

## Zastosowanie sztucznych sieci neuronowych do modelowania ekologicznych właściwości pojazdów

LUCYNA BRZOWSKA, KRZYSZTOF BRZOWSKI,  
KORNEL WARWAS

Akademia Techniczno-Humanistyczna w Bielsku-Białej

W artykule zaproponowano wykorzystanie sztucznych sieci neuronowych do modelowania natężenia emisji związków szkodliwych spalin oraz zużycia paliwa w zależności od parametrów charakteryzujących ruch pojazdu, takich jak chwilowa prędkość i przyspieszenie. Rozważono sztuczne sieci neuronowe z sigmoidalną i radialną funkcją aktywacji neuronu. Kalibracje sieci wykonano w oparciu o dane eksperymentalne określające natężenie emisji i zużycie paliwa w postaci macierzy emisji. Wykorzystano macierze uzyskane podczas badań na hamowni podwoziowej dla zbioru testów jezdnych o różnej dynamice dla pojazdu z silnikiem o zapłonie iskrowym, wyposażonym w reaktor katalityczny oraz dla pojazdu z silnikiem o zapłonie samoczynnym. Porównano dokładność aproksymacji, uzyskaną dla obu rozważanych sztucznych sieci neuronowych. W obu przypadkach jest ona większa niż stosowane, wcześniej przez autorów niniejszej publikacji, aproksymacje wielomianami potęgowymi i funkcjami potęgowymi. Stwierdzono przy tym, że sieć z sigmoidalną funkcją aktywacji neuronu jest bardziej uniwersalna w rozpatrywanym zagadnieniu, zarówno ze względu na jej strukturę jak i zdolność do lepszego odwzorowania natężenia emisji.

### 1. Wstęp

Rzeczywista emisja z silników pojazdów w trakcie ich eksploatacji trakcyjnej stanowi przedmiot licznych prac badawczych. Modelowanie emisji związków szkodliwych przez pojazdy samochodowe wymaga określenia parametrów opisujących ruch pojazdów, bezpośrednio determinujących emisję. Zbiór tych parametrów uzależniony jest od skali przestrzennej i rozpatrywanych interwałów czasowych. Tworzone modele emisji klasyfikowane są ogólnie ze względu na przynależność do następujących grup:

- modele współczynnika emisji (*Emission Factor Models*), np. model MOBILE [1], MVEI [2], CHINA-MOBILE [3],
- modele średniej prędkości (*Average Speed Models*), np. model COPERT [4],
- modele modalne (*Modal Models*), umożliwiające uwzględnienie emisji na biegu jałowym, podczas jazdy ze stałą prędkością i emisji w stanach dynamicznych.

Modele ostatniej grupy (na przykład model MODEM [5]) prowadzą do określenia natężenia emisji danego składnika spalin na podstawie serii badań odwzorowujących różne warunki eksploatacji trakcyjnej.

W przypadku rozpatrywania zagadnień emisji w mikroskali przestrzennej (parking, skrzyżowanie itp.) wykorzystuje się modele modalne, ze względu na konieczność określania warunków determinujących emisję w krótkich, sekundowych przedziałach czasu. W tej grupie modeli, wyróżnia się trzy podstawowe podejścia, prowadzące odpowiednio do:


- macierzy emisji w zależności od prędkości i przyspieszenia pojazdu [6, 7, 8],
- map emisji w zależności od prędkości i wykorzystania mocy silnika [9],
- funkcji analitycznych w oparciu o sparametryzowany model fizyczny [10, 11].

Zaproponowane w artykule postępowanie dotyczy problemu modelowania natężenia emisji na podstawie macierzy emisji, sporządzonej na podstawie pomiarów modalnych. Wygodną metodą jest przy tym charakteryzacja emisji w stanach dynamicznych poprzez macierz określoną dla chwilowej prędkości i przyspieszenia jako parametrów niezależnych. Dla każdej komórki macierzy (elementu) natężenie emisji i zużycie paliwa jest wartością średnią. W niektórych przypadkach wykorzystywana jest średnia ważona, np. w pracy [12]. W innych pracach spotkać można macierze, dla których zmienna niezależna, określająca przyspieszenie, zastępowana jest iloczynem prędkości i przyspieszenia [5, 13]. Ważnym problemem jest dobór odpowiedniego wymiaru komórki (elementu) macierzy emisji. Teoretycznie zmniejszenie elementu prowadzi do zwiększenia dokładności odwzorowania rzeczywistego natężenia emisji i zużycia paliwa. Praktycznie powoduje jednak, że liczne komórki macierzy natężenia emisji i zużycia paliwa pozostają puste. Oznacza to, że w ramach pomiarów przeprowadzonych dla testów jezdnych nie napotkano odpowiedniej kombinacji zmiennych niezależnych. Typowa macierz natężenia emisji bądź zużycia paliwa we współrzędnych prędkość i przyspieszenie, tworzona jest w oparciu o siatkę, gdzie dyskretne wartości prędkości zmieniają się z krokiem 5 km/h, a przyspieszenia co 0,1 m/s<sup>2</sup> [14].

W zadaniach związanych z wykorzystywaniem macierzy emisji szczególną uwagę zwrócić należy na dwa problemy: uśredniania wartości w poszczególnych elementach oraz określenia wartości dla elementów, dla których nie uzyskano informacji. Oba problemy można potraktować łącznie poszukując odpowiedniej funkcji aproksymującej. We wcześniejszych pracach autorów proponowano w tym celu wykorzystanie wielomianów i funkcji potęgowych [12, 15, 16], przy czym w pracy [17] oprócz poszukiwania funkcji typu potęgowego, wykorzystano sztuczne sieci neuronowe z radialną funkcją aktywacji neuronu. W niniejszej pracy autorzy rozwijają ideę stosowania sztucznych sieci neuronowych do aproksymacji macierzy emisji i zużycia paliwa, wprowadzając i testując różne typy sieci. Wykorzystywane przy tym są macierze emisji uzyskane dla dwóch pojazdów osobowych: pojazdu z silnikiem ZI, wyposażonego w reaktor katalityczny oraz pojazdu z silnikiem ZS.


## 2. Macierze emisji

W pracy skorzystano z macierzy emisji i zużycia paliwa uzyskanych na podstawie realizacji zarówno legislacyjnych (FTP-75, NEDC), jak i rzeczywistych testów jezdnych (*City Main Street* (CMS), *City Secondary Street* (CSS), BUWAL T30 oraz BUWAL T50) [18, 19]. Uśredniając wyniki z poszczególnych testów zmniejszono błąd wyznaczania średniego natężenia związków szkodliwych spalin i zużycia paliwa dla poszczególnych elementów macierzy. Rzeczywiste testy jezdne wykorzystane przy tworzeniu macierzy przedstawiono na rysunkach 1-4.




Rys. 1. Przebieg prędkości w teście *City Main Street*

Fig. 1. Speed course of *City Main Street* cycle




Rys. 2. Przebieg prędkości w teście *City Secondary Street*

Fig. 2. Speed course of *City Secondary Street* cycle



Rys. 3. Przebieg prędkości w teście BUWAL T30



Fig. 3. Speed course of BUWAL T30 cycle



Rys. 4. Przebieg prędkości w teście BUWAL T50

Fig. 4. Speed course of BUWAL T50 cycle

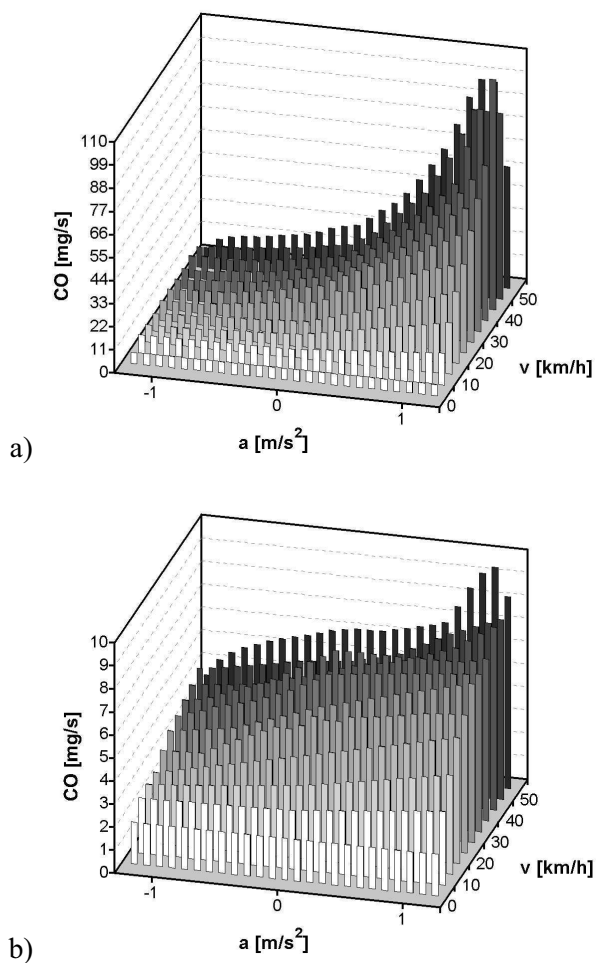
Każda z wykorzystanych w artykule macierzy emisji i zużycia paliwa utworzona była w oparciu o siatkę z krokiem 5 km/h dla prędkości  $v$ , gdzie  $v \in \langle 0,50 \rangle$  km/h, oraz z krokiem 0,1 m/s<sup>2</sup> dla przyspieszenia  $a$ , gdzie  $a \in \langle -1,2;1,2 \rangle$  m/s<sup>2</sup>. W macierzach zgromadzono informacje uzyskane z pomiarów o natężeniu zużycia paliwa ( $F$ ) oraz emisji związków szkodliwych spalin takich jak: tlenek węgla (CO), węglowodory (HC) i tlenki azotu (NO<sub>x</sub>). W przypadku każdego z analizowanych składników spalin, a także dla zużycia paliwa uzyskano pełną macierz emisji (dla każdego elementu macierzy uzyskano informację pomiarową). Na rysunkach 5 i 6 przedstawiono macierze zużycia paliwa oraz natężenia emisji tlenku węgla odpowiednio dla pojazdu z silnikiem ZI oraz pojazdu z silnikiem ZS.



Rys. 5. Macierz natężenia zużycia paliwa: a) dla pojazdu z silnikiem ZI, b) dla pojazdu z silnikiem ZS

Fig. 5. Matrix of intensity of fuel consumption:

a) for a vehicle with SI engine, b) for a vehicle with CI engine

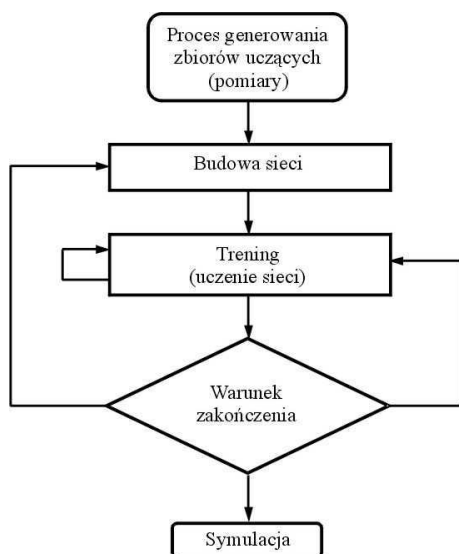


Rys. 6. Macierz natężenia emisji tlenku węgla:  
 a) dla pojazdu z silnikiem ZI, b) dla pojazdu z silnikiem ZS  
 Fig. 6. Matrix of intensity of carbon monoxide emission:  
 a) for a vehicle with SI engine, b) for a vehicle with CI engine

Tak przygotowane macierze, zawierające informacje pomiarową dla każdego elementu w postaci średniej wartości rejestrowanej w różnych testach jezdnych, stanowią podstawę określania właściwości ekologicznych pojazdów. Uzyskanie odpowiednich charakterystyk dynamicznych, a więc funkcji, które opisywałyby natężenie emisji bądź zużycia paliwa  $e$  w zależności od prędkości  $v$  i przyspieszenia pojazdu  $a$ , można sformułować jako zadanie aproksymacji [12, 15, 16]. W niniejszym artykule zaproponowano zastosowanie sztucznych sieci neuronowych o radialnej i sigmoidalnej funkcji aktywacji neuronów do rozwiązania tego zadania.

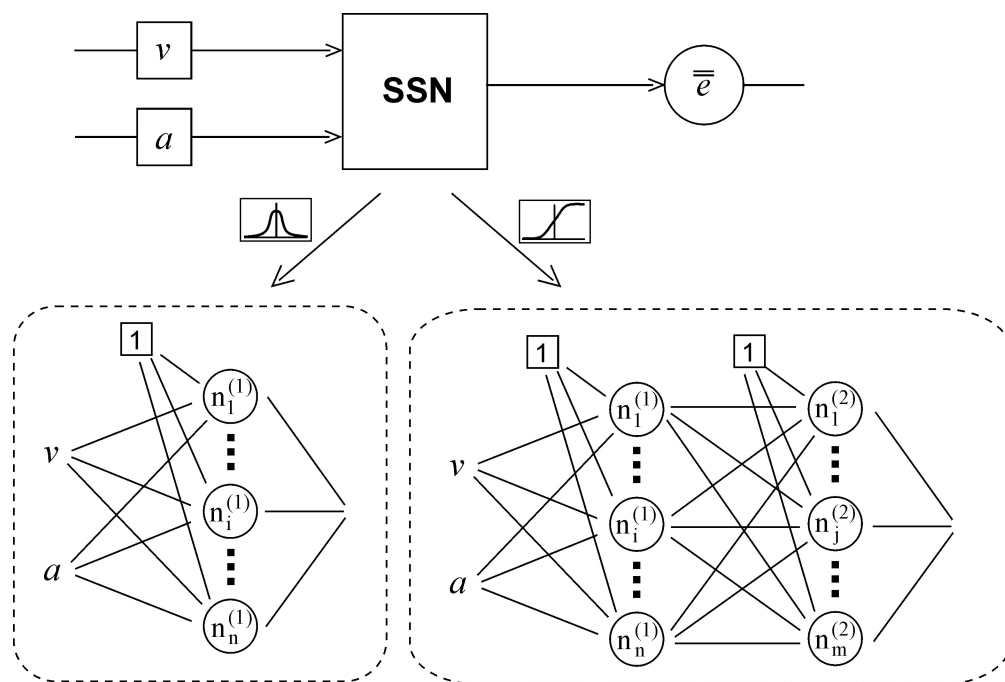
### 3. Struktura proponowanych sieci neuronowych do aproksymacji natężenia emisji i zużycia paliwa

Podstawowym etapem w zadaniach wykorzystujących sztuczne sieci neuronowe, (SSN) jest proces uczenia. W przypadku sieci typu sigmoidalnego uczenie przeprowadza się dla określonej wcześniej struktury sieci (a więc przyjętej liczby warstw oraz liczby neuronów na tych warstwach), która wymaga sprawdzania w procesie iteracyjnym. Proponowaną strukturę sieci poddaje się modyfikacji, jeżeli nie umożliwi osiągnięcia odpowiedniej dokładności odwzorowania wartości ze zbioru uczącego. W przypadku sieci typu radialnego struktura sieci (zazwyczaj jedna warstwa ukryta i liniowy sumator na wyjściu) jest modyfikowana w procesie uczenia, poprzez dobór liczby neuronów na warstwie ukrytej. Ogólny schemat procesu przygotowywania sztucznej sieci neuronowej na podstawie zbioru uczącego przedstawiono na rysunku 7.



Rys. 7. Proces przygotowania sztucznej sieci neuronowej  
Fig. 7. Schema of neural network training

Strukturę zaproponowanych w artykule sztucznych sieci neuronowych, stosowanych do aproksymacji wyników pomiarów stanowiskowych natężenia emisji i zużycia paliwa, przedstawiono na rysunku 8.



Rys. 8. Ogólna struktura proponowanych sztucznych sieci neuronowych  
 Fig. 8. General structure of proposed neural networks

Celem uczenia sieci jest wyznaczenie wartości wag  $w$  neuronów wszystkich warstw sieci w taki sposób, aby przy zadanym wektorze wejściowym  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_m]^T$  gdzie  $\mathbf{x}_j = [v_j, a_j]^T$ , uzyskać na wyjściu sieci wartości sygnałów wyjściowych możliwie bliskie wartościom ze zbioru uczącego. Zadanie to sprowadza się do minimalizacji funkcjonału:

$$\Omega = \Omega(\mathbf{w}) = \frac{1}{2} \sum_{j=1}^m [\bar{e}(v_j, a_j) - e_j]^2, \quad (1)$$

gdzie:  $\bar{e}(v_j, a_j)$  – otrzymane wartości wyjściowe dla  $\mathbf{x}_j$ ,

$e_j$  – natężenie emisji bądź zużycia paliwa ze zbioru uczącego dla  $\mathbf{x}_j$ ,

$m$  – liczba dyskretnych danych w zbiorze uczącym.



Zakładając pojedynczy neuron na warstwie wyjściowej można napisać:

$$\bar{e}(v, a) = \begin{cases} f\left(\sum_{l=1}^s w_l e_l\right) & \text{dla sieci sigmoidalnej} \\ \sum_{l=1}^s w_l f_l(v, a) & \text{dla sieci radialnej,} \end{cases} \quad (2)$$

gdzie:  $w_l$  - waga neuronu  $l$  z warstwy ukrytej,

$e_l$  - natężenie emisji bądź zużycia paliwa obliczone dla neuronu  $l$  z warstwy ukrytej,

$s$  - liczba neuronów na warstwie ukrytej,

$f$  - funkcja aktywacji .

### 3.1 Sieć z sigmoidalną funkcją aktywacji

Wśród metod uczenia sigmoidalnych jednokierunkowych wielowarstwowych sieci neuronowych dominują metody gradientowe. Jedną z najefektywniejszych jest algorytm Riedmilla i Brauna, zwany RPROP (*resilient backpropagation*) [20]. W metodzie tej przy korekcie wag uwzględnia się jedynie znak składowej gradientu, pomijając jej wartość oraz odpowiednio dobiera współczynnik uczenia dla każdej wagi  $w$ . Korekta wag dla każdego neuronu następuje według wzoru:

$$w = w + \Delta w, \quad (3)$$

gdzie  $\Delta w$  oznacza zmianę wartości wagi  $w$  w kolejnym cyklu uczenia.

Zmianę wartości wagi dla każdego neuronu opisuje wzór:

$$\Delta w_k = -\eta_k \operatorname{sgn}(\alpha_k), \quad (4)$$

gdzie:  $\alpha_k = \frac{\partial \Omega(\mathbf{w}_k)}{\partial w}$ ,

$\Delta w_k$  oznacza zmianę wartości wagi  $w$  w kroku  $k$ ,

$\eta_k$  - współczynnik uczenia wagi  $w$  w kroku  $k$ .

Wyznaczenie wartości współczynnika uczenia w każdym cyklu następuje indywidualnie dla każdej wagi  $w$  według zależności:

$$\eta_k = \begin{cases} \min(a\eta_{k-1}, \eta_{\max}) & \text{dla } \alpha_{k-1}\alpha_k > 0 \\ \max(b\eta_{k-1}, \eta_{\min}) & \text{dla } \alpha_{k-1}\alpha_k < 0 \\ \eta_{k-1} & \text{dla } \alpha_{k-1}\alpha_k = 0, \end{cases} \quad (5)$$

gdzie:  $a, b$  – stałe,

$\eta_{\min}, \eta_{\max}$  - minimalna i maksymalna wartość współczynnika uczenia.

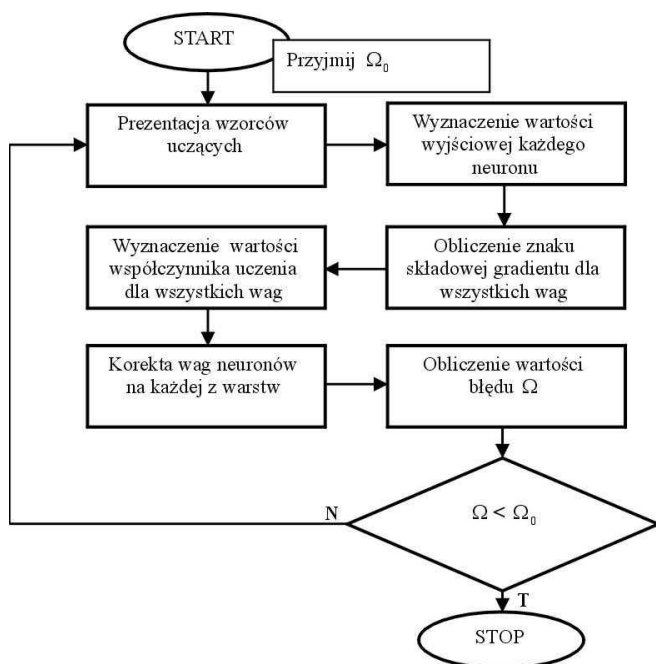
Wartości współczynników  $a, b, \eta_{\min}$  oraz  $\eta_{\max}$  przyjęto zgodnie z tabelą 1.

Tabela 1. Zestawienie wartości stałych i współczynników przyjętych w procesie uczenia sieci typu sigmoidalnego

Table 1. Values of constant variables and coefficients which have been taken in training of sigmoidal neural network

Stała/Współczynnik	a	b	$\eta_{\min}$	$\eta_{\max}$
Wartość	1,2	0,5	$1 \cdot 10^{-6}$	50

Schemat wykorzystanego algorytmu RPROP przedstawiono na rysunku 9.



Rys. 9. Algorytm RPROP  
Fig. 9. RPROP algorithm

Funkcje aktywacji dla wszystkich neuronów przyjęto w postaci funkcji unipolarnej:

$$f\left(\sum_{l=1}^s w_l e_l\right) = \left[1 + \exp\left(-\sum_{l=1}^s w_l e_l\right)\right]^{-1}. \quad (6)$$

### 3.2 Sieć z radialną funkcją aktywacji

W przypadku sieci radialnej rozwiązanie zadania (1) sprowadza się do rozwiązania nadokreślonego układu równań algebraicznych liniowych postaci [17]:

$$\mathbf{e} = \mathbf{B} \cdot \mathbf{w} + \mathbf{r}, \quad (7)$$

$$\mathbf{B} = (b_{l,j})_{\substack{l=1,\dots,s \\ j=1,\dots,m}}, \quad (8)$$

gdzie  $\mathbf{e} = [e_1, \dots, e_j, \dots, e_m]^T$ ,

$b_{l,j} = f_l^{(j)}$ ,  $f_l^{(j)}$  - jest funkcją aktywacji neuronu  $l$  dla sygnału wejściowego

$\mathbf{x}_j$ ,  $\mathbf{w} = [w_1, \dots, w_l, \dots, w_s]^T$ ,

$\mathbf{r}$  - jest wektorem błędów niedopasowania (residuów).

Zadanie polega zatem na minimalizacji normy wektora residuów  $\mathbf{r}$ . Rozwiązanie otrzymuje się po dobraniu liczby neuronów  $s$  na warstwie ukrytej, obliczeniu wektora wag  $\mathbf{w}$  i po przyjęciu postaci funkcji aktywacji osobno dla każdego neuronu. Jako funkcje aktywacji dla każdego z neuronów warstwy ukrytej ( $l = 1, \dots, s$ ) można przyjąć funkcję Gaussa:

$$f_l^{(j)} = f_l(v_j, a_j) = \exp\left[-\frac{(v_j - \bar{v}_l)^2 + (a_j - \bar{a}_l)^2}{2\sigma_l^2}\right], \quad (9)$$

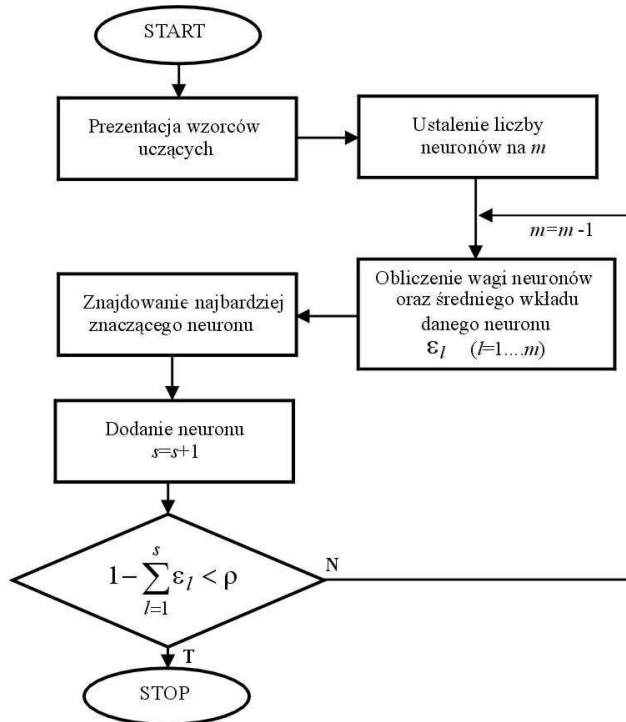
gdzie punkty  $(\bar{v}_l, \bar{a}_l)$  noszą nazwę centrów funkcji Gaussa, a o właściwościach funkcji aktywacji decyduje parametr  $\sigma_l$ . W niniejszej pracy przyjęto, że centra są utożsamiane z wybranymi parami współrzędnych  $(v, a)$ , dla których zdefiniowano w macierzy natężenie zużycia paliwa i emisji poszczególnych związków szkodliwych spalin. Sposoby doboru centrów funkcji opisano w pracy [20].

Parametr funkcji aktywacji  $\sigma_l$  przyjęto w postaci:

$$\sigma_l = \alpha \cdot \max_{1 \leq j \leq m} [(v_j - \bar{v}_l)^2 + (a_j - \bar{a}_l)^2], \quad (10)$$

dobierając parametr  $\alpha$ , jednakowy dla wszystkich funkcji bazowych, poprzez odpowiednie eksperymenty numeryczne.

Uczenie sieci z funkcją aktywacji w postaci (9) zrealizowano metodą ortogonalizacji z wykorzystaniem algorytmu Grama-Schmidta [20], którego uproszczony schemat przedstawiono na rysunku 10.



Rys. 10. Uproszczony schemat algorytmu Grama-Schmidta  
Fig. 10. Simplified schema of Gram-Schmidt algorithm

Występująca w schemacie na rysunku 10 wielkość  $\rho$  jest parametrem sterującym, decydującym o zakończeniu obliczeń i ograniczeniu liczby neuronów  $s$  na warstwie ukrytej.

W tabeli 2 zestawiono wartości parametru  $\alpha$  oraz  $\rho$  przyjmowane przy tworzeniu sieci typu radialnego do aproksymacji danych z macierzy emisji i zużycia paliwa.

Tabela 2. Wartości parametrów  $\alpha$  oraz  $\rho$  przyjęte w procesie uczenia sieci typu radialnegoTable 2. Values of coefficient  $\alpha$  and  $\rho$  which have been taken in training network of radial type

Pojazd z silnikiem	Parametr	Aproksymacja CO, HC, F	Aproksymacja NO <sub>x</sub>
ZI	$\alpha$	$2 \cdot 10^{-3}$	$3,4 \cdot 10^{-3}$
	$\rho$	$10^{-3}$	$10^{-3}$
ZS	$\alpha$	$2 \cdot 10^{-3}$	$2 \cdot 10^{-3}$
	$\rho$	$10^{-3}$	$10^{-3}$

#### 4. Wyniki aproksymacji natężenia emisji i zużycia paliwa przy użyciu sztucznych sieci neuronowych

Sztuczne sieci neuronowe o strukturze opisanej w poprzednim rozdziale zastosowano do aproksymacji danych z macierzy emisji i zużycia paliwa. Liczbę neuronów na poszczególnych warstwach sieci sigmoidalnej i radialnej, w tym na warstwie ukrytej, zestawiono w tabeli 3.

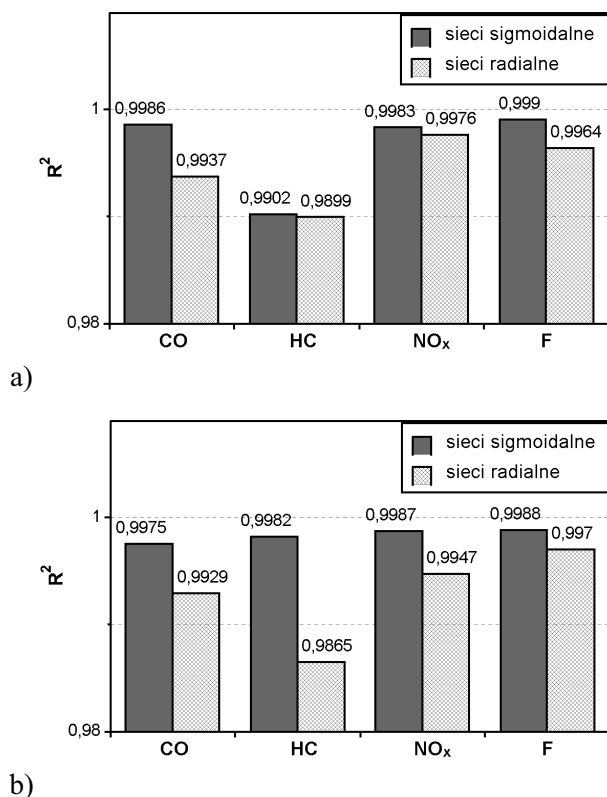
Tabela 3. Liczba neuronów na poszczególnych warstwach w zależności od typu zastosowanej sztucznej sieci neuronowej

Table 3. Number of neurons on layers according to type of network used

Pojazd z silnikiem	Rodzaj sieci	Liczba neuronów na poszczególnych warstwach sieci			
		Warstwa wejściowa	1 warstwa ukryta	2 warstwa ukryta	Warstwa wyjściowa
ZI	Sigmoidalna	2	50	20	1
	Radialna		CO – 171 HC – 169 NO <sub>x</sub> – 125 F - 158	Nie występuje	
ZS	Sigmoidalna	2	50	20	1
	Radialna		CO – 183 HC – 185 NO <sub>x</sub> – 169 F - 157	Nie występuje	

Otrzymane struktury sieci, zapewniające minimalizację funkcjonu (1), wskazują na większą uniwersalność sieci typu sigmoidalnego, której struktura jest wspólna dla wszystkich rozpatrywanych wielkości i rodzajów pojazdu. W przypadku sieci typu radialnego, w procesie ortogonalizacji otrzymano różne struktury w zależności od rodzaju pojazdu i aproksymowanej wielkości.

W celu porównania otrzymywanej dokładności aproksymacji dla obu postaci sztucznej sieci neuronowej, obliczono i porównano kwadrat współczynnika korelacji Pearsona, pomiędzy odpowiedzią danej sieci, a wartością ze zbioru uczącego. Otrzymane wyniki przedstawiono na rysunku 11.




Rys. 11. Porównanie kwadratu współczynnika korelacji Pearsona  $R^2$  dla obu rozważanych sztucznych sieci neuronowych do aproksymacji natężenia emisji i zużycia paliwa:

a) w przypadku pojazdu z silnikiem ZI, b) w przypadku pojazdu z silnikiem ZS

Fig. 11. Comparison of square of Pearson correlation coefficient  $R^2$  for both types of neural networks considered in order to approximate intensity of emission and fuel consumption: a) for a vehicle with SI engine, b) for a vehicle with CI engine


Porównanie współczynników korelacji zestawione na rysunku 11 wskazuje na to, że sztuczną sieć neuronową o sigmoidalnej funkcji aktywacji neuronu wytrenowano lepiej niż sieć radialną. Wynikiem tego jest oczywiście większa dokładność aproksymacji z wykorzystaniem sieci sigmoidalnej, niemniej jednak dokładność aproksymacji z użyciem sieci radialnej również jest na akceptowalnym poziomie.

Na kolejnych rysunkach przedstawiono charakterystyki dynamiczne natężenia zużycia paliwa (rysunki 12,13) i emisji tlenu węgla (rysunki 14,15) dla obu pojazdów obliczone w oparciu o zaimplementowane sztuczne sieci neuronowe.




Rys. 12. Charakterystyki dynamiczne natężenia zużycia paliwa dla pojazdu z silnikiem ZI obliczone na podstawie odpowiedzi obu zaimplementowanych sztucznych sieci neuronowych a) radialnej, b) sigmoidalnej

Fig. 12. Dynamic characteristics of intensity of fuel consumption for a vehicle with SI engine calculated on the base of both neural networks considered a) radial, b) sigmoidal



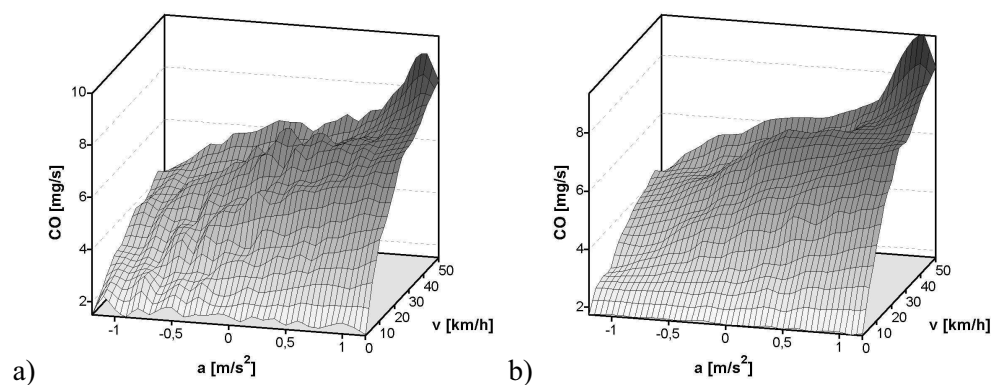
Rys. 13. Charakterystyki dynamiczne natężenia zużycia paliwa dla pojazdu z silnikiem ZS obliczone na podstawie odpowiedzi obu zaimplementowanych sztucznych sieci neuronowych a) radialnej, b) sigmoidalnej

Fig. 13. Dynamic characteristics of intensity of fuel consumption for a vehicle with CI engine calculated on the base of both neural networks considered a) radial, b) sigmoidal



Rys. 14. Charakterystyki dynamiczne natężenia emisji tlenku węgla dla pojazdu z silnikiem ZI obliczone na podstawie odpowiedzi obu zaimplementowanych sztucznych sieci neuronowych a) radialnej, b) sigmoidalnej

Fig. 14. Dynamic characteristics of intensity of carbon monoxide emission for a vehicle with SI engine calculated on the base of both neural networks considered a) radial, b) sigmoidal




Rys. 15. Charakterystyki dynamiczne natężenia emisji tlenku węgla dla pojazdu z silnikiem ZS obliczone na podstawie odpowiedzi obu zaimplementowanych sztucznych sieci neuronowych a) radialnej, b) sigmoidalnej

Fig. 15. Dynamic characteristics of intensity of carbon monoxide emission for a vehicle with CI engine calculated on the base of both neural networks considered a) radial, b) sigmoidal


Bezpośrednie porównanie dokładności aproksymacji, uzyskiwanej dla obu typów sieci, przedstawiono w odniesieniu do wartości zmierzonej w ramach badań. Na rysunkach 16 i 17 przedstawiono porównanie obliczonego i zarejestrowanego natężenia zużycia paliwa oraz natężenia emisji tlenku węgla odpowiednio dla pojazdu z silnikiem ZI i pojazdu z silnikiem ZS w zależności od przyspieszenia pojazdu przy prędkości  $v = 30$  km/h.





Rys. 16. Natężenie zużycia paliwa obliczone na podstawie obu zaimplementowanych sztucznych sieci neuronowych: a) dla pojazdu z silnikiem ZI, b) dla pojazdu z silnikiem ZS

Fig. 16. Intensity of fuel consumption calculated on the base of both neural networks considered: a) for a vehicle with SI engine, b) for a vehicle with CI engine



Rys. 17. Natężenie emisji tlenku węgla obliczone na podstawie obu zaimplementowanych sztucznych sieci neuronowych: a) dla pojazdu z silnikiem ZI, b) dla pojazdu z silnikiem ZS

Fig. 17. Intensity of emission of carbon monoxide calculated on the base of both neural networks considered: a) for a vehicle with SI engine, b) for a vehicle with CI engine

## 5. Podsumowanie

Przedstawiona w pracy metodyka aproksymacji natężenia emisji i zużycia paliwa w zależności od chwilowej prędkości ruchu pojazdu i jego przyspieszenia umożliwia porównywanie właściwości ekologicznych pojazdów poszczególnych kategorii. Źródło danych stanowią macierze utworzone w ramach badań pojazdów na hamowni podwoziowej, podczas realizacji kilku testów jezdnych o różnej dynamice. W pracy wykazano, że do aproksymacji danych zawartych w macierzach emisji i zużycia paliwa przydatne mogą być sztuczne sieci neuronowe. Zaimplementowano dwie sieci, różne pod względem struktury i funkcji aktywacji neuronów dla obu uzyskując dobrą dokładność odwzorowania. Wyznaczane na podstawie sztucznych sieci neuronowych charakterystyki dynamiczne umożliwiają obliczenie natężenia emisji poszczególnych składników spalin dla badanych pojazdów w zależności od dowolnej chwilowej prędkości.

kości i przyspieszenia pojazdu. Jedynym ograniczeniem jest tutaj zakres zmienności parametrów niezależnych (prędkości i przyspieszenia), przyjęty przy tworzeniu macierzy emisji i zużycia paliwa. Proponowana w artykule metodyka zapewnia lepsze odwzorowanie i jest dokładniejsza w porównaniu z wielomianami potęgowymi [12, 16] czy funkcjami potęgowymi [15]. Warto przy tym zwrócić uwagę na to, że sztuczna sieć neuronowa o sigmoidalnej funkcji aktywacji neuronu, pomimo bardziej skomplikowanej struktury (dwie warstwy ukryte) jest bardziej uniwersalna od sieci radialnej, dla której liczba neuronów na warstwie ukrytej jest zróżnicowana ze względu na rodzaj silnika oraz aproksymowaną wielkość. Również dokładność aproksymacji w przypadku zastosowania sieci sigmoidalnej jest większa niż otrzymana dla sieci typu radialnego.

Artykuł powstał w trakcie realizacji projektu badawczego nr 4T12D00826, finansowanego przez Komitet Badań Naukowych.

### Literatura

- [1] User's guide to MOBILE 5. U.S. Environmental Protection Agency, EPA-A-TEB-94-01, 1994.
- [2] Methodology for estimating emissions from on-road motor vehicles. Volume I: introduction and overview. California Environmental Protection Agency Air Resources Board, 1996.
- [3] HAO J., HE D., WU Y., FU L., HE K.: *A study of the emission and concentration distribution of vehicular pollutants in the urban area of Beijing*. Atmospheric Environment, Vol. 34, pp. 453-465, 2000.
- [4] NTZIACHRISTOS L., SAMARAS Z.: *Copert III computer programme to calculate emissions from road transport. Methodology and emission factors*. European Environment Agency, Copenhagen, 2000.
- [5] JOURMARD R., JOST P., HICKMAN J.: *Influence of instantaneous speed and acceleration on hot passenger car emissions and fuel consumption*. SEA Paper 950928, 1995.
- [6] HANSEN J.Q., WINTER M., SORENSON S.C.: *The influence of driving Patterns on petrol Passenger car emissions*. The Science of the Total Environment, Vol. 169, pp.129-139, 1995.
- [7] KISHI Y., KATSUKE S., YOSHIKAWA Y., MORITA I.: *A method for estimating traffic flow fuel consumption - Using traffic simulations*. JSAE Review, Vol. 17, pp.307-311, 1996.
- [8] ZACHARIADIS TH., SAMARAS Z.: *Comparative assessment of European tools to estimate traffic emissions*. International Journal of Vehicle Design, Vol. 18, pp. 312-325, 1997.
- [9] WEST B. H., MCGILL R.N., HODGSON J.W., SLUDER C.S., SMITH D.E.: *Development of data-based light-duty modal emissions and fuel consumption models*. SEA Paper 972910, 1997.
- [10] BARTH M., AN F., NOREBECK J., ROSS M.: *Modal emission modeling: a physical approach*. Transportation Research Record, No. 1520, pp. 81-88, 1996.
- [11] BARTH M., AN F., YOUNGLOVE T., SCORA G., LEVINE C., ROSS M., WENZEL T.: *User's guide: Comprehensive modal emissions model (CMEM) version 2.0*, NCHRP Project 25-11, 2000.
- [12] BRZOZOWSKI K., ROMANISZYN K.: *An effective method of creating dynamic characteristics using drive tests*. The Archive of Mechanical Engineering, Vol. L, No. 4, pp. 403-420, 2003.
- [13] ANDRE M., PRONELLO C.: *Relative influence of acceleration and speed on emissions under actual driving conditions*. International Journal of vehicle Design, Vol. 18, pp. 340-353, 1997.
- [14] STURM P.J. et al.: *Instantaneous emission data and their use in estimating passenger car emissions*. VKM-THD Report, Vol. 74, Verlag der Techn. Univ. Graz, Graz, 1998.
- [15] BRZOZOWSKI K.: *Wybrane aspekty modelowania natężenia emisji w warunkach dynamicznych*. Czasopismo Techniczne Mechanika (PKrak.), z.6-M T.1 Silniki Spalinowe s.125-132, 2004.

- [16] BRZOWSKA L., BRZOWSKI K., *Komputerowe modelowanie emisji rozprzestrzeniania się zanieczyszczeń samochodowych*. Wydawnictwo Naukowe Śląsk, Katowice-Warszawa, 2003.
- [17] BRZOWSKA L., BRZOWSKI K., WOJCIECH S., *Zastosowanie funkcji Gaussa do wyznaczenia charakterystyk dynamicznych emisji związków szkodliwych spalin*, ZN OBR BOSMAL, z. 26(4), s. 7-22, 2004.
- [18] BUWAL *Ergänzungsmessungen zum Projekt „Luftschadstoffemissionen des Strassesverkehrs in der Schweiz 1990-2010“*, BUWAL - Arbeitsunterlage 17, Bern. Switzerland 1994
- [19] STURM P.J.: *Abgasemissionen des Strassenverkehrs und ihre Ausbreitung in der Atmosphäre*. Fortschrittsberichte Reihe 15, Nr 139. VDI Verlag, Düsseldorf, Germany 1995
- [20] OSOWSKI S.: *Sieci neuronowe w ujęciu algorytmicznym*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1996.

## **Modelling of ecological properties of vehicles with neural networks**

### **Summary**

In the paper have been proposed an artificial neural networks for modelling of engine exhaust emission intensity and fuel consumption intensity in dependency on vehicle motion parameters such as instantaneous velocity and acceleration. Two different kind of neural networks have been considered: radial and sigmoidal function for neurons activation. Those neural networks have been calibrated on the experimental data of emission and fuel consumption intensity. The experimental data has been earlier performed in a emission matrix. The emission matrices have been obtained on the base of modal measurements for a set of driving cycles with different dynamic. Two vehicles have been investigated, one vehicle with spark ignition engine equipped with catalytic converter and one vehicle with compression ignition engine. Results of approximation by neural networks are compared for both type of networks in the paper. The error of approximation is less for NNs than for polynomial and power functions used in previously of author works. It can be noticed that neural network with sigmoidal function of neural activation enables us better results of approximation of experimental data and therefore is more useful in the case considered.