

Artificial intelligence in control of IC engine

Abstract: paper shows, that using of artificial intelligence in diesel engine control is possible on the example of fuel injection time (fuel dose) control as well as the injection advance angle in each of cylinders separately. It was proved that for the engine run control it is possible to use Radial Basis Function (RBF) neuronal network. Applying of these networks is easy. The optimization of their structure is also simple. It does not have also the necessity of selection of the function of transformations. It is a big advantage. It was shown that the RBF network is suitable both to modeling of the advance angle of fuel injection and the fuel injection time. In both applications the predictions of values of object responses are with high efficiencies.

Keywords: IC engine, control, artificial intelligence, optimization

Sztuczna inteligencja w sterowaniu silnikiem spalinowym


Streszczenie: Artykuł przedstawia dane potwierdzające, że sterowanie silnikiem spalinowym z wykorzystaniem sztucznej inteligencji jest możliwe. Pokazano to na przykładzie doboru wielkości dawki paliwa oraz kąta wyprzedzenia wtrysku indywidualnie w każdym cylindrze. Sztuczna inteligencję oparto na sieciach neuronowych o radialnych funkcjach bazowych (RBF). Optymalizacja tychże jest stosunkowo prosta gdyż ogranicza się w istocie do wyboiru liczby neuronów w jedynej warstwie pośredniej sieci. Pokazano, że tego typu sieci nadają się zarówno do sterowania kątem wyprzedzenia wtrysku jak i czasem trwania wtrysku. Uzyskana predykcja danych pomiarowych modelem matematycznym jest zadziwiająco dobra.

Słowa kluczowe: silnik spalinowy, sterowanie, sztuczna inteligencja, optymalizacja

1. Wstęp

Dwa angielskie określenia „downsizing” oraz „zero emission” są odpowiednie do scharakteryzowania głównych obecnie kierunków w rozwoju silników spalinowych. W pierwszym przypadku chodzi o uzyskiwanie jak najwyższych mocy z jednostkowej pojemności skokowej przy maksymalizacji sprawności silnika, w drugim najważniejszym jest ograniczenie emisji toksycznych składników spalin, aż do jej całkowitego wyeliminowania.

Obie tendencje realizowane są współcześnie gdyż pierwszą wymusza rynek, a drugą coraz ostrzejsze normy dopuszczalnych emisji. Dalszy rozwój silników wymaga nowego podejścia do szeregu zagadnień, w tym filozofii sterowania procesami w silniku, a zwłaszcza procesem spalania. Dzisiejszy stan jest trudny bowiem do zaakceptowania.



Rys. 1. Eksploatacyjne, zadane i zmierzone wartości współczynnika lambda (proporcji masy powietrza do masy paliwa).

Fig. 1. Exploitation, set and measured values of lambda (air mass ratio of the weight of fuel).

1. Introduction

Two English terms, i.e. "downsizing" and "zero emission" are suitable for characterization of the current, main development directions of the internal combustion engines. In the first case, it's about getting the highest power capacity from the unitary swept volume. The second case consists on the reduction of the toxic waste emission until its complete elimination.

Both of those tendencies are currently realized, because the first one is extorted by the market, while the second increasingly straightened norms of allowed emissions.

Further engines development requires a new approach to the number of issues, including the philosophy of the processes occurring within the engine control, especially the combustion process. Figure 1 shows for example the given and measured values of lambda coefficients (air mass portion to the fuel mass portion).

The significant differences exists between the values of measured and given lambda coefficient. Those differences are especially visible when the measured values are expressed as the function of given values of lambda coefficient.

Theoretically, the given values of lambda coefficient should oscillate around the value of 14,7. The exploitation reality is however different. The given values of lambda coefficient does not vary continuously but discrete. There is only few of them. Whereas the measured values are spread within rather wide limits. Therefore, the combustion process is surely not optimal.

The combustion process control was changed starting from the mechanical–pneumatic, through electro me-

Na rysunku 1 podano np. zadane oraz zmierzone w trakcie eksploatacji naturalnej wartości współczynnika lambda (proporcji masy powietrza do masy paliwa).

Występują znaczne różnice między wartościami zadanymi i zrealizowanymi. Różnice te uwidoczniają się jeszcze bardziej, gdy wartości zmierzone (zrealizowane) przedstawić w funkcji wartości zadanych.

Teoretycznie wartości zadane współczynnika lambda powinny oscylować przy liczbie 14,7. Rzeczywistość eksploatacyjna jest inna. Wartości zadane współczynnika lambda nie zmieniają się w sposób ciągły, a skokowy. Jest ich jedynie kilka. Natomiast wartości zmierzone (zrealizowane) zawarte są w dość szerokich granicach. Nie wydaje się to uzasadnione. Proces spalania z pewnością nie przebiega optymalnie.

Sterowanie procesem sterowania zmieniało się od mechaniczno – pneumatycznego, poprzez elektromechaniczne do elektronicznego. To ostatnie coraz częściej opiera się na biowzorcach, a tymi są m.in. podstawowe w sztucznej inteligencji – sieci neuronowe.

Sieci neuronowe zastosowano w silnikach spalinyowych do sterowania kątem wyprzedzenia wtrysku [1], jak też do diagnostyki istniejących systemów sterowania [2]. Ponadto sieci neuronowe próbuje się wykorzystać do sterowania fazami rozrządu silnika o zapłonie iskrowym [3], do sterowania procesem wtrysku paliwa [4, 5, 6], do sterowania pracą silnika [7], oraz w diagnostyce silnika [8] lub jego urządzeń peryferyjnych [9].

Wykazano, że wprowadzenie sieci neuronowych do sterowania pracą silnika wymaga nowego podejścia do filozofii tego sterowania [10]. Zaprezentowane wyniki prac świadczą o tym, że dzisiejszy, cyfrowy sposób sterowania należy poddać weryfikacji gdyż obecne sterowanie jest sterowaniem sztywnym, wykluczającym adaptowanie się zarówno do zmieniających się warunków pracy silnika, jak też do indywidualnego stopnia jego degradacji.


Wykazano również, że wprowadzenie sieci neuronowych napotyka na trudności związane z budową samych sieci. Główną niedogodnością jest praktyczny brak procedury kreowania struktury sieci. Pokazano jednak, że możliwa jest optymalizacja struktury przyjętej *a priori* [11, 12]. W pracy niniejszej przedstawiono natomiast przykład rozwiązania problemów optymalizacji struktury sieci RBF.

2. Sieci neuronowe RBF

Sieci RBF (Radial Basis Function) [1a] są sieciami trójwarstwowymi, jednokierunkowymi. Sieć taka składa się z warstwy wejściowej, ukrytej i wyjściowej. Neurony w warstwie ukryte zawierają radialne funkcje aktywacji (funkcje Gaussa).

Neurony w warstwie wyjściowej charakteryzują się liniową funkcją aktywacji. Wagi w połączeniach warstwy wejściowej i ukrytej są na stałe równe 1 i nie podlegają zmianom w procesie uczenia, w którym poszukuje się jedynie wartości wag połączeń warstwy ukrytej i wyjściowej. Ponadto wyznacza się parametry

mechanics ending on electronic. The last one is more often based on bio patterns and therefore, among the others, basing on artificial intelligence neural network.



Rys. 4. Zmierzone wartości współczynnika lambda w funkcji wartości zadanych

Fig. 2. The measured values as a function of lambda setpoint

The neural network was employed in the combustion engines for control in terms of injection advance [1], as well as for diagnostics of existing control systems. Furthermore, the neural network are attempted to be employed for timing gear control of the spark ignition engines [3], for the injection process control [4,5,6], for the engine operation control [7], as well as the engines diagnostics [8] or its peripheral devices [9].

It has been shown that employment of the neural network for the engine operation control requires a new approach to the philosophy of engine control [10]. Presented results subjects that the present, digital control procedure must be verified, due to the fact that the present control is direct control, excluding the ability to adapt to the changeable operation condition as well as to the individual level of degradation.

It has been also found that employment of the neural network meets difficulties occurring as a consequence of network design itself. The main drawback is the lack of network designing procedure. It has been shown however, that there is possibility to optimize the networks structured established *a priori* [11, 12]. This paper contains description of an example of the PBF neural network structure optimization.

2. RBF neural network

Networks RBF (Radial Basis Function) [1a] are three layered, and unidirectional. Such a network is combined of entry, hidden and output layer. Neurons in the hidden layer consists the radial activation functions (Gauss functions).

Neurons in the output layer are characterized by linear activation function. The weights in the connection between the input and hidden layer are always equal to one and cannot be change through all learning process. The learning process consists on exploration of the weights on the connection between the hidden and output layer. Furthermore, the parameters of the radial function are determined, i.e. function centre and its width. When those parameters are found, the second stage of training is begun. Here, the weights of the

funkcji radialnej, tzn. centrum funkcji i jej szerokość. Po znalezieniu tych parametrów następuje druga faza trenowania, w której znajdowane są wagi połączeń między warstwą ukrytą a wyjściową. Zaletą sieci radialnych jest bardzo uproszczony algorytm uczenia. Możliwe jest rozdzielenie doboru parametrów funkcji bazowych oraz doboru wag.

3. Symulacja wartości nastaw silnika z wykorzystaniem sieci neuronowych RBF

Przystępując do symulacji pracy silnika spalinowego należy ustalić warunki początkowe. Istotnym czynnikiem, mającym zasadniczy wpływ na jakość predykcji sieci neuronowej, jest dobór ilości neuronów w warstwie ukrytej.

Wykonując symulację (dotyczącą sterowania silnikiem z wykorzystaniem sztucznej inteligencji) zauważono, że najlepsze efekty otrzymuje się gdy ilości neuronów w warstwie ukrytej wynosi od 5 do 14. Dalsze zwiększanie ich liczby nie poprawia jakości zbudowanej sieci, a nawet ją pogarsza [15].

Istotne jest zgromadzenie odpowiedniej ilości danych. W rozpatrywanym przypadku dane te pochodziły z badań hamownianych silnika o zapłonie samoczynnym (turbodoładowanego o pojemności skokowej 1,3 dm³ oraz z systemem sterowania typu common rail). Ponadto dane pochodziły z badań układu wtryskowego na stanowisku modelowym [14], a także z analizy charakterystyk (niektórych) czujników pomiarowych występujących w standardowym osprzęcie silnika.

Zbiór danych do nauki sieci neuronowej pochodził z 400 pomiarów [15]. Został on podzielony w stosunku 2:1:1 na zbiory uczący (200 pomiarów), zbiór testujący (100 pomiarów) i zbiór walidacyjny (100 pomiarów).

Do uczenia sieci neuronowej użyto metody k-średnich. Funkcją aktywacji w warstwie ukrytej była funkcja Gaussa, natomiast warstwy wyjściowej - funkcja liniowa.

Przeanalizowano sieci o radialnych funkcjach bazowych różniących się między sobą liczbą neuronów w warstwie ukrytej. Analizowano sieci z 6, 8, 9 i 11 neuronów w tej warstwie.

Porównam je pod względem mierników jakości.

Poniżej przedstawiono wyniki analizy predykcji przy uwzględnieniu współczynnika korelacji między danymi pomiarowymi oraz wygenerowanymi przez poszczególne sieci. Odpowiednie analizy przeprowadzono oddzielnie w zbiorach, uczącym, testowym i walidacyjnym.

Sieci sparametryzowano tak, że uzyskano niezależne dane dotyczące kąta wyprzedzenia wtrysku paliwa oraz czasu wtrysku, niezależnie w poszczególnych cylindrach, czterocylindrowego silnika. Stwierdzono bowiem, że współczynnik napełnienia poszczególnych cylindrów zmienia się, w funkcji prędkości obrotowej wału korbowego silnika, w bardzo szerokich granicach przy czym nie występują tu prawidłowości typu „zawsze najbardziej napełniany jest cylinder nr 2” [13].

Contention between the hidden and output layer are determined. The advantage of radial network is a very simplified learning algorithm. It is possible to select the chosen parameters with respect to the base function and the weight selection.

3. Simulation of the engine regulation set-point utilizing the RBF neural network

When simulating the operation of the combustion engine it is necessary to specify appropriate initial condition. Here, the very important aspect of the control, which affects quality of the prediction is the numbers of neurons in the hidden layer.

Performing the simulation (concerning the engines control with aid of artificial intelligence) it has been found that the best effects are acquired when the number of neurons in the hidden layer ranges from 5 to 14. Further increase in the neurons numbers does not improve the quality of the network, and even can impair it [15].

It is important to gather appropriate amount of data. In case of the examined solution, the data were acquired during the measurements conducted on the engine test bed. The considered engine is turbocharged spark ignition engine with swept volume of 1,3 dm³ equipped with common rail control system. Furthermore, the additional data were acquired during the investigation of the injection system on the simulated test station [14], as well as the analysis of some measurement sensors with which the standard engine is equipped.

The data collection for the neural network teaching process comprises results of 400 measurements [15]. This has been divided with the ratio of 2:1:1 on the learning collection (200 measurements), testing collection (100 measurements) and validation collection (100 measurements)

For the network learning process the method of k-average was used. The activation function in the hidden layer was the Gaussian function, whereas in the output layer – linear function.

What was analysed here was the networks with radial basis functions which differ with each other with number of neurons in the hidden layer. The network with 6, 8, 9 and 11 neurons in the hidden layer were under investigation.

I will compare them in terms of quality meter.

Below are the results of the prediction analysis taking into account the correlation coefficient between the measurement and data generated by the different networks. The relevant analysis were carried out separately in the learning, the test and validation collection.


The network were prepared so that they have provided independent data on angle of advance of the fuel injection and the time of the injection, independently in the individual cylinders of a four cylinder engine. This is a consequence of that it has been ruled that a coefficient of cylinder filling is a function of crankshafts rotational speed, changing within very wide limits.

4. Wyniki badań symulacyjnych

Wyniki badań okazały się być zaskakujące.

Ogólnie rzecz biorąc uzyskano bardzo wysokie wartości współczynników korelacji, niezależnie od tego ile elektronów zaimplementowano w warstwach pośrednich sieci. Dość tu powiedzieć, że najniższe wartości współczynnika korelacji są większe od 0,95. Zatem z czysto statystycznego punktu widzenia nie ma zasadniczych różnic między predykcją każdą z analizowanych sieci. Jeśli jednak potraktować wyniki symulacji bardziej wnikliwie to okazuje się, że pewne spostrzeżenia wyróżniające dają się zarejestrować.

Na rysunku 3 przedstawiono wartości współczynnika korelacji przy predykcji poszczególnymi sieciami kąta wyprzedzenia wtrysku.



Rys. 2. Współczynnik korelacji w predykcji danych pomiarowych z poszczególnych cylindrów dotyczących kąta wyprzedzenia wtrysku w zależności od liczby neuronów w warstwie pośredniej badanych sieci neuronowych.

Fig. 3. The correlation coefficient for the prediction of measurement data from individual cylinders concerning the injection timing depending on the number of neurons in the intermediate layer neural network test.

Widać wyraźnie, że sieci o 9 neuronach w warstwie pośredniej, wyróżniają się wśród pozostałych. To wyróżnienie dotyczy nie tylko wartości współczynnika korelacji, ale również regularnością zmian. Mianowicie daje się zauważyć, że najwyższe wartości współczynnika korelacji uzyskiwano w zbiorach uczących, następnie w zbiorach testowych i nieco niższą w zbiorach walidacyjnych. Prawidłowości te występują również w przypadku sieci o 11 neuronach (ale przy niższej wartości współczynnika korelacji). Prawidłowości te nie występują w przypadku sieci o 6 czy 8 neuronach. „Najgorsze” wartości predykcji uzyskano przy 8 neuronach w warstwie pośredniej. Jest to o tyle ciekawe, że z kolei najlepszą predykcję uzyskano gdy sieć różniła się jedynie jednym neuronem w warstwie pośredniej. Przy „gorszych” wartościach predykcji prawidłowości dotyczącej zbiorów uczącego, testowego i walidacyjnego nie obserwuje się.

Podobnie spostrzeżenia można podać gdy analizuje się symulacje czasu otwarcia wtryskiwacza – Rys. 4.

Ogólnie rzecz biorąc wartości współczynników są jeszcze wyższe jak te uzyskane przy symulacjach kąta wyprzedzenia wtrysku.

Tu również najwyższe współczynniki korelacji za-

Moreover, there is no such a regularity that „always the most filled is cylinder no 2” [13].


4. The results of simulation investigation

The results proved to be puzzling.

In general, the simulation resulted in very high values of correlation coefficients, regardless of how many electrons were implemented in the intermediate layers of the network. It is enough to say that the lowest value of the correlation coefficient is greater than 0,95. Thus, from a purely statistical point of view there is no essential difference between the prediction of each analysed network. However, if the results of the simulation were considered more closely, it turns out that some of the insights characterizing particular networks can be registered.

Figure 3 shows the values of the injection angle of advance correlation coefficient obtained by prediction on particular networks

It is clear that a network of 9 neurons in the intermediate layer, stand out among the rest. This accentuation does not only concern the value of the correlation coefficient, but also the regularity of change. Namely, it can be seen that the highest values of the correlation coefficient were obtained in the learning collections, then the test collection and slightly lower in the collection of validation. These characteristics are also found in the case of a network with neurons of 11 (but with a lower value of the correlation coefficient). These characteristics are not found in the network with neurons of, 6 or 8. "Worst" of the prediction was obtained with 8 neurons in the intermediate layer. This is inasmuch interesting as, in turn, that the best prediction was achieved when the network differed only in one neuron in the intermediate layer. The "worse" values of the prediction accuracy of the learning, testing and validation collection is not observed. Similar observations can be given when analysing simulations of the injectors opening time – Figure 4.




Rys. 5. Współczynnik korelacji w predykcji danych pomiarowych z poszczególnych cylindrów dotyczących czasu otwarcia wtryskiwacza w zależności od liczby neuronów w warstwie pośredniej badanych sieci neuronowych.

Fig. 4. The correlation coefficient for the prediction of measurement data from each cylinder concerning the injector opening time according to the number of neurons in the intermediate layer examined neural networks.

obserwowano wówczas gdy analizowano dane uzyskane sieci o 9 neuronach w warstwie pośredniej. Również najwyższe wartości współczynnika uzyskano przy zbiorach uczących, następnie testowych a najniższe w zbiorach walidacyjnych. Jednak różnice w wartościach współczynnika korelacji w tych zbiorach, są niższe jak w przypadku symulacji kata wyprzedzenia wtrysku.

Jest natomiast interesujące, że siecią o nieco gorszych parametrach jest sieć o 6 neuronach w warstwie pośredniej. Tu jednak również występuje prawidłowość dotycząca zbiorów uczącego, testowego i walidacyjnego. Gorszą, jak przy 9 czy 6 neuronach w warstwie pośredniej, predykcję uzyskano przy 8 neuronach w tej warstwie. Nie ma tu już prawidłowości dotyczących poszczególnych zbiorów. „Najgorszą” predykcję uzyskano tym razem z sieciami o 11 neuronach w warstwie pośredniej. Tu jednak uzyskano odwrotną prawidłowość dotyczącą poszczególnych zbiorów. Przy 11 neuronach w warstwie pośredniej najniższe wartości współczynnika korelacji uzyskano w zbiorze uczącym, nieco wyższą w zbiorze testowym, a najlepszą, tym razem, w zbiorze walidacyjnym. W zasadzie nie ma żadnych danych porównawczych na podstawie których możliwe byłoby wytłumaczenie zaobserwowanych „prawidłowości”. Jest pewne, że dokładna analiza pozwala wybrać tę sieć, której stosowanie prowadzi do najlepszej predykcji.

Wartości współczynnika korelacji przy poszczególnych sieciach w poszczególnych zbiorach są nadzwyczaj wysokie. Statystycznie oznacza to, że predykcja modelem danych pomiarowych jest niemal idealna. Jednak czy jest to „ostatnie słowo”. Chyba jednak nie. Rysunek 5. przedstawia wartości zmierzone i wygenerowane przy użyciu sieci, a dotyczące czasu wtrysku.



Rys. 3. Porównanie zmierzonych i wygenerowanych przy pomocy modelu matematycznego wartości czasu trwania wtrysku w cylindrze nr 1 badanego silnika.

Fig. 5. Comparison of measured and generated by means of a mathematical model the value of the duration of injection in cylinder No. 1 of the test engine.

Porównanie to wiedzie do dość istotnego spostrzeżenia, że jakkolwiek, statystyczne rzecz ujmując, korelacja między wartościami modelowymi i rzeczywistymi jest bardzo dobra to jednak można będzie spodziewać się lepszej gdyby model matematyczny był lepiej zbudowany. Chodzi mianowicie o to, że charakter zależności odbiega od postaci liniowej. Należałoby również

In general, the coefficients are even higher as those produced by the injection angle of advance simulations.

Here, the highest correlation coefficients were observed when analysing data from a network with 9 neurons in the intermediate layer. Also, the highest values of the coefficient were obtained at learning collections, then the test collections, and the lowest in the validation collection. However, the differences in the values of the correlation coefficient in these collections are lower as the injection angle of advance simulations.

It is however interesting, that a network of slightly worse performance is a network with 6 neurons in the intermediate layer. But here there is a pattern in the collections of learning, test and validation collection as well. Worse, as the 9 or 6 neurons in the intermediate layer, a prediction was obtained with 8 neurons in this layer. Here, there is no any pattern concerning particular collections. "The worst" prediction was obtained this time with the networks with 11 neurons in the intermediate layer. Here, however, the opposite regularity for particular collections can be observed. In case of 11 neurons in the intermediate layer, the lowest values of correlation coefficient was obtained in the teaching collection, a bit higher in the test collection, and the best, this time in the collection of validation. In fact, there are no comparative data on the basis of which it would be possible to explain the observed "regularities". It is certain that thorough an in-depth analysis shall allow to select the network which usability may lead to the best prediction.

The values of the correlation coefficient with the individual networks in the various collections are extremely high. Statistically, this means that the measurement data prediction model is almost perfect. However, is it "the last word". Probably not. Figure 5 shows the values measured and generated by the network, representing the injection time.

This comparison leads to a fairly significant observation, that from the statistical point of view the correlation between modelled and virtual values is very good, however, can be expected to improve if a mathematical model was better developed. It is namely the fact that the nature of the relationship differs from the linear form. It would also lead to a simple trend line that ran through the origin.

5. Conclusion

This paper presents the simulations studies showing the possibilities of using artificial intelligence to control a combustion engine. The results confirms the hypothesis that the control is possible.

Employment of a control which uses an artificial intelligence may be based on utilizing neural networks of neurons radial base functions (RBF).

It is necessary to optimize the neural network which consists of selecting the number of neurons in the intermediate layer. However, there is a group of networks that are almost equal, and their prediction are very good, it is possible to choose the better of them by using additional criteria. Such criteria are, for example

doprowadzić do tego by prosta linii trendu przebiegała przez początek układu współrzędnych.

5. Zakończenie

Przedstawiono wyniki badań stymulacyjnych dotyczących możliwości wykorzystania sztucznej inteligencji do sterowania silnikiem spalinowym. Wyniki te potwierdzają tezę, że sterowanie taki jest możliwe.

Wprowadzenie sterowania wykorzystującego sztuczną inteligencję może opierać się na wykorzystaniu sieci neuronowych z neuronami o radialnych funkcjach bazowych RBF.

Konieczna jest optymalizacja sieci neuronowych, polegająca na doborze ilości neuronów w warstwie pośredniej. Jakkolwiek jest grupa sieci, które są niemalże równorzędne, a ich predykcja bardzo dobra, to jednak można z nich wybrać lepsze stosując dodatkowe kryteria. Takim kryterium są np. wartości współczynnika korelacji w poszczególnych zbiorach. Sieci o najwyższych parametrach predykcji charakteryzują się tym, że współczynnik korelacji przyjmuje najwyższe wartości w odniesieniu do danych ze zbioru uczącego, nieco niższe ze zbioru testowego, a najniższe z danymi ze zbioru walidacyjnego. Prawidłowość ta musi być jednak potwierdzona szerszym materiałem doświadczalnym.

Generalnie rzecz ujmując dobór sieci neuronowej do sterowania silnikiem wymaga głębszych analiz dotyczących ich architektury. Stwierdzono bowiem, iż mimo, że wskaźniki predykcji (np. współczynnik korelacji) przyjmuje bardzo wysokie wartości, zbliżające się wręcz do jedności, to jednak „charakter dopasowania” nie jest zadowalający. Konieczne będą dalsze prace studialne np. wyjaśniające czy przyjęcie liniowych zależności w połączeniach neuronów warstwy pośredniej i warstwy wyjściowej jest uzasadnione. Problematyce omówionej w niniejszym artykule poświęcone będą dalsze prace autora.

the value of the correlation coefficient in the various collections. Networks of the highest prediction are characterized in that, the highest correlation coefficient values are achieved for the data from the learning collection. Slightly lower for the test collection, and the lowest for the validation collection. This pattern, however, must be confirmed by larger experimental material.

Generally speaking, the selection of neural network employed to control an engine requires a deeper analysis of their architecture. It was noted that although the predictive indicators (e.g. correlation coefficient) takes very high values, approaching almost to unity, their " fit character " is not satisfactory. It will be followed by further studies such as explaining whether the adoption of linear dependence in neuronal connections between the intermediate and output layer is justified. Issues discussed in this article will be devoted to further work of the author.

Nomenclature/Skróty i oznaczenia

RBF Radial Basis Function/*Radialne Funkcje Bazowe*

Bibliography/Literatura

- [1] Bauer M., Bredenbeck J., Krause F-L., Pucher H., Raubold W.: Online Prozessoptimierung für aufgeladene Dieselmotoren MTZ Motor-technische Zeitschrift 57 (1996) 6.
- [2] Kessel J-A., Schmidt M., Isermann R.: Modelbasierte Motorsteuerung, -regelung und –überwachung. MTZ Motortechnische Zeitschrift 59 (1998) 4.
- [3] Gölcü M., Sekmen Y., Erduranli P., Sahir S.; Artificial neural-network based modeling of variable valve-timing in a spark-ignition engine, Applied energy (Appl. energy) ISSN 0306-2619.
- [4] Manzie C., Palaniswami M., Watson H.; Gaussian networks for fuel injection control Proceedings of the Institution of Mechanical Engineers. Part D, Journal of automobile engineering (Proc. Inst. Mech. Eng., D J. automob. eng.) ISSN 0954-4070.

-
- [5] Kovalenko O., Derong L., Javahenan H.; Neural network modeling and adaptive critic control of automotive fuel-injection systems. Proceedings of the 2004 IEEE International Symposium on Intelligent Control 2004, pp. 368-373.
- [6] Cuiping Z., Qiugfo Y.; Study On Injection And Ignition Control Of Gasoline Engine Based On Bp Neural Network. China Taiyuan 030024.
- [7] Isermann R., Mueller N.; Modeling And Adaptive Control Of Combustion Engines With Fast Neural Networks. Darmstadt University of Technology, Institute of Automatic Control, Laboratory of Control Systems and Process Automation, Darmstadt, Germany 2001.
- [8] Beuschel M.; Neuronale Netze zur Diagnose und Tilgung von Drehmomentschwingungen am Verbrennungsmotor. Diss. Lehrstuhl für Elektrische Antriebssysteme Technische Universität München, 2000.
- [9] Bayir R., Bay O. F.; Serial Wound Starter Motor Faults Diagnosis Using Artificial Neural Network. Department of Electronics and Computer, Faculty of Technical Education, Gazi University 06500 Teknikokullar, Ankara, TURKEY, 2007.
- [10] Sitnik L.: Koncepcja wykorzystania sieci neuronowych do sterowania nastawami silnika. wielopaliwowego Ogólnopolska Konferencja Naukowa KONSSPAL'96, Wrocław 1996.
- [11] Sitnik L. -Neuronal network for diesel engine control. PTNSS KONGRES – 2005, September 25th – 28th, 2005 Bielsko Biala/Szczyrk Poland, PTNSS P05-C091.
- [12] Sitnik L. Neuronal network for flexible process control In diesel engine. Silniki spalnowe 2007 R, 46 Nr SC3 s. 345-360.
- [13] Rawski F.; Metody wyznaczania czasowych charakterystyk transportu czynnika roboczego w silniku spalinowym. Rozprawa habilitacyjna. Politechnika Warszawska. Warszawa 1999
- [14] Zespół sterowania silnikiem ZS typu Common-Rail. Instrukcja do stanowiska modelowego. Wrocław 2003.
- [15] Pawlaczyk M.; Zastosowanie sztucznej inteligencji w elastycznym sterowaniu silnikiem o zapłonie samoczynnym.. Politechnika Wroclawska, Wydział Mechaniczny, praca dyplomowa. (Promotor L. Sitnik) Wrocław 2012.

Mr Lech J. Sitnik, Prof. DSc., PhDEng. – Professor in the Faculty of Mechanical Engineering at Wrocław University of Technology.

Prof. dr hab. inż. Lech J. Sitnik – profesor na Wydziale Mechanicznym Politechniki Wrocławskiej.

