rozmytych sieci neuronowych

Budowę modelu FNN (Fuzzy Neural Network) zaczyna się od wybrania zmiennych wejściowych i wyjściowych. Stanowią one odpowiednio wejście i wyjście sieci FNN. Następnie należy określić liczbę funkcji przynależności poszczególnych wejść. Dalszy przebieg identyfikacji sieci odbywa się automatycznie według algorytmu uczenia [1, 2, 6].


Podstawowe zalety modeli FNN to: czytelny związek pomiędzy elementami modelu i sieci, wykorzystanie danych pomiarowych do uczenia, możliwość interpretowania jako model rozmyty w formie reguł „jeżeli... to”. Z tych przyczyn rozmyte sieci neuronowe są przydatnym narzędziem do tworzenia modeli przeznaczonych do detekcji uszkodzeń. Rozmyta sieć neuronowa jest strukturą przedstawiającą proces wnioskowania rozmytego w postaci struktury sieci neuronowej. Parametry tej sieci: kształt funkcji przynależności i ich położenie w przestrzeni wejść przedstawione są za pomocą wag połączeń. Tak zbudowana sieć może identyfikować parametry reguł rozmytych wbudowanych w sieć, modyfikując wagi połączeń, wykorzystując algorytm propagacji wstecznej błędu lub inne algorytmy uczenia sieci neuronowych.

FNN można zapisać w formie zbioru reguł rozmytych i rozpatrywać jak model rozmyty. Wyróżnić można trzy rodzaje rozmytych sieci neuronowych [2]:

- stała (singelton),
- kombinacja liniowa wejść (model TSK),
- liczba rozmyta.

Strukturę FNN można podzielić na dwie zasadnicze części. Część pierwsza reprezentuje tzw. przesłanki i odpowiada za fragment reguły rozmytej „jeżeli...”. Realizuje ona część mechanizmu wnioskowania odpowiadającego za obliczenie poziomów zapłonów reguł. Część drugą reprezentuje tzw. konkluzja, co odpowiada fragmentowi reguł rozmytych „to ...”. Oblicza ona wyjście modelu. Część „przesłanek” jest identyczna dla wszystkich rodzajów sieci, różnice występują w części „konkluzji”.

Rys. 1 przedstawia przykład części „przesłanek” FNN dla przypadku o dwu wejściach (x_1 , x_2) i dziewięciu regułach. Każde wejście zostało opisane za pomocą trzech podzbiorów rozmytych A_{ij} .



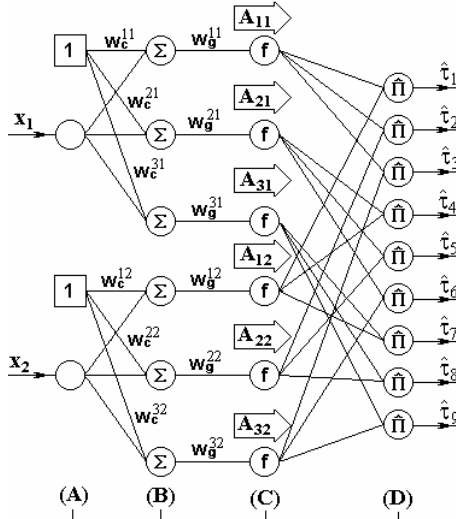
Rys. 1. Realizacja przesłanek w modelu FNN

W artykule przeanalizowano wykorzystanie funkcji przynależności w postaci krzywych gaussowskich lub krzywych o kształcie trójkątnym (funkcje przynależności typu (t)).

Funkcja przynależności klasy (t) jest zdefiniowana wg wzoru (1):

$$t(x; a, b, c) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x-a}{b-a} & \text{dla } a \leq x \leq b \\ \frac{c-x}{c-b} & \text{dla } b \leq x \leq c \\ 0 & \text{dla } x \geq c \end{cases} \quad (1)$$

Strukturę sieci neuronowo rozmytej, której funkcje przynależności są zrealizowane za pomocą funkcji Gaussa można podzielić na warstwy, jak to przedstawiono na rys. 2.



Rys. 2. Realizacja przesłanek w modelu FNN

Warstwa (A) sieci ma jedynie postać symboliczną i służy do przekazywania wejść sieci oraz sygnału równego 1 poszczególnym jednostkom warstwy (B). Koła i kwadraty na rysunku oznaczają jednostki sieci. Symbole w_c^{ij} , w_g^{ij} pomiędzy jednostkami stanowią wagi połączeń sieci. Jednostka w kwadracie oznaczona 1 w warstwie (A) jest elementem sieci o stałym wyjściu równym 1. Wyjście warstwy (C) jest wartością funkcji przynależności zbioru A_{ij} dla określonego wejścia x_j , co można zapisać w postaci wzoru:

$$\mu_{A_{ij}}(x_j) = \exp\left[-(w_g^{ij}(x_j + w_c^{ij}))^2\right] \quad (2)$$

Wzór (2) przedstawia często stosowaną funkcję przynależności: dzwonową funkcję Gaussa. Analizując wzór (2) można zauważyć, że wagi w_c i w_g są parametrami, które decydują o położeniu funkcji w przestrzeni wejść, w_g jest parametrem określającym szerokość funkcji, a w_c decyduje o położeniu w przestrzeni wejścia x .

Sieć poprzez wartości wag w_c i w_g dzieli przestrzeń wejść pomiędzy poszczególne funkcje przynależności (rys. 2). W warstwach (A)÷(C) są obliczane stopnie przynależności funkcji wchodzących w skład przesłanek.

Połączenia między warstwą (C) i (D) realizowane są w taki sposób, aby uzyskać wszystkie kombinacje funkcji przynależności obu sygnałów wejścio-

wych. Zakładając, że przestrzeń wejściowa jest równomiernie podzielona I_1 funkcjami przynależności dla wejścia x_1 oraz odpowiednio I_2 funkcjami przynależności dla wejścia x_2 uzyska się w ten sposób $K = I_1 \times I_2$ przesłanek reguł o postaci (3):

$$R^{i_1, i_2}: \text{jeżeli } (x_1 \text{ jest } A_{i_11} \text{ i } x_2 \text{ jest } A_{i_22}) \text{ to ...} \quad (3)$$

gdzie: $i_1 = 1, \dots, I_1$ oraz $i_2 = 1, \dots, I_2$.

W przykładzie przedstawionym na rys. 2 występuje $3 \times 3 = 9$ reguł rozmytych, których „przesłanki” dzielą przestrzeń wejść na 9 partycji.

W warstwie (D) jest obliczany poziom zapłonu poszczególnych reguł. Poziom zapłonu reguł jest wyznaczany jako iloczyn wartości funkcji przynależności wchodzących w skład „przesłanki”.

Ich zależność między wejściem a wyjściem jest zdefiniowana następująco:

$$\tau_k = \prod_j \mu_{A_{ij}}(x_j) \quad (4)$$

$$\hat{\tau}_k = \frac{\tau_k}{\sum_{k=1}^K \tau_k} \quad (5)$$

gdzie:

- τ_k – jest stopniem przynależności k-tej reguły,
- $\hat{\tau}_k$ – znormalizowany poziom zapłonu k-tej reguły rozmytej,
- K – liczba reguł rozmytych.

FNN można podzielić biorąc pod uwagę część sieci realizującą wnioskowanie, czyli tzw. „konkluzje” reguł rozmytych. Zgodnie z wcześniejszym opisem można wyróżnić trzy typy sieci: konkluzje w postaci wartości stałych, równań liniowych (model Takagi-Sugeno-Kangi) oraz konkluzje w postaci zbiorów rozmytych.

W sieci, w której konkluzję zdefiniowano jako stałą, reguły rozmyte, jakie realizuje model, przyjmują następującą postać (dla dwóch wejść x_1 i x_2):

$$R^{i_1, i_2}: \text{Jeżeli } x_1 \text{ jest } A_{i_11} \text{ i } x_2 \text{ jest } A_{i_22} \text{ to } y = f_k \quad (6)$$

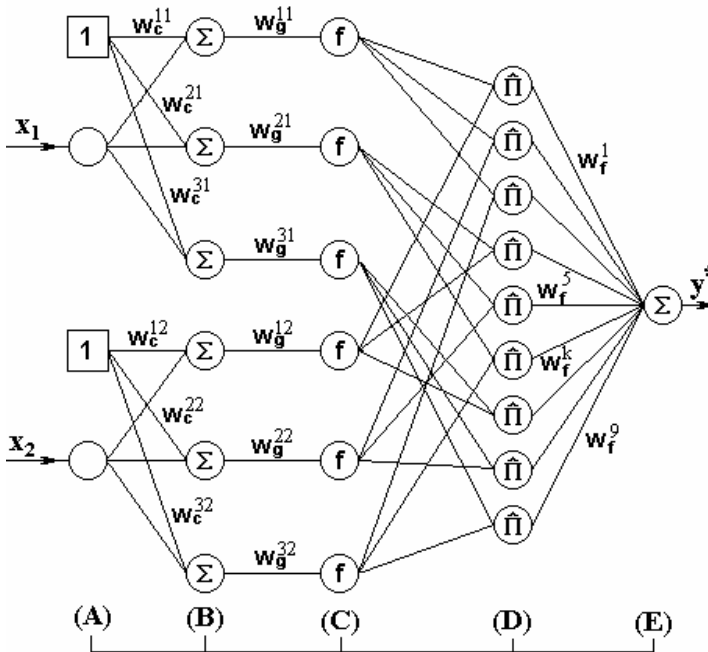
a wyjście sieci można wyrazić za pomocą wzoru:

$$y^* = \frac{\sum_{k=1}^K \tau_k f_k}{\sum_{k=1}^K \tau_k} = \sum_{k=1}^K \hat{\tau}_k f_k \quad (7)$$

gdzie:

- R^{ii2} – reguła rozmyta,
- $A_{i1 1}, A_{i1 2}$ – zbiory rozmyte,
- f_k – wniosek stała,
- K – liczba reguł rozmytych,
- y^* – wartość wyjściowa modelu.

Na rys. 3 przedstawiona została rozmyta sieć neuronowa, której „prześlanka” jest identyczna z rys. 2, natomiast „konkluzja” jest zgodna ze wzorem (6). Jest to przypadek modelu dla dwóch wejść i jednego wyjścia.



Rys. 3. Realizacja modelu FNN z wnioskami w postaci stałych

„Konkluzje” przedstawionej sieci zawarte są w warstwach (D) i (E), a wagi w_f^k reprezentują stałe f_k . Opisaną sieć wg zależności (6) można rozpatrywać jako szczególny przypadek modelu rozmytego Takagi-Sugeno-Kangi, w którym „konkluzje” reguł, zamiast równań liniowych zmiennych wejściowych, zawierają stałe.

Po określeniu rodzaju używanej sieci należy przystąpić do uczenia tej struktury na podstawie danych zebranych na obiekcie. Metoda uczenia FNN

może być oparta na algorytmie propagacji wstecznej błędu. Określa on sposób doboru wag sieci, przy wykorzystaniu gradientowych metod optymalizacji. Podstawę algorytmu stanowi funkcja kryterialna (8). Wartość jej jest tym mniejsza im lepiej są dobrane wagi w sieci.

W rozpatrywanym przypadku funkcja kryterialna przyjmuje postać (8):

$$E(W) = \frac{1}{2}(t - y^*)^2 \quad (8)$$

gdzie:

t – wzorcowa wartość wyjścia z modelu,

y^* – bieżąca wartość wyjścia z modelu,

W – wektor wag sieci.

2. Przykłady zastosowań praktycznych


W układzie regulacji turbiny wyodrębniono związki do zamodelowania. Związki te zostały znalezione pomiędzy sygnałami pomiarowymi wprowadzanymi do układu regulacji [3, 4].

Dane pomiarowe zostały zebrane podczas prób kontrolnych regulacji mocy na bloku energetycznym 120 MW, dzięki czemu uzyskano cały zakres zmian wielkości mierzonych.


Do uczenia wybranych modeli użyto zbioru uczącego. Zbiór ten został zapisany w pliku tekstowym z okresem próbkowania równym 1 s. Weryfikację modeli przeprowadzono na podstawie innego zbioru o tym samym okresie próbkowania. Dane były zbierane w Elektrowni Adamów na bloku energetycznym nr 1 oraz w Elektrowni Konin na bloku energetycznym nr 9.

Proces uczenia modeli przeprowadzono wykorzystując algorytm propagacji wstecznej błędu. W procesie uczenia modyfikacjom podlegały wagi w_f^k , a rozmieszczenie funkcji przynależności nie ulegało zmianie. Współczynnik uczenia wag wynosił $\eta^f = 0,001$. Dla każdego z zamodelowanych związków przeprowadzono badania z różnymi wartościami początkowymi. Wagi w_f^k , które podlegały modyfikacji, dążyły do tej samej wartości niezależnie od punktu startowego. Weryfikacje modeli przeprowadzono na podstawie zbioru z danymi, nie objętymi zestawem uczącym.


W dalszej części pracy zostały przedstawione przykładowe wykresy obrazujące efekty modelowania dla opracowanych sieci. Podczas testów badano wpływ wybranych elementów na jakość uzyskanych modeli. Pod uwagę brane były różne rodzaje sygnałów wejściowych oraz różne kształty funkcji przynależności.




Rys. 4. Efekt modelowania zależności $P = f(Y, p_s, p_T)$, gdzie: P – moc czynna, Y – sygnał sterujący, p_s – ciśnienie w skraplaczu, p_T – ciśnienie pary świeżej. Funkcjami przynależności były krzywe Gaussa



Rys. 5. Efekt modelowania zależności $P = f(Y, P_{t-1})$, gdzie: P – moc czynna, Y – sygnał sterujący. Funkcjami przynależności były krzywe Gaussa



Rys. 6. Efekt modelowania zależności $P = f(Y, p_T)$, gdzie: P – moc czynna, Y – sygnał sterujący, p_T – ciśnienie pary świeżej. Funkcjami przynależności były krzywe typu (t-trójkątne)



Rys. 7. Efekt modelowania zależności z rys. 6 przy zastosowaniu krzywych Gaussa jako funkcje przynależności

Podsumowanie

Wykresy przedstawione na rys. 4-7 przedstawiają modelowanie zmian mocy czynnej (P), przy różnych wariantach układów wejściowych. Model z rys. 4 ma najbardziej skomplikowaną strukturę ze względu na największą liczbę wejść. W zastosowaniach rozmytych sieci neuronowych istotnym problemem jest duża rozbudowa sieci przy zwiększającej się liczbie wejść. Liczba reguł gwałtownie rośnie wraz ze zwiększeniem się liczby wejść i partycji dla poszczególnych zmiennych. Model przedstawiony na rys. 4 składa się z 15 funkcji przynależności i 125 reguł rozmytych.

Model z rys. 5 uwzględnia dynamikę zmian sygnału P poprzez wprowadzenie wielkości modelowanej z kroku poprzedniego na wejście modelu. Modele tego typu zapewniają większą dokładność modelowania, ale w przypadku wystąpienia niektórych uszkodzeń mogą okazać się niewrażliwe. Taka struktura modeli nie gwarantuje szybkiej i niezawodnej detekcji uszkodzenia [2, 3, 4].

Porównanie modeli z jednakowymi sygnałami wejściowymi w zależności od rodzaju funkcji przynależności przedstawiają rys. 6 i 7. Możemy zaobserwować większą dokładność dla modelu z funkcjami przynależności z krzywymi Gaussa. Zastosowanie funkcji Gaussa w niektórych układach sterowania, zwłaszcza starszego typu może być kłopotliwe, dlatego wypróbowano zastosowanie funkcji o kształcie trójkąta.

Przy zastosowaniu trójkątnych funkcji przynależności uzyskano także zadowalające efekty modelowania umożliwiające praktyczne zastosowanie modelu do wykrywania uszkodzeń, co przedstawiono szczegółowo w pracy [3].

Na powyższych wykresach przedstawiono także residua oraz wartość średnią w przesuwym oknie czasowym dla każdego residua. Wielkość okna czasowego do obliczania wartości średnich uwzględnia kompromis między filtracją a niezbyt dużym opóźnieniem podania diagnozy.

Uszkodzenia torów pomiarowych można podzielić na dwa zasadnicze rodzaje: katastroficzne i parametryczne. Uszkodzenia katastroficzne powodują nagłą zmianę wartości residuum, co pociąga za sobą konieczność podjęcia natychmiastowych działań zabezpieczających. Uszkodzenia parametryczne związane są ze zwiększającym się zużyciem elementów i objawiają się w postaci małych zmian wartości residuum. Przy tych zakłóceniach miarami zmian może być średnia sygnału residuum.

Reasumując można stwierdzić, że przedstawione modele mogą być wykorzystane do celów diagnostycznych.

Praca naukowa finansowana ze środków Ministra Nauki i Szkolnictwa Wyższego, wykonana w ramach realizacji Programu Wieloletniego pn. „Doskonalenie systemów rozwoju innowacyjności w produkcji i eksploatacji w latach 2004–2008”.

Bibliografia

1. Drinkow D., Hellendoorn H., Reinfrank M.: Wprowadzenie do sterowania rozmytego. WNT 1996.
2. Kościelny J.M.: Diagnostyka zautomatyzowanych procesów przemysłowych. AOW EXIT, Warszawa 2001.
3. Pawlak M.: Opracowanie mikroprocesorowego układu regulacji turbiny kondensacyjnej tolerującego uszkodzenia torów pomiarowych i diagnozującego pracę urządzenia wykonawczego. Etap V, Etap VI, Etap VII Sprawozdanie ITC-7933, Łódź 2006.
4. Pawlak M.: Detekcja i lokalizacja uszkodzeń torów pomiarowych w układzie regulacji turbiny kondensacyjnej. VII Konferencja Problemy Badawcze Energetyki Ciepłej Warszawa, 6–9 grudnia 2005.
5. Pawlak M.: Algorithms of detection and isolation in control system of condensation turbine. Problemy Eksploatacji 2/2006.
6. Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwa Naukowe PWN 1997.

Recenzent:

Jan M. KOŚCIELNY

Fuzzy Neural Networks for instrument fault diagnosis of condensation turbine control

Summary

In the paper an application of fuzzy neural networks (FNN) for sensor fault diagnosis in condensation turbine control unit was given. The FNN are applied for fault detection processes. The FNN models of turbine power, live steam pressure and steam mass flow rate were created and verified. Satisfactory models performance indexes were obtained. The fault sensitivity of residuals was investigated and approved.

