

# Modelowanie niepewności pomiarowych obiegu turboparowego

## Modeling of measurement uncertainty in turbo steam power plant

NATALIA SZEWCZUK  
MARTA DROSIŃSKA-KOMOR \*

Materiały z XX SKWPWiE, Jurata 2016 r.  
DOI: 10.17814/mechanik.2016.7.196

Artykuł opisuje próbę stworzenia modelu neuronowego wymiennika regeneracyjnego siłowni kondensacyjnej pracującego w zmiennych warunkach ruchu. Wzorzec poprawnej pracy elementów siłowni turboparowej jest pożądanym w dziedzinie diagnostyki, ponieważ poprawnie pracujący model neuronowy jest w stanie zastąpić czasochłonne obliczenia bilansowe.

**SŁOWA KLUCZOWE:** sztuczne sieci neuronowe, modelowanie neuronowe, siłownie kondensacyjne

*Article describes the attempt to create a neural model of condensing power plant's regenerative heat exchanger which works in changing conditions. The proper operation plant's components pattern is needed in areas of diagnosis because this kind of neural model can replace time-consuming and complicated calculations.*

**KEYWORDS:** artificial neural networks, neural modelling, condensation power plant

W przypadku bloków energetycznych elektrowni kondensacyjnych mamy do czynienia z obiektami wyjątkowo skomplikowanymi. Ta wysoka złożoność powoduje, że określenie optymalnych warunków pracy siłowni turboparowej zarówno na etapie projektowania, jak i późniejszej eksploatacji wymaga szeregu czasochłonnych i zawiłych obliczeń opartych na bilansach masy, energii i pędu. Określenie optymalnych parametrów pracy bloku elektrowni kondensacyjnej jest niezbędne, aby na etapie projektowania stworzyć obiekt pracujący bezpiecznie i z jak najlepszą efektywnością. W trakcie eksploatacji obliczone wielkości służą jako parametry wzorcowe dla diagnostyki rzeczywistego stanu pracy siłowni. O ile na etapie projektu złożoność obliczeń nie jest problemem, o tyle na etapie eksploatacji staje się ona kłopotliwa. Duża dynamika zmian w trakcie pracy elektrowni wymusza zastosowanie szybkich i prostych modeli obliczeniowych, które nadążają za zmianami zachodzącymi w układzie. W takim przypadku użyteczne okazują się obliczenia numeryczne.

Podstawą określenia efektywności turbiny parowej w zmiennych warunkach pracy bloku są kalkulacje dotyczące grup stopni turbinowych. W przypadku tych obliczeń znaczącą rolę odgrywają regeneracyjne wymienniki ciepła, ponieważ to ich praca decyduje o wewnętrznym przepływie czynnika przez turbinę. Przepływ ten głównie zależy od tego, jaka część czynnika roboczego zostanie wyprowadzona z kadłuba turbiny upustami do wymienników regeneracyjnych. Przy czym przepływ czynnika roboczego przez grupy stopni turbiny bezpośrednio przekłada się na moc i sprawność całego bloku kondensacyjnego. Stąd też idea, aby tworząc numeryczny model siłowni kondensacyjnej przydatny w szybkiej i efektywnej diagnostyce, rozpocząć od zamodelowania wymiennika regeneracyjnego.

### Model wymiennika regeneracyjnego

Rozpatrując bardzo uproszczony model wymiennika regeneracyjnego można przyjąć, że parametrem, który najtrafniej

definiuje pracę tego urządzenia, jest spiętrzenie temperatur określane także jako końcowa różnica temperatur. Poprzez spiętrzenie temperatur należy rozumieć różnicę między temperaturą nasycenia pary grzejnej kierowanej do wymiennika z upustu, a temperaturą podgrzanego czynnika roboczego na wylocie z wymiennika regeneracyjnego:

$$\Gamma = t_n - t_2$$

gdzie:  $\Gamma$  – spiętrzenie temperatur;  $t_n$  – temperatura nasycenia pary grzejnej kierowanej do wymiennika regeneracyjnego,  $t_2$  – temperatura czynnika roboczego na wylocie z wymiennika regeneracyjnego.

### Model numeryczny

Tworząc model numeryczny opisujący zachowanie wymiennika regeneracyjnego w zmiennych warunkach pracy bloku parowego, można z powodzeniem zastosować sztuczne sieci neuronowe (SSN). W tym przypadku sztuczne sieci neuronowe są w stanie zastąpić żmudne i czasochłonne obliczenia bilansowe, dając wyniki w zaledwie kilka sekund. Modelowaniu numerycznemu poddana została praca wymienników regeneracyjnych elektrowni kondensacyjnej z turbiną o mocy 200 MW.

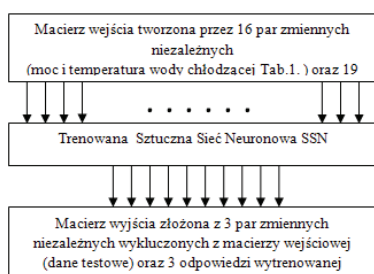
**TABLICA I. Zbiór danych uczących**

NPII		
wartości uzyskane z pomiarów		
moc	temp. wody chłodzącej	spiętrzenie temp.
[MW]	[C]	[C]
170,2	16,9	1,47
161,2	16,1	0,25
187,7	16,9	1,47
194,2	20,1	2,49
125,4	25,7	4,15
172,2	18,9	1,66
129,5	15,7	-0,23
143,1	26,3	4,77
147,8	29,4	4,89
179,4	19,2	1,79
202,1	19,1	3,07
121,7	16,9	0,57
172,2	29,1	5,58
190,7	27,8	7,91
196,4	32,2	7,24
158,2	25,1	6,34
158,2	26,1	6,75
151,6	26,7	5,68
123,2	24,4	4,47

W celu treningu sieci dla każdego z modelowanych wymienników regeneracyjnych stworzone zostały zbiory parametrów zależnych i niezależnych. Parametry te zostały uzyskane na drodze pomiarów wykonanych na bloku kondensacyjnym o mocy 200 MW. Z każdego zbioru wyeliminowano losowo trzy grupy danych. Wielkości te zostały w trakcie treningu sztucznej sieci neuronowej (SSN) potraktowane jako dane testujące, na których badano poprawność przeprowadzonego nauczania.

\* Mgr inż. Natalia Szewczuk (natszew1@pg.gda.pl); mgr inż. Marta Drośńska-Komor (mardrosi@pg.gda.pl) – Katedra Automatyki i Energetyki, Wydział Oceanotechniki i Okrętownictwa, Politechnika Gdańska

Dla każdego z wymienników przeprowadzony został trening według schematu pokazanego na rys. 1.



Rys. 1. Schemat treningu sieci

## Wyniki

Uzyskane w czasie treningu sztucznych sieci neuronowych (SSN) wyniki zostały ze sobą porównane pod względem dopasowania sieci neuronowej do funkcji opisującej zależność pomiędzy parametrami wejściowymi i wyjściowymi. Jako miarę określającą dokładność tego dopasowania przyjęty został błąd średniokwadratowy SSE. Wyniki zostały także porównane pod względem precyzji odwzorowania danych testujących sieć. W tym celu określony został błąd względny.

W tabl. I zestawione zostały rezultaty dla wybranych trzech z sześciu modelowanych wymienników regeneracyjnych, dla dwóch sieci neuronowych różniących się ilością neuronów w warstwie wejściowej.

Najlepsze rezultaty zostały uzyskane dla wymiennika NP11 w przypadku sztucznej sieci neuronowej (SSN) o 11 neuronach w warstwie wejściowej. W przypadku wymiennika regeneracyjnego NP11 również lepsze rezultaty zostały osiągnięte dla modelu neuronowego o 11 neuronach w warstwie wejściowej. Jedynie w przypadku wymiennika WP11 bardziej sprawdziła się sieć o 15 neuronach w pierwszej warstwie.

Uzyskane wyniki są w miarę zadowalające. Ich niedoskonałość może wynikać z faktu, że parametry wprowadzone na wejście modelu uzyskane zostały na drodze pomiaru, przez co obciążone są pewnym błędem czy też niepewnością pomiaru. Na tą niepewność składa się wiele czynników, między innymi środowisko, w którym został wykonany pomiar, metodyka, a co najważniejsze – sam przyrząd mierniczy i jego klasa.

TABLICA II. Zestawienie wyników treningu

nazwa wymiennika	il. neuronów	błąd (SSE), %	błąd względny			$\Sigma$ błąd względny
WP11	11	0,0023	0,345	0,039	0,160	0,544
	15	0,0021	0,381	0,118	0,025	0,523
NP11	11	0,0034	0,204	0,273	0,024	0,501
	15	0,0007	0,149	0,051	0,360	0,560
NP15	11	0,0005	0,277	0,006	0,095	0,379
	15	0,0009	0,327	0,151	0,049	0,527

## Przyszłe próby udoskonalenia modelu


W kolejnym etapie pracy nad modelem planowane jest uwzględnienie niepewności pomiarowych danych wejściowych dla sztucznej sieci neuronowej (SSN). W tym celu wykorzystane zostaną algorytmy logiki rozmytej.

Zbiory rozmyte pozwalają na opisanie zjawisk o charakterze wieloznacznym i nieprecyzyjnym, takich jak „wysoka temperatura”, „niski wzrost”, „duże miasto”. W przypadku rozważań na zbiorach rozmytych zamiast zdaniem typu prawda lub fałsz charakterystycznymi dla logiki klasycznej posługujemy się zdaniem, które uwzględnia pewne nieprecyzyjności. Tak jak

coś, co jest średniej wielkości nie jest do końca ani duże, ani małe, przez co po trochu należy do obu zbiorów.

W przypadku zbiorów rozmytych, korzystając z funkcji przynależności, jesteśmy w stanie definiować takie niekonkretne pojęcia opisujące model, jak: bardzo, trochę, mało, niewiele, zbyt wiele itp. Stopień przynależności opisuje, w jakim stopniu rozpatrywany element należy do zbioru, gdyż element zbioru rozmytego może do niego należeć, nie należeć lub należeć w pewnym stopniu.

W przypadku tworzonego modelu pracy wymienników regeneracyjnych siłowni kondensacyjnej zbiory rozmyte zostaną wykorzystane do zamodelowania niepewności pomiarowych parametrów na wejściu modelu neuronowego. W tym celu wstępnie wykorzystana zostanie funkcja przynależności klasy  $\Lambda$ .



Rys. 3. Funkcja klasy  $\Lambda$  [4]

W przypadku modelowania niepewności zakłada się, że granicami funkcji przynależności będą wartości określone przy pomocy klasy dokładności urządzenia pomiarowego, na którym dokonane zostały pomiary parametrów na wejściu modelu.

## Podsumowanie

Sztuczne sieci neuronowe (SSN) są przydatnym narzędziem modelowania. Przy ich użyciu możliwe jest stworzenie modelu pracy w zmiennych warunkach wymienników regeneracyjnych siłowni turbo parowej. Zamodelowanie elementu obiegu kondensacyjnego daje możliwość stworzenia modelu całej siłowni, co pozwoli zastąpić skomplikowane i czasochłonne obliczenia bilansowe szybkimi i dużo prostszymi kalkulacjami numerycznymi. Zastąpienie obliczeń bilansowych obliczeniami numerycznymi jest szczególnie pożądane w przypadku diagnostyki bloków parowych, gdzie wymagane jest, aby kalkulacje pozwalające na określenie wymaganych parametrów pracy nadążały za dynamicznymi zmianami zachodzącymi w układzie. Stworzony model neuronowy można ulepszyć, wykorzystując elementy zbiorów rozmytych, które pozwolą na uwzględnienie niepewności pomiarowych parametrów wprowadzanych na wejście sztucznej sieci neuronowej (SSN). Ta modyfikacja z pewnością wpłynie korzystnie na dokładność tworzonego modelu.

## LITERATURA

- Gardzielewicz A., Głuch J., Bogulicz M. i in. „Program diagnostyki ciepłno-przepływowej Diagar jako narzędzie prognozowania remontu aparatów składowych turbinowych obiegów energetycznych”. *Materiały V Krajowej Konferencji DPP* 2001, s. 459-462.
- Głuch J. „Metoda diagnostyki ciepłno-przepływowej umożliwiająca rozpoznawanie miejsca i stopnia degradacji turbozespołów energetycznych”. Seria Monografie Nr 81. Gdańsk: Wydawnictwo Politechniki Gdańskiej, 2007.
- Korbicz J., Obuchowicz A., Uciński D. „Sztuczne sieci neuronowe podstawy i zastosowania”. Warszawa: Akademicka Oficyna Wydawnicza PLJ, 1994.
- Łachwa A. „Rozmyty świat zbiorów, liczb, relacji, faktów, reguł i decyzji”. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2001.
- Rutkowska D., Piliński M., Rutkowski L. „Sieci neuronowe, algorytmy genetyczne i systemy rozmyte”. Warszawa: PWN, 1997.
- Tadeusiewicz R. „Sieci neuronowe”. Warszawa: Akademicka Oficyna Wydawnicza, 1993.
- Zurada J., Barski M., Jędruch W. „Sztuczne sieci neuronowe podstawy teorii i zastosowania”. Warszawa: PWN, 1996.