



Krzysztof BRZozowski

# MODEL SIECI NEURONOWEJ DO PROGNOZOWANIA NATĘŻENIA EMISJI DWUTLENKU WĘGLA

### *Streszczenie*

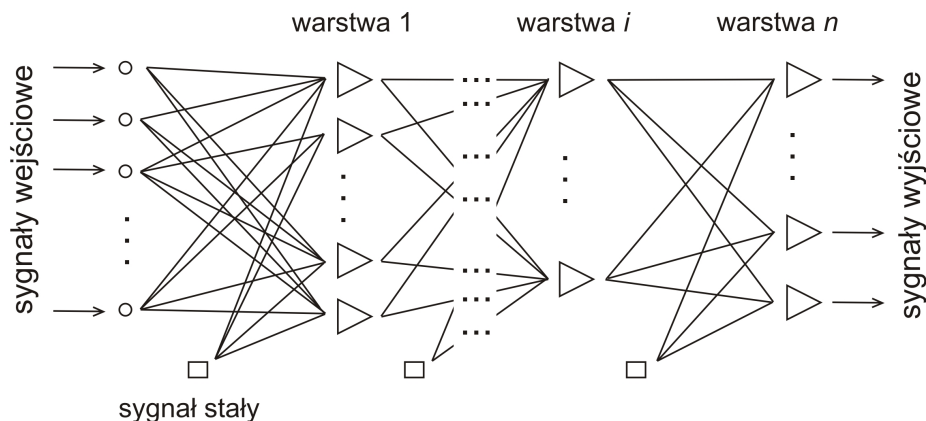
*W pracy zaproponowano zastosowanie sztucznej sieci neuronowej do prognozowania natężenia emisji CO<sub>2</sub> w rzeczywistych warunkach eksploatacji. Jako sygnały wejściowe oprócz chwilowej prędkości i przyspieszenia do sieci wprowadzane są informacje charakteryzujące wcześniejsze obciążenie jednostki napędowej w dwóch dyskretnych chwilach czasu. Przeprowadzono proces uczenia sieci, który w rozważanym przypadku jest tożsamy z identyfikacją parametrów modelu oraz określono dokładność z jaką prognozowane jest natężenie emisji CO<sub>2</sub>.*

### WSTĘP

Problematyka oceny emisji poszczególnych składników spalin oraz zużycia paliwa w rzeczywistych warunkach eksploatacji na podstawie modeli teoretyczno-empirycznych jest wciąż aktualnym zagadnieniem badawczym. Proponowane w tym celu modele istotnie różnią się stopniem szczegółowości wymaganych danych wejściowych i tym samym jakością informacji wyjściowej. Podstawą parametryzacji modeli teoretyczno-empirycznych są badania przeprowadzane na hamowniach podwoziowych i/lub w ramach testów drogowych. Wśród proponowanych modeli odrębną grupę stanowią modele wykorzystujące metody sztucznej inteligencji, w szczególności sieci neuronowe [7]. W zagadnieniach modelowania emisji takie modele formułowano i zastosowano w szeregu pracach, między innymi w [2–7, 9–14, 16–17], w tym również w celu określania natężenia emisji po zimnym rozruchu [8]. Zastosowanie modeli wykorzystujących sieci neuronowe we wcześniejszych pracach autora pozwoliło uzyskać co najmniej akceptowalną dokładność wyników modelowania w porównaniu z wynikami badań [2–7]. Prace te dotyczyły jednak głównie modelowania natężenia emisji wybranych związków szkodliwych, dla których odpowiednimi aktami prawnymi wprowadzono obowiązujący dopuszczalny poziom emisji. Z punktu widzenia strategii Unii Europejskiej dotyczącej trwałego rozwoju, w odniesieniu do polityki transportowej, oprócz celów dotyczących obniżenia emisji poszczególnych składników szkodliwych do poziomu niezagrażającego środowisku i zdrowiu ludzi, równie istotnym jest cel obniżenia zużycia energii w transporcie, co przekłada się bezpośrednio na obniżenie poziomu emisji dwutlenku węgla. Oznacza to zatem, że podejmowanie zagadnień modelowania zużycia paliwa oraz emisji CO<sub>2</sub>, szczególnie w odniesieniu do rzeczywistych warunków eksploatacji jest równie aktualne co w przypadku związków szkodliwych spalin. W związku z tym w niniejszej pracy zaproponowano model sieci neuronowej do prognozowania natężenia emisji CO<sub>2</sub>.

# 1. MODEL SIECI NEURONOWEJ DO PREDYKCJI NATEŻENIA EMISJI DWUTLENKU WĘGLA

W zagadnieniach związanych z predykcją emisji związków powstających w procesie spalania paliwa z wykorzystaniem sieci neuronowych stosowane są sieci różnego rodzaju, przy czym częściej niż sieci radialne wykorzystywane są sieci wielowarstwowe jednokierunkowe. Podstawowy schemat architektury sieci jednokierunkowej wielowarstwowej przedstawiono na rys. 1.



Rys. 1. Podstawowy schemat architektury jednokierunkowej wielowarstwowej sieci neuronowej

Architekturę wielowarstwową jednokierunkową przyjęto również w modelu sformułowanym w niniejszej pracy, przy czym jako funkcję aktywacji neuronu zastosowano funkcję bipolarną postaci:

$$f(\mathbf{w}^t \mathbf{z}) = 2 \left[ 1 + e^{-\lambda \mathbf{w}^t \mathbf{z}} \right]^{-1} - 1 \quad (1)$$

gdzie:  $\mathbf{w}$  – wektor wag dla sygnałów wejściowych neuronu,

$\mathbf{z}$  – wektor sygnałów wejściowych do neuronu,

$\lambda$  – współczynnik wyznaczający zakres liniowości funkcji (przyjęto jako równy 0,4).

Wartość stanowiąca sygnał wyjściowy dla każdego z neuronów w sieci obliczana jest według przyjętej funkcji aktywacji (1). Oznacza to, że wartość funkcji aktywacji dla każdego z neuronów stanowiących pierwszą warstwę sieci zależy bezpośrednio od sygnałów wejściowych do sieci, uwzględnianych w ogólnym przypadku ze zróżnicowanymi wagami. Sygnały wejściowe wprowadzają zatem informację, która jest przetwarzana przez sieć i na podstawie której obliczana jest odpowiedź sieci.

W modelach emisji związków szkodliwych podstawowymi wielkościami charakteryzującymi chwilowe warunki eksploatacji są: chwilowa prędkość i przyspieszenie pojazdu. Wynika to z podstawowego założenia, że natężenie emisji jest zdeterminowane mocą wytwarzaną przez jednostkę napędową, która zależy od prędkości i przyspieszenia pojazdu [2]. Klasyczne podejście polega przy tym na tworzeniu dwuwymiarowej macierzy, w postaci której przedstawia się uśrednione natężenie emisji danego składnika spalin dla ustalonych dyskretnych przedziałów wartości zmiennych niezależnych [6]. Zmiennymi niezależnymi są: prędkość oraz przyspieszenie (np. w modelu DGV) lub prędkość oraz iloczyn prędkości i przyspieszenia, jak w modelu MODEM. Wykorzystywane są również modele natężenia emisji (np. PHEM), w których przyjęto charakterystykę chwilowych warunków eksploatacji na podstawie prędkości silnika i zapotrzebowania mocy silnika. W takim przypadku uwzględnia się nie tylko dynamikę ruchu, ale również np. pochylenie drogi i przełożenie skrzyni biegów. Modele te wymagają jednak odpowiednio

większego zbioru danych, umożliwiających obliczenie prędkości obrotowej silnika oraz zapotrzebowania mocy silnika [2].

W pracy założono, że podstawowym kryterium praktycznej przydatności formułowanego modelu jest minimalizacja zbioru danych wejściowych. Na tej podstawie zdecydowano o wykorzystaniu wyłącznie informacji o chwilowej prędkości i przyspieszeniu, uwzględniając jednak dodatkową informację o stanach poprzedzających aktualne obciążenie jednostki napędowej. W tym celu dołączono informację o chwilowej prędkości i przyspieszeniu w wybranych chwilach czasowych poprzedzających analizowany moment czasu. Przeprowadzona analiza wyników badan eksperymentalnych w zakresie korelacji między natężeniem emisji CO<sub>2</sub> oraz wartością chwilowej prędkości oraz natężeniem emisji CO<sub>2</sub> a wartością chwilowego przyspieszenia pojazdu wskazała na pomijanie małą wartość uzyskiwanych korelacji dla okresu czasu przekraczającego 2 s. W ten sposób ustalono, że po przyjęciu rozdzielczości czasowej modelu odpowiadającej jednej sekundzie, istotna jest informacja o aktualnej prędkości pojazdu i jego przyspieszeniu oraz o wartościach tych parametrów w dwóch poprzednich dyskretnych chwilach czasu, odpowiednio jedną i dwie sekundy wcześniej.

W proponowanym modelu sygnałami wejściowymi dla pierwszej warstwy sieci jest zatem informacja o aktualnej prędkości pojazdu i jego przyspieszeniu oraz o wartościach tych parametrów w dwóch poprzednich dyskretnych chwilach czasu. Tym samym na pierwszej warstwę sieci podawanych jest jednocześnie sześć sygnałów, które stanowią wektor sygnałów wejściowych postaci:

$$\mathbf{I} = [v(t), a(t), v(t-1), a(t-1), v(t-2), a(t-2)]^T. \quad (2)$$

Ponieważ zastosowano sieć o połączeniach typu każdy z każdym, sygnały te są następnie przetwarzane przez każdy z neuronów pierwszej warstwy ukrytej zgodnie z funkcją aktywacji (1) a wynikowy sygnał przekazywany jest do każdego z neuronów kolejnej warstwy sieci, dla których również obliczane są funkcje aktywacji. Jako rezultat przetwarzania sygnałów wejściowych przez sieć oczekiwana jest informacja o natężeniu emisji CO<sub>2</sub>, stąd na wyjściu z sieci występuje tylko jeden neuron. Przyjmując teraz, że ostatnia warstwa ukryta sieci zawiera  $k$  – neuronów, wartość sygnału wyjściowego z sieci jest obliczana jako:

$$E_{CO_2}(\mathbf{I}) = f\left(\sum_{i=1}^k w_i \cdot z_i\right). \quad (3)$$

Funkcjonalność proponowanego modelu zależy od poprawnej identyfikacji jego parametrów, czyli nieznanymi wektorów wag  $\mathbf{w}$ .


## 2. IDENTYFIKACJA PARAMETRÓW MODELU

Zastosowanie sformułowanego modelu do obliczania natężenia emisji CO<sub>2</sub> w rzeczywistych warunkach eksploatacji wymaga wyznaczenia właściwych współczynników wag wszystkich połączeń w sieci, tj. zarówno tych dotyczących sygnałów wejściowych jak i połączeń pomiędzy kolejnymi wewnętrznymi warstwami sieci. Proces identyfikacji wektorów wag  $\mathbf{w}$  nazywany jest uczeniem sieci neuronowej, przeprowadzanym dla przyjętej a priori architektury sieci.

Do wyznaczenia wag poszczególnych połączeń sieci zastosowano tzw. uczenie z nauczycielem, które polega na cyklicznym powtarzaniu zadawania na wejściu sieci sygnałów ze zbioru uczącego  $\{\mathbf{I}_{(j)}, E_{CO_2}^{(j)}\}, j = 1, \dots, n$  i porównywaniu sygnału wyjściowego z sieci  $E_{CO_2}(\mathbf{I}_{(j)})$  z sygnałem oczekiwanym  $E_{CO_2}^{(j)}$ , zdefiniowanym dla danego wzorca uczącego ( $j$ ). Tak realizowany proces pozwala obliczyć błąd odpowiedzi sieci. Warto tutaj jednocześnie

nadmieni, że zastosowano losowy dobór wag początkowych oraz losowe zadawanie wzorców uczących.

Jako zbiór uczący wykorzystano zarejestrowane wyniki badań eksperymentalnych dla samochodu z silnikiem o zapłonie iskrowym przeprowadzone w ramach realizacji ruchu o przebiegu prędkości jak na rys. 2. Charakterystykę zbioru uczącego zaprezentowano w tabeli 1.



**Rys. 2.** Przebieg prędkości pojazdu, dla którego dane o natężeniu emisji CO<sub>2</sub> wykorzystano procesie identyfikacji parametrów modelu

**Tab.1.** Charakterystyka zbioru uczącego

Liczba wzorców	Prędkość minimalna [m/s]	Prędkość maksymalna [m/s]	Przyspieszenie minimalne [m/s <sup>2</sup> ]	Przyspieszenie maksymalne [m/s <sup>2</sup> ]
1084	0	25,7	-8	10,3

Podstawowym zadaniem uczenia jest minimalizacja błędu odpowiedzi sieci, który zdefiniowano w postaci błędu średniokwadratowego obliczanego dla wszystkich  $n$  wzorców uczących:

$$\Omega = \frac{1}{2} \sum_{j=1}^n [E_{CO_2}(\mathbf{I}_{(j)}) - E_{CO_2}^{(j)}]^2 \quad (4)$$

Do uczenia sieci zastosowano metodę momentum z przyrostowym uaktualnianiem wag tj., w  $l+1$  kroku uczenia sieci, po prezentacji wzorca uczącego  $\{\mathbf{I}_{(l)}, E_{CO_2}^{(l)}\}$  modyfikowano wagi według zależności [15]:

$$\mathbf{w}^{(l+1)} = \mathbf{w}^{(l)} - \eta^{(l)} \nabla \Omega(\mathbf{w}^{(l)}) + \alpha (\mathbf{w}^{(l)} - \mathbf{w}^{(l-1)}) \quad (5)$$

gdzie:  $\eta$  – współczynnik uczenia,

$\alpha$  – współczynnik momentu o wartościach z przedziału  $[0,1]$ .

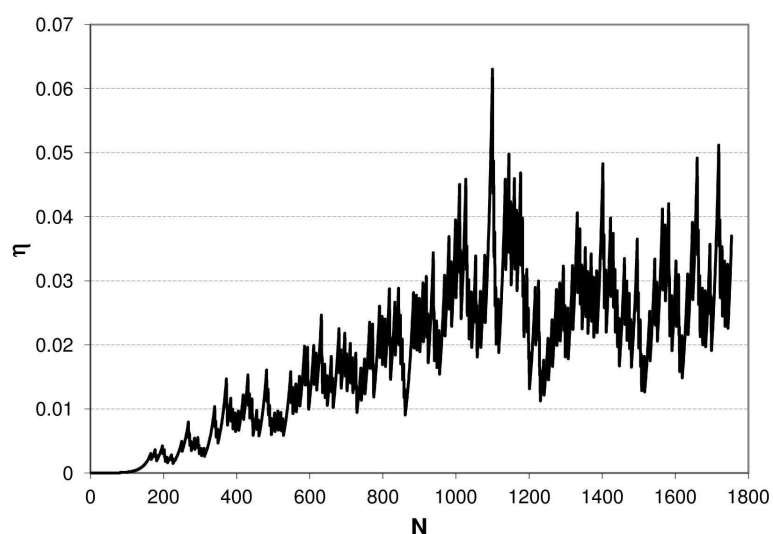
W każdym kroku algorytmu uczenia kontrolowano również zmianę wartości błędu. W zależności od wartości błędu uzyskanego w  $(l)$  i  $(l-1)$  kroku modyfikowano współczynnik uczenia  $\eta$  według zależności [15]:

$$\eta^{(l+1)} = \begin{cases} 0,7\eta^{(l)} & \text{dla } \Omega^{(l)}(\Omega^{(l-1)})^{-1} > 1,06 \\ 1,15\eta^{(l)} & \text{w przeciwnym przypadku} \end{cases} \quad (6)$$


Uczenie sieci wykonywano do momentu osiągnięcia przyjmowanej a priori wartości średniego błędu kwadratowego. Jeżeli dla przyjętej architektury sieci mimo wielu powtórzeń procesu uczenia nie udało się osiągnąć zakładanej wartości błędu, zmieniano architekturę sieci. Ostatecznie ustalono architekturę sieci postaci 6-29-9-1, co oznacza że na pierwszej warstwie ukrytej znajduje się 29 neuronów a drugą warstwę stanowi 9 neuronów.

Przebieg zmian wartości współczynnika  $\eta$  w trakcie uczenia sieci o architekturze 6-29-9-1 przedstawiono na rys. 3. Z kolei na rys. 4. przedstawiono zmianę procentowego średniego błędu względnej odpowiedzi sieci w kolejnych krokach algorytmu. Błąd ten został zdefiniowany w postaci:

$$\Omega_w = \frac{1}{n} \sum_{j=1}^n \frac{|E_{CO_2}^{(j)} - E_{CO_2}(\mathbf{I}_{(j)})|}{E_{CO_2}^{(j)}} 100\% \quad (7)$$



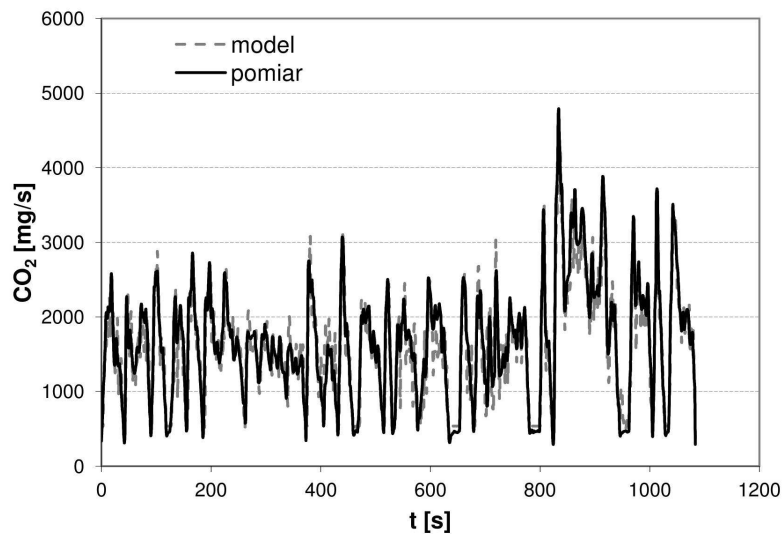
Rys. 3. Zmiana współczynnika uczenia  $\eta$  w poszczególnych cyklach uczących



Rys. 4. Zmiana dokładności odwzorowania zbioru uczącego w poszczególnych cyklach uczących

Graficzną prezentację skuteczności przeprowadzonego procesu identyfikacji przedstawiono na rys. 5 zestawiając wartości natężenia emisji CO<sub>2</sub> wykorzystane jako zbiór

uczący oraz obliczone z modelu po uwzględnieniu wag połączeń ustalonych w procesie identyfikacji.




**Rys. 5.** Porównanie obliczonego i zarejestrowanego natężenia emisji CO<sub>2</sub> dla zbioru uczącego wykorzystanego w procesie identyfikacji

Współczynnik determinacji obliczony dla danych przedstawionych na rys. 5 wynosi  $R^2 = 0,87$ .

### 3. OCENA DOKŁADNOŚCI PREDYKCJI NATĘŻENIA EMISJI CO<sub>2</sub> ORAZ WNIOSKI KOŃCOWE

W pracach związanych z formułowaniem modelu emisji ostatnim etapem postępowania jest ustalenie jakości wyników uzyskiwanych z modelu. W tym celu do weryfikacji dokładności wyznaczania natężenia emisji przez model wykorzystano inny niż w procesie identyfikacji zbiór wyników badań eksperymentalnych tego samego pojazdu. Przebieg prędkości pojazdu w badaniach, których wyniki wykorzystano do weryfikacji dokładności modelu przedstawiono na rys. 6. Charakterystykę zbioru weryfikującego zaprezentowano w tabeli 2.

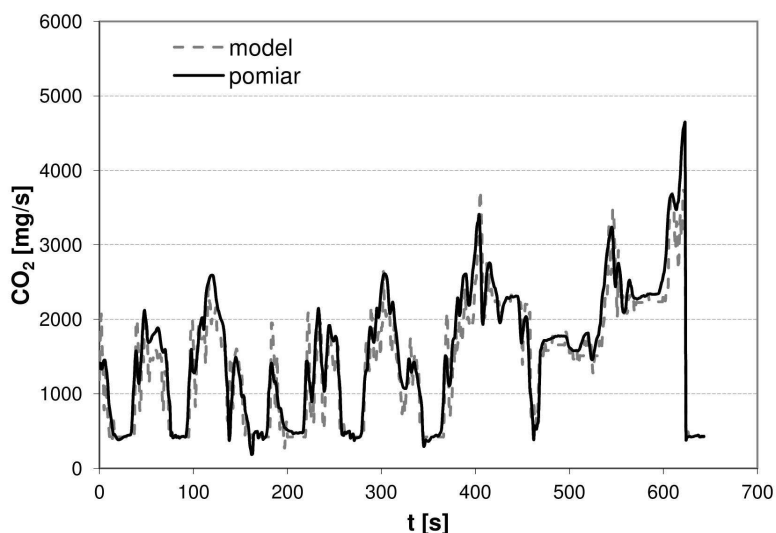


**Rys. 6.** Przebieg prędkości pojazdu, dla którego weryfikowano dokładność wyznaczania natężenia emisji CO<sub>2</sub>

**Tab.2.** Charakterystyka zbioru weryfikującego

Liczba wzorców	Prędkość minimalna [m/s]	Prędkość maksymalna [m/s]	Przyspieszenie minimalne [m/s <sup>2</sup> ]	Przyspieszenie maksymalne [m/s <sup>2</sup> ]
646	0	25,4	-9,3	8,9

Graficzne zestawienie natężenia emisji CO<sub>2</sub> obliczonego przez sieć neuronową oraz rzeczywistego, zarejestrowanego w trakcie badań przedstawiono na rys. 7.



**Rys. 7.** Porównanie obliczonego i zarejestrowanego natężenia emisji CO<sub>2</sub>

Współczynnik korelacji natężenia emisji CO<sub>2</sub> obliczonego oraz zarejestrowanego w badaniach weryfikacyjnych wynosi  $R^2=0,88$  a średni procentowy błąd względny 15,7%.

Na podstawie uzyskanych wyników weryfikacji oraz w porównaniu z dokładnością wyznaczania natężenia emisji CO<sub>2</sub> uzyskiwaną po zastosowaniu modelu obciążeniowego [1], można stwierdzić, że proponowany model, bazując na uproszczonym odwzorowaniu obciążenia jednostki napędowej, umożliwia wyznaczane chwilowego natężenia emisji CO<sub>2</sub> z akceptowalną dokładnością. Dla porównania warto tutaj jednocześnie podkreślić, że dokładność obliczeń natężenia emisji CO<sub>2</sub> dla modeli obciążeniowych wykorzystujących informację o chwilowym zapotrzebowaniu mocy silnika wyrażona wartością średniego procentowego błędu względnego kształtuje się na poziomie 10%.

## **A MODEL OF AN ARTIFICIAL NEURAL NETWORK FOR ESTIMATION OF INTENSITY OF CARBON DIOXIDE EMISSION**

### **Abstract**

*Paper presents an application of an artificial neural network for estimation of intensity of CO<sub>2</sub> in traffic conditions. The input signals are: instantaneous vehicle velocity, instantaneous acceleration and information about engine load in two discrete time points in the past. The trainee process was performed for identification of parameters of the model. The accuracy of results obtained from the model was calculated.*

## BIBLIOGRAFIA

1. Adamski W., Brzozowski K.: *Wyznaczanie zużycia paliwa i emisji dwutlenku węgla dla pojazdu z silnikiem ZI*. Archiwum Motoryzacji nr 1, 2009.
2. Boulter P.G., McCrae I.S. Barlow T.J.: *A review of instantaneous emission models for road vehicles*. Transport Research Laboratory, Project report PPR 267, 2007.
3. Brzozowska L., Brzozowski K., Warwas K.: *Zastosowanie sztucznych sieci neuronowych do modelowania ekologicznych właściwości pojazdów*. Archiwum Motoryzacji nr 3, 2005.
4. Brzozowski K., Drag Ł.: *Modelowanie natężenia emisji związków szkodliwych z silnika ZI pojazdu samochodowego w warunkach ruchu miejskiego*. Logistyka, nr 6, 2010.
5. Brzozowski K., Nowakowski J.: *Zastosowanie sztucznych sieci neuronowych do modelowania emisji z silnika o zapłonie samoczynnym*, Journal of KONES 12(1-2), 2005.
6. Brzozowski K.: *Mikroskalowe modele emisji i dyspersji zanieczyszczeń samochodowych*, Zeszyty Naukowe Akademii Techniczno-Humanistycznej – Rozprawy Naukowe (18), Bielsko-Biała 2006.
7. Brzozowski K., Nowakowski J.: *Model sterowania emisją związków szkodliwych spalin silników o zapłonie samoczynnym*. WKŁ, Warszawa 2012.
8. Brzozowski K., Wojciech S.: *Wyznaczanie natężenia emisji po zimnym rozruchu silnika z zastosowaniem sztucznych sieci neuronowych*. Archiwum Motoryzacji nr 2, 2007.
9. Canakci M., Erdil A., Arcaklioğlu E.: *Performance and exhaust emissions of a biodiesel engine*. Applied Energy 83, 2006.
10. Canakci M., Ozsezen A.N., Arcaklioğlu E., Erdil A.: *Prediction of performance and exhaust emissions of a diesel engine fueled with biodiesel produced from waste frying palm oil*. Expert Systems with Applications 36, 2009.
11. Ghazikhani M., Mirzaii I.: *Soot emission prediction of a waste-gated turbo-charged DI diesel engine using artificial neural network*. Neural Comput. & Applic. 20, 2011.
12. Ghobadian B., Rahimi H., Nikbakht A.M., Najafi G., Yusaf T.F.: *Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network*. Renewable Energy 34, 2009.
13. He Y., Rutland C.J.: *Application of artificial neural networks in engine modeling*. International Journal of Engine Research 5(4), 2004.
14. Kesgin U.: *Genetic algorithm and artificial neural network for engine optimization of efficiency and NO<sub>x</sub> emission*. Fuel 83, 2004.
15. Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa 1996.
16. Shivakumar, Srinivasa Pai P., Shrinivasa Rao B.R.: *Artificial Neural Network based prediction of performance and emission characteristics of a variable compression ratio CI engine using WCO as a biodiesel at different injection timings*. Applied Energy, 88, 2011.
17. Yusaf T.F., Buttsworth D.R., Saleh K.H., Yousif B.F.: *CNG-diesel engine performance and exhaust emission analysis with the aid of artificial neural network*. Applied Energy 87, 2010.

### **Autor:**

**dr hab. inż. Krzysztof BRZOZOWSKI, prof. ATH** – Akademia Techniczno-Humanistyczna w Bielsku-Białej.