

## NEURAL MODELLING OF THE VEHICLE POWERTRAIN

**Jerzy Jantos, Jarosław Mamala, Adam Danielczok**

Politechnika Opolska  
45-271 Opole, ul. Mikołajczyka 5  
tel. +48 77 4006272, fax. +48 77 4006342  
e-mail: jantos@po.opole.pl

### Abstract

*In the proposed method of powertrain work quality valuation, the technique of artificial neural networks was applied. With such a network the work of the whole system with powertrain, vehicle, driver and environment was modelled. Original in this method is the application of neural network to inversion model, which make possible the investigations by determined vehicle speed profile. It was shown that the neural network, trained on the base of measurements results, carried out in the test vehicle while normal traffic, not only good represents actual relationships but also makes possible prediction of selected work indexes at an arbitrary vehicle speed profile. The results proved that the proposed method can be useful especially to qualifying of automatic powertrain control algorithms in passenger car.*

*Keywords: powertrain, neural network, control algorithms*

## NEURONOWE MODELOWANIE SAMOCHODOWEGO UKŁADU NAPĘDOWEGO

### Streszczenie

*W proponowanej metodzie oceny jakości działania samochodowego układu napędowego wykorzystano technikę sztucznych sieci neuronowych. Za pomocą takiej sieci modelowano pracę całego systemu obejmującego układ napędowy, pojazd, kierującego nim człowieka oraz otoczenie. Oryginalną cechą proponowanej metody jest zastosowanie sieci neuronowej do odwzorowania odwrotnego, co umożliwia badania przy założonym profilu prędkości samochodu. Wykazano, że sieć neuronowa, wytrenowana w oparciu o wyniki pomiarów przeprowadzonych w samochodzie badawczym, podczas normalnego ruchu drogowego, nie tylko dobrze odwzoruje rzeczywiste zależności ale umożliwia także predykcję wybranych wskaźników pracy przy dowolnym profilu prędkości. Uzyskane wyniki dowodzą przydatności metody głównie do wartościowania algorytmów automatycznego sterowania samochodowym układem napędowym.*

*Słowa kluczowe: układ napędowy, sieć neuronowa, algorytmy sterowania*


### 1. Wprowadzenie

Układ napędowy wywiera decydujący wpływ na własności ruchowe samochodu, zużycie paliwa oraz emisję substancji szkodliwych. Proces doskonalenia układu napędowego jest ściśle powiązany z oceną jakości jego działania. Przy ocenie energetycznego i ekologicznego aspektu działania układu napędowego najczęściej wykorzystuje się procedury badawcze określone wymogami homologacyjnymi. Ze względu na wymaganą powtarzalność i jednoznaczność, badania homologacyjne są przeprowadzane na hamowni podwoziowej, w ściśle określonych warunkach [5]. Uzyskiwane wyniki odnoszą się jednak wyłącznie do warunków pracy układu napędowego zdeterminowanych wspomnianymi procedurami stąd ich wartość porównawcza jest ograniczona. Jest to istotna niedogodność, gdyż rzeczywiste warunki pracy układu napędowego znacznie odbiegają od zastępczych, wynikających z tzw. cykli jezdnych. Z tego powodu jest celowe opracowanie procedury umożliwiającej obiektywną ocenę samo-

chodowego układu napędowego pracującego w warunkach rzeczywistych. Problem nabiera szczególnego znaczenia w przypadku zautomatyzowanych układów napędowych, wymagających weryfikacji algorytmu sterowania. W tym opracowaniu zaproponowano taką metodą opartą na *sztucznej sieci neuronowej* [2].

## 2. Założenia metody

Proponowana metoda opiera się na założeniu, że jest możliwe neuronowe tj. za pomocą *sztucznej sieci neuronowej*, modelowanie samochodowego układu napędowego. Założenie to wynika z charakterystycznych właściwości sieci neuronowej a w szczególności możliwości odwzorowania silnie nieliniowych, wielowymiarowych zależności oraz zdolności do uczenia się. W literaturze jest wiele przykładów wykorzystania sztucznych sieci neuronowych [1, 2, 6]. Jednak proponowane rozwiązanie wyróżnia się sposobem ujęcia rozpatrywanych zależności. W odróżnieniu od typowych zastosowań, w których modelowane są zależności proste, w tym przypadku wykorzystano sieć neuronową do modelowania zależności odwrotnej. Jako wielkości wejściowe do sieci przyjęto, bowiem profil prędkości liniowej i przyspieszenia wzdłużnego samochodu (rys.1), które w układzie rzeczywistym są podstawowymi wielkościami wyjściowymi.

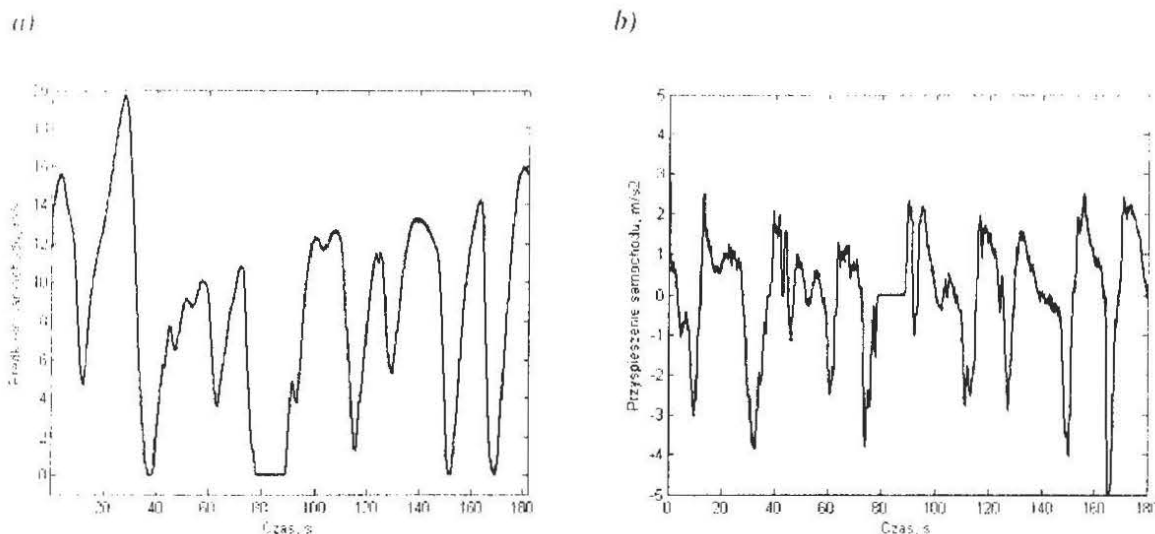


Rys. 1. Struktura wykorzystanej sieci neuronowej typu *Feed-forward back propagation*  
 Fig. 1. Structure of used *Feed-forward back propagation* neural network

Takie odwrócenie zadania modelowania umożliwia jednak badania układu napędowego przy dowolnych profilach prędkości, w tym również zdeterminowanych cyklami jezdny, co jak wykazano dalej ma kluczowe znaczenie w proponowanej metodzie. Za wielkości wyjściowe przyjęto natomiast takie wskaźniki jak: uchylenie przepustnicy w silniku, prędkość obrotowa silnika, strumień zużywanego paliwa, stężenie substancji szkodliwych w spalinach.

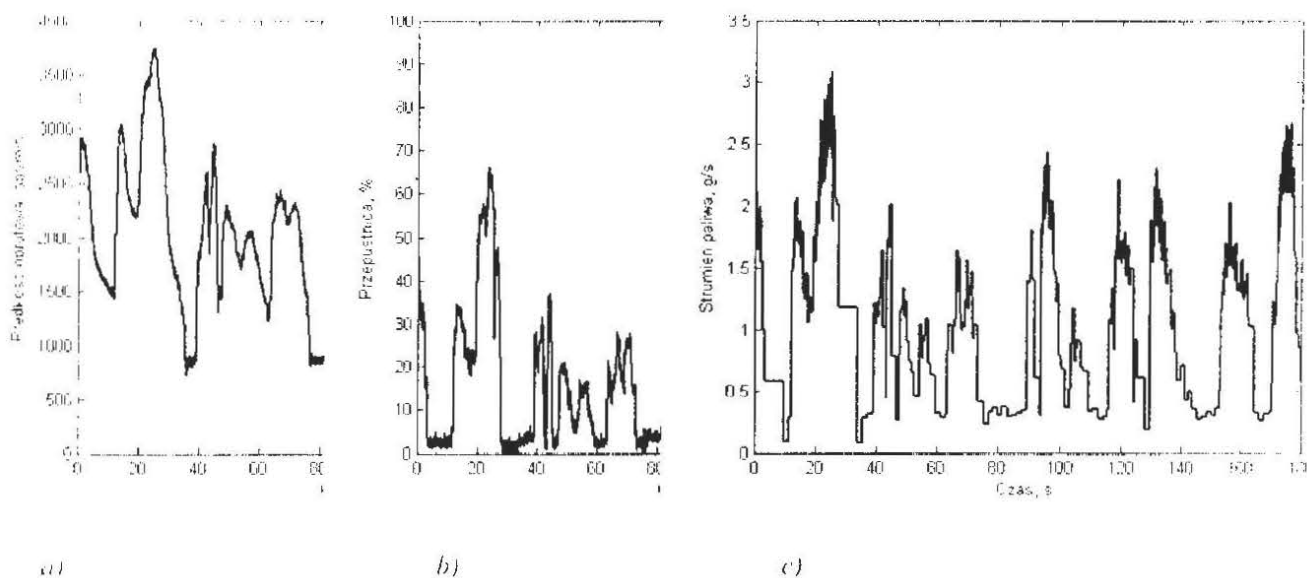
## 3. Sposób prowadzenia badań

Zgodnie z przyjętymi założeniami zaprojektowana sieć neuronowa powinna modelować działanie samochodowego układu napędowego. Jednak podstawowym warunkiem poprawnego odwzorowania jest odpowiedni dobór parametrów sieci, co można osiągnąć w procesie jej uczenia. Do treningu sieci wykorzystano wyniki pomiarów zarejestrowane podczas badań własnych przeprowadzonych podczas ruchu drogowego samochodu doświadczalnego. W tym charakterze wykorzystano samochód *Fiat Punto II Speer Gear*, wyposażony w automatyczny układ napędowy na bazie mechanicznej przekładni bezstopniowej [3, 4]. Przykładowe przebiegi wielkości traktowanych jako wejściowe dla sieci przedstawiono na rysunku 2.



Rys. 2. Przykładowe profile wielkości wejściowych do sieci: a) prędkość samochodu, b) przyspieszenie wzdłużne  
 Fig. 2. Exemplary profiles of net inputs: a) vehicle speed, b) longitudinal acceleration

Przykładowe profile wielkości przyjętych za wyjściowe przedstawiono na rysunku 3.



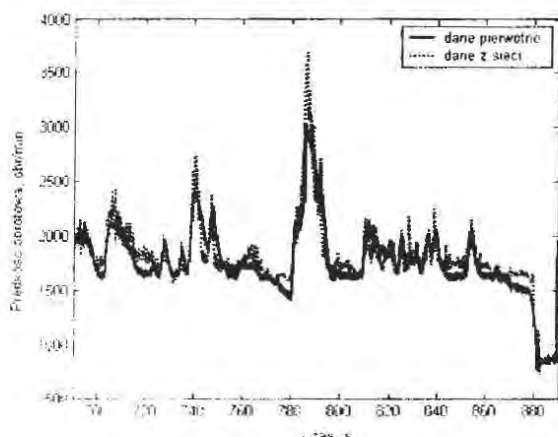
Rys. 3. Przykładowe profile wielkości wyjściowych z sieci:  
 a) prędkość obrotowa silnika, b) uchylenie przepustnicy, c) strumień zużywanego paliwa  
 Fig. 3. Exemplary profiles of net outputs: a) engine speed, b) throttle, c) fuel stream

#### 4. Trening i weryfikacja sieci neuronowej


Zaprojektowaną sieć neuronową trenowano przy wykorzystaniu danych uczących zebranych na kilku krótkich odcinkach pomiarowych. Na każdym z odcinków pomiarowych korzystano tylko z jednego algorytmu sterowania układem napędowym a trening jednej sieci przeprowadzono na danych z wielu pomiarów wykonanych przy tym samym algorytmie. Dla oceny jakości odwzorowania, realizowanego przez wytrenowaną sieć neuronową, porównano rzeczywiste, zarejestrowane przebiegi z przebiegami wielkości wyjściowych sieci neuronowej uzyskanymi przez podanie na wejście sieci zarejestrowanych sygnałów wejściowych (rys.4). Ilościowe porównanie umożliwia tabela 1, w której zestawiono sumaryczną objętość rzeczy-

wicie zużytego paliwa z objętością paliwa określoną przez całkowanie sygnału strumienia paliwa otrzymanego na wyjściu wytrenowanej sieci neuronowej.

a)



b)



Rys. 4. Porównanie przebiegów rzeczywistych z wielkościami wyjściowymi sieci neuronowej:

a) prędkość obrotowa silnika, b) strumień zużywanego paliwa


Fig. 4. Comparison of actual profiles with net outputs: a) engine speed, b) fuel stream

Symbolem A oznaczono wyniki dla całego zbioru uczącego, wykorzystanego do trenin- gu sieci, symbolem B i C oznaczono wyniki uzyskane dla podzbiorów zbioru uczącego A, natomiast symbol D odnosi się do wyników uzyskanych na odcinku pomiarowym nie wyko- rzystanym do treningu sieci.

Tabela 1. Porównanie sumarycznego zużycia paliwa  
Table 1. Comparison of global fuel consumption

Próba	A	B	C	D
Wynik pomiaru, $10^{-6} \text{ m}^3$	1464,25	240,21	114,37	274,38
Wynik obliczeń, $10^{-6} \text{ m}^3$	1463,67	226,04	118,21	249,09
Błąd względny %	0,4	5,89	3,85	9,2

Względny błąd odwzorowania zilustrowano na rysunku 5. Jak widać, błąd odwzorowania jest większy w przypadku krótkich odcinków pomiarowych. Z rysunku tego wynika także, że wytrenowana sieć neuronowa umożliwia także badania symulacyjne dla dowolnych profili prędkości, również tych, które nie są podzbiorami zbioru uczącego, a uzyskane wyniki obar- czone są błędem nie przekraczającym 10% nawet w przypadku krótkiego odcinka pomiaro- wego.



Rys. 5. Względny błąd obliczeń zużycia paliwa przy wykorzystaniu sieci neuronowej

Fig. 5. Relative error of fuel consumption calculation with use of neural network


## 5. Trening i weryfikacja sieci neuronowej

Z wcześniejszych rozważań wynika, że wytrenowana sieć neuronowa dobrze odwzoruje działanie układu napędowego. Tym samym można ją wykorzystać do predykcji wybranych




wskaźników pracy przy dowolnych, również standardowych profilach prędkości. Na rysunku 6 przedstawiono wyniki symulacji dla kilku typowych profili prędkości z wykorzystaniem sieci neuronowych wytrenowanych dla różnych algorytmów sterowania układem napędowym oznaczonych odpowiednio symbolami D, DE, L oraz S.

a)



b)

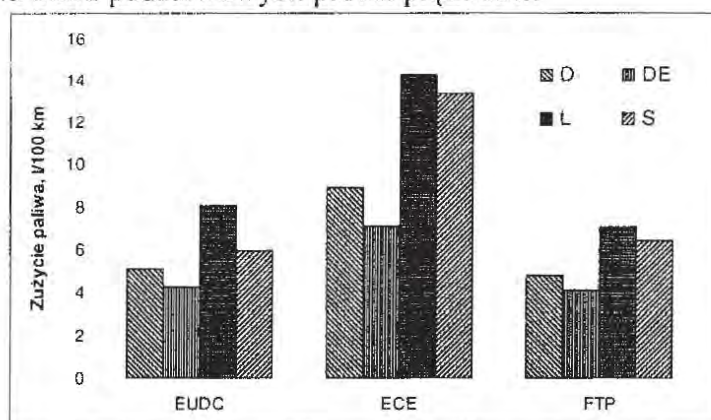


Rys. 6. Wyniki symulacji przy wykorzystaniu wytrenowanych sieci neuronowych dla profilu EUDC:

a) prędkość obrotowa silnika, b) strumień zużywanego paliwa

Fig. 6. Simulation results with trained neural networks for EUDC profile: a) engine speed, b) fuel stream

Natomiast na rys. 7 zestawiono przebiegowe zużycie paliwa, wyznaczone w oparciu o wyniki symulacji dla kilku podstawowych profili prędkości.



Rys. 7. Zużycie paliwa dla standardowych profili prędkości wyznaczone metodą symulacji przy różnych algorytmach sterowania układem napędowym

Fig. 7. Fuel consumption in the standard velocity profiles determined with simulation method for different control algorithms

## 6. Podsumowanie

W pracy dowiedziono, że odpowiednio dobrana sztuczna sieć neuronowa dobrze odwzoruje silnie nieliniowe, wielowymiarowe zależności wynikające z działania samochodowego układu napędowego. Sieć neuronowa wytrenowana na zbiorze danych pomiarowych zebranych przy określonym algorytmie sterowania dobrze symuluje jego charakterystyczne właściwości. Tym samym możliwe jest określenie wybranych wskaźników pracy dla dowolnego profilu prędkości również syntetycznego. Istotną zaletą proponowanej metody jest to, że wiedza nabyta przez sieć neuronową wynika z rzeczywistych a nie zastępczych warunków pracy a wybrane wskaźniki pracy można w sposób powtarzalny określić nie dysponując hamownią podwoziową. Zalety te sprawiają, że proponowana metoda jest szczególnie przydatna do oceny algorytmów automatycznego sterowania układem napędowym samochodu osobowego.

## Podziękowanie

Praca naukowa finansowana ze środków Komitetu Badań Naukowych w latach 2003 – 2006 jako projekt badawczy.

## Literatura

- [1] Brace C.J., Deacon M., Vaughan N.D.: *Prediction of emissions from turbocharged passenger car diesel engine using a neural network*, School of Mechanical Engineering, University of Bath 2001
- [2] Howlett R., Zoysa M., Walters S., Howson P.: *Neural network techniques for monitoring and control of internal combustion engines*, Genova, Italy 1999
- [3] Jantos J., Korniak J., Mąmala J., Siłka W.: *Driveability and fuel consumption improvement through integrated fuzzy logic control of powertrain with spark ignition engine and continuously variable transmission*, FISITA World Automotive Congress, Barcelona 2004, nr F2004F414
- [4] Jantos J.: *Zintegrowane sterowanie samochodowym, spalinowym układem napędowym o przełożeniu zmiennym w sposób ciągły*, studia i monografie, z. 141, Oficyna Wydawnicza Politechniki Opolskiej, Opole 2003
- [5] Taylor C.F.: *The internal combustion engine theory and practice*, M.I.T. Press, Cambridge 2001
- [6] Traver M., Atkinson R.,J., Atkinson C.,M.: *Neural Network based diesel engine emissions prediction using in-cylinder combustion pressure*, West Virginia University, 1999