

Dr hab. Inż. Krzysztof Brzozowski, prof. ATH

Department of Transport and Applied Computer Science
University of Bielsko-Biała
Ul. Willowa 2, 43-309 Bielsko-Biała, Poland
E-mail: kbrzozowski@ath.eu
Tel. /Fax 33 8279 289

Dr hab. Inż. Jacek Nowakowski, prof. ATH

Department of Combustion Engines and Vehicles
University of Bielsko-Biała
Ul. Willowa 2, 43-309 Bielsko-Biała, Poland
E-mail: jnowakow@ath.bielsko.pl
Tel. 33 8279 257, Fax: 33 8279 351

**TOKSYCZNOŚĆ SPALIN SILNIKA O ZAPŁONIE SAMOCZYNNYM
W WARUNKACH ZMIENNEGO OBCIĄŻENIA DLA RÓŻNYCH WARTOŚCI
PARAMETRÓW REGULACYJNYCH**

Słowa kluczowe: silnik o zapłonie samoczynnym, parametry regulacyjne, emisja związków szkodliwych

Streszczenie. W pracy przedstawiono postępowanie prowadzące do eksperymentalnej identyfikacji zależności zadymienia i emisji związków szkodliwych od wybranych parametrów regulacyjnych silnika o zapłonie samoczynnym. W ramach badań przeprowadzono identyfikację emisji tlenków azotu, węglowodorów, tlenku węgla oraz zadymienia spalin w zależności od: prędkości obrotowej, dawki paliwa, stopnia recyrkulacji spalin i kąta wyprzedzenia wtrysku. Do uogólnienia wyników badań eksperymentalnych zaproponowano wykorzystanie sztucznych sieci neuronowych. Obliczone wartości wskaźników wykorzystanych do oceny błędów aproksymacji oraz predykcji zadymienia i emisji związków szkodliwych spalin potwierdzają skuteczność zaproponowanej metody uogólnienia badań identyfikacyjnych.

1. Wprowadzenie

Obecnie rozwój tłokowych silników spalinowych w dużej mierze jest zdeterminowany poprzez działania mające na celu ograniczenie środowiskowych skutków ich eksploatacji. Kierunek badań wyznacza konieczność spełniania przyszłych wymagań w zakresie emisji związków szkodliwych spalin jak i zużycia paliwa. Wprowadzenie wysokociśnieniowych układów wtryskowych sterowanych elektronicznie umożliwiło spełnienie istniejących wymagań prawnych a doskonalenie algorytmów sterujących tymi układami umożliwi dalsze zmniejszanie negatywnego oddziaływania na środowisko naturalne. Wobec powyższego istotnym zagadnieniem badawczym jest opracowywanie odpowiednich (optymalnych) algorytmów sterowania pracą silnika w zmiennych warunkach eksploatacji uwzględniających podstawowe parametry regulacyjne silnika, takie jak [12, 15, 19]:

- prędkość obrotowa,
- dawka paliwa, przebieg i ciśnienie wtrysku,
- kąt wyprzedzenia wtrysku,
- stopień recyrkulacji spalin.

W przypadku silników doładowanych sprężarkowo algorytmy sterowania mogą ponadto uwzględniać również dodatkowe parametry, takie jak [12, 21]:

- ciśnienie ładunku w kolektorze dolotowym,
- temperaturę ładunku w kolektorze dolotowym.

Standardowe postępowanie zmierzające do zdefiniowania algorytmu sterowania silnika obejmuje badania doświadczalne, na podstawie których wyznaczane są tzw. dyskretne mapy sterowania. Mapy po wprowadzeniu do sterownika, dla danego przedziału wartości prędkości obrotowych i przedziału wartości obciążenia, definiują wartości pozostałych parametrów regulacyjnych oraz współczynniki korekcyjne dla stanów nieustalonych [17]. Takie podejście pozostawia jednak miejsce na zastosowanie bardziej precyzyjnego sterowania bazującego na zależnościach ciągłych, a więc bez uśredniania wyników badań dla przyjętych a priori przedziałów wartości prędkości obrotowych i przedziału wartości obciążenia. Takie zadanie było już realizowane przez autorów, między innymi w pracach [6, 13]. W kontekście realizacji sterowania ze względu na emisję związków szkodliwych, podstawowym elementem przygotowania odpowiednich algorytmów jest identyfikacja toksyczności spalin silnika w warunkach zmiennego obciążenia dla dowolnych technicznie możliwych do zrealizowania wartości parametrów regulacyjnych.

Podobne zagadnienia związane z poszukiwaniem ciągłych aproksymacji emisji realizowane były między innymi w pracach [7, 8, 9, 10, 11, 16, 20]. W pracy [9] autorzy wykorzystali sieć neuronową o prostej architekturze do modelowania emisji cząstek stałych, przedstawiając wyniki w postaci powierzchni aproksymujących dla wybranych zakresów wartości prędkości obrotowej i momentu obrotowego. Modelowaniem zadymienia spalin z wykorzystaniem sieci neuronowych zajmowali się również autorzy pracy [10] odwzorowując wielkość zadymienia w poszczególnych modach testu ECE-R49. Sieci neuronowe do predykcji emisji spalin z silnika zasilanego olejem napędowym, biodieslem i mieszanin obu paliw zaproponowano w pracy [7]. Badania eksperymentalne przeprowadzono jednak tylko dla jednego wybranego punktu pracy silnika odpowiadającego pełnemu obciążeniu przy prędkości obrotowej 1400 obr/min, które następnie wykorzystano zarówno w procesie uczenia jak i weryfikacji sieci neuronowej. Sieć neuronową autorzy pracy zastosowali do określenia emisji dla procentowo zróżnicowanych mieszanin oleju napędowego i biodiesla. Podobne zagadnienie rozważano w pracy [8] przeprowadzając badania dla maksymalnego obciążenia przy różnych prędkościach obrotowych. Z kolei w pracy [16] modelowano emisję z silnika z wykorzystaniem sieci neuronowych w zależności od stopnia sprężania, procentowego udziału biodiesla oraz kąta wyprzedzenia wtrysku. Przedstawione wyniki ograniczono tylko dla warunków odpowiadających pełnemu obciążeniu. W ostatniej z wcześniej przywołanych prac [20] sieć neuronową zastosowano do modelowania momentu napędowego, zużycia paliwa i emisji spalin z silnika o zapłonie samoczynnym zasilanego dwupaliwowo olejem napędowym i sprężonym gazem ziemnym CNG. Dane do uczenia sieci zostały pozyskane wyłącznie w warunkach maksymalnego obciążenia przy danej prędkości obrotowej. Zagadnienie modelowania emisji z wykorzystaniem sztucznych sieci neuronowych stanowiło również przedmiot rozważań w pracy [11], ponownie wyłącznie w warunkach maksymalnego obciążenia przy danej prędkości obrotowej. Wspólną cechą wskazywaną przez autorów przywołanych prac jest konkluzja, że sieci neuronowe z wystarczającą dokładnością odwzorowują emisję związków szkodliwych spalin stanowiąc tym samym alternatywę dla pełnych, czasochłonnych badań eksperymentalnych.

W niniejszej pracy przedstawiono własny sposób identyfikacji zależności pomiędzy emisją a wartościami poszczególnych parametrów regulacyjnych, a także sposób ich uogólniania z wykorzystaniem sztucznych sieci neuronowych. W tym zakresie niniejsza praca stanowi uzupełnienie i rozwinięcie koncepcji przedstawionych w pracy [18].

2. Opis badań identyfikacyjnych

Badania identyfikacyjne zależności pomiędzy emisją tlenków azotu, węglowodorów i tlenku węgla oraz zadymieniem spalin a wartością parametrów regulacyjnych

przeprowadzono na silniku o zapłonie samoczynnym, przeznaczonym i wykorzystywanym do napędu pojazdów osobowych, którego dane techniczne przedstawiono w Tabeli 1.

Tab. 1. Dane techniczne silnika


Engine	CI engine supercharged by a turbo compressor with direct injection equipped with an electronically controlled Common Rail system
Layout of cylinders	4 in line
Number of valves per cylinder	4
Bore	69.6 mm
Stroke	82 mm
Total displacement	1248 cm ³
Compression ratio	16.8
Maximum power	55.2 kW / 4000 rpm
Maximum torque	190 N·m / 1500 rpm

Badania zrealizowano na dynamicznej hamowni silnikowej składającej się z następujących urządzeń:

- hamulca dynamometrycznego typu AVL Dynoexact APA 202,
- systemu sterowania AVL PUMA OPEN 1.3,
- panelu kontrolnego stanowiska AVL EMCON 400.

Emisję składników szkodliwych spalin rejestrowano z użyciem zestawu analizatorów AVL CEB 200, wyposażonego w moduły analizatorów CLD, HFID oraz NDIR, a do pomiaru zadymienia spalin zastosowano dymomierz filtracyjny typu AVL 415S.

Realizacja założonych badań identyfikacyjnych wymagała zmiany standardowych parametrów pracy silnika. W ramach niniejszej pracy przeprowadzono identyfikację emisji tlenków azotu, węglowodorów, tlenku węgla oraz zadymienia spalin w zależności od: prędkości obrotowej, dawki paliwa, stopnia recyrkulacji spalin i kąta wyprzedzenia wtrysku, przy czym zmiana trzech ostatnich parametrów wymaga ingerencji w oprogramowanie centralki sterującej silnika co zrealizowano wykorzystując oprogramowanie INCA V6.2 i urządzenie do przeprogramowania ECU - ETAS ES590. Zakres zrealizowanych badań identyfikacyjnych przedstawiono na rys. 1.



Rys. 1. Schemat zakresu badań identyfikacyjnych

Należy tutaj podkreślić, że w całym zakresie realizowanych badań przedstawionych na rys. 1 dawka paliwa podawana była z podziałem na stałą, niezależną od punktu pracy silnika dawkę pilotującą oraz zmienną dawkę główną. Standardowy algorytm sterowania dawką wtrysku w badanym silniku zawiera bowiem różne, zależne od punktu pracy silnika, strategie przebiegu wtrysku. Uniemożliwia to jednoznaczną identyfikację emisji tlenków azotu, węglowodorów, tlenku węgla oraz zadymienia spalin w zależności od parametrów regulacyjnych silnika.

Kolejny etap prac identyfikacyjnych obejmował uogólnienie wyników badań silnika dla dowolnych, technicznie możliwych do realizacji wartości parametrów regulacyjnych. Realizacja tego etapu wymagała sformułowania odpowiedniego zadania aproksymacji funkcji wielu zmiennych. Możliwe są tutaj dwa podejścia:

- aproksymacja dla przyjętej a priori postaci funkcji aproksymującej, której współczynniki wyznacza się z wykorzystaniem metody najmniejszych kwadratów,
- aproksymacja z wykorzystaniem jednokierunkowych sztucznych sieci neuronowych o radialnych lub sigmoidalnych funkcjach aktywacji neuronów.

Pierwszy z wymienionych sposobów aproksymacji zastosowano między innymi w pracy [1] przyjmując wielomian potęgowy postaci:

$$F^*(\mathbf{x}) = \sum_{i_1=0}^{n_1} \dots \sum_{i_j=0}^{n_j} \dots \sum_{i_r=0}^{n_r} a_{i_1, \dots, i_j, \dots, i_r} x_1^{i_1} \dots x_j^{i_j} \dots x_r^{i_r} \quad (1)$$

gdzie:

$a_{0, \dots, 0, \dots, 0}, \dots, a_{n_1, \dots, n_j, \dots, n_r}$ - współczynniki wielomianu,

n_1, \dots, n_r - całkowite i nieujemne maksymalne potęgi odpowiednich elementów wektora parametrów regulacyjnych \mathbf{x} .

Wielomian potęgowy (1) po zastosowaniu większych wykładników pozwala uzyskać bardzo dobre dopasowanie do wyników badań. Jego wadą jest jednak mocno lokalny charakter

dopasowania, i w konsekwencji słabe własności uogólniające poza najbliższym otoczeniem węzłów aproksymacji. Wobec powyższego w pracach [12, 13] aproksymacje wyników badań toksyczności realizowano z wykorzystaniem funkcji potęgowych,

$$F^*(x) = \alpha_0 x_1^{\alpha_1} \cdot \dots \cdot x_j^{\alpha_j} \cdot \dots \cdot x_r^{\alpha_r} \quad (2)$$

gdzie $\alpha_0 \div \alpha_r$ są współczynnikami o wartościach rzeczywistych.

Funkcje te, pomimo gorszego dopasowania w węzłach aproksymacji niż wielomiany potęgowe, zapewniają akceptowalne własności uogólniające. Stosowano również modyfikacje funkcji potęgowych postaci (2), np. w pracy [2] zaproponowano wprowadzenie wyrazu wolnego w celu zapewnienia nieujemności funkcji w całej dziedzinie argumentów:

$$F^*(\mathbf{x}) = \alpha_0 x_1^{\alpha_1} \cdot \dots \cdot x_j^{\alpha_j} \cdot \dots \cdot x_r^{\alpha_r} + \alpha_{r+1} \quad (3)$$

Druga z wymienionych wcześniej metod korzystająca z metod sztucznej inteligencji nie wymaga przyjmowania a priori postaci funkcji aproksymującej. Takie rozwiązanie zastosowano w niniejszej pracy.

3. Aproksymacja z wykorzystaniem jednokierunkowych sztucznych sieci neuronowych

Do uogólnienia wyników badań identyfikacyjnych wykorzystywane mogą być sztuczne sieci neuronowe, jednokierunkowe o architekturze zawierającej tzw. warstwę lub warstwy ukryte. Zastosowanie sztucznych sieci neuronowych w zadaniu aproksymacji wyników badań emisji wykorzystywane było już we wcześniejszych pracach autorów [3, 4, 5, 6] funkcją aktywacji, o jednym lub wielu neuronach na warstwie wyjściowej. W zdaniach aproksymacji emisji oznacza to, że na wyjściu sieci pojawiał się pojedynczy sygnał (wówczas sieć służyła do aproksymacji emisji jednego składnika spalin) lub kilka sygnałów co oznaczało wykorzystywanie jednej sieci neuronowej do aproksymacji emisji wszystkich analizowanych składników. Zestawienie błędów aproksymacji przedstawione np. w pracy [4], w tym porównane z błędami aproksymacji z wykorzystaniem funkcji potęgowej [2, 3], potwierdza ich przydatność w zadaniach aproksymacji emisji związków szkodliwych spalin. Stąd też w niniejszej pracy do uogólnienia wyników identyfikacji zastosowano sztuczne sieci neuronowe o sigmoidalnej funkcji aktywacji neuronu w postaci unipolarnej:

$$f(\mathbf{w}^t \mathbf{z}) = \left[1 + e^{-\mathbf{w}^t \mathbf{z}} \right]^{-1} \quad (4)$$

gdzie:


\mathbf{w} - wektor wag połączeń wejściowych neuronu,

\mathbf{z} - wektor sygnałów wejściowych do neuronu.

Zakładając pojedynczy neuron na warstwie wyjściowej, wartość sygnału wyjściowego, dla k -elementowej ostatniej warstwy ukrytej jest obliczana jako:

$$F^*(\mathbf{x}) = f\left(\sum_{i=1}^k w_i \cdot z_i\right) \quad (5)$$

Uczenie sieci, polegające na modyfikacji wag poszczególnych połączeń pomiędzy neuronami tworzącymi sieć, wykonywano do czasu gdy średni błąd względny dla całego zbioru uczącego osiągnął co najmniej wartość oczekiwaną. Do uogólnienia wyników badań identyfikacyjnych zaproponowano zastosowanie czterech sieci o ogólnej architekturze jak na rys. 2.



Rys. 2. Ogólna architektura wykorzystanych sieci neuronowych w zadaniu aproksymacji

Zaproponowane w niniejszej pracy sieci na wejściu mają cztery sygnały zmienne odpowiadające elementom wektora parametrów regulacyjnych \mathbf{x} i jedno wejście stałe, a na wyjściu tylko jeden sygnał odpowiadający emisji danego związku. Sieci trenowano tak długo, aż średni błąd względny aproksymacji dla każdego ze składników spalin osiągnął wartość mniejszą niż 10% zarówno w zbiorze uczącym jak i w zbiorze weryfikującym zdolność uogólniania odpowiedzi każdej z czterech sieci.

Do uczenia sieci wykorzystano metodę momentum z przyrostowym uaktualnianiem wag tj., w $n+1$ kroku uczenia sieci modyfikowano wagi według zależności [14]:

$$\mathbf{w}^{(n+1)} = \mathbf{w}^{(n)} - \beta^{(n)} \nabla E(\mathbf{w}^{(n)}) + \delta(\mathbf{w}^{(n)} - \mathbf{w}^{(n-1)}) \quad (6)$$

gdzie:

β - współczynnik uczenia,

E - funkcja celu w postaci błędu średniokwadratowego odpowiedzi sieci w stosunku do wartości oczekiwanych dla danego wektora uczącego,

$\nabla E(\mathbf{w})$ - wektor gradientu funkcji celu,

δ - współczynnik momentu o wartościach z przedziału $[0,1]$.

W procesie uczenia stosowano losowy dobór wag początkowych po każdym powtórzeniu uczenia sieci oraz losowe zadawanie wzorców uczących. Jeżeli dla danej architektury sieci, po zastosowaniu wielu powtórzeń procesu uczenia nie udało się osiągnąć zakładanego poziomu średniego błędu względnego, architekturę sieci modyfikowano. Wejściową architekturę sieci z jedną warstwą ukrytą wpiętych modyfikowano poprzez zwiększanie liczby neuronów na warstwie ukrytej (do maksymalnie 11) a następnie wprowadzono drugą warstwę ukrytą, z jednym neuronem. W dalszej kolejności testowano architektury dodając neurony na warstwie drugiej do momentu zrównania liczby neuronów na obu warstwach. W przypadku, gdy sieć o równej liczbie neuronów na obu warstwach dalej nie pozwalała osiągnąć zakładanego poziomu dokładności odwzorowania zbioru uczącego zwiększano liczbę neuronów na pierwszej warstwie o jeden przyjmując jednocześnie pojedynczy neuron na warstwie drugiej. Dalej postępowano zgodnie z opisanym powyżej

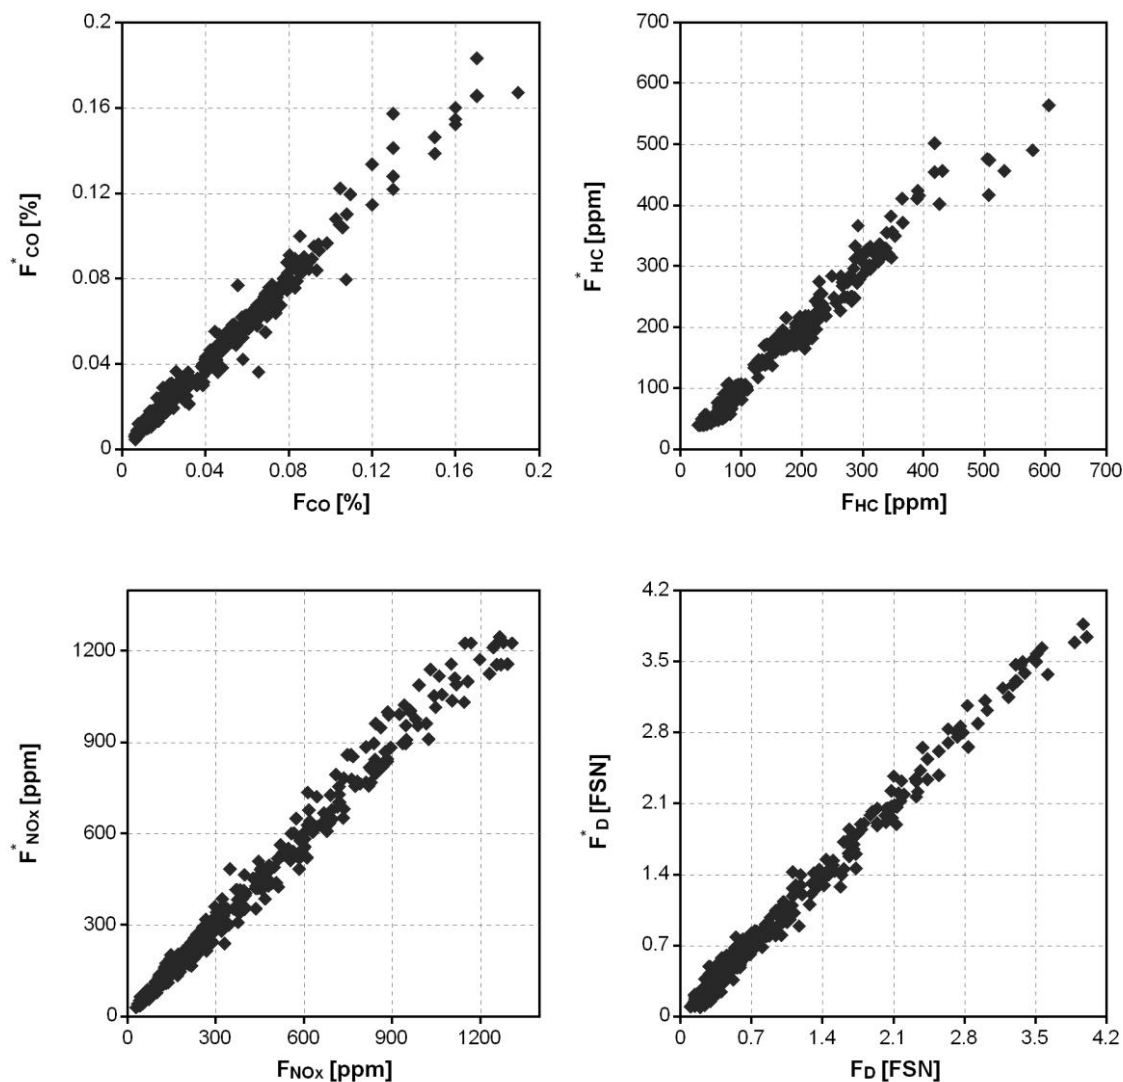
schematem, ponownie testując sieci z coraz to większą liczbą neuronów na warstwach ukrytych.

W wyniku zastosowania opisanego schematu działania, dla każdego związku znaleziono minimalną architekturę sieci umożliwiającą aproksymację emisji, w każdym przypadku wymagająca dwóch warstw ukrytych jednak o różnej liczbie neuronów na poszczególnych warstwach. Zestawienie informacji o przyjętej architekturze sieci neuronowych oraz wartości wskaźników wykorzystanych do oceny błędów aproksymacji i predykcji przedstawiono w Tabeli 2.

Tab. 2. Architektura sieci neuronowych oraz wartości wskaźników wykorzystanych do oceny błędu aproksymacji w zbiorze uczącym i błędu predykcji dla zbioru wykorzystanego w procesie weryfikacji

	CO	HC	NO _x	D
<i>Architecture</i>				
The number of neurons on the first hidden layer	7	5	4	9
The number of neurons on the second hidden layer	5	4	3	9
<i>Evaluation of the approximation quality for a training set</i>				
Average relative percentage error	8.48	8.98	8	9.85
Median of average relative percentage error	5.82	6.71	6.50	6.56
Coefficient of determination	0.979	0.976	0.986	0.991
<i>Evaluation of the approximation quality for a verification set</i>				
Average relative percentage error	9.82	9.55	6.79	7.92
Median of average relative percentage error	7.24	7.33	6.86	6.00
Coefficient of determination	0.983	0.983	0.972	0.97

Na rys. 3 przedstawiono porównanie zadymienia spalin i emisji rozpatrywanych związków uzyskanych jako odpowiedzi sztucznych sieci neuronowych (F^*) dla parametrów regulacyjnych stanowiących sygnały wejściowe ze zbioru uczącego i weryfikującego w odniesieniu do wartości zarejestrowanych eksperymentalnie (F).

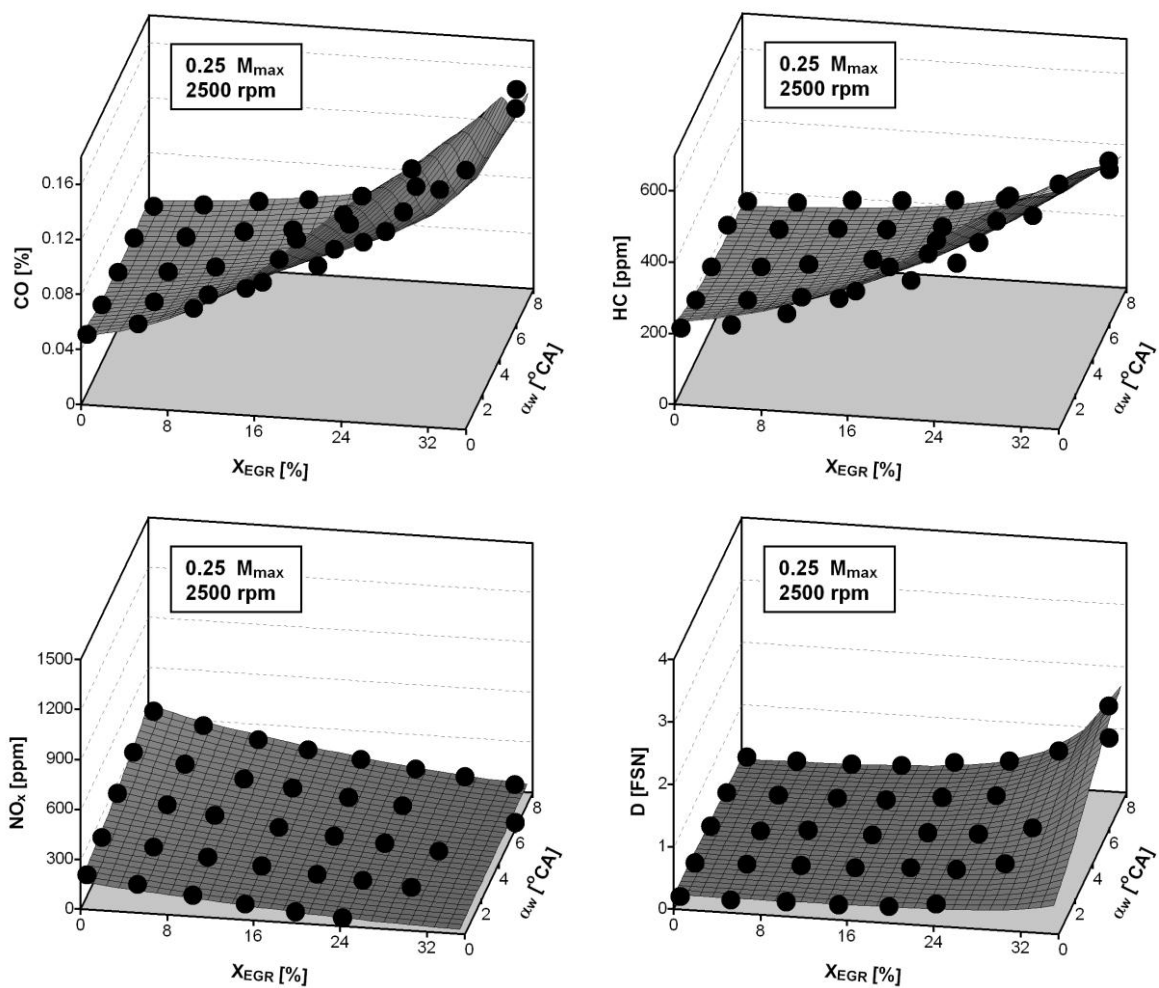


Rys. 3. Porównanie emisji rozpatrywanych związków i zadymienia spalin uzyskanych jako odpowiedzi sztucznych sieci neuronowych (F^*) w odniesieniu do wartości zarejestrowanych eksperymentalnie (F)

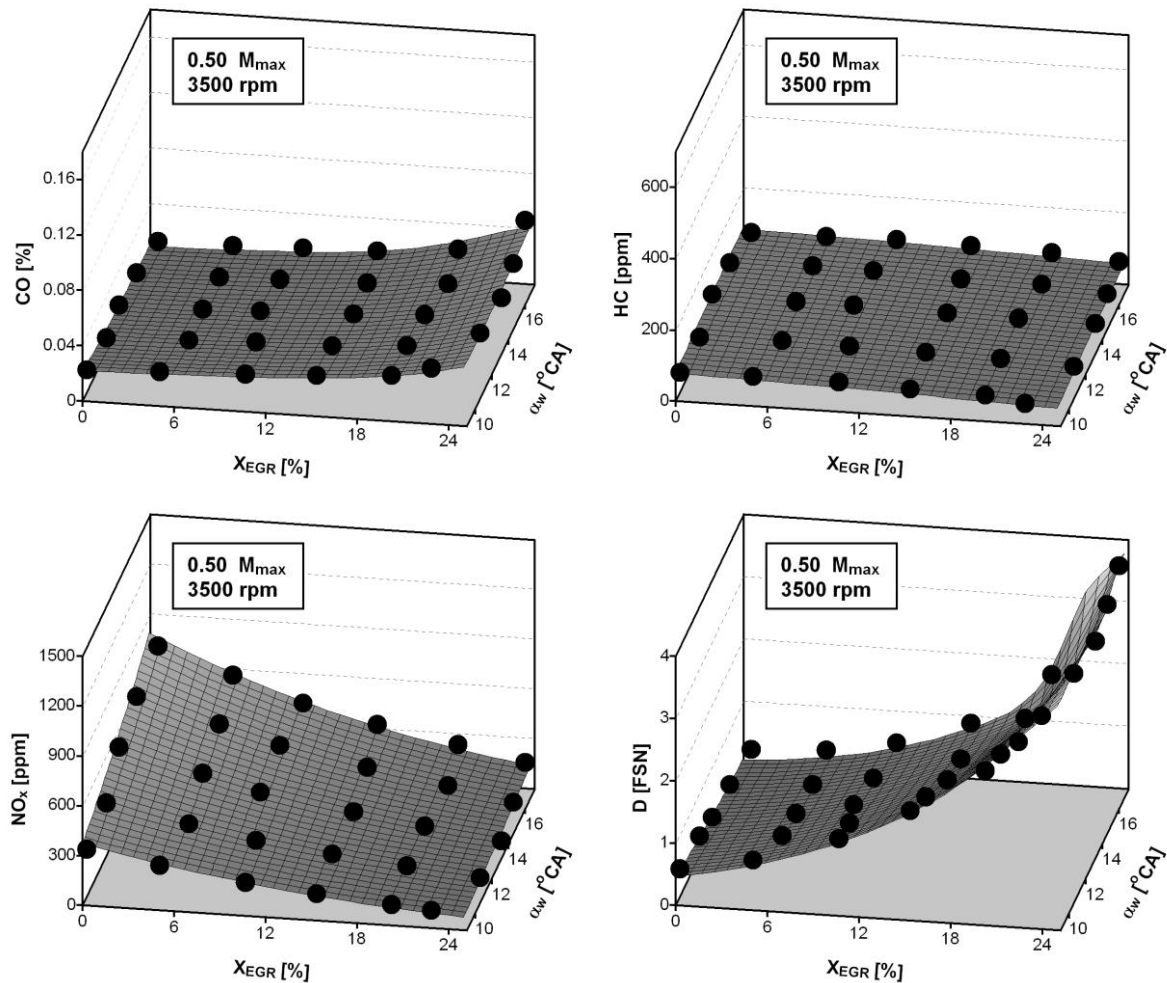
Wartości uzyskanych błędów aproksymacji i predykcji przedstawione w Tabeli 2 potwierdzają skuteczność zaproponowanej metody uogólnienia badań identyfikacyjnych w zakresie odwzorowania toksyczności i zadymienia spalin. Średnie błędy względne zarówno aproksymacji danych ze zbioru uczącego jak i predykcji w przypadku zbioru weryfikacyjnego nie przekraczają 10%.

4. Podsumowanie

Przedstawione w niniejszej pracy postępowanie identyfikacyjne jest jednym z etapów przygotowania algorytmów sterowania parametrami regulacyjnymi w celu ograniczenia zadymienia i emisji związków szkodliwych spalin. Uzyskane powierzchnie prezentujące aproksymowane wartości wyników badań eksperymentalnych zadymienia i emisji związków szkodliwych dla dwóch wybranych prędkości obrotowych i dwóch wartości obciążenia przedstawiono na rys. 4 i 5. Widoczne na powierzchniach markery prezentują wartości dyskretne uzyskane w trakcie badań identyfikacyjnych.

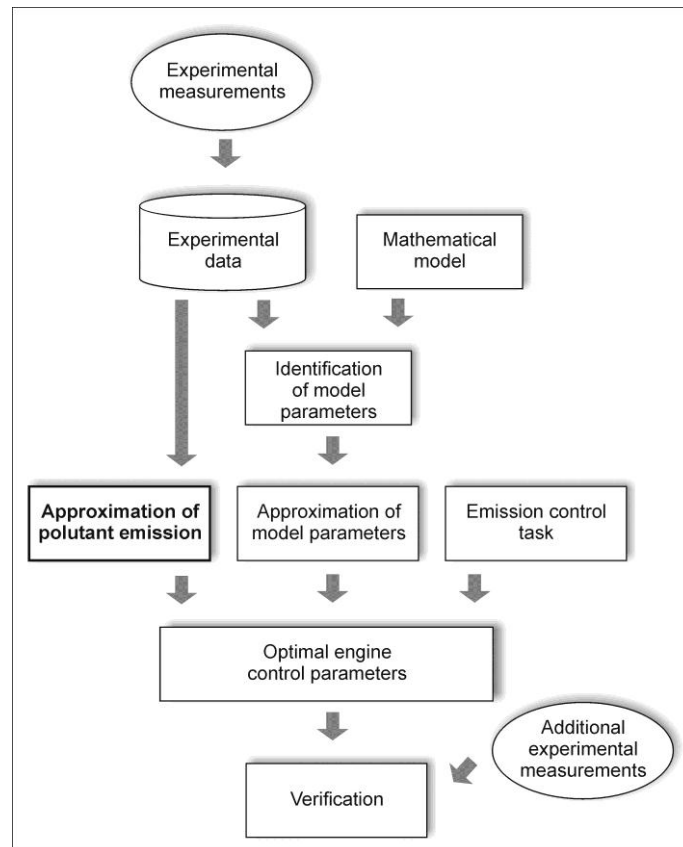


Rys. 4. Powierzchnie aproksymujące zadymienie i emisję związków szkodliwych spalin wyznaczone z wykorzystaniem sztucznych sieci neuronowych dla prędkości obrotowej 2500 obr/min i obciążenia $0,25 M_{max}$



Rys. 5. Powierzchnie aproksymujące zadymienie i emisję związków szkodliwych spalin wyznaczone z wykorzystaniem sztucznych sieci neuronowych dla prędkości obrotowej 3500 obr/min i obciążenia $0,5 M_{max}$

Docelowa realizacja zadania sterowania emisją, zapewniającego jednocześnie utrzymanie parametrów trakcyjnych wymaga dodatkowo sformułowania modelu cyklu roboczego i rozwiązania zadania optymalizacji poprzez odpowiedni dobór wartości parametrów regulacyjnych. Schemat metodologii postępowania przedstawiono na rys. 6.



Rys. 6. Schemat metodologii postępowania w celu sformułowania i rozwiązania zadania sterowania emisją

Warto zwrócić uwagę, że w prezentowanym schemacie postępowania zadanie aproksymacji zostanie sformułowane również w odniesieniu do parametrów teoretyczno-empirycznego modelu cyklu roboczego silnika ZS. Również i w tym przypadku autorzy planują wykorzystać do jego realizacji metody sztucznej inteligencji.

Literatura

1. Brzozowski K, Romaniszyn K. An effective method of creating dynamic characteristics using drive tests. *The Archive of Mechanical Engineering* 2003; 50(4): 403-420.
2. Brzozowski K. Mikroskalowe modele emisji i dyspersji zanieczyszczeń samochodowych. *Zeszyty Naukowe ATH - Seria Rozprawy Naukowe*; 18, 2006.
3. Brzozowski K, Nowakowski J. Zastosowanie sztucznych sieci neuronowych do modelowania emisji z silnika o zapłonie samoczynnym. *Journal of KONES: Internal Combustion Engines* 2005; 12(1-2): 51-59.
4. Brzozowska L, Brzozowski K, Warwas K. Zastosowanie sztucznych sieci neuronowych do modelowania ekologicznych właściwości pojazdów. *The Archives of Automotive Engineering* 2005; 3: 229-247.
5. Brzozowska L, Brzozowski K, Nowakowski J. An application of artificial neural network to diesel engine modelling. *Proceedings of the Third IEEE Workshop Intelligent Data Acquisition and Advanced Computing Systems - Technology and Application* 2005: 142-146.

6. Brzozowski K, Nowakowski J. The model of compression ignition engine with artificial neural networks. *Combustion Engines* 2008; 1: 44-49.
7. Canakci M, Erdil A, Arcaklioğlu E. Performance and exhaust emissions of a biodiesel engine. *Applied Energy* 2006; 83: 594-605.
8. 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* 2009; 36: 9268-9280.
9. de Lucas A, Durán A, Carmona M, Lapuerta M. Modeling diesel particulate emissions with neural networks. *Fuel* 2001; 80: 539-548.
10. Ghazikhani M, Mirzaii I. Soot emission prediction of a waste-gated turbo-charged DI diesel engine using artificial neural network. *Neural Comput. & Applic.* 2011; 20: 303-308.
11. 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* 2009; 34: 976-982.
12. Nowakowski J. Model cyklu roboczego silnika o zapłonie samoczynnym i jego zastosowanie do doboru parametrów regulacyjnych. *Zeszyty Naukowe ATH - Seria Rozprawy Naukowe*; 15, 2005.
13. Nowakowski J, Brzozowski K. Numerical model and programme for simulating working process in the compression-ignition engine with EGR. *Proceedings of the 12th European Automotive Congress EAEC 2009*: 1-18.
14. Osowski S. *Sieci neuronowe w ujęciu algorytmicznym*. Warszawa: WNT, 1996.
15. Ponti F, Corti E, Serra G, De Cesare M. Common Rail Multi-Jet Diesel Engine Combustion Model Development for Control Purposes. *SAE Paper 2007-01-0383*.
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* 2011; 88: 2344-2354.
17. Sobieszczński M, Pietras D, Kniefel T. Dobór algorytmów sterowania rozruchem, nagrzewaniem, wolnymi obrotami oraz recyrkulacją spalin silnika o zapłonie iskrowym zasilanego w systemie wtrysku MPI. *The Archive of Automotive Engineering* 2002; 2-3: 53-67.
18. Sobieszczński M, Brzozowski K, Nowakowski J, Tekielak K. The impact of SI engine controlling parameters on the content of toxic components and smokiness of exhaust gases. *Maintenance and Reliability* 2008; 3: 53-61.
19. Tomishima H, Matsumoto T, Oki M, Nagata K. The Advanced Diesel Common Rail System for Achieving a Good Balance Between Ecology and Economy. *SAE Paper 2008-28-0017*.
20. 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* 2010; 87: 1661-1669.
21. Wang E. Control System Design for Variable Nozzle Turbocharger. *SAE Paper 2009-01-1668*.