

Ryszard ROJEK, Krzysztof BARTECKI, Jacek KORNIAKPOLITECHNIKA OPOLSKA, WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI I INFORMATYKI,
INSTYTUT AUTOMATYKI I INFORMATYKI**Metody sztucznej inteligencji w zastosowaniach automatyki****Dr hab. inż. Ryszard ROJEK**

Jest dyrektorem Instytutu Automatyki i Informatyki na Wydziale Elektrotechniki, Automatyki i Informatyki Politechniki Opolskiej. Główne badania prowadzi w zakresie modelowania procesów o parametrach rozłożonych, metod sztucznej inteligencji w zastosowaniach automatyki oraz zaawansowanych metod sterowania procesami przemysłowymi.



e-mail: kaeii@po.opole.pl

Dr inż. Krzysztof BARTECKI

Stopień naukowy doktora nauk technicznych uzyskał w 2004 roku w Politechnice Opolskiej. Pracuje w Instytucie Automatyki i Informatyki Politechniki Opolskiej na stanowisku adiunkta. Główny kierunek badań naukowych obejmuje zastosowanie sztucznych sieci neuronowych w zagadnieniach modelowania, identyfikacji oraz sterowania obiektami dynamicznymi.



e-mail: barteki@po.opole.pl

Dr inż. Jacek KORNIAK

Stopień naukowy doktora nauk technicznych uzyskał w 2005 roku w Politechnice Opolskiej. Pracuje w Instytucie Automatyki i Informatyki Politechniki Opolskiej na stanowisku adiunkta. Główny kierunek badań naukowych dotyczy zastosowania metod logiki rozmytej w zagadnieniach modelowania, identyfikacji oraz sterowania złożonymi obiektami.



e-mail: korniakj@po.opole.pl

W artykule przedstawiono wybrane możliwości zastosowań wymienionych wyżej metod sztucznej inteligencji w zagadnieniach automatyki. Zawarto ogólny przegląd struktur identyfikacji i sterowania obiektami dynamicznymi, opartych na sztucznych sieciach neuronowych. Wskazano także na praktyczne aspekty wykorzystania metod logiki rozmytej w sterowaniu układem napędowym samochodu osobowego.

2. Sztuczne sieci neuronowe w identyfikacji i sterowaniu obiektami dynamicznymi

Wiele spośród stosowanych obecnie układów regulacji automatycznej to klasyczne układy z regulatorami proporcjonalnymi (P), proporcjonalno-całkującymi (PI) lub proporcjonalno-całkującą-różniczkującymi (PID). Algorytmy te dla większości typowych zastosowań dają zadowalające rezultaty. Jednak w przypadku obiektów charakteryzujących się znacznymi nieliniowościami lub niestacjonarnością, jakość sterowania może ulec znacznemu pogorszeniu, wymuszając np. konieczność częściej ingerencji w nastawy regulatorów [1]. Z tego względu w nowoczesnych układach sterowania coraz częściej stosowane są np. algorytmy wykorzystujące harmonogramowanie wzmocnienia regulatora (ang. *gain scheduling*) oraz układy regulacji adaptacyjnej. Jednocześnie, jak wspomniano w punkcie 1., coraz więcej uwagi poświęca się rozwiązaniom bazującym na metodach sztucznej inteligencji, w tym m.in. algorytmom wykorzystującym sztuczne sieci neuronowe (SSN). O atrakcyjności sieci neuronowych jako narzędzia do rozwiązywania zadań modelowania, identyfikacji oraz sterowania, decydują ich korzystne właściwości, do których zalicza się przede wszystkim [4, 5, 6]:

- możliwość aproksymacji dowolnych wielowymiarowych ciągłych zależności nieliniowych,
- zdolność adaptacji (uczenia się), czyli dopasowywania wartości parametrów (tzw. współczynników wagowych) do zmian charakterystyk obiektu i zakłóceń,
- dużą szybkość działania, związaną z równoległym sposobem przetwarzania informacji i efektywnością stosowanych algorytmów,
- zdolność generalizacji (uogólniania), czyli generowania właściwych odpowiedzi na dane niewykorzystywane w procesie uczenia.

Poniżej dokonano przeglądu podstawowych struktur identyfikacji oraz sterowania obiektami dynamicznymi, wykorzystujących wymienione wyżej właściwości sztucznych sieci neuronowych.

2.1. Struktury neuronowych modeli identyfikacyjnych

Obecnie znanych jest wiele algorytmów identyfikacji dla obiektów liniowych. Jednak stosunkowo mało jest efektywnych metod

Streszczenie

W artykule przedstawiono wybrane aspekty zastosowania metod sztucznej inteligencji w zagadnieniach automatyki. Zawarto ogólny przegląd metod identyfikacji i sterowania opartych na sztucznych sieciach neuronowych. Wskazano także na możliwość wykorzystania logiki rozmytej do optymalizacji pracy samochodowego układu napędowego.

Słowa kluczowe: sieci neuronowe, logika rozmyta, identyfikacja, sterowanie automatyczne.

Methods of artificial intelligence in applications of automatic control**Abstract**

In this paper, some issues concerning application of neural networks and fuzzy logic in automatic control are presented. Neural identification and control methods are briefly reviewed. Fuzzy logic approach to powertrain control of a passenger car is also shown.

Keywords: neural networks, fuzzy logic, identification, automatic control.

1. Wprowadzenie

Rosnąca złożoność nowoczesnych linii technologicznych oraz procesów przemysłowych, a także potrzeba spełniania wysokich wymagań dotyczących niezawodności oraz bezpieczeństwa pracy, stanowią duże wyzwanie dla projektantów układów automatyki. Wymagają one stosowania w dziedzinach modelowania, identyfikacji i sterowania nowoczesnych metod obliczeniowych, do których można zaliczyć między innymi metody oparte na zagadnieniach tzw. sztucznej inteligencji, w tym sztucznych sieci neuronowych i logiki rozmytej [1, 7, 9, 12].

Uniwersalność sztucznych sieci neuronowych wynika przede wszystkim z ich właściwości aproksymacyjnych, adaptacyjnych i generalizacyjnych. Z kolei podejście oparte na teorii zbiorów rozmytych umożliwia złączenie wymogów precyzji w procesie tworzenia modeli i umożliwia opis złożonych systemów przy użyciu zmiennych skwantowanych w sposób intuicyjny.

identyfikacji dla systemów nieliniowych, w szczególności zaś dla obiektów dynamicznych o nieznannej strukturze [4]. Ze względu na wymienione wcześniej korzystne właściwości, szerokie zastosowanie mają tutaj także metody bazujące na sztucznych sieciach neuronowych. Wśród wielu struktur SSN, w rozwiązywaniu zadaniowej identyfikacji najczęściej stosowane są wielowarstwowe, statyczne sieci jednokierunkowe. Efekt zachowania dynamicznego uzyskiwany jest w tego typu sieciach przez rozszerzenie wektora wejść sieci o wartości wielkości wejściowej i wyjściowej obiektu z poprzednich chwil czasowych (ang. *Tapped Delay Lines*, TDL). Poniżej dokonano przeglądu podstawowych struktur identyfikacji z zastosowaniem SSN dla obiektów z pojedynczym wejściem oraz pojedynczym wyjściem (ang. *Single Input Single Output*, SISO).

Model NNFIR (ang. *Neural Network Finite Impulse Response*) stanowi nieliniowe rozszerzenie klasycznego liniowego modelu FIR, tzn. modelu o skończonej odpowiedzi impulsowej. Można go opisać następującą zależnością:

$$\hat{y}(k) = f[u(k - n_d), u(k - n_d - 1), \dots, u(k - n_d - n_u)], \quad (1)$$

gdzie u jest sygnałem wejściowym obiektu, $\hat{y}(k)$ jest predykcją wartości sygnału wyjściowego obiektu w k -tej dyskretniej chwili czasowej, zaś $f[\cdot]$ jest nieliniową funkcją opóźnionych sygnałów wejściowych obiektu, realizowaną przez jednokierunkową sieć neuronową. Zakłada się ponadto, że znane są całkowite wartości n_d oraz n_u , określające odpowiednio: opóźnienie sygnału wyjściowego obiektu względem sygnału wejściowego oraz liczbę kolejnych próbek wejściowych, mających wpływ na wartość sygnału wyjściowego obiektu. Obiektu dynamicznego posiadającego bieguny nie można opisać w sposób dokładny przy pomocy równania (1). Jednak jeśli obiekt ten jest stabilny, a jego odpowiedź impulsowa zanika względnie szybko, może być aproksymowany przy pomocy modelu NNFIR z wystarczającą dokładnością [6].

Model NNARX (ang. *Neural Network AutoRegressive with eXogenous variables*) stanowi rozszerzenie klasycznego modelu ARX (określanego także nazwą sterowanego modelu autoregresyjnego lub modelu szeregowo-równoległego) na przypadek nieliniowy. Opisuje go następująca zależność [2, 3]:

$$\hat{y}(k) = f[y(k-1), y(k-2), \dots, y(k-n_y), u(k-n_d), u(k-n_d-1), \dots, u(k-n_d-n_u)]. \quad (2)$$

Zakłada się tu, że wpływ na wartość sygnału wyjściowego obiektu y w k -tej chwili czasowej mają, obok opóźnionych wartości wejść u , także poprzednie wartości sygnału y . Wymagane jest przy tym ustalenie wartości n_y , określającej liczbę opóźnionych próbek wyjściowych uwzględnionych w modelu.

Podobnie jak w przypadku struktury NNFIR (1), pomiędzy predykcją sygnału wyjściowego obiektu a wartościami sygnałów wejściowych modelu istnieje jedynie zależność algebraiczna, dzięki czemu zapewniona jest stabilność predyktora. Jest to szczególnie istotne w przypadku rozpatrywanej klasy modeli nieliniowych, gdzie analiza stabilności jest znacznie utrudniona w porównaniu z analogicznymi modelami liniowymi.

Model NNARMAX (ang. *Neural Network AutoRegressive, Moving Average with eXogenous variables*) stanowi rozszerzenie klasycznego modelu ARMAX (czyli sterowanego modelu autoregresyjnego z ruchomą średnią) na przypadek nieliniowy:

$$\hat{y}(k) = f[y(k-1), y(k-2), \dots, y(k-n_y), u(k-n_d), u(k-n_d-1), \dots, u(k-n_d-n_u), \varepsilon(k-1), \varepsilon(k-2), \dots, \varepsilon(k-n_e)]. \quad (3)$$

W modelu tym, oprócz części autoregresyjnej związanej z opóźnionymi wyjściami oraz części zawierającej opóźnione wejścia, uwzględnia się także część związaną z ruchomą średnią błędów predykcji $\varepsilon(k) = y(k) - \hat{y}(k)$.


Ze względu na fakt, że w modelu tym występuje sprzężenie zwrotne (wartość sygnału wyjściowego modelu \hat{y} zależy od poprzednich wartości błędu predykcji ε , a więc pośrednio także od poprzednich wartości wyjść modelu), rozpatrywana neuronowa struktura identyfikacji ma postać rekurencyjną. O ile w przypadku liniowego modelu ARMAX łatwo sprawdzić stabilność predyktora poprzez zbadanie pierwiastków odpowiedniego wielomianu modelu, o tyle w przypadku rozpatrywanego modelu nieliniowego analiza stabilności jest utrudniona. Może się na przykład zdarzyć, że model NNARMAX będzie stabilny w jednym punkcie pracy, a niestabilny w innym [6].

Model NNOE (ang. *Neural Network Output Error*) stanowi rozszerzenie modelu OE (zwanego też równoległym modelem identyfikacji) na przypadek nieliniowy. Równanie opisujące ten model jest następujące:

$$\hat{y}(k) = f[\hat{y}(k-1), \hat{y}(k-2), \dots, \hat{y}(k-n_y), u(k-n_d), u(k-n_d-1), \dots, u(k-n_d-n_u)]. \quad (4)$$

Zakłada się tutaj, iż w celu predykcji wyjścia obiektu w k -tym kroku czasowym można posłużyć się wartościami predykcji z kroków poprzednich. Zastosowanie powyższej struktury rekurencyjnej ograniczone przez fakt, że nawet przy założeniu stabilności identyfikowanego obiektu nie można zapewnić stabilności modelu. Z tego względu, zakładając że wyjście obiektu jest pomiarowo dostępne, korzystniej jest stosować szeregowo-równoległą strukturę identyfikacji NNARX (2).

Modele NNSS (ang. *Neural Network State Space*), czyli neuronowe modele w przestrzeni stanów, stanowią alternatywę w stosunku do przedstawionych wcześniej modeli wejściowo-wyjściowych (rys. 1).



Rys. 1. Struktura szeregowo-równoległego modelu NNSS
Fig. 1. Structure of NNSS series-parallel identification model

Jeżeli oprócz wejścia u i wyjścia y obiektu dostępne pomiarowo są także wszystkie jego zmienne stanu reprezentowane przez wektor \mathbf{x} , to równanie stanu i równanie wyjścia modelu nieliniowego można opisać następująco:

$$\begin{aligned} \hat{\mathbf{x}}(k) &= \mathbf{f}[\mathbf{x}(k-1), u(k-1)] \\ \hat{y}(k) &= \mathbf{g}[\mathbf{x}(k), u(k)], \end{aligned} \quad (5)$$

gdzie $\hat{\mathbf{x}}(k) \in \mathbb{R}^n$ stanowi predykcję wektora stanu obiektu w k -tej chwili czasowej, zaś $\mathbf{f}[\cdot]$ oraz $\mathbf{g}[\cdot]$ reprezentują nieliniowe funkcje stanu oraz wyjścia, realizowane przez odrębne sieci neuronowe (rys. 1).

Model opisany równaniami (5) jest odpowiednikiem wejściowo-wyjściowego modelu szeregowo-równoległego (2). Zastępując w tych równaniach wektor stanu obiektu $\mathbf{x}(k)$ jego wartością

predykowaną, otrzymujemy odpowiednik wejściowo-wyjściowego modelu równoległego (4):

$$\begin{aligned}\hat{x}(k) &= f[\hat{x}(k-1), u(k-1)] \\ \hat{y}(k) &= g[\hat{x}(k), u(k)].\end{aligned}\quad (6)$$

Istotną cechą opisaną równaniami (6) równoległej struktury NNSS jest możliwość predykcji także niemierzalnych składowych wektora stanu $x(k)$. Ta właściwość modelu równoległego jest przydatna np. przy realizacji neuronowego filtra Kalmana [4].

Struktury hybrydowe. Obok wymienionych wcześniej podstawowych struktur neuronowych modeli identyfikacyjnych, wymienić można ich różnego typu modyfikacje, polegające np. na wprowadzeniu do części modelu składnika liniowego. Wśród nich wyróżnić można m.in. [1, 6]:

- strukturę NNARX (2) wykorzystującą dwie odrębne sieci neuronowe: $f_u[\cdot]$ dla opóźnionych wejść oraz $f_y[\cdot]$ dla opóźnionych wyjść obiektu bądź też złożoną z sieci neuronowej oraz składnika liniowego;
- strukturę NNOE (4), zmodyfikowaną w sposób podobny jak wyżej; szczególnie atrakcyjny jest tu przypadek modelu opisanego równaniem:

$$\hat{y}(k) = -\sum_{i=1}^{n_y} a_i \hat{y}(k-i) + f_u[u(k-n_d), \dots, u(k-n_d-n_u)], \quad (7)$$

ze względu na fakt, iż ułatwiona jest analiza stabilności takiego modelu - dla jej zapewnienia konieczne jest przyjęcie założenia, że pierwiastki równania charakterystycznego:

$$z^{n_y} + a_1 z^{n_y-1} + \dots + a_{n_y} = 0 \quad (8)$$

będą się znajdowały wewnątrz koła jednostkowego na płaszczyźnie zespolonej;

- strukturę NNARMAX, przekształconą do następującej postaci:

$$\begin{aligned}\hat{y}(k) &= f_{yu}[y(k-1), \dots, y(k-n_y), \\ &u(k-n_d), u(k-n_d-1), \dots, u(k-n_d-n_u)] + \\ &+ \sum_{i=1}^{n_e} c_i \varepsilon(k-i),\end{aligned}\quad (9)$$

umożliwiającej, podobnie jak w przypadku struktury (7), zapewnienie stabilności modelu poprzez dobór odpowiednich wartości parametrów c_i jego części liniowej.

- liczne modyfikacje nieliniowych modeli w przestrzeni stanu, np. zakładające, że sygnał wyjściowy obiektu jest liniowo zależny od wektora stanu lub jego predykcji [6].

Sieci rekurencyjne. Możliwości zastosowań SSN w dziedzinie modelowania i identyfikacji obiektów dynamicznych nie ograniczają się jedynie do sieci jednokierunkowych. W literaturze spotkać można wiele przykładów zastosowań sieci rekurencyjnych, charakteryzujących się występowaniem w swojej strukturze sprzężeń zwrotnych. Sprzężenia te mogą występować wewnątrz neuronu i noszą wówczas nazwę sprzężeń lokalnych. W odróżnieniu od sprzężeń „wewnątrzneuronowych”, sprzężenia zwrotne występujące między neuronami noszą nazwę sprzężeń globalnych. Najbardziej znane spośród sieci globalnie rekurencyjnych, mające zastosowanie w modelowaniu obiektów dynamicznych to sieci neuronowe: Hopfielda, Elmana oraz Jordana. Znane są liczne przykłady udanych zastosowań tej klasy sieci w zagadnieniach modelowania oraz identyfikacji systemów dynamicznych [1, 4, 5, 6].

2.2. Przegląd metod sterowania neuronowego

Obok zagadnień neuronowej identyfikacji obiektów nieliniowych, wiele uwagi poświęca się również możliwości wykorzystania sztucznych sieci neuronowych jako układów realizujących zadanie sterowania nieliniowymi obiektami dynamicznymi. Wśród metod sterowania neuronowego, w których sieć neuronowa wykorzystywana jest bezpośrednio do realizacji regulatora, najszerszej znaną techniką jest tzw. modelowanie odwrotne (ang. *inverse modelling*). Polega ona na wykorzystaniu jako regulatora sieci neuronowej reprezentującej „odwrotność” dynamiki obiektu. Istnieje wiele odmian tej oraz innych metod sterowania neuronowego, różne są także kryteria ich klasyfikacji. Można tu wymienić m.in. układy [5]:

- pracujące w pętli otwartej lub zamkniętej,
- z modelem odniesienia lub bez tego modelu,
- regulacji bezpośredniej oraz pośredniej,
- zorientowane bądź nie zorientowane na cel,
- bazujące na odwrotności modelu obiektu oraz pozostałe,
- z uczeniem uogólnionym lub specjalizowanym.

Istotnym kryterium klasyfikacji regulatorów neuronowych jest również sposób, w jaki dostrajane są ich współczynniki wagowe. Można wyróżnić tu dwie zasadnicze grupy metod modyfikacji wag, działające w oparciu o:

- sygnał sterujący obiektem,
- żądany wyjściowy sygnał obiektu.

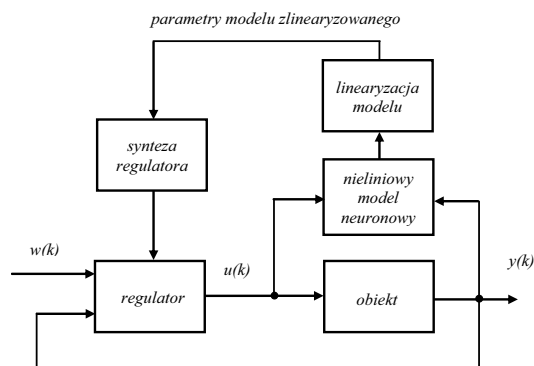
Wśród układów bazujących na żądanym sygnale sterującym wymienić można m.in. [1, 5]:

- Neuronowe regulatory naśladowcze (ang. *mimic controllers*), w których sieć uczona jest zachowania konwencjonalnego regulatora (na przykład PID). Tak nauczony regulator neuronowy jest w stanie samodzielnie sterować obiektem.
- Układy sterowania neuronowego z uczeniem pośrednim (ang. *indirect learning architecture*), w których model neuronowy, reprezentujący odwrotność dynamiki obiektu, dostrajany jest w oparciu o różnicę między aktualną wartością sygnału wejściowego obiektu, a generowaną przez ten model wartością sygnału sterującego. Nauczona sieć jest wykorzystywana do sterowania obiektem. Jej dostrajanie może odbywać się zarówno w trybie *off-line*, jak i *on-line*.

Z kolei w grupie metod bazujących na żądanym sygnale wyjściowym wskazać można:

- Układy sterowania bezpośredniego, działające na wspomnianej wyżej zasadzie odwrotności modelu obiektu (ang. *direct inverse control*). Współczynniki wagowe regulatora neuronowego dostrajane są tutaj bezpośrednio z wykorzystaniem sygnału uchybu regulacji bądź też w oparciu o różnicę między sygnałem wyjściowym obiektu a sygnałem wyjściowym modelu odniesienia. Istnieje wiele odmian tej strategii sterowania; znane są układy pracujące zarówno w pętli zamkniętej, jak i w torze otwartym.
- Układy sterowania z neuronowym emulatorem obiektu (ang. *forward modelling and inverse control*). Regulator neuronowy realizujący „odwrotność” obiektu dostrajany jest tu z wykorzystaniem metody propagacji wstecznej błędu w neuronowym modelu obiektu bądź w oparciu o metodę tzw. propagacji wstecznej w czasie (ang. *backpropagation through time*).
- Układ sterowania z tzw. wewnętrznym modelem neuronowym (ang. *neural internal model control*), bazujący, podobnie jak poprzednie układy, na odwrotności modelu obiektu.
- Układ neuronowego sterowania predykcyjnego (ang. *neural predictive control*). W strukturze tej wykorzystuje się neuronowy model obiektu, emulujący jego zachowanie z zadaniem horyzontem czasowym. Wygenerowany przez model predykcyjny sygnał wyjściowy obiektu przekazywany jest do optymalizatora układu, który wyznacza, w oparciu o odpowiedni wskaźnik jakości, sygnał sterujący obiektem.

Oprócz wspomnianych wyżej metod sterowania *stricte* neuronowego, istnieje także duża grupa metod hybrydowych, w których sieć neuronowa nie jest „samodzielnym” regulatorem, lecz służy np. rozszerzeniu możliwości konwencjonalnego algorytmu sterowania. Zakłada się w tym przypadku, że połączenie aproksymacyjnych i adaptacyjnych właściwości sieci neuronowych z klasycznymi algorytmami regulacji (np. PID lub predykcyjnej) w znaczący sposób może polepszyć jakość działania układu. Jako przykład takiej strategii, przedstawiono na rys. 2. strukturę układu regulacji adaptacyjnej z bieżącą linearyzacją nieliniowego, neuronowego modelu obiektu (ang. *Neural Model Instantaneous Linearization*, NMIL).



Rys. 2. Struktura układu regulacji adaptacyjnej z bieżącą linearyzacją modelu neuronowego

Fig. 2. Adaptive control scheme based on instantaneous linearization of neural model of the plant

Parametry modelu liniowego, uzyskiwane sekwencyjnie w kolejnych punktach pracy w wyniku linearyzacji neuronowego modelu obiektu (np. NNARX), wykorzystywane są do syntezy regulatora, realizującego jeden z klasycznych algorytmów sterowania. Wyniki badań symulacyjnych wskazują na znaczną poprawę jakości sterowania, np. w porównaniu z klasycznym algorytmem regulacji PID [1, 2, 3].


3. Sterowanie rozmyte układem napędowym samochodu osobowego

Charakterystyczną cechą klasycznych metod sterowania jest to, że algorytm sterowania wyrażony jest w sposób analityczny za pomocą równań algebraicznych, różniczkowych, różnicowych, transmitancji, itd. Przeprowadzenie syntezy takiego algorytmu sterowania wymaga sformalizowania ściśle określonego opisu (np. w postaci modelu matematycznego) dynamiki obiektu sterowania. W pracach inspirowanych przez L. Zadeha, E. Mamadaniego i S. Assiliana wprowadzono ideę formułowania algorytmów sterowania za pomocą reguł logicznych, których źródło stanowi wiedza wyspecjalizowanego operatora procesu (eksperta). Dzięki takiemu ujęciu algorytmy sterowania oparte na regułach heurystycznych lub lingwistycznych mogą być wykorzystywane do sterowania złożonymi (trudnymi w opisie) procesami technologicznymi [9, 12]. Narzędziem umożliwiającym ujęcie w sterowaniu sposobu pojmowania i myślenia ludzkiego może być logika rozmyta, natomiast takie sterowanie przyjęło się nazywać rozmytym. Podstawowy paradygmat sterowania rozmytego traktuje zatem algorytm sterowania opartego na metodach logiki rozmytej jako system ekspertowy na bazie wiedzy. Zastosowanie logiki rozmytej w regulatorach przemysłowych pozwala na podejście jakościowe (a nie klasyczne - ilościowe) w sposobie sterowania procesem technologicznym. Godząc się na niedokładność w sposobie opisu procesu, algorytmy rozmyte mogą wykazywać pewną odporność na zmiany parametrów procesu, tym samym wpływając na efektywność sterowania.

3.1. Kierowca – samochód – otoczenie w ujęciu systemowym

Jako przykład sterowania obiektem, w którym istotną rolę odgrywa czynnik ludzki jest oddziaływanie człowieka-kierowcy na elementy wykonawcze układu napędowego samochodu osobowego. Z doświadczenia wynika, że złożone zadanie sterowania samochodowym układem napędowym odpowiednio przygotowany kierowca rozwiązuje stosunkowo dobrze (w przypadku manualnego sterowania układem napędowym). Jednakże długa jazda, zwłaszcza w warunkach miejskich wymaga częstych zmian biegów i nadmiernie absorbuje kierującego samochodem, który w konsekwencji jest niezdolny do wysokiej koncentracji i „bezbłędne” sterowanie układem napędowym. Jako dodatkową przeszkodę w sterowaniu należy również wskazać fakt niewystarczającego stanu wiedzy przeciętnego kierowcy o istotnych czynnikach, wywierających wpływ na właściwości dynamiczne, energetyczne i ekologiczne układu napędowego. Wpływ powyższych czynników na parametry sterowania układem napędowym sprawia, że coraz bardziej atrakcyjne stają się układy sterowane automatycznie, oparte na jakościowo nowych algorytmach sterowania, z wykorzystaniem metod ekspertowych oraz nowoczesnych układów mechatronicznych (np. przekładni o przełożeniu zmiennym w sposób ciągły - CVT). Tym samym widoczna jest tendencja do wyeliminowania bezpośredniego oddziaływania kierowcy na parametry pracy jednostki napędowej (silnika, elementów nastawczych) oraz układu przeniesienia napędu. Rola kierowca sprowadza się do kontrolowania prędkości (względnie przyspieszenia) oraz kierunku jazdy [8].

W samochodzie osobowym, traktowanym jako jeden system (rys. 3), wyróżnić można następujące elementy: proces myślowy kierowcy (wpływający na żądaną moc na kołach samochodu) oraz układ przeniesienia napędu (UPN), oddziałujący z określoną sprawnością na jakość przetwarzania energii w układzie napędowym (UN).

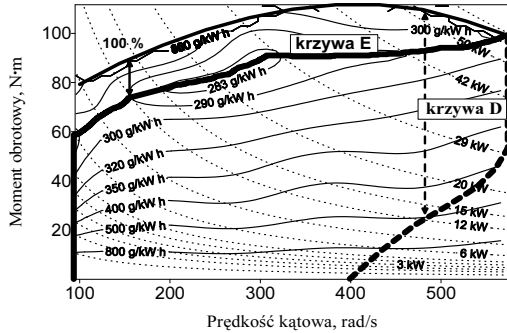


Rys. 3. Układ: kierowca – samochód – otoczenie w ujęciu systemowym
Fig. 3. The driver, car and environment as one system

Źródłem energii w systemie jest silnik, charakteryzujący się określonymi stratami w procesie przemiany strumienia energii chemicznej (dostarczanej z paliwem) w moc mechaniczną. O wielkości tych strat decyduje układ przeniesienia napędu, determinujący przełożenie kinematyczne pomiędzy silnikiem a kołami samochodu oraz dopasowujący charakterystyki silnika do potrzeb związanych z ruchem samochodu w obecności zakłóceń pochodzących z otoczenia. Sposób efektywnego sterowania takim systemem polega na jednoczesnym oddziaływaniu (w sposób zintegrowany) na te elementy, które mają istotny wpływ na polepszenie sprawności energetycznej (ogólnej) UN. W rozważanym systemie elementami tymi są: przepustnica, określająca stopień zasilania silnika oraz przekładnia o przełożeniu w sposób ciągły, determinująca przełożenie w UPN.

Jednym z elementów przedstawionego systemu jest silnik spalinowy o zapłonie iskrowym (ZI), stanowiący podstawową jednostkę napędową w samochodzie osobowym. Sterowanie takim silnikiem wymaga rozwiązania szeregu problemów związanych z zapewnieniem odpowiedniej mocy na kołach. Trudności

w sterowaniu silnikiem wynikają m.in. z ograniczonego przedziału wartości momentu obrotowego i prędkości kątowej wału korbowego oraz innych wskaźników charakteryzujących stan pracy jednostki napędowej (rys. 4). Układ napędowy jest bowiem elementem złożonego układu energetycznego, a sposób jego sterowania wywiera znaczący wpływ na własności ruchowe samochodu, sprawność energetyczną i emisję substancji szkodliwych.



Rys. 4. Charakterystyka ogólna silnika doświadczalnego
Fig. 4. The general characteristic of experimental car engine


Przyjęcie określonego punktu pracy na charakterystyce ogólnej silnika (rys. 4) ze względu na uzyskiwaną sprawność wyznacza zbiór punktów należących do krzywych: E (duża sprawność, niekorzystne własności dynamiczne) oraz D (duża dynamika, wysokie zużycie paliwa). Zatem zasadniczy problem w sterowaniu układem napędowym sprowadza się do pogodzenia sprzeczności, zachodzącej pomiędzy tzw. sterowaniem efektywnym (ekonomicznym), zapewniającym minimalne zużycie paliwa oraz ograniczającym emisję substancji szkodliwych a sterowaniem dynamicznym, które zapewni odpowiednie własności dynamiczne samochodu [10].

3.2. Zintegrowane sterowanie rozmyte układem napędowym

Stosowane dotychczas algorytmy sterowania układem napędowym, dla których jedynym kryterium jakości działania była sprawność energetyczna osiągnięta w quasi-ustalonym stanie pracy, nie pozwalały na uzyskanie efektywnego rozwiązania. Konieczne było nowe podejście uwzględniające stany dynamiczne, a kluczem do rozwiązania problemu może być tzw. sterowanie zintegrowane układem napędowym, przy szczególnym uwzględnieniu wiedzy eksperckiej. W tradycyjnym układzie sterowania układem napędowym wychylenie pedału przyspieszenia jest wprost powiązane ze stopniem zasilania silnika (uchyleniem przepustnicy). Zadaniem tego układu jest regulacja wyłącznie prędkości kątowej silnika według funkcji $\omega=f(\Theta)$, wynikającej z przebiegu wybranej krzywej pracy w obszarze charakterystyki ogólnej silnika. Zadanie regulacji jest realizowane najczęściej za pomocą regulatora typu PI bądź PID. W ustalonych warunkach pracy jakość działania takiego układu regulacji jest zadowalająca. Jednak w przypadku szybkich zmian zapotrzebowania mocy działanie układu staje się nieefektywne. Powodem tego jest niedostateczny strumień energii doprowadzony do kół napędzanych, pomniejszony wskutek akumulacji energii mechanicznej w ruchomych częściach związanych z wałem korbowym silnika.

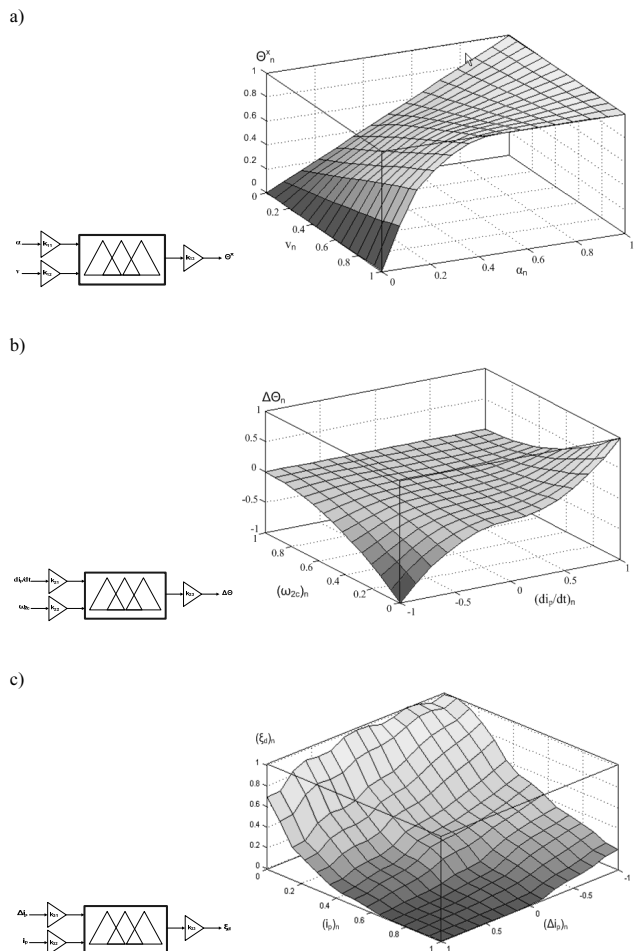
Układ napędowy samochodu osobowego jest elementem złożonego układu energetycznego, a sposób jego sterowania wywiera znaczący wpływ na wskaźniki pracy. W tym rozumieniu zintegrowany algorytm sterowania rozmytego (ESTFC) powinien bazować na związkach przyczynowo-skutkowych, występujących pomiędzy elementami układu napędowego, kierowcą samochodem oraz otoczeniem [10]. W proponowanym układzie sterowania zintegrowanego UN podstawową wielkością wejściową jest wychylenie pedału przyspieszenia, natomiast wprowadzenie do ukła-

du sterowania regulatorów rozmytych, zastępuje zachowanie i oddziaływanie kierowcy na UN (rys. 5).



Rys. 5. Idea zintegrowanego sterowania rozmytego samochodowym układem napędowym
Fig. 5. The idea of fuzzy control system of car powertrain

Z punktu widzenia UN wymagana moc na kołach jest ściśle określona wyłącznie w przypadku śledzenia zadanego profilu prędkości. Stąd wniosek, że zapotrzebowanie mocy na kołach samochodu nie jest jednoznacznie określone i nie musi, w sposób zdeterminowany, wynikać z położenia pedału przyspieszenia. To spostrzeżenie stało się podstawą interpretacji sterującego działania kierowcy w nowy, odmienny sposób. W oparciu o przedstawiony wyżej opis sposobu działania układu napędowego i przyjęte założenia, wynikające z wiedzy eksperta, umożliwiły realizację bloków (regulatorów) rozmytych odpowiedzialnych za sterowanie stopniem zasilania silnika i przełożeniem w układzie napędowym (ilorazem sił naporu na koła pasowe przekładni CVT) (rys. 6) [9].




Rys. 6. Bloki rozmyte oraz ich powierzchnie sterowania: statyczny (a) oraz dynamiczny (b) stopień zasilania silnika, (c) iloraz sił naporu w CVT
Fig. 6. The fuzzy controllers for engine supply a), b) and transmission unit c)

Z uwagi na niekorzystny przebieg procesu przejściowego (odczuwalne szarpnięcia), zaproponowano zastąpienie regulacji przełożenia przekładni CVT za pomocą regulatora PI, regulatorem rozmytym. Sterując bowiem prędkością zmiany przełożenia przekładni CVT można wpływać na proces akumulacji energii w rozpatrywanym układzie napędowym. Blok rozmyty, określający iloraz sił naporu w kołach przekładni CVT w zależności od przełożenia i jego zmiany przedstawiono na rys. 6 [9].

3.3. Badania algorytmów sterowania układem napędowym

Badania, oceniające działanie zastosowanych tradycyjnych algorytmów sterowania (ESR-E i ESR-D) oraz zintegrowanego sterowania rozmytego (ETSFC), przeprowadzono metodą symulacji komputerowej, w oparciu o cykle jezdne, stosowane w badaniach homologacyjnych pojazdów. Ilościowe porównanie wybranych wskaźników energetyczno-ekologicznych w cyklach jezdnych przedstawiono na rys. 7 [9].



Rys. 7. Ilościowe porównanie wskaźników energetyczno-ekologicznych w cyklach jezdnych

Fig. 7. The comparison of Q_v , CO, HC and NO_x emissions for ESR-E, ESR-D and ETSFC strategy

Uzyskane oceny rozpatrywanych wskaźników energetyczno-ekologicznych wskazują na to, że zastosowanie algorytmu ETSFC w układzie napędowym, zapewnia mniejsze zużycie paliwa, jak również mniejszą emisję substancji szkodliwych do środowiska, w porównaniu do układów napędowych o tradycyjnym sterowaniu (ESR-E, ESR-D).

W ramach badań symulacyjnych przeprowadzono dodatkowo ocenę sprawności energetycznej w każdym z cykli jezdnych, rozumianej jako iloraz energii dostarczonej w odniesieniu do energii dostarczonej z paliwem. Uzyskane wyniki (tab. 1) wskazują, że algorytm ETSFC zapewnia największą sprawność energetyczną procesu przetwarzania energii w UN [9, 10, 11].

Tab. 1. Sprawność energetyczna UN w cyklach jezdnych
Tab. 1. The power efficiency of car powertrain in driving cycles

Algorytm	Cykl UDC	Cykl EUDC	Cykl FTP
ESR-E	6,84 %	13,12 %	7,44 %
ESR-D	4,52 %	8,15 %	4,82 %
ETSFC	7,27 %	13,12 %	8,29 %

3.4. Wniosek końcowy

Przedstawiona idea sterowania rozmytego oparta na wiedzy eksperckiej jest przykładem jakościowo nowego podejścia w dziedzinie syntezy algorytmów sterowania UN. Autonomiczny charakter tego sterowania, polegający na ograniczeniu oddziały-

wania kierowcy na elementy wykonawcze UN oraz wykorzystanie metod opartych na sztucznej inteligencji, może znacząco wpływać na uzyskanie lepszej sprawności energetycznej w układzie. Wykazana efektywność działania zintegrowanego sterowania rozmytego w UN, polegająca na ograniczeniu zużycia paliwa oraz emisji substancji szkodliwych, stwarza możliwość implementacji opracowanego rozwiązania we współcześnie produkowanych samochodach.

4. Podsumowanie

Celem artykułu nie było przedstawienie wyczerpującego studium problemu, lecz zwrócenie uwagi na możliwości praktycznego wykorzystania metod opartych na sztucznych sieciach neuronowych i logice rozmytej w zagadnieniach automatyki. Pokazano wybrane rezultaty prac doktorskich zrealizowanych w ramach prezentowanej tematyki [1, 9, 12]. Prace te dotyczyły zastosowań sztucznej inteligencji w rozwiązywaniu zadań identyfikacji, modelowania i sterowania obiektami przemysłowymi. W szczególności opracowano algorytmy optymalizacji pracy systemów grzewczych, samochodowego układu napędowego oraz układu napędowego hutniczego dużej mocy.

5. Literatura

- [1] Bartecki K.: Zastosowanie algorytmów neuronowych do optymalizacji pracy systemów grzewczych. Rozprawa doktorska, Politechnika Opolska, Wydział Elektrotechniki i Automatyki, Opole, 2004, (promotor: dr hab. inż. R. Rojek).
- [2] Bartecki K., Rojek R.: Neuronowo-adaptacyjne sterowanie procesem wymiany ciepła. Materiały XV Krajowej Konferencji Automatyki, Warszawa, 27-30 VI 2005, tom 3, ss. 187-192.
- [3] Bartecki K., Rojek R.: Instantaneous linearization of neural network model in adaptive control of heat exchange process. 11th IEEE International Conference on Method and Model Automation and Robotics, 29.08 – 01.09 2005, Międzyzdroje, pp. 967-972.
- [4] Korbicz J., Obuchowicz A., Uciński D.: Sztuczne Sieci Neuronowe. Podstawy i zastosowania. AOW, W-wa, 1994.
- [5] Ng G.W.: Application of Neural Networks to Adaptive Control of Nonlinear Systems. Control Systems Centre UMIST, 1997.
- [6] Nørgaard M., Ravn O., Poulsen N.K., Hansen L.K.: Neural Networks for Modelling and Control of Dynamic Systems. Springer, London, 2000.
- [7] Rojek R., Bartecki K., Korniak J.: Zastosowanie sztucznych sieci neuronowych i logiki rozmytej w automatyce. Praca zbiorowa pod redakcją R. Rojka. Skrypt Politechniki Opolskiej nr 234, Opole.
- [8] Jantos J.: Zintegrowane sterowanie samochodowym, spalinowym układem napędowym o przełożeniu zmiennym w sposób ciągły, Studia i Monografie, z.141, Oficyna Wydawnicza, Politechnika Opolska, Opole, 2003.
- [9] Korniak J.: Racjonalizacja pracy układu energetycznego samochodu osobowego z wykorzystaniem logiki rozmytej. Rozprawa doktorska, Politechnika Opolska, Wydział Elektrotechniki i Automatyki, Opole, 2005, (promotor: dr hab. inż. R. Rojek).
- [10] Korniak J., Rojek R.: Aspekt energetyczny sterowania rozmytego samochodowym układem napędowym. Materiały XV Krajowej Konferencji Automatyki, Warszawa, 27-30 VI 2005, tom 3., 279-284.
- [11] Korniak J., Rojek R.: A fuzzy logic approach to powertrain control of a passenger car. 11th IEEE International Conference on Method and Model Automation and Robotics, 29.08 – 01.09 2005, Międzyzdroje, Poland.
- [12] Olesiak K.: Badania modelowe napędu hutniczego dużej mocy z wykorzystaniem logiki rozmytej. Rozprawa doktorska, Politechnika Częstochowska, Wydział Elektryczny, Częstochowa, 2003, (promotor: dr hab. inż. R. Rojek).