

## EXPLOITATION CHARACTERISTICS OF AN ENGINE CAR

**Jarosław Mamala, Jerzy Jantos**

*Politechnika Opolska*

*ul. Mikołajczyka 5*

*45 – 271 Opole*

*tel.: +48 77 4006272*

*fax: +48 77 4006272*

*e-mail: mamala@po.opole.pl*

### **Abstract**

*The authors of the paper prove the ability of artificial neural network to determination of spark ignition engine power map not only on the stand investigations basis but also with use of measurement results. It is shown that the artificial neural network trained on the basis of road measurement represents, better real relationships. On the job one proved that properly projected and trained artificial neural network well would copy strongly non-linear, multidimensional consequential dependences from the activity of the car driving powertrain. Proposed method can be especially useful to estimation of the impact of algorithms of the steering with the powertrain system of the passenger car.*

## CHARAKTERYSTYKI EKSPLOATACYJNE SILNIKA SAMOCHODOWEGO

### **Streszczenie**

*Autorzy referatu dowodzą możliwości wykorzystania sztucznych sieci neuronowych do określenia charakterystyki mocy silnika o zapłonie iskrowym nie tylko w oparciu o wyniki badań stanowiskowych, ale również na podstawie wyników pomiarów zrealizowanych w rzeczywistych warunkach ruchu. Wykazano, że sieć neuronowa wytrenowana w oparciu o wyniki pomiarów uzyskanych, podczas normalnego ruchu drogowego, lepiej odwzoruje rzeczywiste zależności w układzie napędowym. W pracy dowiedziono, że odpowiednio zaprojektowana i wytrenowana sztuczna sieć neuronowa dobrze odwzoruje silnie nieliniowe, wielowymiarowe zależności wynikające z działania samochodowego układu napędowego. Proponowana metoda może być szczególnie przydatna do oceny działania algorytmów sterowania układem napędowym samochodu osobowego.*

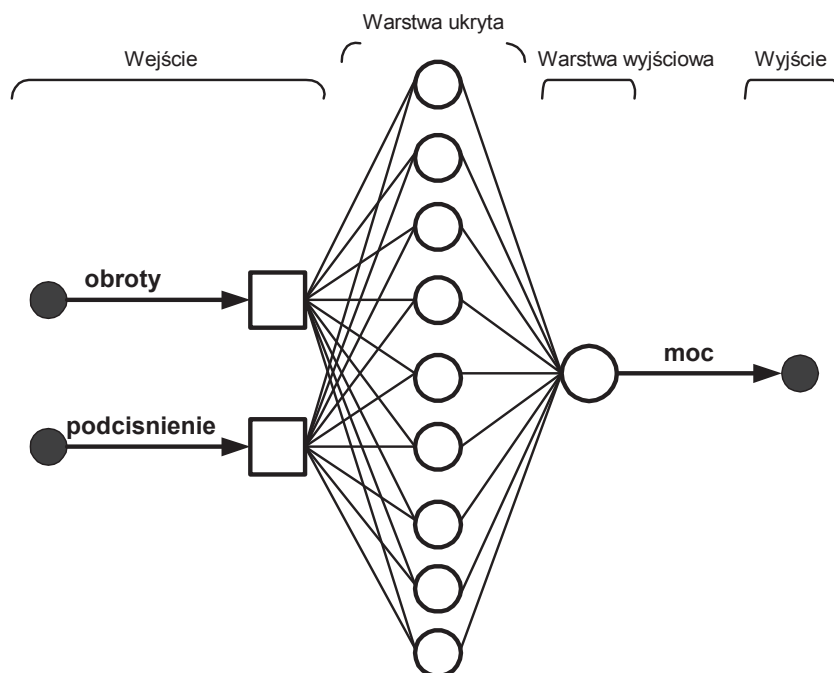
### **1. Wprowadzenie**

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 działania jego podzespołów, w skład którego wchodzi silnik i skrzynia biegów [6]. Konieczne jest zatem prowadzenie stosownych badań. Poszukiwanie optymalnej konfiguracji układu napędowego samochodu osobowego wiąże się koniecznością testowania wielu wariantów. Sprawdzone i skuteczną metodą rozwiązywania tego typu problemów są badania realizowane techniką symulacji cyfrowej. Jednak opis systemu energetycznego układu napędowego w postaci równań analitycznych jest utrudniony. Zasadniczym powodem tych trudności jest wieloetapowość procesu przetwarzania energii zachodzącego w silniku, charakteryzującego się m.in. cyklicznością, niestacjonarnością i silną nieliniowością oraz zjawiskami akumulacji. Z tego względu, w badaniach własności trakcyjnych układu napędowego zakłada się uproszczenia polegające na opisie silnika za pomocą odpowiednich charakterystyk statycznych zapisanych w pamięci układu. Najczęściej są to charakterystyki mocy, momentu obrotowego silnika oraz czasowego zużycia paliwa wyrażone jako funkcje prędkości obrotowej i podciśnienia w kolektorze dolotowym czy zamiennie uchylenia przepustnicy. Jednak udział stanów przejściowych w pracy

samochodowego silnika ZI jest na tyle znaczący, że wspomniane wyżej uproszczenia skutkują błędami obliczeniowymi. Znane są liczne prace określające dokładność odwzorowania parametrów silnika za pomocą charakterystyk statycznych [4, 7]. W tym opracowaniu zaproponowano własną metodę opartą na sztucznej sieci neuronowej [1, 2, 3, 5, 8, 10], którą wykorzystano do odwzorowania charakterystyki silnika. W celu uwzględnienia rzeczywistych warunków eksploatacji wykorzystano sztuczne sieci neuronowe do odwzorowania charakterystyki eksploatacyjnej silnika otrzymanej na podstawie wyników badań drogowych. Jak znaczący jest wpływ jakości odwzorowania charakterystyki silnika na wynik obliczeń mocy w układzie napędowym to kolejny problem, który poruszono w tym opracowaniu.

## 2. Założenia metody

Znane są metody określania charakterystyk silnika z wykorzystaniem sztucznych sieci neuronowych (rys. 1).



Rys. 1. Struktura wykorzystanej sieci neuronowej 2 x 9 x 1 typu Feed-forward back propagation  
Fig. 1. Structure of used Feed-forward back propagation neural network 2 x 9 x 1

Jak wykazano w pracach [1, 2, 3, 5, 8, 10, 11, 12], można do tego celu wykorzystać sztuczne sieci neuronowe, które są trenowane bezpośrednio na wynikach pomiarów. Założenie to wynika z charakterystycznych właściwości sieci neuronowej a w szczególności możliwości odwzorowania silnie nieliniowych, wielowymiarowych zależności. W literaturze jest wiele przykładów wykorzystania sztucznych sieci neuronowych [1, 2, 6]. Jak wykazano w pracy [8] sieć neuronowa typu *radialbasis* nadają się dobrze do odwzorowania i aproksymacji charakterystyki silnika w warunkach ustalonych, jednak do silnie nieliniowych zależności, jakie zachodzą w warunkach rzeczywistej jazdy drogowej, lepiej nadają się sieci ze wsteczną propagacją błędów typu *feed-forward back propagation* opisaną w pracach [5, 10]. Ze względu na własności sztucznych sieci neuronowych dane wejściowe do sieci należy sprowadzić do wartości względnych. Wartość względną obliczono ze wzoru:

$$x_w = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

Jako wielkości wejściowe do sieci neuronowej przyjęto, prędkość obrotową silnika i podciśnienie w kolektorze dolotowym, które w układzie rzeczywistym są podstawowymi wielkościami charakteryzującymi stan pracy.

### 3. Charakterystyki silnika

Proponowane rozwiązanie z wykorzystaniem sztucznych sieci neuronowych wyróżnia się sposobem ujęcia rozpatrywanych zależności. W odróżnieniu od typowych zastosowań w tym przypadku wykorzystano sieć neuronową do modelowania charakterystyki silnika bezpośrednio z danych pomiarowych w tym również z badań drogowych.

#### 4. 3.1. Wyniki pomiarów statycznych

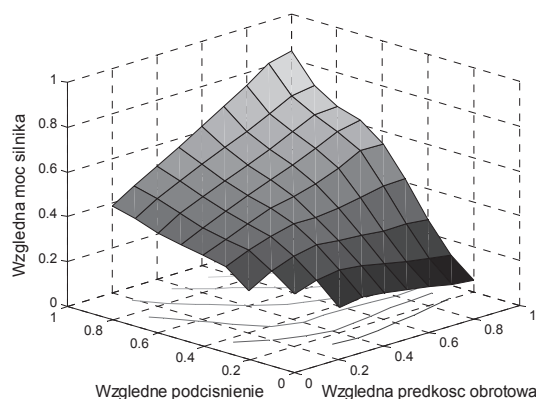
Podjęty w opracowaniu problem rozpatrzono na przykładzie charakterystyk silnika o zapłonie iskrowym (ZI), którego podstawowe parametry zestawiono w tabeli 1.

Tabela 1. Parametry techniczne silnika  
Table 1. The technical of engine parameters

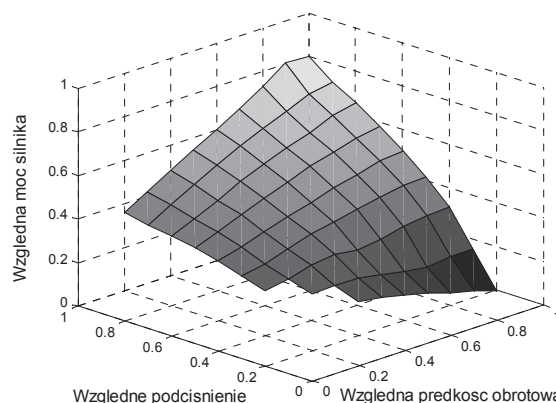
Nazwa	Parametr
Typ Silnika	CE
Pojemność skokowa w $\text{cm}^3$	1598
Moc maksymalna wg DIN w kW	59
Prędkość obrotowa mocy maksymalnej w obr/min	5200
Maksymalny moment obrotowy wg DIN w N·m	125
Prędkość obrotowa maksymalnego momentu w obr/min	3200

Pomiary przeprowadzono na stanowisku badawczym [9] określając charakterystyki prędkościowe dla 15 arbitralnie przyjętych wartości uchylenia przepustnicy.

a)



b)



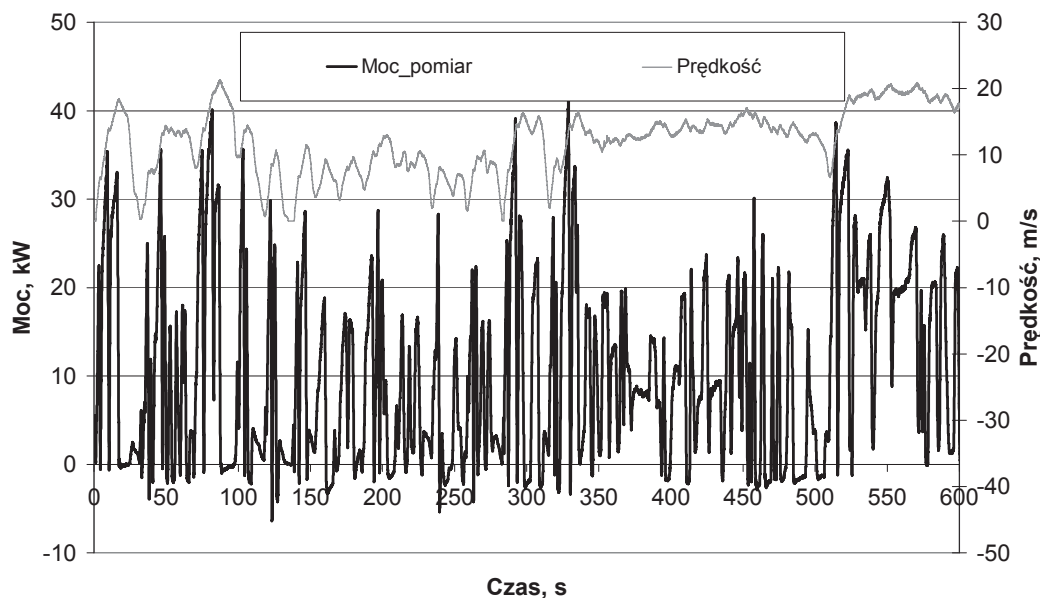
Rys. 2. Względna statyczna charakterystyka silnika odwzorowana za pomocą sieci neuronowej: a) sieć typu radialbasis b) sieć typu feed-forward back propagation

Fig. 2. Engine static relative map represented with artificial neural network: a) radial basis b) feed - forward back propagation

#### 5. 3.2. Wyniki pomiarów drogowych

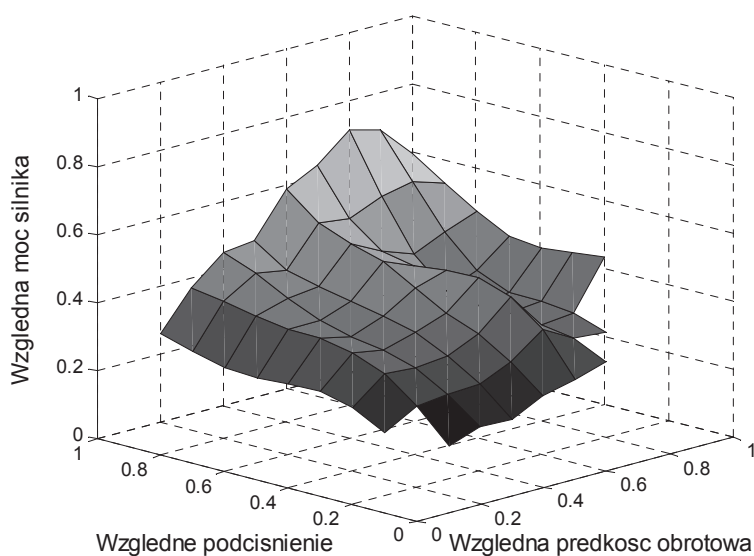
Cechą charakterystyczną samochodu poruszającego się w rzeczywistych warunkach ruchu są częste zmiany mocy doprowadzonej do kół. Analiza wyników rejestracji jazdy drogowej dowodzi, że zmiany żądanej mocy silnika są bardzo częste (rys. 3). Szczególnie w warunkach jazdy miejskiej gdzie częstotliwość, zakres i dynamika zmian jest bardzo duża. W rezultacie prędkość obrotowa silnika i podciśnienie w kolektorze dolotowym nie są stałe jak w

przypadku pomiarów wykonywanych podczas wyznaczania charakterystyki prędkościowej silnika w warunkach statycznych na hamowni silnikowej. Do treningu sieci wykorzystano wyniki pomiarów zarejestrowane podczas badań własnych przeprowadzonych podczas ruchu drogowego samochodu doświadczalnego na odcinku 7,5 km w czasie 11 min. Samochód doświadczalny był wyposażony w identyczny silnik jak podczas badań stanowiskowych oraz została wykorzystana identyczna aparatura pomiarowa, na którą składał się m.in. układ do pomiaru momentu obrotowego na wale napędowym [9].



Rys. 3. Przykładowy profil prędkości samochodu i mocy w układzie napędowym  
 Fig. 3. Exemplar vehicle speed and power profile

Poniżej (rys. 4) przedstawiono eksploatacyjną charakterystykę mocy silnika otrzymaną bezpośrednio z badań drogowych w rzeczywistych warunkach ruchu, wyznaczoną za pomocą sztucznej sieci neuronowej.

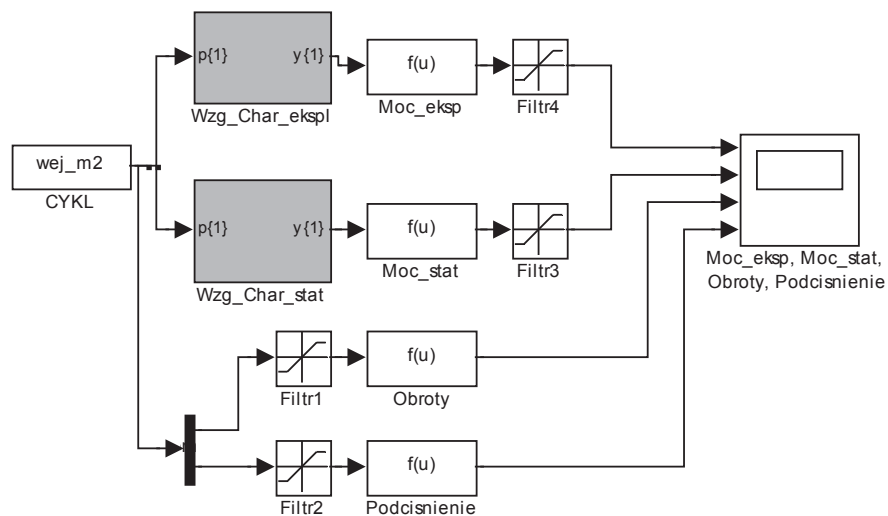


Rys. 4. Względna eksploatacyjna charakterystyka mocy silnika odwzorowana za pomocą sieci neuronowej  
 Fig. 4. Relative operating engine power map represented with artificial neural network

Określone za pomocą sztucznych sieci neuronowych charakterystyki silnika można jak wykazano w pracy [8] wykorzystać do obliczania parametrów wybranego punktu pracy silnika, w tym przypadku mocy w zależności od zadanej wartości prędkości obrotowej i podciśnienia w przewodzie dolotowym.

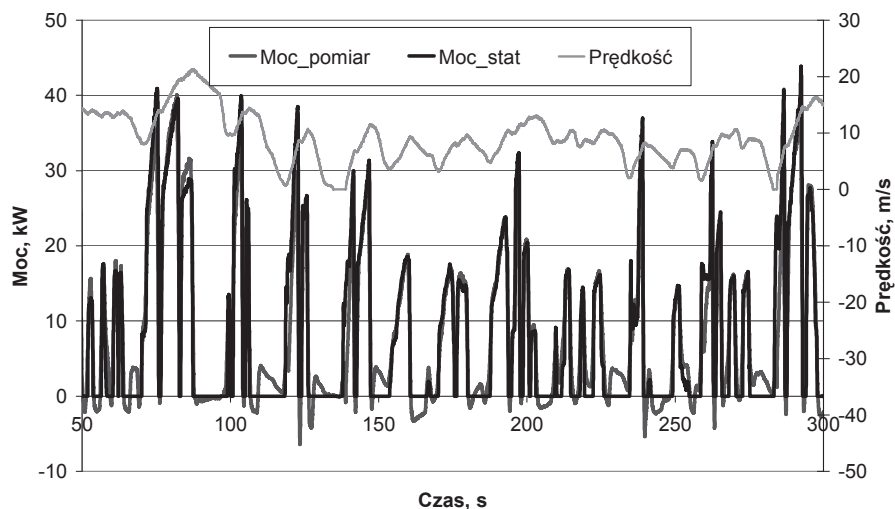
## 6. Badania symulacyjne

Zgodnie z przyjętymi założeniami, zaprojektowane sieci neuronowe odwzorujące charakterystyki mocy silnika, statyczną i eksploatacyjną poddano weryfikacji. W tym celu przeprowadzono badania symulacyjne. Do przeprowadzenia badań symulacyjnych wykorzystano nakładkę *Simulink* z pakietu *Matlab*. Schemat blokowy modelu utworzonego w *Simulinku* przedstawiono na rysunku 5.

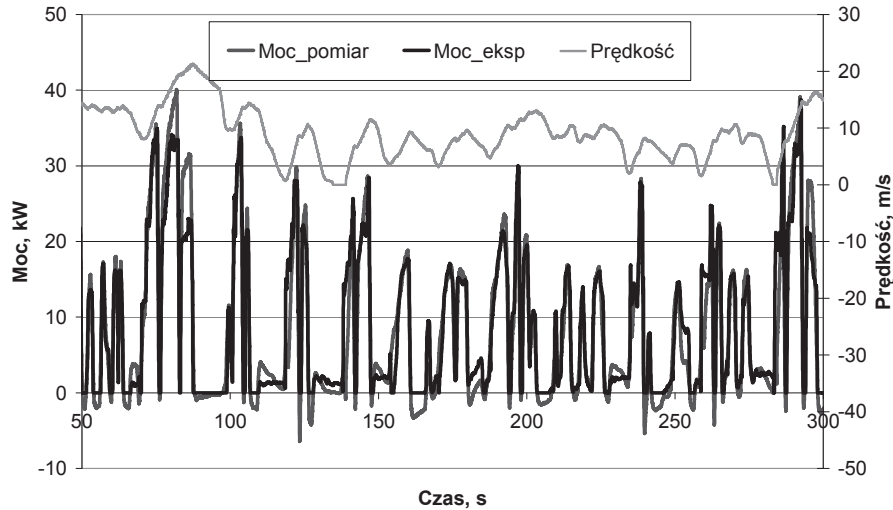


Rys. 5. Model wykorzystany do weryfikacji charakterystyk silnika  
Fig. 5. Model used to engine map verification

Wyniki symulacji przedstawiono na rysunkach 6 i 7, gdzie porównano moc silnika zarejestrowaną podczas badań drogowych do mocy silnika obliczonej z charakterystyki statycznej i eksploatacyjnej. Na rysunkach tych przedstawiono także profil prędkości samochodu. Określono także błąd względny odwzorowania, przyjmując jako wartość odniesienia moc zmierzoną podczas badań drogowych w rzeczywistych warunkach ruchu.



Rys. 6. Wyniki symulacji przy wykorzystaniu neuronowej charakterystyki statycznej silnika  
Fig. 6. Simulation results with use of engine static neutral map



Rys. 7. Wyniki symulacji przy wykorzystaniu neuronowej charakterystyki eksploatacyjnej silnika  
 Fig. 7. Simulation results with use of engine operating neutral map


Wartość błędu względnego przedstawionego, obliczono z zależności:

$$\Delta x = \frac{\sum_{i=1}^n |x_p - x_s|}{\sum_{i=1}^n x_p} \quad (2)$$

gdzie:

$x_p$  – wynik pomiaru mocy z badań drogowych,  
 $x_s$  – wynik symulacji modelu.

Jak widać (rys. 8), względny błąd jest zdecydowanie większy w przypadku odwzorowania profilu prędkości z użyciem charakterystyki statycznej.



Rys. 8. Względny błąd obliczeń mocy w układzie napędowym  
 Fig. 8. Relative computation error of engine power

Z rysunku tego wynika także, że wytrenowana sieć neuronowa umożliwia także badania symulacyjne dla dowolnych profili prędkości, a uzyskane wyniki obarczone są błędem nieprzekraczającym 10%.

## 7. Podsumowanie

W pracy dowiedziono, że odpowiednio zaprojektowana i wytrenowana sztuczna sieć neuronowa dobrze odwzoruje silnie nieliniowe, wielowymiarowe zależności wynikające z działania samochodowego układu napędowego. Sieć neuronowa wytrenowana na zbiorze danych pomiarowych zebranych w rzeczywistych warunkach ruchu umożliwia symulacyjne badania układu napędowego. 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 statycznych warunków pracy silnika a wybrane wskaźniki pracy można w sposób powtarzalny określić bez potrzeby prowadzenia kontrolnych badań stanowiskowych. Zalety te sprawiają, że proponowana metoda może być szczególnie przydatna do oceny działania algorytmów sterowania układem napędowym samochodu osobowego.

## 8. Podziękowanie

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

## 9. 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] He J., Rutland C., Application of artificial neural network for integration of advanced engine simulation methods, Peoria, 2000.
- [3] Howlett R., Zoysa M., Walters S., Howson P., Neural network techniques for monitoring and control of internal combustion engines, Genova, Italy, 1999.
- [4] Jantos J., Korniak J., Mamala 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, , F2004 F414, 2004.
- [5] Jantos J., Mamala J., Danielczok A., Neuronowe modelowanie samochodowego układu napędowego, Journal of Kones 2004, 30th International Scientific Conference on Internal Combustion Engines, Zakopane 2004.
- [6] 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.
- [7] Jantos J., Mamala J., Zużycie paliwa podczas ruchu samochodu ze zmienną prędkością, Konstrukcja, badania, eksploatacja, technologia pojazdów samochodowych i silników spalinowych, PAN oddział w Krakowie, Teka Komisji Naukowo-Problemovej Motoryzacji, Kraków 1999, z.18 str.121-126, 1999.
- [8] Mamala J., Jantos J., Odwzorowanie charakterystyk silnika za pomocą sztucznych sieci neuronowych, Zeszyt naukowy Politechniki Opolskiej, seria Mechanika, Opole 2005 (w druku), 2005.



- [9] Mamala J., Jantos J., Stanowisko dynamiczne do badań układu pojazd - silnik techniką symulacji stanowiskowej, VI Międzynarodowa Konferencja Naukowo - Techniczna AUTOPROGRES'98, Jachranka 1998, ss. 19-27, 1998.
- [10] Mamala J., Jantos J., Weryfikacja algorytmów sterowania samochodowym układem napędowym z wykorzystaniem sieci neuronowych, Badania symulacyjne w technice samochodowej, Lublin 2005.
- [11] Taylor C.F., The internal combustion engine theory and practice, M.I.T. Press, Cambridge 2001.
- [12] Traver M., Atkinson R. J., Atkinson C. M., Neural Network based diesel engine emissions prediction using in-cylinder combustion pressure, West Virginia University, 1999.