

RAFAŁ LONGWIC*, WINCENTY LOTKO**, KRZYSZTOF GÓRSKI**

MODELE REGRESYJNE SIECI NEURONOWYCH W ZASTOSOWANIU DO IDENTYFIKACJI PRZEBIEGU PARAMETRÓW PROCESU SPALANIA W SILNIKU O ZAPŁONIE SAMOCZYNNYM

REGRESSION MODELS OF NEURAL NETWORKS IN APPLICATION TO THE IDENTIFICATION OF THE COMBUSTION PROCESS PARAMETERS IN THE DIESEL ENGINE

Streszczenie

W artykule przedstawiono zastosowanie modeli regresyjnych sieci neuronowych dostępnych w programie Statistica do identyfikacji przebiegu wybranych parametrów procesu spalania zachodzącego w silniku o zapłonie samoczynnym. Badania prowadzono metodą swobodnego przyspieszania. Przeanalizowano, na ile metoda sieci neuronowych jest czuła na modyfikacje składu paliwa.

Słowa kluczowe: sieci neuronowe, silnik o zapłonie samoczynnym, proces spalania

Abstract

In the paper demonstrates models of regression neural networks available in Statistica for identification of selected parameters of the combustion process research conducted by free acceleration. Referring to the method of neural network is sensitive to modifications in the composition of the fuel.

Keywords: neural networks, Diesel engine, combustion process

* Dr hab. inż. Rafał Longwic, Katedra Pojazdów Samochodowych, Wydział Mechaniczny, Politechnika Lubelska.

** Prof. dr hab. inż. Wincenty Lotko, dr inż. Krzysztof Górski, Instytut Eksploatacji Pojazdów i Maszyn, Wydział Mechaniczny, Politechnika Radomska.

1. Wstęp

Sieci neuronowe to techniki analityczne wzorowane na (hipotetycznym) procesie uczenia w systemie poznawczym i funkcjach neurologicznych mózgu. Są one zdolne do przewidywania nowych obserwacji (określonych zmiennych) na podstawie innych obserwacji (dokonanych na tych samych lub innych zmiennych) po przeprowadzeniu procesu tzw. uczenia w oparciu o istniejące dane [13]. W artykule wykorzystano metodę sieci neuronowych dla zbudowania modelu wpływu kąta dynamicznego początku tłoczenia paliwa i prędkości obrotowej wału korbowego silnika na wartości średniego ciśnienia indykowanego uzyskiwanego w warunkach swobodnego przyspieszania, przy zasilaniu silnika mieszaninami oleju napędowego (ON) z eterem etylo-tert-butyłowym (EETB). Badania dotyczące zastosowanie EETB w mieszaninach z ON są częścią przedsięwzięcia naukowego podejmowanego przez autorów, a dotyczącego poszukiwania dodatku do oleju napędowego, który wpływałby na poprawę przebiegu procesu spalania w silniku o zapłonie samoczynnym (ZS) [7, 8]. W tym zakresie wykazano m.in. bardzo korzystny wpływ EETB na ograniczenie emisji cząstek stałych (PM) [7]. Również rezultaty badań prowadzonych przez innych autorów wykazują szereg korzyści ekologicznych wynikających z zastosowania EETB jako dodatku zawierającego tlen do oleju napędowego [10, 14].

Należy również mieć na uwadze fakt, że szereg różnic we własnościach fizykochemicznych EETB w stosunku do oleju napędowego ma wielokierunkowy wpływ na przebieg procesu spalania i wtrysku przebiegającego w warunkach statycznych jak i nieustalonych. Zbudowanie modelu fizycznego uwzględniającego ten wpływ może być bardzo trudne lub wręcz niemożliwe w realizacji. Rozwiązaniem w tym zakresie jest zatem zastosowanie modelu sieci neuronowych. Wykorzystano zatem metodę sieci neuronowych dla stworzenia modelu przebiegu średniego ciśnienia indykowanego (wielkość wyjściowa) dla silnika o zapłonie samoczynnym w warunkach rozpędzania. Przyjęto, że wejściami ilościowymi w modelu sieci neuronowych jest prędkość obrotowa wału korbowego silnika i kąt dynamicznego początku tłoczenia paliwa. Wejściem jakościowym była zawartość objętościowa EETB w mieszaninie z olejem napędowym. Zbiór uczący uzyskano na podstawie przeprowadzonego eksperymentu. Zdecydowano się na wybór metody sieci neuronowych z uwagi na nieliniowy charakter modelu oraz możliwość jego prostej implementacji w zagadnieniach sterowania [1–4, 9, 11, 12].

2. Badania empiryczne – pozyskanie danych do zbioru uczącego sieci neuronowych

Przeprowadzone badania empiryczne miały na celu uzyskanie danych niezbędnych dla zbudowania modelu przebiegu średniego ciśnienia indykowanego silnika o zapłonie samoczynnym w warunkach rozpędzania, w oparciu o metodę sieci neuronowych. Rejestrowano prędkość obrotową wału korbowego silnika i ciśnienie wewnątrz komory spalania, w warunkach swobodnego rozpędzania wywołanego skokową zmianą położenia dźwigni sterującej dawką paliwa. Obiektem badawczym był niedoładowany silnik o zapłonie samoczynnym z wtryskiem bezpośrednim.

W celu wykonania badań empirycznych zestawiono stanowisko pomiarowe pokazane na rys. 1 [8].

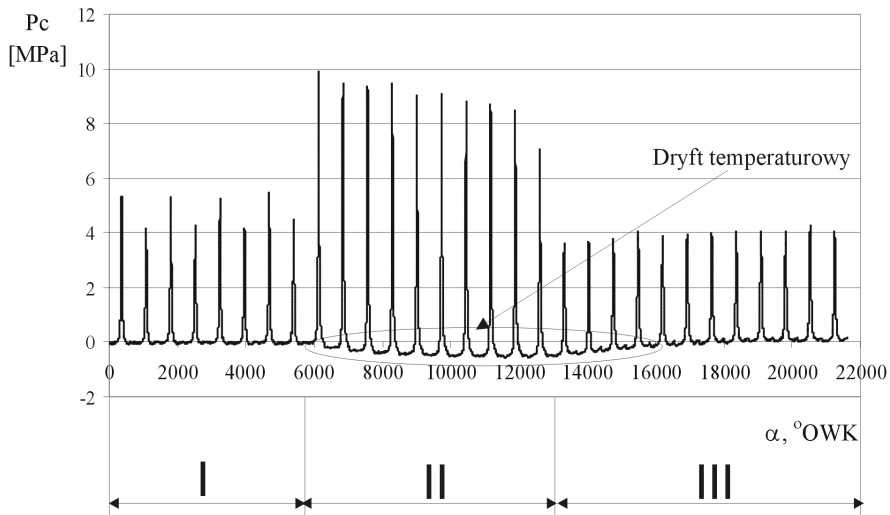
żenie listwy sterującej dawką paliwa $h \cong \text{const}$, przyspieszenie kątowe wału korbowego silnika $\varepsilon = 0$;

- 2) okres pracy w warunkach swobodnego rozpędzania – $n \neq \text{const}$, nieustalony stan cieplny silnika, $h = h_{\text{max}}$, $\varepsilon \neq 0$;
- 3) okres pracy na biegu luzem – $n = n_{\text{max}}$, quasi-ustalony stan cieplny silnika, $h \cong \text{const}$, $\varepsilon = 0$.

Tabela 1

Własności fizykochemiczne badanych paliw [8]

Paliwo	Napięcie powierzchniowe [mN/m]	Liczba cetanowa [-]	Gęstość [g/cm ³]	Wartość opałowa [MJ/kg]	Lepkość kinematyczna [mm ² /s]
ON	25,9	52,7	0,839	42,8	2,79
EETB10	24,6	46	0,831	42,1	2,24
EETB20	23,3	42,7	0,821	41,1	1,79
EETB30	22,1	38,4	0,814	40,8	1,47
EETB40	21,2	31,4	0,804	40,0	1,21




Rys. 2. Wartości ciśnienia w komorze spalania dla 30 kolejnych cykli pracy silnika w warunkach swobodnego rozpędzania – przebieg pierwotny bez żadnej obróbki numerycznej

Fig. 2. Values of the pressure in the combustion chamber for 30 next cycles of work of the engine in conditions of free speeding up – original course without no numeric treatment

Uzyskane przebiegi ciśnienia w komorze spalania posłużyły do obliczenia wartości średniego ciśnienia indykowanego. Dane te wykorzystano jako zbiór uczący w metodzie sieci neuronowych.

3. Model regresyjny sieci neuronowych

W wyniku przeprowadzonych obliczeń uzyskano model sieci neuronowej typu MLP (Multilayer Perceptrons), którego schematyczny widok przedstawiono na rys. 3.



Rys. 3. Schemat modelu sieci neuronowych

Fig. 3. Diagram of the neural networks

Perceptron wielowarstwowy (MLP) to najczęściej wykorzystywana architektura sieci neuronowej [11–13]. Każdy neuron oblicza tu ważoną średnią z doprowadzonych do niego wejść, a wynik przelicza za pomocą funkcji przejścia i przekazuje na wyjście. W każdej warstwie neuronów sieci MLP jest też składnik przesunięcia. Jest to dodatkowy neuron, który na wyjściu zawsze ma wartość 1. Wartość ta oddziałuje na wszystkie neurony następnej warstwy ważoną wagą, która bywa nazywana progim. Neurony, łącznie z neuronem przesunięcia, zorganizowane są w topologię jednokierunkowych warstw. Sieć MLP ma więc prostą interpretację modelu z wejściem, wyjściem, szeregiem wag i progów jako parametrów dostosowywanych dla osiągnięcia generalizujących własności modelu [13]. Taka sieć, z odpowiednią liczbą warstw i neuronów w warstwach, może modelować zależność o niemal dowolnej złożoności. Dobór właściwej liczby warstw ukrytych i liczby występujących w nich neuronów jest w przypadku perceptronu najistotniejsza. Nie bez znaczenia jest też wybór funkcji aktywacji i metody uczenia sieci.

Opracowany model posiada strukturę złożoną z siedmiu neuronów w warstwie wejściowej, trzech neuronów w warstwie ukrytej i jednego neuronu w warstwie wyjściowej (sieć MLP 7-3-1). Jako funkcję aktywacji w warstwie ukrytej przyjęto funkcję typu logistycznego. Jako funkcję aktywacji w warstwie wyjściowej przyjęto funkcję typu tangens hiperboliczny [13]. Uzyskano jakość uczenia na poziomie 0,948. Jakość testowania wynosiła 0,971, a jakość walidacji 0,898. Błąd uczenia wynosił 0,000082, a błąd testowania i walidacji odpowiednio 0,000108 i 0,000115. Zastosowano algorytm uczenia o oznaczeniu BFG S 86 [13].

4. Analiza odpowiedzi modelu sieci neuronowej

Na rysunkach 4 i 5 pokazano powierzchnię odpowiedzi dla opracowanego modelu sieci neuronowej MLP 7-3-1. Na rys. 4 zobrazowano wpływ kąta dynamicznego początku tłoczenia paliwa i prędkości obrotowej wału korbowego silnika na uzyskiwane wartości średniego ciśnienia indykowanego w warunkach swobodnego rozpędzania. Wnioskowanie na podstawie modelu oparte było o obserwacje pochodzące z zastosowania wszystkich paliw, których własności fizykochemiczne zawarto w 2. rozdziale pracy. Analiza powyższej powierzchni odpowiedzi wskazuje, że:

- dla początkowych cykli procesu swobodnego rozpędzania (małe wartości prędkości obrotowej) większe wartości średniego ciśnienia indykowanego uzyskiwano dla mniejszych kątów dynamicznego początku tłoczenia paliwa,
- największe wartości średnich ciśnień indykowanych uzyskiwano dla dużych kątów dynamicznego początku tłoczenia paliwa i dla dużych wartości prędkości obrotowych silnika,
- dla małych kątów dynamicznego początku tłoczenia paliwa i dużych prędkości obrotowych wartości średniego ciśnienia indykowanego gwałtownie malały.

Powyższe obserwacje są zgodne z ogólną teorią w obszarze silników spalinowych [6–8]. Wzrost kąta dynamicznego początku tłoczenia paliwa (oczywiście w pewnym zakresie) będzie powodował wzrost prędkości narastania ciśnienia (zjawisko, które może być niekorzystne), ale również wzrost maksymalnej wartości ciśnienia spalania. W efekcie może wystąpić nieznaczny wzrost średnich ciśnień indykowanych. Zbyt późny wtrysk paliwa przy dużych wartościach prędkości obrotowej silnika może powodować zbyt późny samozapłon w procesie spalania i dalszy wtrysk paliwa będzie przedłużał się na suw rozprężania co wpłynie na zmniejszenie średnich ciśnień indykowanych.


Na rys. 5 zobrazowano wpływ zawartości EETB w mieszaninie objętościowej z ON i prędkości obrotowej wału korbowego silnika na uzyskiwane wartości średniego ciśnienia indykowanego w warunkach swobodnego rozpędzania. Wnioskowanie na podstawie modelu oparte było o obserwacje pochodzące z pomiarów dla wszystkich ustawień kąta dynamicznego początku tłoczenia paliwa. Analiza wartości powyższej powierzchni odpowiedzi wskazuje, że wzrost zawartości EETB w mieszaninie z ON wpływa na zmniejszenie wartości średnich ciśnień indykowanych uzyskiwanych w warunkach swobodnego rozpędzania. Słuszność powyższego wniosku potwierdza choćby pobieżna analiza własności fizykochemicznych badanych paliw (tabela 1). Wynika z niej, że wraz ze wzrostem zawartości EETB w mieszaninie z ON maleje wartość opałowa oraz gęstość i lepkość paliwa. Dwa z ostatnich parametrów oddziałują dodatkowo na zmniejszenie dawki wtrysku.

Najbardziej interesującą powierzchnię odpowiedzi zamieszczono na rys. 6. Obrazuje ona jak kąt dynamicznego początku tłoczenia paliwa i zawartość EETB w mieszaninie z ON wpływają na średnie ciśnienie indykowane w warunkach swobodnego rozpędzania wału korbowego silnika. Wnioskowanie na podstawie modelu oparte było o obserwacje pochodzące z pomiarów dla wszystkich z prędkości wału korbowego silnika. Analiza powyższej powierzchni pozwala na optymalizację doboru kąta dynamicznego początku tłoczenia paliwa i zawartości EETB w mieszaninie z ON w celu uzyskania maksymalnych wartości średniego ciśnienia indykowanego. Stwierdzono między innymi, że:

- dla zawartości do około 20% EETB w mieszaninie z ON, w zakresie kątów dynamicznego początku tłoczenia paliwa od 8° do 24° OWK (zakres zmienności kąta uwzględniony w modelu jest szerszy od zakresu wynikającego z badań empirycznych) uzyskiwano naj-


większe wartości średniego ciśnienia indykowanego dla warunków swobodnego rozpełnienia silnika,

- porównywalnie wysokie wartości średniego ciśnienia indykowanego uzyskiwano dla zawartości ETTB w mieszaninie z ON w zakresie od około 30% do 45%, ale dla kątów dynamicznego początku tłoczenia paliwa w zakresie zmienności od około 20° do 24°OWK,
- najmniejsze wartości średniego ciśnienia indykowanego uzyskiwano dla dużych zawartości ETTB w mieszaninie z ON i dla małych kątów dynamicznego początku tłoczenia paliwa (rys. 6).




Rys. 4. Powierzchnia odpowiedzi dla modelu sieci neuronowej – $p_i = f(a_{dp}, n)$

Fig. 4. The surface of answer of neural network for model – $p_i = f(a_{dp}, n)$



Rys. 5. Powierzchnia odpowiedzi dla modelu sieci neuronowej – $p_i = f(\text{paliwo}, n)$


Fig. 5. The surface of answer of neural network for model – $p_i = f(\text{fuel}, n)$



Rys. 6. Powierzchnia odpowiedzi dla modelu sieci neuronowej – $p_i = f(\text{paliwo}, a_{dpt})$

Fig. 6. The surface of answer of neural network for model – $p_i = f(\text{fuel}, a_{dpt})$

Ponadto na rys. 7 zobrazowano wzajemną zależność pomiędzy obserwowanymi wartościami średniego ciśnienia indykowanego a różnicami pomiędzy tymi wartościami średniego ciśnienia indykowanego uzyskanymi w wyniku obliczeń z wykorzystaniem modelu – tzw. resztami [13]. Wartości tak obliczonych reszt nie przekraczały 0,038 MPa. Jednocześnie reszty zbliżone do zera występowały dla największej liczby obserwacji w zakresie dużych wartości średniego ciśnienia indykowanego tj. w obszarze najbardziej interesującym dla analizy pracy silnika w warunkach rozpędzania.



Rys. 7. Różnice (reszty) pomiędzy wartościami średniego ciśnienia indykowanego uzyskanymi z modelu a obserwowanymi wartościami średniego ciśnienia indykowanego

Fig. 7. The differences (the rest) among values of mean indicated pressure from model and the observed values of mean indicated pressure

5. Wnioski

Złożone zjawiska zachodzące w obrębie procesów roboczych silnika nie zawsze pozwalają na budowę opisujących je modeli fizycznych. Podejmuje się wówczas próbę identyfikacji modelu fizycznego na podstawie obserwacji pochodzących z badań empirycznych. W celu wykonania ww. identyfikacji posługiwano się dotychczas metodami aproksymacji danych empirycznych za pomocą określonych funkcji matematycznych lub wykorzystywano analizę harmoniczną (w odniesieniu do zjawisk zmiennych w czasie) [3]. W ostatnim okresie wykorzystuje się nowe techniki identyfikacji modeli na podstawie badań empirycznych. Można do nich zaliczyć dla przykładu dyskretną lub ciągłą analizę falkową [1, 4] czy też wykorzystywaną w niniejszym artykule metodę sieci neuronowych [2]. Metoda sieci neuronowych opiera się o teorię sztucznej inteligencji, a jej zaletą w stosunku do wymienionych powyżej metod jest możliwość „uczenia się”, co ma szczególne znaczenie w odniesieniu do procesów sterowania, czy też diagnostyki.

W artykule pokazano zastosowanie modelu regresyjnego sieci neuronowych do identyfikacji modelu wpływu kąta dynamicznego początku tłoczenia paliwa i zawartości EETB w mieszaninie z ON na uzyskiwane wartości średniego ciśnienia indykowanego. Uzyskano sieć neuronową MLP 7-3-1 opartą o teorię perceptronu wielowarstwowego. Zobrazowano działanie modelu sieci neuronowej za pomocą powierzchni odpowiedzi. Oszacowano błędy wykonanych obliczeń. Uzyskano interesujące spostrzeżenia w zakresie możliwości stosowania EETB jako dodatku do oleju napędowego dla silników o zapłonie samoczynnym. Na uwagę zasługuje fakt, że złożony charakter wpływu stosowanych mieszanin zamodelowano za pomocą wejścia jakościowego, które opisano jako zawartość objętościową EETB w mieszaninie z ON. Wnioski wynikające z działania modelu wydają się znajdować potwierdzenie w ogólnej teorii działania silników spalinowych [6–8].

Literatura

- [1] Bogus P., Merkiś J., *Misfire detection of locomotive diesel engine by non-linear analysis*. Mech. Syst. Signal. Proc. 19, 2005, 881-889.
- [2] Brace C. J., Deacon M., Vaughan N.D., *Prediction of emissions from turbocharged passenger car diesel engine using a neural network*, Scholl of Mechanical Engineering, University of Bath, 2001.
- [3] Chłopek Z., *Modelowanie procesów emisji spalin w warunkach eksploatacji trakcyjnej silników spalinowych*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1999.
- [4] Daw C.S., Finney C.E.A., Kennel M. B., Coccelly F.T., *Observing and modelling nonlinear dynamics in an inetrnal combustion engines*, Phys. Rev., E, 57, 1998, 2811-2819.
- [5] Kacprzak T., Ślot K., *Sieci neuronowe komórkowe*, PWN, Warszawa–Łódź 1995.
- [6] Longwic R., *Analiza procesu ciśnienia indykowanego silnika o zapłonie samoczynnym w warunkach nieustalonych*, Monografia, Wydawnictwo Politechniki Lubelskiej, Lublin 2005.

- [7] Lotko W., Górski K., *Zasilanie silnika wysokoprężnego mieszaninami ON i EETB*, WNT, Warszawa 2011.
- [8] Lotko W., Górski K., Longwic R., *Nieustalone stany pracy silnika wysokoprężnego zasilanego olejem napędowym z eterem etylo-tert-butylowym*, Monografia, WKiŁ, Warszawa 2010.
- [9] Mamala J., Jantos J., *Weryfikacja algorytmów sterowania samochodowym układem napędowym z wykorzystaniem sieci neuronowych*, Teka Komisji Naukowo-Problekowej PAN, Kraków 2005.
- [10] Menezes E.W., Silva R., Cataluña R., Ortega R.J.C., *Effect of ethers and ether/ethanol additives on the physicochemical properties of diesel fuel and on engine tests*, FUEL 85, 2006, 815-822.
- [11] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [12] Rutkowska D., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa–Łódź 1997.
- [13] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
- [14] Li T., Suzuki M., Ogawa H., *Effects of ethyl tert-butyl ether addition to diesel fuel on characteristics of combustion and exhaust emissions of diesel engines*, FUEL 88(10), 2009, 2017-2024.