

## Zastosowanie zaimplementowanej w FPAA kaskadowej sieci neuronowej do klasyfikacji jakości węgla w komorach spalania

**Streszczenie.** W pracy przedstawiono efektywny system klasyfikacji jakości paliwa w komorach spalania z wykorzystaniem sztucznej sieci neuronowej. Proponowany system wykorzystuje analizę pomierzonych parametrów procesu spalania w kotłach. Parametry te wykorzystano do wytrenowania sieci ANN tj. do policzenia za pomocą programu MATLAB współczynników wagowych połączeń synaptycznych poszczególnych neuronów sieci. Otrzymane współczynniki zostały wykorzystane do skonfigurowania sieci ANN. Sieć ta została zaimplementowana w układzie FPAA i przetestowana na przykładach klasyfikacji paliwa dostarczanego do komory spalania. W pracy przedstawiono i omówiono wyniki badań.

**Abstract.** A hardware artificial neural network for classification a quality of a coal fuel in combustion chambers is presented in the paper. Proposed method is based on an analysis of measured combustion process parameters in the chamber by the feedforward artificial neural network. Measured parameters have been used to train neural network weights with a help of MATLAB program. Calculated weights have been used to determine the quality of the coal fuel loaded into the chamber. The ANN has been tested by the MATLAB program and the FPAA implemented network. Obtained results are presented and discussed. (An Application of the FPAA Implemented Cascaded Neural Network to the Classification of Coal Fuel in Combustion Chambers).

**Słowa kluczowe:** sztuczna sieć neuronowa, układ FPAA, klasyfikacja, proces spalania.

**Keywords:** artificial neural network, FPAA device, classification, combustion process.

### Wprowadzenie

Wytwarzanie ciepła w systemach grzewczych na skalę przemysłową jest zwykle obciążone dużymi stratami. Główną przyczyną strat jest zjawisko niepełnego spalania w komorze paleniskowej paliwa stałego jakim jest węgiel, w trakcie którego oprócz utleniania węgla do dwutlenku węgla (CO<sub>2</sub>), powstają także niepożądane gazy: CO, H<sub>2</sub> i CH<sub>4</sub>. Na to zjawisko wpływa kilka różnych czynników. Są to m.in. rodzaj i jakość węgla, ilość i ciśnienie nadmuchu powietrza czy temperatura wody obiegowej w kotłach. Detekcja ilości niepożądanych gazów czy wyznaczenie jakości węgla dostarczonego do komory spalania wymagają czasochłonnych procedur pomiarowych za pomocą specjalistycznej aparatury [1, 2]. Natomiast szybkie wyznaczenie jakości paliwa w trakcie spalania daje informacje do natychmiastowego sterowania procesem spalania. Ostatnio pojawiły się opisywane w literaturze rozwiązania wykorzystujące metody sztucznej inteligencji (AI) do optymalizacji procesu spalania [3-10]. Proponowane w pracy podejście polega na szybkiej klasyfikacji węgla w komorze spalania. W tym celu została opracowana kaskadowa sztuczna sieć neuronowa (ANN) feedforward zaimplementowana w analogowym układzie reprogramowalnym (FPAA). Sieć ANN po wytrenowaniu może służyć do szybkiej klasyfikacji, a układ FPAA umożliwia prototypowanie układowej implementacji sieci i jej współpracę z układem sterowania procesem spalania, a także równoległe przetwarzanie i programowanie struktury sieci [11-15].

### Proponowane rozwiązanie

Proponowana metoda wykorzystuje analizę pomierzonych parametrów procesu spalania w komorze paleniskowej kotła. Pomiarów zostały wykonane za pomocą systemu telemetrycznego. Pomierzone parametry wykorzystano do wytrenowania sieci ANN tj. do policzenia współczynników wagowych połączeń synaptycznych poszczególnych neuronów sieci. Wytrenowana sieć ANN jest wykorzystywana do wyznaczania jakości węgla w komorze spalania. Została ona zaimplementowana w układzie FPAA i przetestowana w celu weryfikacji otrzymanych rozwiązań.

Pomiary parametrów procesu spalania

Za pomocą systemu telemetrycznego dla dwóch kotłów WR-25 wykonanych w technologii ścian szczelnych zostało pomierzonych sześć parametrów spalania węgla. Są to:

- $x_1$ , temperatura wody obiegowej na wyjściu z kotła w °C;
- $x_2$ , grubość warstwy opału w cm;
- $x_3$ , ciśnienie nadmuchu powietrza dostarczonego do komory spalania w kPa;
- $x_4$ , prędkość posuwu rusztu w %;
- $x_5$ , zawartość tlenu w komorze spalania w %;
- $y$ , jakość paliwa 1..10.

Wykonano 8479 pomiarów w zbliżonych warunkach atmosferycznych przy temperaturze zewnętrznej 3-5°C. Przykłady danych pomiarowych są przedstawione w tabeli 1. Wykorzystano je do wyznaczania jakości paliwa w funkcji pięciu pozostałych parametrów. Funkcję tę uzyskano w procesie trenowania sieci ANN.

Tabela 1. Pomiary parametrów procesu spalania

	Wejścia					Wyjście
	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$y$
1	91,9653	43,9306	26,4451	7,4896	11,6474	1
2	95,4335	44,5665	27,0231	7,3925	11,6474	1
:	:	:	:	:	:	:
3642	95,2023	43,4971	26,9942	8,1936	11,6474	2
3644	98,0347	45,1445	24,7399	8,5942	11,6474	2
:	:	:	:	:	:	:
6159	108,9017	53,6705	33,7861	7,1861	11,6473	4
6160	110,2312	53,6705	33,7861	7,1861	11,6473	4

Sztuczna sieć neuronowa feedforward Obecnie, wykorzystuje się wiele różnych struktur sieci ANN [16–20] w systemach klasyfikacji czy sterowania. W proponowanym rozwiązaniu wykorzystywana jest kaskadowa sieć feedforward. Jest ona zbudowana z neuronów przedstawionych na rysunku 1a i opisanych następującą zależnością



$$(1) \quad y = f(\mathbf{w}^T \mathbf{x} + b)$$

gdzie:  $y$ ,  $b$  oznaczają sygnały wyjścia i wstępnej polaryzacji,  $\mathbf{x}$ ,  $\mathbf{w}$  oznaczają wektory sygnałów wejściowych i współczynników wagowych połączeń synaptycznych,


$f$  oznacza bipolarną sigmoidalną funkcję aktywacji wyrażoną następująco

$$(2) \quad f(out) = \frac{2}{1 + e^{-\lambda out}} - 1$$

gdzie  $\lambda > 0$  jest proporcjonalna do wzmocnienia neuronu.



Rys. 1. Sieć neuronowa; a) model sztucznego neuronu; b) warstwa ukryta sztucznej sieci neuronowej



Rys. 2. Struktura proponowanej sieci neuronowej

Kaskadowa sieć feedforward ANN zawiera jedną warstwę wejściową, kilka ukrytych warstw i jedną warstwę wyjściową. Pojedyncza  $k$ -ta warstwa ukryta jest pokazana na rysunku 1b i opisana następującym wyrażeniem

$$(3) \quad y^{(k)} = F[W^{(k)}x^{(k)} + b^{(k)}]$$

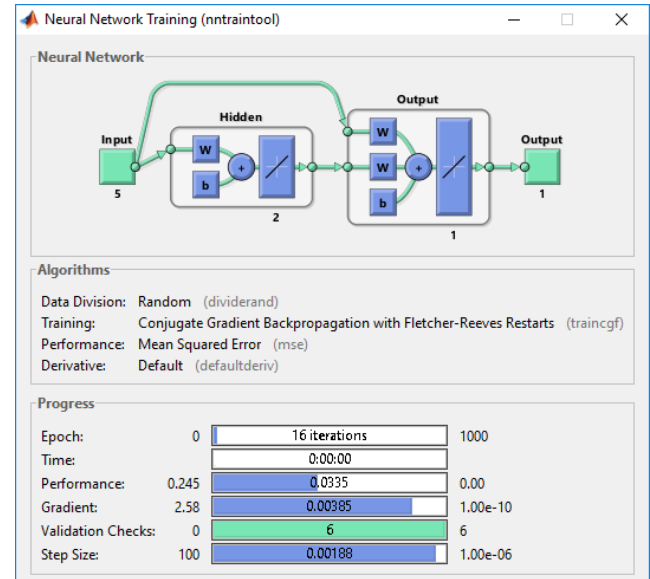
gdzie,  $x^{(k)}$ ,  $y^{(k)}$ ,  $b^{(k)}$  oznaczają wektory sygnałów wejściowych, wyjściowych i wstępnej polaryzacji neuronów  $k$ -tej warstwy,

$W^{(k)}$  oznacza macierz współczynników wagowych połączeń synaptycznych neuronów  $k$ -tej warstwy,

$F$  oznacza bipolarną sigmoidalną funkcję aktywacji wyrażoną następująco

$$(4) \quad F[-] = \begin{bmatrix} f(-) & 0 & \dots & 0 \\ 0 & f(-) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & f(-) \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

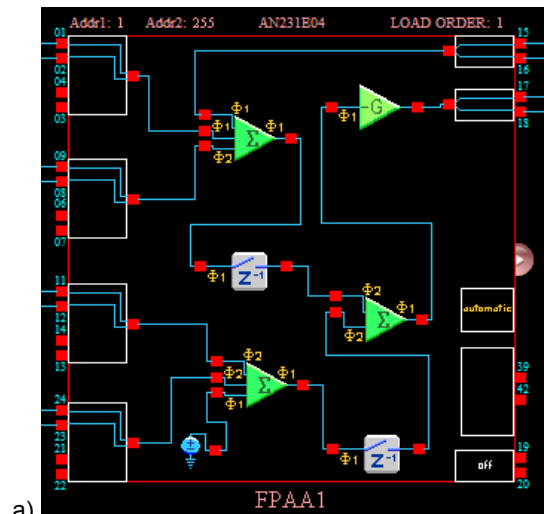
Dla celów odwzorowania funkcji pięciu zmiennych zaproponowano strukturę sieci ANN pokazanej na rysunku 2.



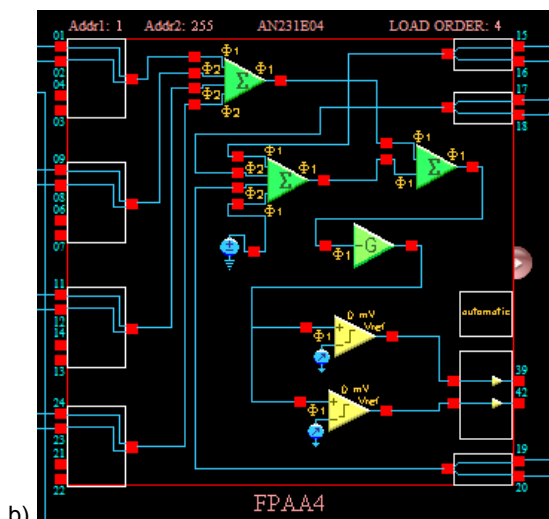
Rys. 3. Struktura proponowanej sieci neuronowej oraz proces uczenia w programie Matlab

Do trenowania sieci wykorzystywane są różne metody [16-22]. Dla proponowanej sieci zastosowano metodę gradientów sprzężonych z regułą adaptacji wag Fletchera-Reevesa [20].

Implementacja sieci ANN w układzie FPA



a)



Rys. 4. Implementacja sztucznej sieci neuronowej, a) neuron w warstwie ukrytej, b) neuron wyjściowy

Celem pracy jest budowa efektywnego systemu klasyfikacji jakości paliwa w komorach spalania z wykorzystaniem układu FPAA AN231E04 [23]. Wykorzystuje on technikę przełączanych pojemności. Układ posiada cztery analogowe rekonfigurowalne bloki (CABs). Są one zbudowane ze wzmacniaczy operacyjnych, kondensatorów, kanałów połączeń, kluczy, zegarów i globalnych punktów wejścia i wyjścia. Proponowana sieć ANN została zaimplementowana w programie MATLAB celem wytrenowania współczynników wagowych sieci. Wytrenowana sieć została zaimplementowana w układzie FPAA i wykorzystana do klasyfikacji jakości paliwa. Struktura sieci jest pokazana na rysunku 3. Warstwa ukryta sieci jest zbudowana z dwóch neuronów. Jeden został zaimplementowany w układzie FPAA<sub>1</sub> i pokazany na rysunku 4a, a drugi w układzie FPAA<sub>2</sub>. Neuron wyjściowy został zaimplementowany w układzie FPAA<sub>4</sub> i pokazany na rysunku 4b.

### Badania eksperymentalne

Pomierzone wartości parametrów procesu spalania zestawione w tabeli 1 zostały wykorzystane do trenowania sieci ANN za pomocą programu MATLAB. Proces trenowania jest pokazany na rysunku 3, a wyniki trenowania sieci w tabeli 2. Otrzymane współczynniki zostały wykorzystane do skonfigurowania sieci ANN do klasyfikacji paliwa dostarczanego do komory spalania. Otrzymana sieć ANN została zaimplementowana w układzie FPAA i przetestowana.

Tabela 2. Obliczone wagi dla zaprojektowanej sieci neuronowej

Warstwa	Zaprojektowana sieć neuronowa		Polaryzacja
	Wagi		
$w^{(1)}$	$w_{11} = 0,0494$ $w_{12} = 0,0414$ $w_{13} = 0,5582$ $w_{14} = -0,1624$ $w_{15} = 0,6115$	$w_{21} = 0,0426$ $w_{22} = -0,6922$ $w_{23} = -0,4092$ $w_{24} = 0,2212$ $w_{25} = -0,4417$	$b_1 = 0,0490$ $b_2 = -0,4215$
$w^{(2)}$	$w_1 = 0,0521$ $w_2 = 0,3857$ $w_3 = -0,7958$ $w_4 = -0,2478$ $w_5 = -0,7795$		$b = 0,3896$
$w^{(3)}$	$w_1 = 0,0384$ $w_2 = -0,3895$		

Wyniki testów są pokazane w tabeli 3. Potwierdzają one, że układowa realizacja sieci szybko klasyfikuje rodzaj paliwa i

może zostać wykorzystana w układzie sterowania procesem spalania.

Tabela 3. Dane testujące zaprojektowaną sieć neuronową

	Wejścia					ANN	FPAA
	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$		
1	119,5375	64,2196	40,5780	5,8812	11,6473	1	1
2	122,0231	63,8439	39,4508	6,3849	11,6473	1	1
:	:	:	:	:	:	:	:
3	98,4393	41,8786	24,7398	8,3939	11,6473	2	2
4	96,0693	43,4971	26,4450	8,5942	11,6473	2	2
5	113,1791	61,6763	34,9421	7,3924	12,4595	3	3
6	119,8843	73,0057	47,3988	6,6823	12,4595	4	4
7	122,6011	73,1213	47,3988	5,7780	12,4595	4	4

### Podsumowanie

Proponowana kaskadowa sieć feedforward ANN została zaprojektowana i zaimplementowana w układzie FPAA w celu klasyfikacji paliwa dostarczanego do komór spalania. Posiada ona następujące zalety: niski koszt, możliwość programowania struktury sieci, szybkie i równoległe przetwarzanie. Dzięki układowej implementacji w układzie FPAA może ona zostać zintegrowana ze sterownikiem pracy pieca.

**Autorzy:** dr inż. Robert Suszyński, prof. dr hab. inż. Krzysztof Wawryn, mgr inż. Jacek Marciniak, Politechnika Koszalińska, Wydział Elektroniki i Informatyki, ul. J.J. Sniadeckich 2, 75-453 Koszalin, E-mail: [robert.suszynski@tu.koszalin.pl](mailto:robert.suszynski@tu.koszalin.pl), [Krzysztof.Wawryn@tu.koszalin.pl](mailto:Krzysztof.Wawryn@tu.koszalin.pl)

### LITERATURA

- [1] Lou C., Zhou H., Yu P., and Jiang Z., Measurements of the flame emissivity and radiative properties of particulate medium in pulverized-coal-fired boiler furnaces by image processing of visible radiation, in *Proc. of the Combustion Institute*, vol. 31, (2007), 2771-2778
- [2] Göllés M., Reiter S., Brunner T., Dourdoumas N., and Oberberger I., Model based control of a small-scale biomass boiler, *Control Engineering Practice*, vol. 22, (2014), 94-102
- [3] Kalogirou S.A., Artificial intelligence for the modeling and control of combustion processes: a review, *Progress in Energy and Combustion Science*, vol. 29, (2003), 515-566
- [4] Hosovsky A., Genetic optimization of neural network structure for modeling of biomass-fired boiler emissions, *Journal of applied science in the thermodynamics and fluid mechanics*, vol. 9, no. 2, (2011), 1-6
- [5] Manke P., and Tembhurne S., Application of back propagation neural network to drum level control in thermal power plants, *International Journal of Computer Science*, (2012), 520-526
- [6] Ye H., and Ni W., Static and transient performance prediction for CFB boilers using a Bayesian-Gaussian Neural Network, *J. of Thermal Science*, (1997), 141-148
- [7] Blasco J., Fueyo N., Dopazo C., and Chen J.Y., Self-organizing-map approach to chemistry representation in combustion applications, *Combustion Theory and Modelling*, vol. 4, no. 1, (2000), 61-76
- [8] Wang L., The application of fuzzy neural network to boiler steam pressure control, *International Journal of Computer Science*, (2013), 704-707
- [9] Marciniak J., The detection of anomalies in controlling of the combustion process by using a genetic algorithm, *Diagnostyka*, vol. 17, no. 1, (2016), 21-26
- [10] Marciniak J., The detection of anomalies in controlling of the combustion process by using a negative selection algorithm, *Diagnostyka*, vol. 17, no. 1, (2016), 28-31
- [11] Znamirovski L., Palusinski O.A., and Vrduhula S.B.K., Programmable Analog/Digital Arrays in Control and Simulation, *Analog Integrated Circuits and Signal Processing*, vol. 39, (2004), 55-73
- [12] Balen T.R., Andrade A.Q., Azais F., Lubaszewski M., and Renovell M., Applying the Oscillation Test Strategy to FPAA's

- Configurable Analog Blocks, *Journal of Electronic Testing: Theory and Applications*, vol. 21, (2005), 135-146
- [13] Widyantara H., Rivai M., and Purwanto D., Neural Network for Electronic Nose using Field Programmable Analog Arrays, *Int. J. of Electrical and Computer Engineering (IJECE)*, vol. 2, no. 6, (2012), 739-747
- [14] Suszynski R., and Wawryn K., Rapid prototyping of algorithmic A/D converters based on FPAA devices, *Bulletin of the Polish Academy of Sciences-Technical Sciences*, vol. 61, no. 3, (2013), 691-696
- [15] Suszynski R., and Wawryn K., Prototyping of Higher Order Sigma Delta ADC Based on Implementation of a FPAA, In *Proc. of the Int. Conf. on Signals and Electronic Systems (ICSES)*, (2012), 1-4
- [16] Żurada J.M., Introduction to Artificial Neural systems, West Publishing Company, 1992
- [17] Van der Smagt P.P., Minimization methods for training feedforward neural networks, *Neural Networks*, vol. 7, (1994), 1-11
- [18] Wawryn K., and Strzeszewski B., Current mode circuits for programmable WTA neural network, *Analog Integrated Circuits and Signal Processing*, vol. 27, no. 1-2, (2001), 49-69
- [19] Swietlicka A., Gugala K., Jurkowlaniec A., et al., The Stochastic, Markovian, Hodgkin-Huxley Type of Mathematical Model of The Neuron, *Neural Network World*, vol. 25, no. 3, (2015), 219-239
- [20] Fletcher R., and Reeves C.M., Function minimization by conjugate gradients, *Comput. J.*, vol. 1, (1964), 149-154
- [21] Talaska T., and Dlugosz R., Analog Sorting Circuit for the Application in Self-Organizing Neural Networks Based on Neural Gas Learning Algorithm, (2015), 282-286
- [22] Wojtyna R., Analog low-voltage low-power CMOS circuit for learning Kohonen networks on silicon, *Int. Conf. Mixed Design of Integrated Circuits and Systems*, (MIXDES), (2010), 209-214
- [23] "AnadigmApex dpASP" Family User Manual. Anadigm. Inc.. 2005J. Clerk Maxwell. A Treatise on Electricity and Magnetism. 3rd ed.. vol. 2. Oxford: Clarendon. 1892. 68-73