

NEURONOWA SYMULACJA FLUKTUACJI CIŚNIENIA I TEMPERATURY PARY W UPUŚCIE PAROWEGO BLOKU ENERGETYCZNEGO

Justyna ŚLĘZAK-ŻOŁNA, Jerzy GŁUCH

Politechnika Gdańska, Wydział Oceanotechniki I Okrętownictwa
Katedra Automatyki Okrętowej i Napędów Turbinowych
Gdańsk 80-952, ul. Narutowicza 11/12, jslezak@pg.gda.pl

Streszczenie

W artykule przedstawiono metodę symulacji neuronowej dla zastosowań w diagnostyce on-line obiektów energetycznych. Model neuronowy opiera się na statycznych jednokierunkowych sztucznych sieciach neuronowych oraz na danych pomiarowych z parowego bloku energetycznego o mocy 200 MW. Sieci podają wartości referencyjne parametrów przepływowych pary dla aktualnych warunków obciążenia obiektu. Badano wpływ na jakość symulacji neuronowej takich czynników jak: sposób definiowania stanu obciążenia obiektu, dobór danych uczących i testujących, metody wyszukiwania najlepszych struktur sieci, wpływ błędów pomiarowych i sezonowych zmian warunków pracy obiektu. Dokładność modelu porównano ze sprawdzonym modelem analitycznym danego obiektu.

Słowa kluczowe: sztuczne sieci neuronowe, diagnostyka on-line, parowy blok energetyczny.

NEURAL SIMULATION OF PRESSURE AND TEMPERATURE FLUCTUATIONS AT STEAM EXTRACTION OF POWER UNIT WITH STEAM TURBINE

Summary

This paper presents neural simulation method for on-line diagnostics use for steam power units. Neural model is based on static feedforward artificial neural networks and measurements from steam 200 MW power unit. The networks give reference steam flow parameters for current operation settings. Researched was dependence on neural simulation quality such factors as: defining power settings, teaching and testing data selection, searching out of the best networks architecture, measurement errors and seasonal changes of operation conditions. Accuracy of neural calculations was compared with verified analytical model of the object.

Keywords: artificial neural networks, on-line diagnostics, steam power unit.

1. WSTĘP

Obecnie w energetyce powszechne są rozbudowane systemy monitorujące bieżącą pracę obiektów. Setki pomiarów parametrów pracy obiegu zbierane są na ekranach pulpitu operatorów, aby ułatwić obsługę, poprawić bezpieczeństwo i zwiększyć kontrolę nad tymi skomplikowanymi obiektami. Jednak w większości przypadków ta ogromna ilość informacji nie jest w pełni wykorzystana i sprowadza się do zdalnego sterowania obiektem oraz śledzenia poprawnej wartości parametrów pracy. Gdzieś tam tylko wyznaczane są na bieżąco uproszczone wskaźniki sprawności pracy najważniejszych urządzeń i porównywane z wartościami referencyjnymi podawanymi przez producenta urządzeń, które nie uwzględniają aktualnych warunków pracy ani dynamiki zmian obciążenia bloków parowych.

Brakuje więc wiarygodnej informacji o referencyjnym stanie obiektu podawanej dla aktualnego stanu pracy. Źródłem takiej informacji powinien być model obiektu, spełniający

podstawowe wymagania operatora bloku, czyli: dostarczanie informacji o referencyjnym stanie pracy układu dla aktualnych warunków ruchowych, z dobrą dokładnością i w czasie zbliżonym do czasu taktowania systemu monitorującego.

Sztuczne sieci neuronowe mogą okazać się metodą pozwalającą spełnić te wymogi. Ich przydatność do symulowania parametrów pracy ustabilizowanego cieplnie obiegu parowego została sprawdzona w pracy [1]. Następnym etapem jest potwierdzenie skuteczności tej metody do wyznaczenia wzorcowych parametrów pracy obiektu w trybie on-line, z uwzględnieniem dynamiki procesów w nim zachodzących.

W artykule zawarto dotychczasowe wyniki mające na celu zweryfikować metodę poprzez:

- neuronowe wyznaczenie parametrów ciśnienia i temperatury pary w 2 i 6 upuście regeneracyjnym w odpowiedzi na zadany stan obciążenia bloku;
- kontrolę dokładności neuronowej symulacji w procesie testowania sieci;

— wyznaczanie chwilowych wartości wskaźnika sprawności kadłuba średnioprężnego (SP) turbiny na podstawie parametrów wyznaczanych neuronowo oraz porównanie go ze wskaźnikiem wyznaczanym bezpośrednio z danych pomiarowych.

2. MODEL NEURONOWY

1.1. Dane eksploatacyjne

Bazą do budowy modelu są dane pomiarowe z systemu monitoringu bloku parowego ze zmodernizowaną turbiną TK200. Wyniki pomiarów w systemie są wyznaczane z częstotliwością 10 sekund i archiwizowane raz na dobę. Zestaw danych do trenowania sieci neuronowych zawierał 27 dobowych plików z okresu 3 lat eksploatacji i charakteryzował się zróżnicowaniem pór roku, konfiguracji urządzeń układu i warunków pracy.

1.2. Sztuczne sieci neuronowe (SSN)

Symulowane funkcje charakteryzowały się bardzo nieregularnym przebiegiem z wieloma punktami nieciągłości. Do tego typu celów najskuteczniejsze są jednokierunkowe SSN z sigmoidalną i liniową funkcją przejścia, uczone metodą wstecznej propagacji błędu i algorytmem Levenberg'a-Marquardt'a [1,2]. Zmiennymi w strukturze sieci były wejściowe macierze uczące (definiujące stan obciążenia bloku), liczba neuronów oraz iteracji procesu uczenia (epok treningu).

1.3. Zestawy danych uczących

Właściwością modelowania typu „czarnej skrzynki” - takim jak modelowanie neuronowe - jest to, że struktura modelu powstaje na „bazie” danych wejściowych i wyjściowych. Dlatego definiowanie aktualnego stanu pracy bloku ma decydujące znaczenie w procesie neuronowej symulacji parametrów pary w upustach.

Zestaw parametrów definiujących aktualny stan obciążenia bloku został nazwany zestawem **parametrów niezależnych** [3] pracy bloku. Wykorzystano go jako zbiór bazowy do poszukiwań optymalnych danych wejściowych dla sieci, Tabela 1. Odpowiedzią układu na zadany zestaw parametrów niezależnych jest zbiór **parametrów zależnych** [3] – wyników pomiarów parametrów cieplno-przepływowych pary w najważniejszych punktach obiegu. Wyznaczanie wskaźnika sprawności kadłuba turbiny SP wymaga znajomości wartości ciśnienia i temperatury w 2 i 6 upuście pary (pu2, pu6, tu2, tu6). Każda z sieci wyznacza wartość jednego parametru w danym punkcie obiegu.

Tabela 1. Parametry niezależne pracy obiektu.

Lp.	Symbol	Nazwa	Wymiar
1	M	Moc czynna generatora	MW
2	F	Masowe natężenia przepływu pary świeżej z kotła	t/h
3	P1	Ciśnienie pary świeżej	MPa
4	T1	Temperatura pary świeżej	°C
5	T2	Temperatura pary przegrzanej	°C
6	W1	Masowe natężenie przepływu wody wtryskiwanej do WP	t/h
7	W2	Masowe natężenie przepływu wody wtryskiwanej do SP	t/h
8	Pk	Ciśnienie w kondensatorze	kPa

1.4. Proces uczenia sieci

Ze względu na podstawowe znaczenie parametrów niezależnych w procesie uczenia sieci, sprawdzono wpływ każdego z nich na efektywność procesu uczenia. Przygotowano zestaw macierzy wejściowych, które różniły się zbiorem parametrów, Tabela 2. Dla każdego z tych zestawów przeprowadzono serię treningów i wybrano najbardziej efektywną sieć, aby następnie porównać najlepsze wyniki z wszystkich serii.

Tabela 2. Zestawy parametrów niezależnych wchodzących w skład macierzy uczących.

Lp.	Zestaw parametrów
1	M
2	M P
3	M P T1
4	M P T1 T2
5	M P T1 T2 W1
6	M P T1 T2 W1 W2
7	M P T1 T2 W1 W2 Pk
8	M P T1 T2 W1 W2 Pk F
9	F
10	F P
11	F P T1
12	F P T1 T2
13	F P T1 T2 W1
14	F P T1 T2 W1 W2
15	F P T1 T2 W1 W2 Pk
16	M P T1 W1 Pk
17	MFPk

Jednym z rezultatów procesu uczenia sieci był rozkład proporcji pomiędzy zestawem danych uczących i testujących. Aby wykazać najkorzystniejszy zestaw uczący porównywano wyniki testowania wielu sieci. Ze względu na uzyskane wyniki oraz na to, że korzystne jest aby zbiór danych testujących sieci był jak największy, wybrano zestaw jednodobowy jako wystarczający

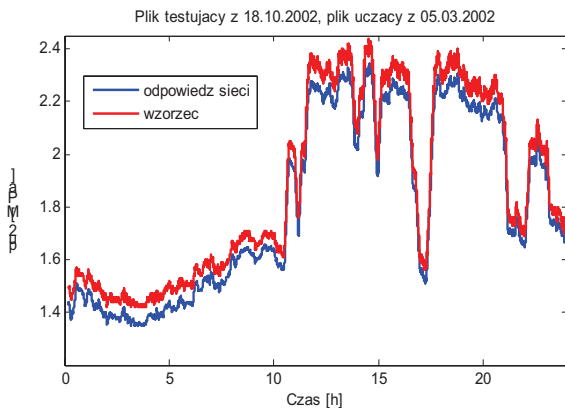
i dający dobre efekty w procesie uczenia. Sieci były trenowane na kilku charakterystycznych plikach różniących się znacznie przebiegiem obciążenia bloku. Oprócz powyższych sprawdzono także wpływ na jakość trenowania między innymi:

- Uśrednianie temperatury pary świeżej (T1) i przegrzanej (T2) w zakresie 20 minut wstecz.
- Uzupełnianie parametru mocy o wartości poprzedzające na 12 minut wstecz („historia” obciążenia)
- Numeryczne korygowanie systematycznych (stacyjnych) błędów odpowiedzi sieci
- Kilka typów standardowej normalizacji danych wejściowych do sieci
- Trybów pracy obiegu z włączoną i wyłączoną regeneracją wysokoprężną

1.5. Testowanie sieci

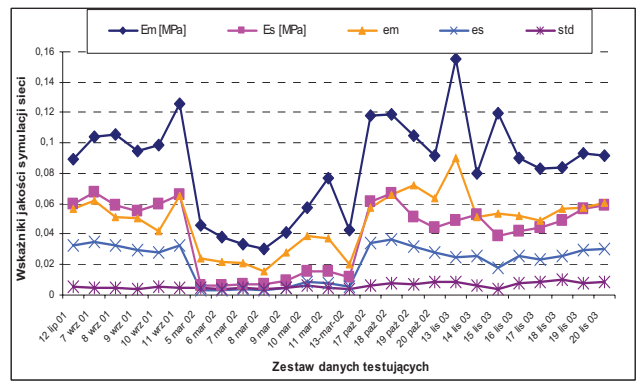
Proces testowania sieci był najważniejszym etapem pracy, ponieważ decydował o przydatności i jakości uzyskanego modelu. Z tego względu starano się, aby zestaw danych testujących był na tyle obszerny, by reprezentować rzeczywiste warunki pracy obiektu.

Zestaw danych testujących jest ponad 20-krotnie większy od zestawów uczących, można więc uznać uzyskane sieci za dobrze przetestowane i oceniać wszystkie parametry i czynniki trenowania wyłącznie na podstawie wyników testowania.



Rys. 1. Przykład wyników testowania sieci na pliku dobowym.


Ocena skuteczności sieci neuronowych była realizowana w kilku etapach. Pierwszym z nich było przeprowadzenie symulacji na wszystkich plikach testujących i wyznaczenie 5 wskaźników efektywności symulacji: wartości maksymalnego bezwzględnego (**Em**) i względnego (**em**) błędu, wartości średniego bezwzględnego (**Es**) i względnego (**es**) błędu oraz wartości średniego odchylenia standardowego (**std**), Rys. 1 i 2. Następnie wskaźniki z testowania danej sieci na wszystkich plikach były uśredniane i sprowadzane do jednego zbiorczego wyniku. W ten sposób można było porównywać wyniki dużej ilości sieci w poszukiwaniu najlepszych struktur.



Rys. 2. Przykład zbiorczego wyniku testowania danej sieci symulującej wartość ciśnienia. Wartości wskaźników uśrednionych po całym zestawie testującym: $Em \text{ śr} = 0,085127 \text{ Mpa}$; $Es \text{ śr} = 0,040839 \text{ Mpa}$; $em \text{ śr} = 0,048603$; $es \text{ śr} = 0,021736$; $std \text{ śr} = 0,006026$.

2. WYNIKI

Podstawowym celem pracy było znalezienie struktur sieci możliwie najlepiej symulujących przebieg ciśnienia i temperatury pary w upustach regeneracyjnych. Dzięki prostemu systemowi oceny jakości sieci można było porównać wyniki około 700 struktur, co pozwoliło ocenić wpływ wielu czynników na proces symulowania neuronowego.



Rys. 3. Wyniki porównania własności najlepszych sieci symulujących ciśnienie dla danego zestawu parametrów niezależnych.

Wyniki testowania sieci symulujących chwilowe wartości ciśnienia w upustach wykazały prawidłowość: hierarchię wpływu poszczególnych parametrów na skuteczność symulacji. Podstawowe nateżenie dla sieci miały moc oraz masowe nateżenie przepływu, reszta parametrów powodowała jedynie dalszą poprawę wyników, Rys. 3. Taka prawidłowość nie miała miejsca dla sieci symulujących wartość temperatury. Tutaj najlepsze wyniki dla wszystkich serii treningów były zbliżone,


więc do symulacji temperatury wystarczyła moc lub wydatek pary świeżej.

Zastąpienie w macierzach wejściowych wartości chwilowych temperatury pary świeżej i przegrzanej wartościami uśrednianymi spowodował niewielką poprawę efektywności symulacji, zwłaszcza przy najbardziej dynamicznych zmianach obciążenia.

Uzupełnianie macierzy uczących o „historie mocy” z reguły poprawiało wyniki sieci. Jednak efekt ten dla symulacji temperatury był dużo mniejszy niż dla ciśnienia.

Wyniki wykazały, że korzystny wpływ na jakość symulacji parametru temperatury ma zastosowanie jednej ze standardowych normalizacji danych wejściowych dla sieci, a największym problemem było występowanie stałej wartości błędu mimo dobrego odtwarzania fluktuacji parametru - „przesunięcia” odpowiedzi sieci w stosunku do wartości wzorcowej o znaczną wartość. Błąd ten był tym większy im większy był odstęp czasu między plikiem uczącym i testującym. Ważne jest, że wpływu na to nie miało sezonowe włączanie i wyłączanie regeneracji wysokoprężnej na obiekcie. Po prostej korekcie numerycznej jakość symulacji okazała się zadowalająca: $es < 1\%$.

Wyniki obliczeniowego odtwarzania fluktuacji sprawności kałłuba SP turbiny 200 MW na podstawie wyliczonych neuronowo chwilowych wartości ciśnień i temperatur wykazały zbliżoną dokładność do sprawności liczonej bezpośrednio z danych pomiarowych, Rys. 5.



Rys. 4. Przykład obliczeniowego (wzorzec) i neuronowego (odpowiedź) odtwarzania fluktuacji sprawności kałłuba SP turbiny.

3. PODSUMOWANIE

Przydatność metody sztucznych sieci neuronowych do wyznaczania chwilowych referencyjnych wartości sprawności turbiny została potwierdzona uzyskanymi wynikami testowania sieci: $es \approx 2\%$ i $em \approx 6\%$.

Czas pozyskiwania informacji o referencyjnych wartościach parametrów pracy obiegu jest na tyle krótki, że spełnia wymogi diagnostyki on-line.

Zaletą takiego modelu jest jego prostota i niski koszt wykonania a zarazem duża użyteczność – może funkcjonować jako dodatkowa lub wewnętrzna aplikacja wpisana w dowolny program, system monitorujący lub diagnostyczny.

LITERATURA

- [1] Ślęzak-Żoła J.: *Neuronowy symulator turbinowej siłowni parowej dużej mocy*, Praca magisterska WOiO Politechniki Gdańskiej, Gdańsk 2004.
- [2] Demuth H., Beale M.: *Neural Network Toolbox for use with Matlab*, The MathWorks, Inc., 1996 Natick.
- [3] Głuch J.: *Weryfikacja wybranych współczynników eksperymentalnych procesu projektowania przepływowego turbin oparta o standardowe pomiary bloków energetycznych*, Pr. Doktorska. Wydz. Oceanotechniki i Okrętownictwa Politechniki Gdańskiej, Gdańsk 1992.
- [4] Ślęzak-Żoła J., Głuch J.: *Charakterystyki sprawnościowe on-line jako symptomy niesprawnej pracy bloków energetycznych*, Diagnostyka Procesów i Systemów, Warszawa, Akademicka Oficyna Wydawnicza EXIT, 2007, Rozdział, str. 285-293



Mgr inż. **Justyna ŚLĘZAK-ŻOŁNA.**
Asystentka w Katedrze Automatyki Okrętowej i Napędów Turbinowych Wydziału Oceanotechniki i Okrętownictwa na Politechnice Gdańskiej; Doktorantka 4-go roku Studium Doktoranckiego: *Współczesne technologie i konwersja energii*



Dr inż. **Jerzy GŁUCH.**
Adiunkt w Katedrze Automatyki Okrętowej i Napędów Turbinowych Wydziału Oceanotechniki i Okrętownictwa na Politechnice Gdańskiej