

## AN APPLICATION OF ARTIFICIAL NEURAL NETWORK TO EXHAUST EMISSION MODELLING FROM DIESEL ENGINE

Krzysztof Brzozowski, Jacek Nowakowski

Akademia Techniczno-Humanistyczna  
Willowa 2  
43-309 Bielsko-Biała  
tel./fax: +48 (33) 8279289  
e-mail: kbrzozowski@ath.bielsko.pl  
e-mail: jnowakow@ath.bielsko.pl

### Abstract

*The paper presents an application of artificial neural network to modelling emission from Diesel engine. In our study six independent engine control variables have been identified and used. In order to found the relations between engine control parameters and emission the radial artificial neural network (ANN) has been applied. The ANN has been trained on the base of measurement results whose cover a wide range of steady state engine operating conditions. The accuracy of ANN output has been compared with calculation based on power function proposed in earlier works. In the paper has been shown that ANN gives better emission approximation than power function. A good correspondence of ANN prediction values has been achieved also in comparison to results of additional experiment data.*

## ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO MODELOWANIA EMISJI Z SILNIKA O ZAPŁONIE SAMOCZYNNYM

### Streszczenie

*Emisja związków szkodliwych spalin z silnika o zapłonie samoczynnym. Przyjęto sześć parametrów charakteryzujących warunki pracy silnika, w zależności od których przy użyciu zaimplementowanych sztucznych sieci neuronowych określano emisję związków szkodliwych i zadymienie spalin. Zaproponowane sieci wytrenowano na zbiorze ponad 200 dyskretnych danych pomiarowych rejestrowanych w całym polu pracy silnika. Dokładność odpowiedzi sieci porównano z obliczeniami w oparciu o funkcje potęgowe zaproponowane we wcześniejszych pracach. W pracy pokazano, że postępowanie z wykorzystaniem sztucznych sieci neuronowych lepiej nadaje się do aproksymacji emisji i zadymienia niż funkcje potęgowe. Wykorzystując sieci neuronowe uzyskano dobrą dokładność odpowiedzi sieci w porównaniu z rezultatami dodatkowych badań.*

### 1. Wstęp

W zakresie prac rozwojowych dotyczących silników spalinowych wykorzystuje się modele matematyczne o różnej strukturze. Oprócz modeli klasy CFD stosuje się także modele teoretyczno-empiryczne, wymagające określenia szeregu parametrów empirycznych. Modele takie są szczególnie przydatne w zagadnieniach, w których czas obliczeń odgrywa istotną rolę, stąd kluczową sprawą bywa zapewnienie efektywności numerycznej modelu. Problem domykania równań takiego modelu ze względu na parametry empiryczne może być rozwiązany w sposób opisany w pracy [2] gdzie skalowania modelu dokonano poprzez odpowiednio sformułowane zadaniem optymalizacji. Modele teoretyczno-empiryczne, formułowane są w oparciu o posiadaną informację badawczą, dotyczącą jednakże pewnych dyskretnych stanów pracy silnika. Pojawia się zatem problem aproksymacji danych

dyskretnych, tak aby zapewnić dobre odwzorowanie modelu dla całego zakresu pracy silnika. Klasa aproksymacji, a więc sposób uogólnienia zarejestrowanych w wyniku eksperymentu badawczego danych, będzie wprost determinować poprawność wnioskowania o zachowaniu się badanych wielkości w innych stanach silnika (dla których nie wykonywano badań).

W niniejszej pracy przedstawiono metodę aproksymacji danych pomiarowych dotyczących emisji związków szkodliwych spalin i zadymienia, uzyskanych dla pewnych dyskretnych wartości parametrów regulacyjnych w turbodoładowanym silniku o zapłonie samoczynnym z recyrkulacją spalin. Do aproksymacji wykorzystywać można różne postaci funkcji, ale niezależnie od ich postaci problem minimalizacji średniego błędu kwadratowego aproksymacji sprowadza się do określenia ich parametrów [3]. We wcześniejszych pracach autorów [2, 3, 8] wykorzystywano wielomiany i funkcje potęgowe które zapewniały aproksymację w ujęciu globalnym. Inny sposób podejścia do aproksymacji wyników badań przedstawiono w niniejszej pracy, gdzie do aproksymacji wykorzystano sztuczne sieci neuronowe z radialną funkcją aktywacji neuronu, zapewniając lokalny charakter aproksymacji. Przykład zastosowania sieci neuronowej wykorzystanej do aproksymacji emisji związków szkodliwych z silnika ZS można znaleźć np. w pracy [6], z kolei w pracy [7] wykorzystano sieci neuronowe do aproksymacji wyników modelowania procesu roboczego silnika w pakiecie KIVA-ERC. W obu cytowanych pracach wykorzystano jednakże sieci neuronowe o sigmoidalnej funkcji aktywacji neuronu. Wyniki aproksymacji dla zaproponowanej postaci sieci neuronowej z radialną funkcją aktywacji porównano z wynikami otrzymywanym dla wcześniej używanych funkcji potęgowych.

## 2. Opis badań eksperymentalnych

Eksperymentalną identyfikację emisji i zadymienia spalin w zależności od wybranych parametrów regulacyjnych silnika przeprowadzono na silniku o zapłonie samoczynnym. Podstawowe dane techniczne silnika przedstawiono w tabeli 1.


*Tabela 1. Dane techniczne silnika*  
*Table 1. Engine specification*

Typ silnika	silnik ZS z turbosprężarką, chłodnicą powietrza doładowującego i recyrkulacją spalin
Budowa / Liczba cylindrów	rzędowy / 4
Zawory na cylinder	4
Średnica cylindra [mm]	79
Skok tłoka [mm]	86
Pojemność skokowa [cm <sup>3</sup> ]	1668
Stopień sprężania	18,4
Moc maksymalna [kW]	55 przy 4400 obr/min
Moment obrotowy maksymalny [Nm]	165 przy 1800 ÷ 3000 obr/min

W pracy przyjęto, że emisję składników spalin takich jak: tlenków azotu (NO<sub>x</sub>), tlenku węgla (CO), węglowodorów (HC) i zadymienie (D) można przedstawić w zależności od parametrów regulacyjnych silnika. Jako parametry regulacyjne przyjęto 6 wielkości:  $n$  - prędkość obrotowa silnika,  $B_0$  - dawka paliwa,  $\varphi_w$  - kąt wyprzedzenia wtrysku,  $p$  - ciśnienie i  $T$  - temperatura czynnika w kolektorze dolotowym oraz  $X_{EGR}$  - stopień recyrkulacji spalin.


Do badań identyfikacyjnych wyznaczono punkty pomiarowe w taki sposób, aby badania objęły możliwie jak najszerszy obszar pracy silnika. Wartości prędkości obrotowych

wyznaczono w oparciu o test hamowniany ESC [5], dodatkowo uwzględniając prędkość obrotową 1884 obr/min (rys. 1).



Rys. 1. Zakres pracy silnika w badaniach  
Fig. 1. Engine operating area investigated

W badaniach uwzględniono różne wartości momentu obrotowego obciążając silnik poprzez hamulec dynamometryczny momentami o wartościach: 25%, 50%, 75% i 100% maksymalnego momentu obrotowego silnika przy danej prędkości obrotowej. Dla tak wyznaczonych dyskretnych stanów pracy silnika w każdym punkcie zmieniano kąt wyprzedzenia wtrysku i stopień recyrkulacji spalin. Dyskretne punkty pola pracy silnika, w których przeprowadzono badania przedstawiono schematycznie na rys. 2.



Rys. 2. Punkty pomiarowe w polu pracy silnika  
Fig. 2. Measurement points in engine operating area

Identyfikacje emisji i zadymienia spalin przeprowadzono ogółem dla 231 dyskretnych punktów pracy silnika w zależności od zadanych parametrów regulacyjnych. Można proces badawczy opisać następująco: dla  $j = 0, 1, \dots, m$  ( $m = 231$ ) oraz zestawu parametrów regulacyjnych odpowiadającemu każdemu przypadkowi, a więc:

$$\mathbf{x}^{(j)} = [n^{(j)}, B_0^{(j)}, \varphi_w^{(j)}, p^{(j)}, T^{(j)}, X_{EGR}^{(j)}]^T, \quad (1)$$

gdzie  $\mathbf{x}^{(j)}$  - wektor zmiennych niezależnych (parametrów regulacyjnych), dla którego rejestrowano cztery wielkości  $F_s^{(j)}$  dla  $s = 1, \dots, 4$  tj. emisję tlenku węgla, węglowodorów, tlenków azotu oraz zadymienie spalin.

Zastosowanie otrzymanych wyników pomiarów w pracach związanych z modelowaniem emisji z silnika bądź w sterowaniu wymaga zdefiniowania formuł określających poszczególne wielkości  $F_s$  jako ciągle funkcje parametrów regulacyjnych, tj:

$$F_s = F_s^*(\mathbf{x}), \text{ dla } s = 1, 2, 3, 4. \quad (2)$$


Tak sformułowanie zadanie można wykonać poprzez zastosowanie sztucznych sieci neuronowych, wytrenowanych na otrzymanej w wyniku pomiarów informacji o emisji związków szkodliwych i zadymieniu spalin.

### 3. Sformułowanie zadania aproksymacji

Aproksymacji funkcji dyskretnych  $F_s$  dokonano metodą najmniejszych kwadratów [4] minimalizując funkcjonały:

$$\Omega_s = \sum_{j=0}^m [F_s^*(\mathbf{x}^{(j)}) - F_s^{(j)}]^2 \text{ dla } s = 1, 2, 3, 4 \quad r = 6, \quad (3)$$

wykorzystując sieci neuronowe, osobno do predykcji każdej wielkości  $F_s$  z pojedynczym neuronem na warstwie wyjściowej [9]. Schemat zastosowanych sieci przedstawiono na rys. 3.



Rys. 3. Schemat zaimplementowanej sieci neuronowej  
Fig. 3. Artificial neural network implemented

Zadanie aproksymacji z wykorzystaniem sztucznych sieci neuronowych może zostać sformułowane w postaci (indeks  $s$  pominięto):

$$F^*(\mathbf{x}^{(j)}) = \sum_{i=0}^k w_i \cdot \eta_i(\mathbf{x}^{(j)}, \mathbf{t}^{(i)}), \quad (4)$$

gdzie  $w_i$  - nieznanymi współczynniki dla  $i = 0, 1, 2, \dots, k$ ,  $\eta_i$  - funkcje bazowe dla  $i = 0, 1, 2, \dots, k$ ,  $k \leq m$  liczba centrów,  $m$  - liczba danych dyskretnych w zadaniu uczenia sieci. Przyjęto, że funkcje bazowe mają postać funkcji Gaussa

$$\eta_i(\mathbf{x}^{(j)}, \mathbf{t}^{(i)}) = \eta_i^{(j)} = \exp\left[-\frac{\|\mathbf{x}^{(j)} - \mathbf{t}^{(i)}\|^2}{2\sigma_i^2}\right], \quad (5)$$

gdzie  $\|\mathbf{x}^{(j)}\| = \left\{ \sum_{l=1}^6 [x_l^{(j)}]^2 \right\}^{\frac{1}{2}}$ ,  $\mathbf{t}^{(i)} = [n^{(i)}, B_0^{(j)}, \varphi_w^{(i)}, p^{(i)}, T^{(i)}, X_{EGR}^{(i)}]^T$  - i-te centrum funkcji bazowej oraz

$$\sigma_i = \alpha \cdot \max_{0 \leq j \leq m} \left[ \sum_{l=1}^6 (x_l^{(j)} - t_l^{(i)})^2 \right]. \quad (6)$$

W niniejszej pracy postanowiono przyjmować tą samą wartość współczynnika  $\alpha$  dla każdego neuronu w pojedynczym zadaniu aproksymacji wielkości  $F_s$ . Współczynnik ten może zostać uzyskany z wykorzystaniem procedury optymalizacji opisanej w pracy [1]. Rozwiązanie zadania aproksymacji można sformułować w postaci układu równań, które w zapisie macierzowym mają postać

$$\mathbf{F} = \mathbf{B} \cdot \mathbf{W} + \mathbf{r} \quad (7)$$

dla  $\mathbf{B} = (b_{ij})_{\substack{i=0, \dots, m \\ j=0, \dots, s}}$ , gdzie  $b_{ij} = \eta_i^{(j)}$ ,  $\mathbf{W} = [w_0, \dots, w_n]^T$ ,  $\mathbf{F} = [F(\mathbf{x}^0), \dots, F(\mathbf{x}^m)]^T$ ,  $\mathbf{r}$  - wektor residuum.

W celu minimalizacji funkcjonału

$$\|\mathbf{r}\|^2 = \|\mathbf{B}\mathbf{W} - \mathbf{F}\|^2 = \sum_{j=0}^m \left[ \sum_{i=0}^k w_i \cdot \eta_i^{(j)}(\mathbf{x}^{(j)}, \mathbf{t}^{(i)}) - F(\mathbf{x}^{(j)}) \right]^2, \quad (8)$$

wykorzystano metodę Grama-Schmidta [9] która pozwala określić  $q \leq k$  najbardziej znaczących funkcji bazowych  $\eta_i$ . Algorytm wyboru liczby neuronów na warstwie ukrytej jest realizowany dopóki nie jest spełniony warunek postaci

$$1 - \sum_{l=1}^k \varepsilon_l < \rho, \quad (9)$$

gdzie  $\varepsilon_l$  - waga l-tej funkcji bazowej,  $\rho$  - współczynnik tolerancji spełniający warunek  $0 < \rho < 1$ .

W pracy, wartość współczynnika tolerancji  $\rho$  jak i współczynnika  $\alpha$  z równania (6) określono na podstawie [1]. W wyniku uczenia sieci algorytmem Grama-Schmidta uzyskano następującą liczbę neuronów ( $q$ ): dla sieci odwzorowującej CO  $q = 35$ , dla HC  $q = 53$ , dla NO<sub>x</sub>  $q = 32$  oraz dla zadymienia D  $q = 34$  [1].


Wyniki aproksymacji porównano przy tym z wynikami otrzymywanymi dla następującej postaci funkcji aproksymacyjnej:

$$F_s^* = \alpha_0^{(s)} x_1^{\alpha_1^{(s)}} \cdot \dots \cdot x_j^{\alpha_j^{(s)}} \cdot \dots \cdot x_6^{\alpha_6^{(s)}}, \quad \text{dla } s = 1, 2, 3, 4. \quad (10)$$

a więc funkcji potęgowej wielu zmiennych wykorzystanej między innymi w pracach [2, 3].

#### 4. Dokładność aproksymacji

Przy wykorzystaniu dyskretnych danych pomiarowych, otrzymanych w wyniku badań opisanych w rozdziale 2, przeprowadzono porównanie wyników aproksymacji uzyskanych dla funkcji potęgowych i proponowanych w pracy sieci neuronowych. Na rys. 4 przedstawiono odwzorowanie wartości zarejestrowanych eksperymentalnie z tymi otrzymywanymi po zastosowaniu obu rodzajów aproksymacji.



Rys. 3. Porównanie wartości uzyskanych w wyniku aproksymacji w odniesieniu do wartości uzyskanych w pomiarach

Fig. 3. Comparison of approximated values and measured in experiment

Podobnie jak w pracy [3] można wprowadzić kryterium porównawcze obu sposobów aproksymacji w postaci:

$$E_s = \sum_{j=0}^m [F_s^*(\mathbf{x}^{(j)}) - F_s^{(j)}]^2 \cdot \left[ \sum_{j=0}^m [F_s^{(j)}]^2 \right]^{-1} \cdot 100\% . \quad (11)$$

Wartość powyższego wyrażenia oznacza sumę kwadratów błędów aproksymacji, odniesioną do sumy kwadratów wartości pomierzonych. Wyniki porównania obu aproksymacji po zastosowaniu kryterium (11) przedstawiono w tabeli 2.

Tabela 2. Wartość  $E$  (11) dla aproksymacji siecią neuronową i funkcją potęgową  
Table 2. Value of  $E$  (see 11) for approximation task by ANN and power function

Klasa aproksymacji	$E_s$ [%]			
	CO	HC	NO <sub>x</sub>	D
Funkcja potęgowa	35	5,7	1,6	6,3
Siec neuronowa	2,25	0,25	0,17	0,83

Porównując wyniki aproksymacji przy zastosowaniu obu postaci funkcji wg kryterium (12), można stwierdzić, że aproksymacja o charakterze lokalnym uzyskana po zastosowaniu sieci neuronowych pozwala na lepsze odwzorowanie wyników badań. Interesujące jest także porównanie przydatności obu klas aproksymacji do predykcji emisji i zadymienia dla nowych danych pomiarowych. W celu weryfikacji przydatności proponowanych sieci neuronowych i funkcji potęgowych do predykcji emisji związków szkodliwych i zadymienia spalin zrealizowano dodatkowe badania eksperymentalne. Badania obejmowały inne stany pracy silnika niż te przedstawione na rys 2., dla których emisja i zadymienie obliczone zostały w oparciu o proponowane sieci i funkcje potęgowe. Wartości parametrów regulacyjnych, dla których wykonano badania przedstawiono w Tabeli 3.

Tabela 3. Dane wykorzystane do oceny sieci neuronowych i funkcji potęgowych  
Table 3. Data for validation of ANNs and power functions performance

Opcja	$n$ [obr/min]	$M$ [Nm]	$B_0$ [kg]	$\varphi_w$ [°OWK]	$p$ [hPa]	$T$ [K]	$X_{EGR}$ [%]
A	2616	41	$1 \cdot 10^{-5}$	-10	1384	327	0
B	2618	41	$1 \cdot 10^{-5}$	-5	1360	330	8
C	3345	35	$1,1 \cdot 10^{-5}$	-13	1434	327	0
D	3341	35	$1,1 \cdot 10^{-5}$	-3	1458	335	8
E	3342	69	$1,5 \cdot 10^{-5}$	-14	1536	330	0
F	3347	104	$2,1 \cdot 10^{-5}$	-13	1535	336	8

Emisja związków szkodliwych spalin i zadymienie uzyskane dla obu proponowanych metod po przyjęciu parametrów regulacyjnych jak w Tabeli 3, porównano z wynikami eksperymentu. W Tabeli 4 przedstawiono względny błąd procentowy obliczonych wartości w odniesieniu do obu metod i rozważanych wielkości.

Tabela 4. Błąd procentowy obliczeń na podstawie sieci neuronowych i funkcji potęgowych  
Table 4. Percentage errors for ANNs outputs and calculations by power functions

	CO		HC		NO <sub>x</sub>		D	
	funkcja potęgowa	siec neuronowa	funkcja potęgowa	siec neuronowa	funkcja potęgowa	siec neuronowa	funkcja potęgowa	siec neuronowa
A	3,8	22,2	0,6	1,7	6,7	2,2	0,5	2,7
B	4,2	9,33	7,1	1,2	4,2	4,8	13,6	7,9
C	12,4	6,2	6,7	4	10,2	2,2	60,9	29,9
D	9,7	1,7	15,9	3	6,7	0,6	55,8	4,8
E	15	4	24,2	3,5	21,8	8,4	20	6
F	85	6,3	22,8	6,6	10,2	2,3	73	6,4

Na podstawie wyników zestawionych w tabeli 4 można przypuszczać, że dla wystarczająco dużego zbioru danych dyskretnych otrzymanych na podstawie badań zastosowanie sieci neuronowych do aproksymacji emisji i zadymienia pozwoli na dobre odwzorowanie tych wielkości w całym zakresie pracy silnika

## 5. Podsumowanie

Przedstawione w pracy postępowanie wykorzystujące sztuczne sieci neuronowe do aproksymacji danych eksperymentalnych o emisji związków szkodliwych i zadymieniu spalin, pozwala na lepsze odwzorowywanie tych wielkości niż ma to miejsce po zastosowaniu funkcji potęgowych. Jest to wynikiem lokalnego charakteru aproksymacji (wiele funkcji bazowych) oraz zastosowanej funkcji wymuszenia w postaci funkcji Gaussa. Zdolność odwzorowywania zmian badanych wielkości w całym polu pracy silnika, dla sieci wytrenowanych na ponad 200 zbiorach uczących zarejestrowanych w wyniku badań jest dobra w przypadku węglowodorów i tlenków azotu. Niemniej jednak w przypadku tlenku węgla i zadymienia spalin wskazane byłoby poszerzenie badań identyfikacyjnych i ponowne wytrenowanie sieci, tak aby błąd predykcji tych wielkości zbliżyć do poziomu osiągniętego w przypadku węglowodorów i tlenków azotu.

## Literatura

- [1] Brzozowska L. Brzozowski K. Nowakowski J., An application of artificial neural network to Diesel engine modelling. IDAACS' Workshop 2005, Sofia, in press.
- [2] Brzozowski K. Nowakowski J., Application of optimisation to scaling of the mathematical model of the working cycle of CI engine, The Archive of Mechanical Engineering, Vol. L II, pp. 21-39, 2005.
- [3] Brzozowski K. Nowakowski J. Wojciech S., Wyznaczanie emisji związków szkodliwych spalin i zadymienia w zależności od parametrów pracy silnika ZS. ZN OBR Bosmal, Zeszyt 23, pp. 31-42, 2004.
- [4] Chapra S.C. Canale R. P., Numerical methods for engineers. McGraw-Hill Higher Education. New York, 2002.
- [5] Directive 1999/96/EC of the European Parliament and of the Council of 13 December 1999, Official Journal of the European Communities.
- [6] Gamo S. O., Ouladsine M., Rachid A., Diesel engine exhaust emissions modelling using artificial neural network. SAE paper 1999-01-1163.
- [7] He Y. Rutland C. J., Application of artificial neural networks in engine modelling. International Journal of Engine Research, Vol. 5, No. 4, pp.281-296, 2004.
- [8] Nowakowski J., Zastosowanie optymalizacji do skalowania modelu cyklu roboczego silnika ZS. Czasopismo Techniczne, z.6-M, pp. 601-608, 2004.
- [9] Osowski S., Sieci neuronowe w ujęciu algorytmicznym. WNT. Warszawa, 1996.