

ANDRZEJ AUGUSTYNOWICZ

Modelowanie typu kierowcy samochodu

Opole 2009

SPIS TREŚCI

Wykaz oznaczeń.....	5
Wykaz skrótów.....	7
1. Wprowadzenie.....	9
2. Przedmiot pracy.....	13
2.1 Geneza problemu.....	13
2.2 Cel i zakres pracy.....	13
3. Estymacja typu kierowcy w samochodzie wyposażonym w układ regulacji prędkości i odstęp.....	15
3.1 Tradycyjne modele matematyczne.....	16
3.2 Model neuronowy Kraissa.....	18
3.3 Model rozmyty Protzela.....	20
4. Adaptacyjne sterowanie zespołem napędowym.....	25
4.1 Typ kierowcy jako kryterium wyboru przełożenia.....	27
4.2 System INVECS.....	28
4.3 System TCU-DRV.....	30
4.4 System identyfikacji stylu kierowcy w samochodzie z napędem hybrydowym.....	31
5. Przykłady modelowania kierowcy technikami sztucznej inteligencji ...	35
5.1 Sterowanie prędkością samochodu oparte na logice rozmytej.....	38
5.2 Badania układu sterowania ogranicznika prędkości samochodu metodą symulacji komputerowej.....	38
5.3 Zastosowanie algorytmu genetycznego do strojenia regulatora rozmytego.....	44
6. Klasyfikacja typu kierowcy metodą rankingu.....	49
6.1 Badania drogowe.....	49
6.2 Budowa rankingu.....	51
6.3 Wyniki rankingu.....	52
7. Analiza sygnału generowanego pedałem przyspieszenia.....	57
7.1 Profil prędkości - efekt działania kierowcy.....	58
7.2 Analiza częstotliwościowa sygnału generowanego pedałem przyspieszenia.....	59
8. Estymacja i klasyfikacja typu kierowcy.....	65
8.1 Klasyfikator neuronowy.....	65
8.1.1. Rekurencyjne sieci neuronowe.....	67
8.1.2. Struktura rekurencyjnej sieci typu Elmana.....	69
8.1.3. Klasyfikator neuronowy typu kierowcy.....	70
8.1.4. Ocena działania klasyfikatora neuronowego.....	78
8.2 Klasyfikator falkowy.....	78
8.2.1. Definicje i własności transformaty falkowej.....	78

8.2.2.	Analiza falkowa sygnału pedału przyspieszenia.....	83
8.2.3.	Falkowy klasyfikator typu kierowcy	90
8.2.4.	Ocena działania klasyfikatora falkowego	92
8.3	Klasyfikator chaotyczny typu kierowcy	93
8.3.1.	Wymiar fraktalny szeregu czasowego	93
8.3.2.	Rekonstrukcja przestrzeni fazowej szeregu czasowego ...	95
8.3.3.	Wymiar korelacyjny sygnału pedału przyspieszenia	97
8.3.4.	Interpretacja graficzna uzyskanych wyników.....	104
9.	Koncepcja systemu kompleksowej oceny pracy kierowcy samochodu ciężarowego.....	109
10.	Podsumowanie	113
	Literatura.....	115
	Streszczenia	127

WYKAZ OZNACZEŃ

a_R, a_D	– rzeczywiste, docelowe przyspieszenie wzdłużne samochodu, m/s^2
$C(R)$	– całka korelacyjna
CTF_f	– ciągła transformata falkowa
D	– wymiar korelacyjny
d	– wymiar przestrzeni stanu
de	– zmiana uchybu, m/s
E	– funkcja błędów sieci neuronowej
e	– uchyb między prędkością zadaną a prędkością pojazdu, $km/h, m/s$
f	– częstotliwość, Hz
i	– liczba obiektów
i_b	– przełożenie skrzyni biegów
j	– liczba zmiennych syntetycznych
F_n	– siła napędowa, N
F_{op}	– sumaryczna siła oporów ruchu, N
$H(x)$	– funkcja Heaviside'a
I	– wskaźnik jakości funkcji celu
$K(\tau)$	– funkcja autokorelacji
K_p, K_I	– parametry regulatora
k_d, k_v	– współczynniki wagowe: odstepu, prędkości, s^{-1}
$\max x_{ij}$	– największa realizacja danego kryterium w analizowanym zbiorze
$\min x_{ij}$	– najmniejsza realizacja danego kryterium w analizowanym zbiorze
M	– moment obrotowy, $N\cdot m$
M_e	– moment użyteczny silnika, $N\cdot m$
m	– przesunięcie okna czasowego, s
n	– prędkość obrotowa silnika, obr/min
Q_i	– wartość zmiennej syntetycznej
$p_s(t)$	– funkcja położenia pedału przyspieszenia
s	– skala
t	– czas, s
t_R	– czas reakcji, s
u_p	– wejście neuronu
v	– prędkość liniowa samochodu, km/h
v_R, v_D	– rzeczywista, docelowa prędkość liniowa samochodu, km/h
v_F, v_L	– prędkość liniowa samochodu śledzącego, poprzedzającego, km/h
W_{ij}	– macierz połączeń synaptycznych
w_p	– waga synaptyczna
$X(n,k)$	– krótkoczasowa transformata Fouriera sygnału dyskretnego
$X(t,f)$	– krótkoczasowa transformata Fouriera sygnału ciągłego

x_{ij}	– zmienna diagnostyczna
z_{ij}	– unormowana zmienna diagnostyczna
Y, x	– odstęp, m
α	– położenie pedału przyspieszenia, %
$d\alpha$	– zmiana położenia pedału przyspieszenia %/s
λ	– współczynnik korygujący (stała regulacyjna), k/s ²
$\mu(x)$	– funkcja przynależności
$\psi(t)$	– falka podstawowa
τ	– przesunięcie czasowe, s
ω	– prędkość kątowna wału korbowego, rad/s

WYKAZ SKRÓTÓW

ACC	– Adaptive Cruise Control, adaptacyjna regulacja prędkości jazdy
AGS	– Adaptive Getriebesteuerung, adaptacyjne sterowanie skrzynką biegów
All-Shift	– system stosowany w samochodach Lexus, modyfikujący sposób zmiany przełożeń w oparciu o zachowanie kierowcy oraz warunki na drodze
Brake by Wire	– elektroniczny pedał hamulca
CVT	– Continuously Variable Transmission, przekładnia o przełożeniu zmiennym w sposób ciągły
Distronic	– komputerowy system Mercedesa pomagający utrzymać bezpieczny odstęp od poprzedzającego pojazdu zarówno podczas jazdy z włączonym tempomatem, jak i bez niego
DFT	– Discrete Fourier Transform, dyskretna transformata Fouriera
Drive by Wire	– elektroniczny pedał przyspieszenia
DSI	– Driver Style Identifier, identyfikator stylu jazdy
DSP	– Dynamisches Schaltprogramm, dynamiczny program przełączania biegów w skrzyni automatycznej
EGS	– Elektronische Getriebe Steuerung, elektroniczna skrzynia biegów
FFT	– Fast Fourier Transform, szybka transformata Fouriera
FLC	– Fuzzy Logic Control, Regulator rozmyty
FNN	– False Nearest Neighbour metod, metoda najbliższych fałszywych sąsiadów
INVECS	– Intelligent & Innovative Vehicle Electronic Control System, system automatycznej skrzyni biegów firmy Mitsubishi.
Kickdown	– przełączenie biegu na najniższy możliwy przy danej prędkości jazdy po gwałtownym naciśnięciu pedału przyspieszenia do położenia końcowego
PELOPS	– Program for the dEvelopment of Longitudinal micrOscopic traffic Processes in a Systemrelevant environment, program badawczy Instytutu Pojazdów w Aachen w Niemczech
PSD	– Power Spectral Density, widmowa gęstość mocy

SJ	– estymator stylu jazdy
Steer by Wire	– elektroniczny układ kierowniczy
STFT	– Short Time Fourier Transform, krótkoczasowa transformata Furiera
TCU-DRV	– Transmission Control Unit – Driver Route Vehicle, system automatycznej skrzyni biegów firmy BMW i Technical University of Braunschweig
Tempomat	– system utrzymywania stałej prędkości jazdy bez potrzeby naciskania na pedał przyspieszenia
WJ	– wskaźnik jazdy
WT	– Wavelet Transform, transformata falkowa
X-by-Wire	– układ sterowany elektronicznie

1. WPROWADZENIE

Stale narastające wymagania w stosunku do sterowania coraz większą liczbą układów współczesnego samochodu wynikają z takich celów jak: zmniejszanie poziomu toksyczności emitowanych spalin i zużycia paliwa, podnoszenie bezpieczeństwa i komfortu jazdy kierowcy oraz jadących z nim osób, poprawianie właściwości manewrowych i jezdnych samochodu [19, 25, 50, 70-78, 118, 144].

W przypadku modernizacji systemów automatycznego kierowania pojazdami wyraźnie widoczna jest rozwijająca się tendencja zastępowania układów mechanicznych układami "X-by-Wire", które odbierają polecenia kierowcy za pomocą czujników, dokonujących elektronicznej obróbki sygnałów i przekazujących polecenia dalej do poszczególnych elementów wykonawczych. Realizowanym obecnie coraz powszechniej systemem jest "Drive by Wire" - elektroniczny pedał gazu [32, 128, 129, 139, 140, 142].

Również w dziedzinie układów hamulcowych oraz układów kierowniczych szereg firm intensywnie pracuje nad systemami elektronicznymi, takimi jak "Steer by Wire" i "Brake by Wire", które stanowią podstawę dla rozwoju nowych funkcji zwiększających bezpieczeństwo i komfort jazdy. Systemy X-by-Wire umożliwiają pożądane skoordynowanie działania układu kierowniczego pojazdu z dynamiką pracy układu hamulcowego, a także stwarzają dodatkowe możliwości integracji z innymi funkcjami podwozia, a nawet całego pojazdu. Nadto systemy te, w pełni programowalne, dają możliwość optymalizacji właściwości manewrowych i jezdnych samochodu oraz funkcji bezpieczeństwa aktywnego, jak kontrola stabilności ruchu pojazdu [128, 129, 142].

Działania człowieka zachodzące w środowisku naturalnym przy wykorzystaniu urządzenia technicznego jakim jest samochód, są wzajemnie powiązane. Te powiązania można zobrazować analizując system człowiek - pojazd - środowisko. Wiele prac poświęconych jest próbom analizy takiego systemu przy wykorzystaniu techniki komputerowej. Potrzebny jest do tego celu odpowiedni model matematyczny. Aby jednak wyniki analizy były prawdziwe, nie tylko w odniesieniu do zastosowanego modelu, ale również mogły być przeniesione do realnie występujących sytuacji, sformalizowany opis musi być adekwatny do rzeczywistości [145, 158].

Najłatwiejszy do sformalizowanego opisu tego systemu jest pojazd. W literaturze można znaleźć wiele modeli matematycznych dobrze opisujących właściwości pojazdów [40, 42, 44, 49, 51, 52, 66, 67, 108, 157, 161]. Nieco trudniejsze jest matematyczne ujęcie wpływu otoczenia na system [2, 57, 61, 109, 122, 127, 145, 153, 156].

Reagowanie i podejmowanie decyzji na drodze, tego samego kierowcy, w podobnych sytuacjach drogowych może być różne. Dlatego szczególnie ważny jest problem budowy sformalizowanego modelu kierowcy, jeśli chce się poprawnie sterować pojazdem czy też analizować sytuacje na drodze przy zastosowaniu symulacji komputerowych. Jak wynika z analizy literaturowej, działanie kierowcy najtrudniej jest opisać w sposób sformalizowany [57÷63, 65, 68, 69, 81, 83, 91, 92, 95, 96, 101, 106, 109, 115, 122, 127, 145, 146, 151, 152, 156, 158].

Dotychczas stosowane modele kierowców, wykorzystywane w symulacjach ruchu pojazdu, są w zasadzie członami układu sterowania, który może realizować określoną strategię ruchu. Modele takie nie uwzględniają całego bogactwa możliwych reakcji kierowcy w różnych warunkach ruchu i warunkach pracy samego obiektu sterowania, jakim jest samochód. Są więc niewystarczające do pełnej analizy systemu człowiek – pojazd – środowisko.

Różnorodność prezentowanych w literaturze modeli kierowcy jest pochodną wielości obszarów, w jakich mają być one wykorzystywane [79, 124, 127, 158]. Pierwszy z tych obszarów to obszar projektowania i wstępnych badań własności samochodu. Szczegółowymi zagadnieniami rozwiązywanymi w tym zakresie są:

1. Doskonalenie konstrukcji samochodów - analizy działania układu kierowniczego, jezdnego, zawieszenia metodami symulacji komputerowej, pozwalającymi prowadzić wiele badań już w fazie projektowania, które dawniej były prowadzone w fazie badań prototypów.
2. Tworzenie modeli, które uzupełniając model pojazdu umożliwiają analizę; wpływu bocznego wiatru na stateczność samochodu, przebiegu procesu hamowania uwzględniającego również m.in. czas reakcji kierowcy, wyboru prędkości jazdy, zależnej od subiektywnej oceny kierującego i jego sposobu reagowania.

Drugim obszarem, który stworzył zapotrzebowanie na rozwój i analizę modeli kierowcy, są programy badawcze. Zadaniem programów jest tworzenie różnorodnych systemów sterowania ruchem samochodu z perspektywnym celem tworzenia automatycznego pilota dla samochodu. Etap pośredni dla realizacji tego celu to systemy asystujące, które nie przejmują roli decyzyjnej od człowieka, a jedynie wspomagają jego działania korygując lub ograniczając manewry, które człowiek wykonywałby w sposób daleki od optymalnego. Wszystkie te systemy wymagają w jakimś zakresie uwzględnienia zachowania kierowcy, czyli tworzenia jego pewnych modeli.

Prace badawcze zmierzające do automatyzacji ruchu pojazdów bazują na dwóch koncepcjach [127]:

- a) wyposażenia dróg w systemy sterowania ruchem pojazdów.
- b) przystosowania pojazdów do automatycznego ruchu po normalnych drogach. Koncepcja ta wymaga zastąpienia w jak największym stopniu funkcji realizowanych dotychczas przez kierowcę, tzn.:

- ustalenia pozycji pojazdu w stosunku do drogi i innych użytkowników ruchu,
- utrzymywania bezpiecznego dystansu w stosunku do pojazdu poprzedzającego,
- utrzymywania pojazdu na torze jazdy,
- rozpoznawania znaków drogowych i reagowanie na nie,
- rozpoznawania innych obiektów, które pojawiają się na drodze i reagowanie na nie.

W przeciwieństwie do dwóch poprzednio wskazanych obszarów zastosowań, które są związane ze sferą tworzenia konstrukcji samochodu, trzeci obszar dotyczy sfery eksploatacji samochodu i umożliwia aranżowanie zaawansowanych programów symulacyjnych na przykład do symulacji ruchu samochodu w warunkach ekstremalnych, które z powodzeniem służą do odtwarzania przebiegu wypadków drogowych.

Niestety większość modeli kierowcy jest tylko podobna do modeli opisujących reguły ludzkich czynności. Tylko w rzadkich przypadkach jest możliwe jednoznaczne zapisanie zachowania człowieka matematycznymi metodami liniowej teorii regulacji. Działanie człowieka - kierowcy jest na ogół bardziej złożone. Ta złożoność jest główną przyczyną tego, iż stworzenie w miarę pełnego modelu kierowcy mającego wszechstronne zastosowania jest celem dosyć odległym. Na dzisiaj tworzone są modele cząstkowe ukierunkowane na określone zastosowania. Stąd taka ich różnorodność.

Jednym z kryteriów podziału modeli kierowcy, spotykanych w literaturze [109, 156, 157], może być podział na modele jakościowe i ilościowe.

Modele jakościowe - opisują w sposób niesformalizowany matematycznie zachowanie kierowcy, jego sposób działania w poszczególnych sytuacjach. Modele jakościowe dają wartościowe wskazania dla strukturalnej złożoności zachowania kierowcy w procesie kierowania samochodem. Dla przykładu: przedstawiają wskazania dla wyboru prędkości albo wyboru odstępów w stosunku do krawędzi jezdni itp. Ogólnie modele te tworzone są w celu werbalnego opisywania i objaśnienia rzeczywistości.

Modele ilościowe - to modele, których zadaniem jest realizowanie określonego ruchu samochodu, bez względu na to, czy jest to mechanizm działania zbliżony do zachowań kierowcy, czy też nie. Modele te opisują działanie człowieka w sposób mechanistyczny, traktując go najczęściej jako pewien układ automatycznej regulacji. Zaletą tych modeli jest sformalizowany matematycznie zapis działania kierowcy, co daje możliwość praktycznego wykorzystania w różnych działaniach technicznych.

Innym sposobem podziału jest podział na modele oparte na strategii funkcji opisu (kompensacyjne) oraz modele oparte na antycypacji [156].

Modele kompensacyjne to takie, które działają na zasadzie likwidowania błędów, na przykład położenia samochodu względem nakazanego toru ruchu. W modelach tych kierowca nie przewiduje dalszego rozwoju wypadków.

Zajmuje się jedynie na bieżąco takim działaniem, aby tor ruchu pojazdu możliwie mało odbiegał od toru zamierzonego. Dlatego też modele kompensacyjne nie mogły być zastosowane w wielu manewrach, ponieważ nie uwzględniały tego, że kierowca rozgląda się po otoczeniu i na tej podstawie określa strategię dalszego swojego działania.

Ograniczenia tego nie mają modele antycypacyjne, zwane w niektórych publikacjach modelami predykcyjnymi. Strategia przyjęta w tych modelach polega na kompensacji błędu położenia, ale na podstawie położenia przewidywanego w najbliższej przyszłości. Jednym z parametrów takiego modelu jest odcinek antycypacji (obserwacji) lub czas antycypacji. W czasie ruchu pojazdu istnieje ścisła zależność pomiędzy tymi wartościami.

Powstawanie modeli antycypacyjnych było swoistą reakcją na fakt, że modele kompensacyjne źle się sprawdzały w próbach wykorzystania do automatycznego kierowania samochodem. Dostrzeżono, że kierowca działa uprzedzająco, czyli antycypuje przyszłą sytuację. Jednakże mimo takiego działania kierowcy, tor ruchu samochodu w wyniku działania czynników zewnętrznych może podlegać odchyleniu. Kierowca w takich przypadkach podejmuje działanie mające na celu skompensowanie tego odchylenia. Zatem, jeżeli to możliwe, projektuje się modele mieszane.

2. PRZEDMIOT PRACY

2.1. GENEZA PROBLEMU

Zagadnieniem o charakterze bardziej szczegółowym, któremu ostatnio poświęca się sporo uwagi, jest modelowanie właściwości kierowcy. Złożoność jego zachowania oraz duża liczba czynników zewnętrznych na nie wpływających jest główną przyczyną tego, że stworzenie pełnego, mającego szersze zastosowanie modelu kierowcy jest celem dość odległym. Z tego względu zagadnienie to często ogranicza się do jednego z wybranych aspektów tego modelu, ujmującego najistotniejsze cechy kierowcy, jak np. styl czy technika prowadzenia pojazdu.

Właściwa analiza sygnałów, poprzez które prowadzący oddziałuje na samochód, daje możliwość rozpoznania typu kierowcy i stosowną interpretację jego zachowań w różnych sytuacjach drogowych. Na podstawie tych informacji system sterowania będzie mógł wybierać najbardziej korzystny algorytm sterowania i związane z nim parametry pracy silnika oraz przekładni, dostosowując się jednocześnie do oczekiwań prowadzącego [2, 6, 7, 9, 11-17, 20-24, 57, 61, 105, 122, 148, 153, 160].

Obecnie można wyodrębnić trzy obszary zainteresowań w kwestii sterowania samochodem, których strategie uwzględniają rozpoznawanie i ocenę typu kierowcy. Dziedzinami tymi są :

- elektroniczne sterowanie skrzynią biegów,
- adaptacyjna regulacja prędkości jazdy,
- elektroniczne zarządzanie źródłami energii w samochodach z napędem hybrydowym.

2.2. CEL I ZAKRES PRACY

Dokonując przeglądu literatury dotyczącej estymacji typu kierowcy stwierdzono, że liczba publikacji dotyczących tego problemu jest stosunkowo niewielka. Uznano zatem za celowe uzupełnienie dostępnej na ten temat wiedzy.

Celem pracy jest zdefiniowanie estymatorów identyfikujących styl jazdy kierowcy samochodu. Zaprezentowane metody estymacji opisano wybranymi narzędziami matematycznymi, takimi jak sieć neuronowa, transformata falkowa oraz wykorzystywany w teorii chaosu wymiar fraktalny.

W rozdziale trzecim przedstawiono wybrane z literatury modele kierowcy opisujące zachowanie kierowcy jako operatora, decydującego o charakterze profilu prędkości kierowanego pojazdu. Wskazano na stosowanie przez badaczy

do opisu modeli najnowszych metod matematycznych opartych na sieciach neuronowych czy też zbiorach rozmytych.

W rozdziale czwartym zaprezentowano kilka przykładów praktycznego wykorzystania modelu kierowcy opisującego jego styl jazdy do sterowania pracą zespołem napędowym. Przytoczone przykłady dotyczą zarówno sterowania adaptacyjnego ograniczającego się jedynie do doboru przełożenia w skrzyni biegów, a także strategii zarządzania źródłami energii w samochodzie z napędem hybrydowym.

Rozdział piąty zawiera przykłady własne autora wykorzystane do modelowania kierowcy technikami sztucznej inteligencji. Należy do nich ogranicznik wybranej przez kierowcę prędkości samochodu, oparty na logice rozmytej. Dodatkowo zaprezentowano strojenie rozmytego regulatora prędkości jazdy przy użyciu algorytmu genetycznego.

Rozdział szósty stanowi propozycję sklasyfikowania zbadanych przez autora kierowców pod względem ich typu, stosowaną powszechnie w badaniach operacyjnych metodą rankingu. Podstawą wykonanego rankingu były zarejestrowane w ramach badań drogowych przebiegi czasowe wybranych parametrów ruchu samochodu, a także reakcje nim kierujących na pedale przyspieszenia.

W rozdziale siódmym dokonano analizy sygnału generowanego pedałem przyspieszenia. Wykazano, że gęstość widmowa mocy (PSD) funkcji przyspieszenia pedału przyspieszenia może być parametrem służącym do oceny sposobu jazdy kierowcy.

Rozdział ósmy stanowi oryginalne osiągnięcie autora, bowiem przedstawia trzy metody estymacji typu kierowcy. Pierwsza z nich to estymacja przy zastosowaniu rekurencyjnej sieci neuronowej typu Elmana. W metodzie drugiej zaproponowano transformatę falkową do estymacji opartej na przebiegu sygnału generowanego pedałem przyspieszenia. W metodzie trzeciej posłużono się zaś teorią chaosu do estymacji typu kierowcy.

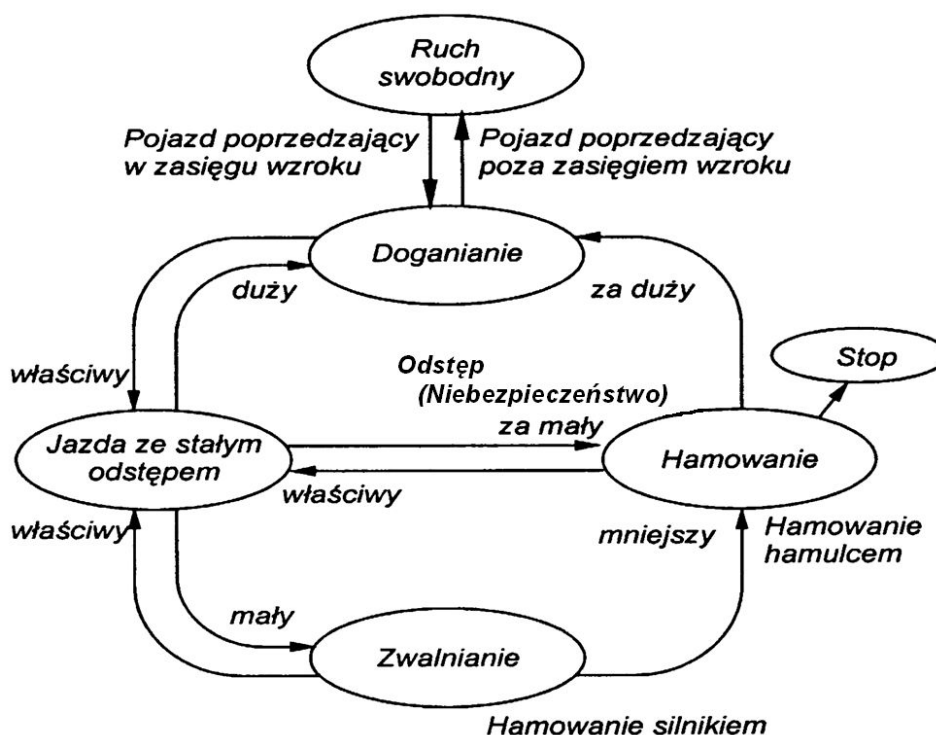
W rozdziale dziewiątym zaproponowano koncepcję kompleksowej oceny pracy kierowcy samochodu ciężarowego obejmującą estymację typu kierowcy.

Rozdział dziesiąty stanowi podsumowanie pracy oraz wykaz osiągniętych celów.

3. ESTYMACJA TYPU KIEROWCY W SAMOCHODZIE WYPOSAŻONYM W UKŁAD REGULACJI PRĘDKOŚCI I ODSTĘPU

Studiowanie zachowań człowieka występującego w charakterze kierowcy rozpoczęło się około 1950 roku i odtąd jest stale rozwijane. Ogólna forma tych pierwszych modeli kierowcy oparta była na założeniu, że każdy kierowca reaguje w ściśle określony sposób na bodźce, które prowadzą do pobudzenia reakcji zmierzających do przyspieszania lub zwalniania kierowanym samochodem [6, 7, 10, 13, 56].

Powodem takiego reagowania mogła być zmiana odstępów od poprzedzającego samochodu lub zmiana warunków otoczenia. W takiej sytuacji kierujący pojazdem podążającym za pojazdem go poprzedzającym próbuje utrzymać zamierzony pomiędzy pojazdami dystans (rys. 3.1).




Rys. 3.1. Algorytm utrzymania odstępów pomiędzy pojazdami [127, 161]

3.1. TRADYCYJNE MODELE MATEMATYCZNE

Typowym przypadkiem, gdy kierowca musi dostosowywać prędkość jazdy do prędkości poprzedzającego go pojazdu i utrzymywać odstęp umożliwiający bezpieczne hamowanie jest jazda w kolumnie. System utrzymywania bezpiecznego odstępu musi precyzyjnie śledzić odstęp pomiędzy pojazdami.

Jak wynika z literatury tematu radarowe systemy śledzące odstęp od pojazdu poprzedzającego, jednocześnie liczące pochodną po czasie jego chwilowej prędkości nie są wystarczające do sprawnego sterowania. Jak ustalono, ważny jest również sposób reagowania kierowcy pedałem przyspieszenia na bieżące decyzje systemu [8, 10, 38].

Zachowanie się kierującego samochodem, który zbliża się do innego użytkownika drogi, jadącego również w tym samym kierunku może być różne. Wynika to z jego temperamentu i preferowanego stylu jazdy. Dlatego też system adaptacyjnej regulacji prędkości jazdy ACC (Adaptive Cruise Control), wzbogacony o możliwość rozróżniania zachowania się kierującego może w sposób adaptacyjny podejmować decyzje o zmianie chwilowej prędkości samochodu (rys. 3.2).



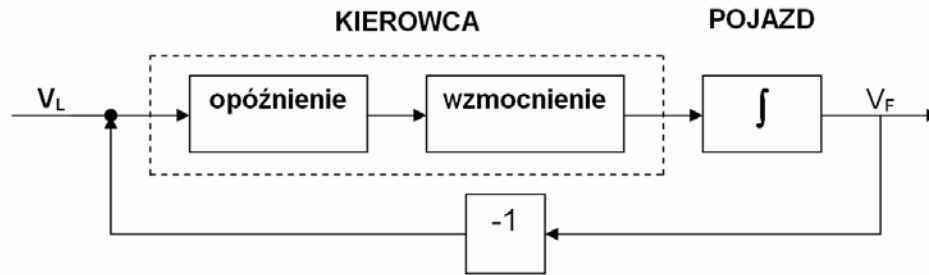
Rys. 3.2. Struktura modelu kierowcy pojazdu śledzącego (Y – odstęp, m) [40]

Przykładowy prosty model matematyczny Chandlera [40], którego schemat przedstawiono na rys. 3.3, opisano zależnością

$$a_F(t) = \frac{\lambda}{m} [V_L(t - t_R) - V_F(t - t_R)], \quad (3.1)$$


gdzie:

- $a_F(t)$ – przyspieszenie samochodu śledzącego, m/s^2 ,
- $a_L(t)$ – przyspieszenie samochodu poprzedzającego, m/s^2 ,
- m – masa pojazdu śledzącego, kg,
- t_R – czas reakcji, s,
- v_F – prędkość samochodu śledzącego, m/s,
- v_L – prędkość samochodu poprzedzającego, m/s,
- λ – stała regulacyjna, kg/s^2 .



Rys. 3.3. Model kierowcy pojazdu śledzącego [34, 40]

Z czasem pojawiło się szereg modeli o coraz większym stopniu skomplikowania. Na stopień skomplikowania niewątpliwie wpływał gwałtowny rozwój elektroniki powiązanej z wytwarzaniem i programowaniem regulatorów. W ramach programu PELOPS (**P**rogram for the **d**Evelopment of **L**ongitudinal **m**icro**S**copical traffic **P**rocesses in a **S**ystemrelevant environment) został opracowany hierarchiczny regulator, którego strukturę przedstawiono na rys. 3.4 [94, 95].



Rys. 3.4. Struktura regulatora ACC w programie PELPOS [94]

Pierwsza pętla regulacji dotyczy przyspieszenia, która w zależności od regulatora prędkości nastawia żądane przyspieszenie. Ta zmiana powinna być niezależna od zewnętrznych zakłóceń i zmian oporów ruchu, oddziałując bezpośrednio na chwilowe położenie przepustnicy silnika lub siłę hamowania na kołach. Regulator przyspieszenia zawiera modele układu przeniesienia napędu samochodu. Regulator prędkości, działający w hierarchii ponad regulatorem przyspieszenia, wpływa na zadawane przyspieszenie, przy uwzględnieniu ograniczeń takich jak prędkość maksymalna oraz maksymalne przyspieszenie i opóźnienie. W zewnętrznej pętli regulatora realizowana jest opcja regulacji

odstępu, tworzona z różnicy pomiędzy odstępem zadany a rzeczywistym, powiązana z korektą prędkości względnej. Wartość korekty prędkości jest następnie przekazana dalej do regulatora prędkości.

Docelową wartość przyspieszenia określa zależność [94]

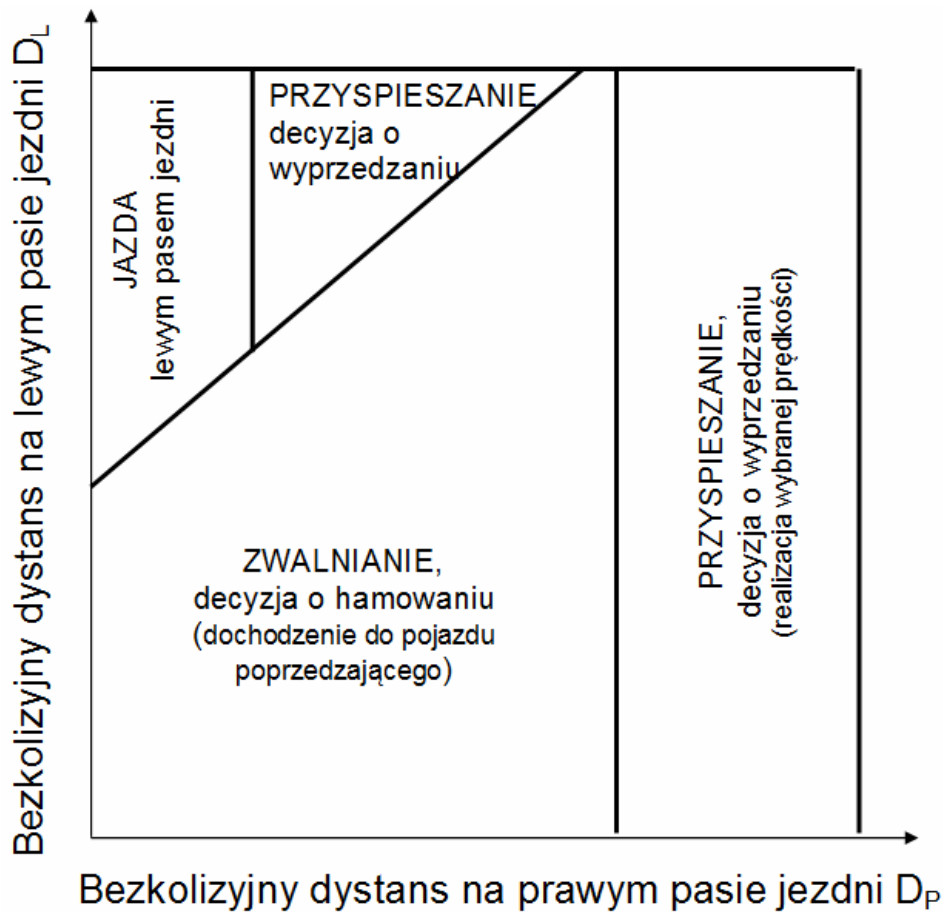
$$a_{\text{target}} = k_v (k_d \cdot (x - x_{\text{target}}) - v), \quad (3.2)$$

gdzie: a_{target} – przyspieszenie docelowe, m/s^2 ,
 k_v – współczynnik wagi prędkości, s^{-1} ,
 k_d – współczynnik wagi odstępu, s^{-1} ,
 x – odstęp, m ,
 x_{target} – docelowy odstęp, m ,
 v – rzeczywista prędkość, m/s .

Tak zdefiniowane modele nie odwzorowują zachowania się prawdziwego kierowcy, rozpoznając jego intencje i uwzględniając w sterowaniu pojazdem błędy, jakie popełnia. Jak wynika z dostępnej literatury uzyskano już pewne osiągnięcia w tej dziedzinie poprzez zastosowanie sieci neuronowych i logiki rozmytej [64, 88, 123].

3.2. MODEL NEURONOWY KRAISSA


Jednym z pierwszych badaczy, który zastosował ludzkie umiejętności w modelu opartym na sieci neuronowej, był Kraiss [88]. Zbudowany na bazie sieci neuronowej model działa na zasadzie asystenta operatora kierowcy samochodu osobowego. Autor pomysłu przewidział do tego celu oddzielny wyświetlacz, na którym wyświetlałyby się podpowiedzi dla kierowcy o możliwości przyspieszania lub zwalniania pojazdu oraz o ewentualności zmiany pasa ruchu. System proponowałby również wykonanie manewru wyprzedzania (rys. 3.5).



Rys. 3.5. Algorytm działania regulatora neuronowego Kraissa [88]

Na rys. 3.6 przedstawiono architekturę operatora neuronowego, w którym nauczona sieć dawała na wyjściu dwie podpowiedzi, odnośnie sposobu realizowania profilu prędkości oraz odnośnie zmian toru ruchu. Na wejściu przewidziano cztery sygnały reprezentujące: bezkolizyjne odstępstwa od pojazdów poprzedzających na pasie prawym D_P i lewym D_L oraz prędkość samochodu i jego lokalizację na jezdni. Przewidziano również piąty sygnał generowany przez przełącznik warunków ruchu.

Jak widać była to pierwsza próba stworzenia modelu, który rozpoznaje nie tylko intencje kierującego pojazdem, ale potrafi odnieść je do otoczenia, w jakim chwilowo porusza się pojazd.




Rys. 3.6. Architektura modelu asystenta kierowcy zbudowanego na bazie sieci neuronowej [88]


3.3. MODEL ROZMYTY PROTZELA

Protzel i inni [64, 123], również w ramach programu PELOPS, opracowali system doboru bezpiecznego odstęp, rozbudowując znany już system ACC, o moduł oparty o logikę rozmytą. Moduł w zależności od typu kierowcy, „ostrożnego” lub „sportowego”, odmiennie realizuje bezpieczny odstęp od pojazdu poprzedzającego. Oznacza to, że system jest w stanie rozpoznać typ kierowcy poprzez jego oddziaływanie na aktywny pedał przyspieszenia oraz hamulca, a w sytuacji stwierdzenia zbliżania się samochodu do go poprzedzającego jest w stanie uruchomić procedury jego zwalniania, różne w zależności od typu kierowcy. Schemat systemu przedstawia rys. 3.7.

Specyfiką i zaletą tego typu modelowania jest to, że zastosowane w nim bazy reguł logicznych, zadowolająco określają w systemie zależności przyczynowo-skutkowych zachowania kierowcy. Na rys. 3.8 przedstawiono charakterystyki w oparciu, o które ustala się docelowy odstęp pomiędzy pojazdami, dla kierowcy „ostrożnego” i o skłonnościach do jazdy „sportowej”, uzależniony również od rozwijanej prędkości oraz warunków pogodowych. Przechodzenie z jednego typu kierowcy na drugi umożliwia 10-stopniowa rozmyta funkcja przynależności.



Rys. 3.7. Składowe systemu ACC (Adaptive Cruise Control) [64]



Rys. 3.8. Charakterystyki określające docelowy odstęp dla dwóch skrajnie różniących się temperamentem kierowców [123]

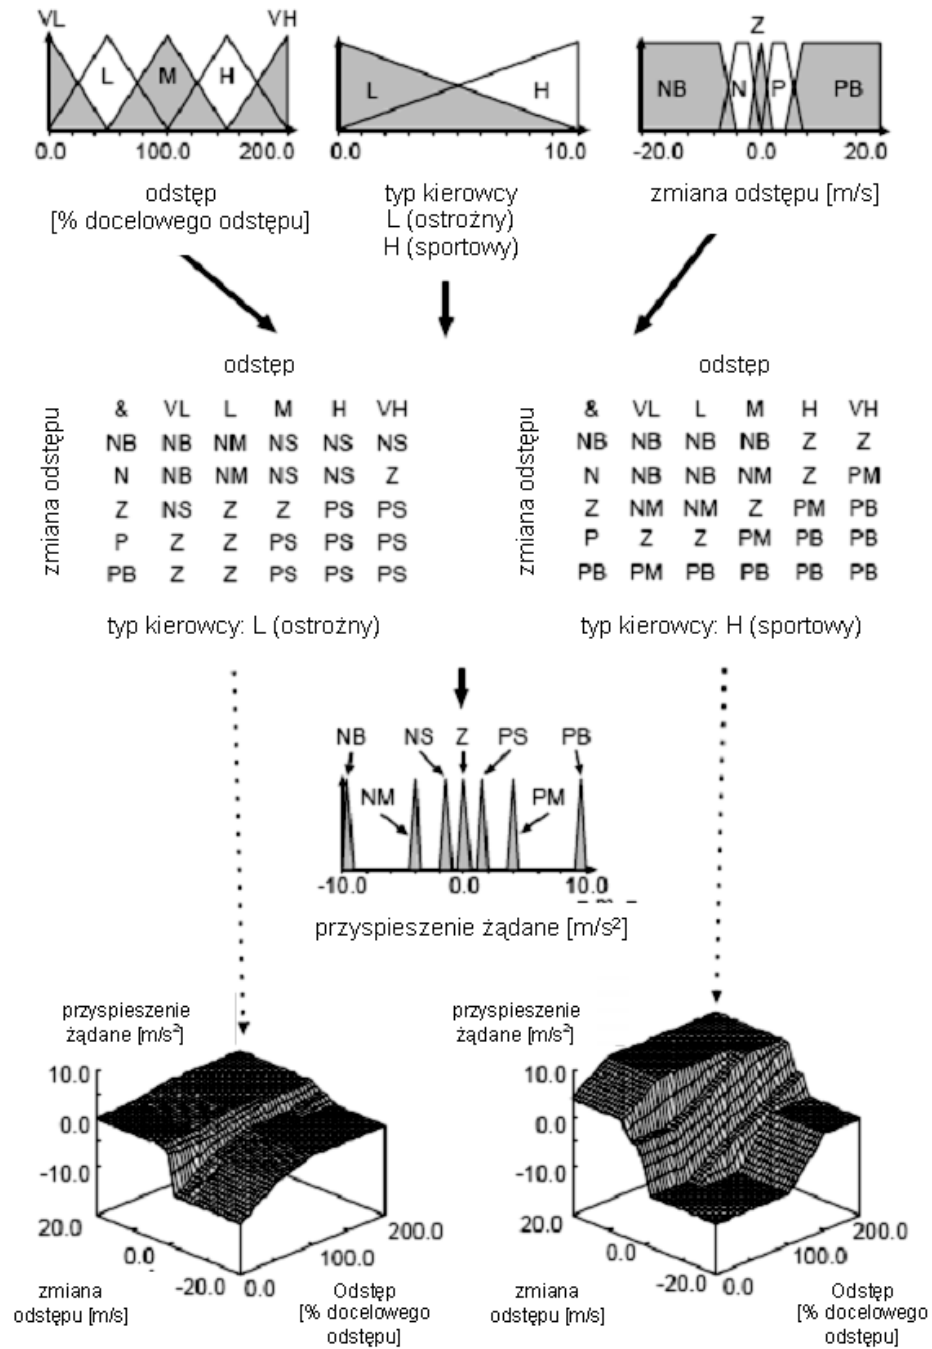
Z zamieszczonych na rys. 3.9 charakterystyk przyspieszeń docelowych wynika, że w zależności od wartości chwilowego odstępu pojazdu od pojazdu go poprzedzającego, a także wartości prędkości względnej pomiędzy pojazdami, samochód może dalej przyspieszać do prędkości docelowej lub być przez system hamowany. Zależy to bowiem od wartości wybranej przez kierowcę pedałem przyspieszenia prędkości docelowej i oczywiście od jego temperamentu, zidentyfikowanego wcześniej przez system.

System, aby spełnić oczekiwania kierowcy „sportowego”, w odróżnieniu od „ostrożnego”, uruchamia proces zwalniania po osiągnięciu zdecydowanie mniejszego odstępu od pojazdu go poprzedzającego. Samochód jest przy tym znacznie intensywniej hamowany. Po uzyskaniu docelowego, a zarazem bezpiecznego odstępu, system stara się go utrzymywać, reagując niezwłocznie na ewentualne zmiany prędkości pojazdu poprzedzającego.

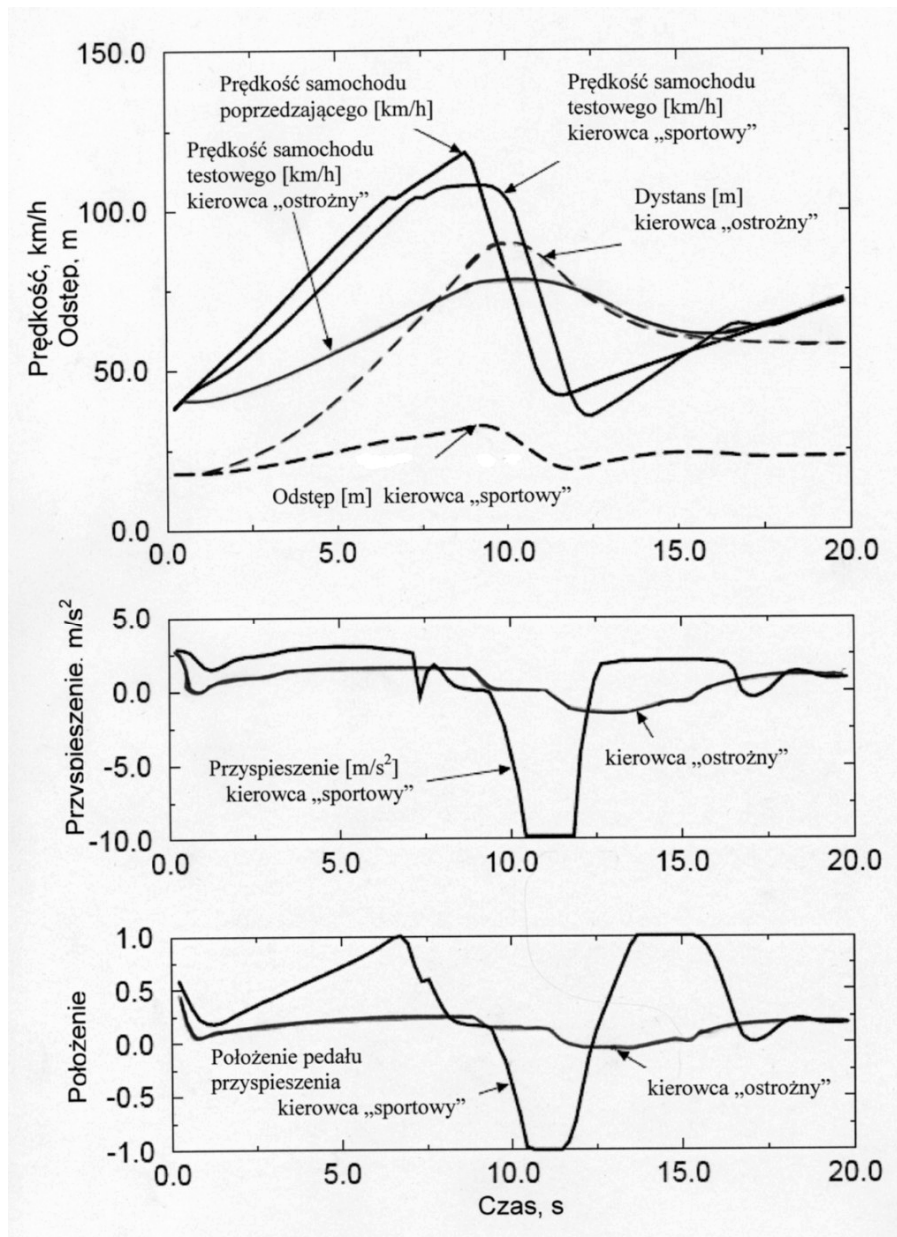
Postępowanie systemu opartego o logikę rozmytą wynika z przesłanek baz reguł stanowiących wytyczne, według których należy postępować. Mówią nam, jak ma się zachowywać obiekt sterowany w momencie zaistnienia danego przypadku na wejściu. Przypadki te mogą zostać zapisane za pomocą wzorów lub w postaci tabeli kombinacji wejściowych zbiorów rozmytych jak na rys. 3.9. W prezentowanym modelu Protzela mamy pięć zmiennych wejściowych, a każda z nich ma również pięć zbiorów rozmytych gdzie: VH – bardzo duży, H – duży, M – średni, L – mały, VL – bardzo mały, NB – ujemny duży, N – ujemny, Z – zero, P – dodatni, PB – dodatni duży.

Istotę pracy systemu dobrze oddają czasowe przebiegi zmian prędkości samochodu, jego przyspieszenia oraz położenia pedału przyspieszenia, przedstawione na rys. 3.10. Profil prędkości samochodu kierowcy „sportowego” jest zbliżony do profilu prędkości samochodu poprzedzającego. Realizacja takiego zadania jest jednoznaczna z gwałtownymi zmianami wartości przyspieszenia, a także podobnymi zmianami sygnału generowanego przez pedał przyspieszenia.

Samochód kierowcy „ostrożnego” dzięki pracy systemu utrzymuje większy dystans od pojazdu poprzedzającego i co za tym idzie, łagodniej reaguje na jego zmiany prędkości. Łagodne są też fazy hamowania i przyspieszania.



Rys. 3.9. Bazy reguł oraz wynikające z nich charakterystyki żądanych przyspieszeń samochodu [123]



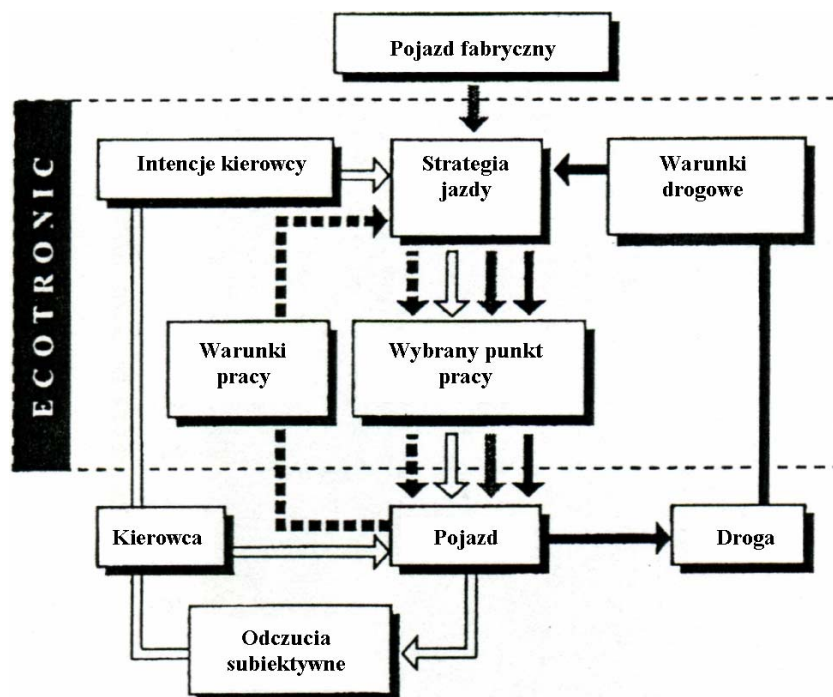
Rys. 3.10. Wycinek 20-sekundowej jazdy testowej samochodu z systemem Fuzzy ACC za pojazdem poprzedzającym dla dwóch typów kierowcy „sportowego” i „ostrożnego” [123]

4. ADAPTACYJNE STEROWANIE ZESPOŁEM NAPĘDOWYM

Najnowsze układy sterowania skrzynkami automatycznymi zamiast opcji wyboru programu jazdy przez kierowcę mają oprogramowanie, które umożliwia dopasowanie do warunków jazdy. Przede wszystkim dotyczy to możliwości rozpoznania typu (charakteru) kierowcy oraz sytuacji drogowej. Założenia takie realizuje adaptacyjne sterowanie skrzynką biegów (AGS - Adaptive Getriebesteuerung), stosowane w skrzynkach biegów samochodów BMW oraz dynamiczny program przełączania (DSP - Dynamisches Schaltprogramm) samochodów Audi [39, 53, 54, 100, 134, 155].

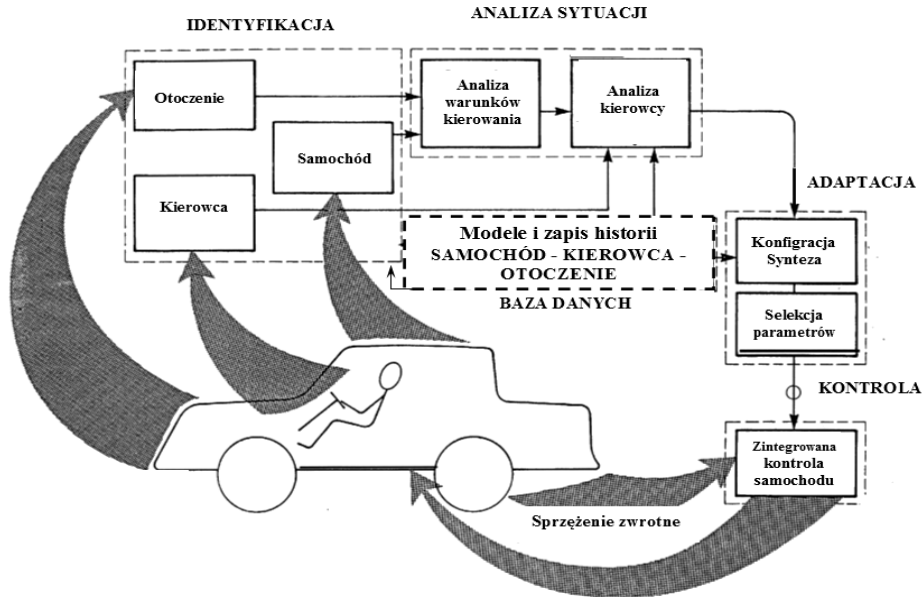
Dobór przełożenia odbywa się po uprzednim zarejestrowaniu i przeanalizowaniu parametrów ruchu samochodu, wskaźników pracy zespołu napędowego oraz po rozpoznaniu typu kierowcy i sytuacji drogowej.

Na rys. 4.1 przedstawiono schemat systemu sterowania układem napędowym wyposażonym w przekładnię ZF-CVT. Układ poza uwzględnieniem życzeń kierowcy operatora rozpoznaje warunki drogowe, w jakich porusza się samochód [37].



Rys. 4.1. Schemat sterowania układem napędowym z przekładnią ZF-CVT [37]

Jednym z pierwszych badaczy, który potraktował samochód jako zbiór układów, którym można nadać cechy adaptacyjne jest Fillings [49]. Już w 1986 roku zaproponował on rozwiązanie mające na celu identyfikację, analizę oraz archiwizowanie danych mogących wspomagać pracę samochodu jako systemu energetycznego, wykonującego określone działania transportowe, w określonym środowisku, kierowanego przez człowieka pełniącego funkcję regulatora warunków jego pracy. Schemat pojazdu adaptacyjnego przedstawia rys. 4.2.



Rys. 4.2. Samochód adaptacyjny [49]

Fillings zaproponował, aby system rozpoznawał temperament kierowcy, a co za tym idzie, skłonności do określonego stylu jazdy. Typ kierowcy miałby być identyfikowany na podstawie: oddziaływania na pedał przyspieszenia i drążek zmiany biegów, ruchów ciała (głowy) oraz ciśnienia tętniczego krwi lub tylko samego tętna. Identyfikacja kierowcy, którego profil byłby już zarejestrowany w bazie samochodu, odbywałaby się na podstawie karty magnetycznej lub głosu. Pojazd identyfikowałby również warunki otaczające samochód na podstawie: temperatury, ciśnienia atmosferycznego, położenia nad poziomem morza, czujników deszczu i przejrzystości powietrza, czujników nierówności drogi, informacji o natężeniu ruchu od pojazdów sąsiadujących oraz z nadajników radiowych lub GPS. Podsystem zarządzający pracą układu przeniesienia napędu wybierałby jeden z czterech programów jazdy różnicując

sposób doboru i zmiany przełożeń, sztywność zawieszenia, pola podaży mocy i momentu silnika (tab.4.1).

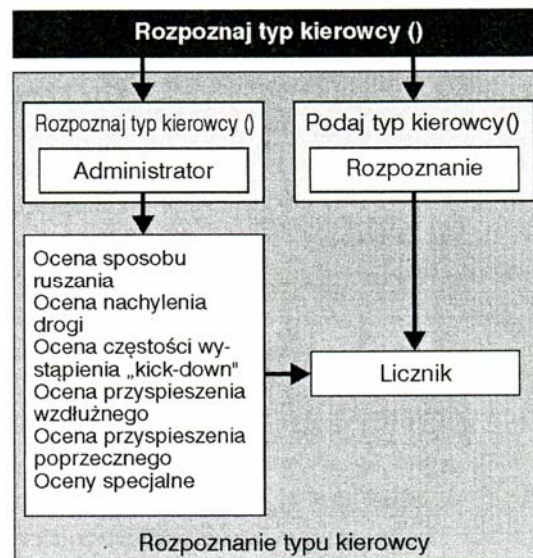
Tabela. 4.1

Programy jazdy - definicje stanów adaptacyjnych [49]

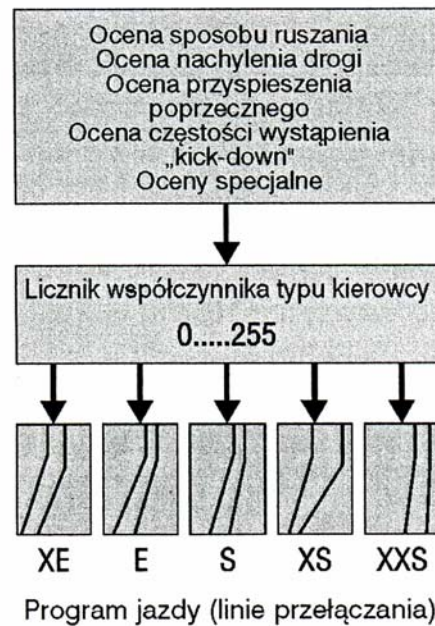
Rodzaj programu - jazdy	Przełożenie	Zawieszenie	Obszar pracy silnika
sportowa - autostradowa	szybkie zmiany	średnie	maksymalnej mocy
rodzinna - autostradowa	najwyższe możliwe	miękkie	cały zakres
sportowa - miejska	wysokie	twarde	maksymalnego momentu
rodzinna – miejska	najwyższe możliwe	średnio miękkie	cały zakres

4.1. TYP KIEROWCY JAKO KRYTERIUM WYBORU PRZEŁOŻENIA

Rozpoznanie typu kierowcy przeprowadza się w oparciu o ocenę jego zachowania się w różnych sytuacjach drogowych. Strategie rozpoznawania typu kierowcy przedstawia rys. 4.3. Jednym z kryteriów jest częstość wciskania przez kierowcę pedału przyspieszenia do pozycji „kickdown”. Równie ważny jest sposób operowania pedałem hamulca. Ocena typu kierowcy wskazuje, czy aktualny styl jazdy ma znamiona oszczędnego czy sportowego. Wynikiem oceny jest współczynnik, od 1 do 255, przyporządkowany do określonego programu jazdy (rys. 4.4) [120]:



Rys. 4.3. Algorytm rozpoznawania typu kierowcy [120]




Rys. 4.4. Dobór programu jazdy w oparciu o obliczony współczynnik typu kierowcy.
Programy: XE – superekonomiczny, E – ekonomiczny, S – neutralny,
XS – sportowy, XXS – supersportowy [120]

4.2. SYSTEM INVECS

Koncern samochodowy Mitsubishi skonstruował automatyczną skrzynię biegów, w której zastosowano system INVECS (Intelligent & Innovative Vehicle Electronic Control System), wspomagający dobór przełożenia oparty na zbiorach rozmytych (fuzzy logic). Istotnym elementem systemu jest śledzenie generowanych przez kierowcę zmian położenia pedału przyspieszenia.


Jeśli przyjąć, że samochodem kieruje człowiek gwałtownie operujący pedałem przyspieszenia, system przypisze mu czynnik „sportowy” np. rzędu 80%. Oznacza to, że przełączanie biegów na wyższe odbywać się będzie tak, aby wymuszać jazdę dynamiczną. Natomiast podczas zwalniania przekładnia będzie również szybko zmieniać przełożenie, redukując biegi w kierunku możliwie najniższych. Z kolei kierowca operujący pedałem przyspieszenia łagodnie spowoduje, że biegi przełączane będą rzadziej, sprawiając, że jazda samochodem bardziej ekonomiczna. Przełożenia będą mogły być wówczas tak dobierane, aby zespół napędowy mógł pracować w obszarze najwyższej możliwej sprawności [84].

Cechą charakterystyczną przekładni z systemem INVECS jest zaprojektowany specjalnie dla niej algorytm, uczący się zachowań kierowcy-operatora. Efektem takich działań jest matematyczny model kierowcy, jak wspomniano wcześniej, oparty na logice rozmytej, opisujący prawdopodobne jego zachowania w kwestii upodobań do stylu jazdy np. sportowej. Model posiada również pewne możliwości predykcji zachowań kierowcy jadącego już wcześniej takim samochodem (rys. 4.5).



Rys. 4.5. Wpływ typu kierowcy na częstość zmian przełożenia [84]

Na rys. 4.6 przedstawiono wybrane charakterystyki ilustrujące sposoby przełączania biegów: górna z 3 na 4, zaś dolna redukcji z 4 na 3, w zależności od typu jazdy. Jeżeli przekładnia pracuje w trybie jazdy sportowej, to w trakcie przyspieszania przełączenie biegu z 3 na 4 następuje w wyższym przedziale prędkości samochodu w porównaniu do przełączenia, jakie byłoby zrealizowane w trybie pracy przekładni skojarzonej ze spokojnym stylem jazdy. Zamykanie przepustnicy i redukcja biegu z 4 na 3, dla programu sportowego, podobnie jak to miało miejsce podczas przyspieszania samochodu, realizowana jest również przy wyższych prędkościach. Oznacza to, że układ napędowy samochodu przechodząc z trybu pracy „jazda spokojna” na tryb „jazda sportowa” spowoduje częstsze zmiany przełożenia [85].




Rys. 4.6. Charakterystyki przełączania biegów dla różnych stylów jazdy [85]

4.3. SYSTEM TCU-DRV

Osman Aliefendioğlu [2] i Ferit Kückükay [89] zaproponowali model identyfikujący typy kierowców, nazywane jako łagodny, przeciętny, agresywny, w oparciu o następujące parametry:

- kąt nachylenia profilu zmian położenia pedału przyspieszania przy jego naciskaniu α ,
- czas trwania naciskania na pedał przyspieszenia t_{KF} ,
- czas trwania odciążania nacisku pedału przyspieszenia t_{KO} ,
- kąt nachylenia profilu zmian położenia pedału hamulca przy jego naciskaniu β ,
- czas trwania naciskania na pedał hamulca t_Z ,



Rys. 4.7. Charakterystyki czasowe trajektorii uchyleń przepustnicy oraz zmian położenia pedału hamulca [2]

4.4. SYSTEM IDENTYFIKACJI STYLU KIEROWCY W SAMOCHODZIE Z NAPĘDEM HYBRYDOWYM

Rozwiązaniem coraz bardziej obecnie powszechnym jest wyposażanie samochodów w dwa źródła napędu: silnik elektryczny i spalinowy. Jednakże napędy takie, zwane hybrydowymi wymagają odpowiedniego sterowania, w zależności od przyjętej strategii i założonej funkcji celu [3, 26, 27, 98, 135].

Istotnym elementem zarządzania podażą energii są oczekiwania kierowcy, który w pierwszej kolejności decyduje o tym, jak szybko chce jechać i z jaką intensywnością przyspieszać. Oznacza to, że rozpoznawanie intencji kierowcy w samochodach o napędzie hybrydowym jest zadaniem pożądanym.

Jong Seob Won, w swojej pracy naukowej zaproponował system DSI (Driver Style Identifier) identyfikacji stylu jazdy kierowcy, za pomocą zbiorów rozmytych [159, 160]. Przyjął do modelu trzy typy kierowców: spokojnego, normalnego i agresywnego. Zaproponował, że system w celu identyfikacji typu kierowcy będzie śledził intensywność przyspieszania samochodu. System miałby zatem, co pewien interwał czasowy, mierzyć przyspieszenie wzdłużne samochodu, a następnie obliczać jego wartość średnią a_{sr} . Jong Seob Won przyjął również, że do pełnej identyfikacji procesu potrzebny będzie również drugi wskaźnik, określony jako iloraz odchylenia standardowego przyspieszenia, znanego w statystyce matematycznej jako miernik zmienności, do wartości średniej przyspieszenia a_{sr} . Zasadność takiego postępowania ilustrują trzy przykłady przedstawione w tabeli 4.2.

Jak z nich wynika, mimo wyraźnie różniących się od siebie, zmierzonych w trzech seriach, wartości przyspieszenia, uzyskano jednakową wartość średnią dla każdej z serii. Dlatego też, aby poprawnie ocenić charakter zmienności przyspieszenia w analizowanych seriach należy dodatkowo obliczyć stosowny iloraz, którego uzyskana wartość wspólnie z wartością średnią pozwoli

zbudować bazę reguł. Bazę reguł rozmytego identyfikatora typu kierowcy przedstawiono w tabeli 4.3.

Tabela. 4.2

Przykłady obliczeniowe wskaźników z serii zmierzonego przyspieszenia [159]

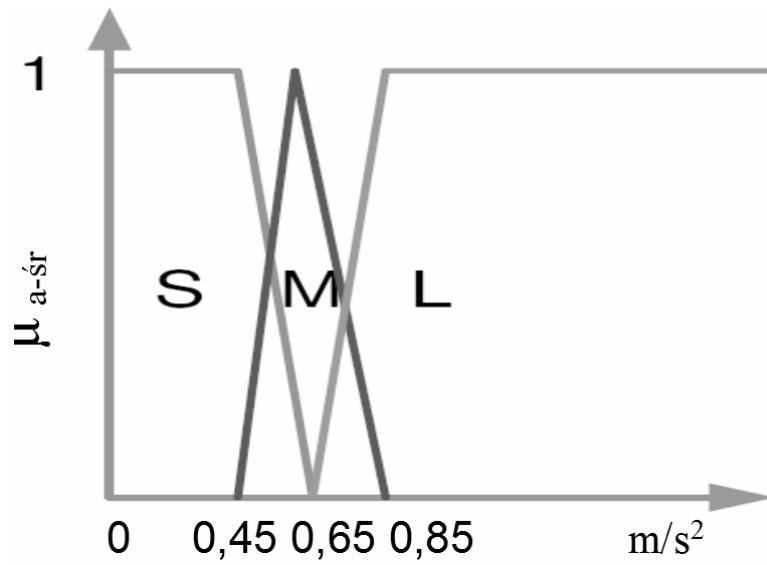
	1	2	3
a - przyspieszenie z pomiaru [m/s ²]	0,3/0,5/0,7	0,1/0,5/0,9	0,01/0,1/1,39
a _{sr} - przyspieszenie średnie [m/s ²]	0,5	0,5	0,5
odchyl. stand. przyspieszenia [m/s ²]	0,2	0,4	0,77
<u>odchyl. stand. przyspieszenia</u> a _{sr}	0,4	0,8	1,54

Tabela. 4.3

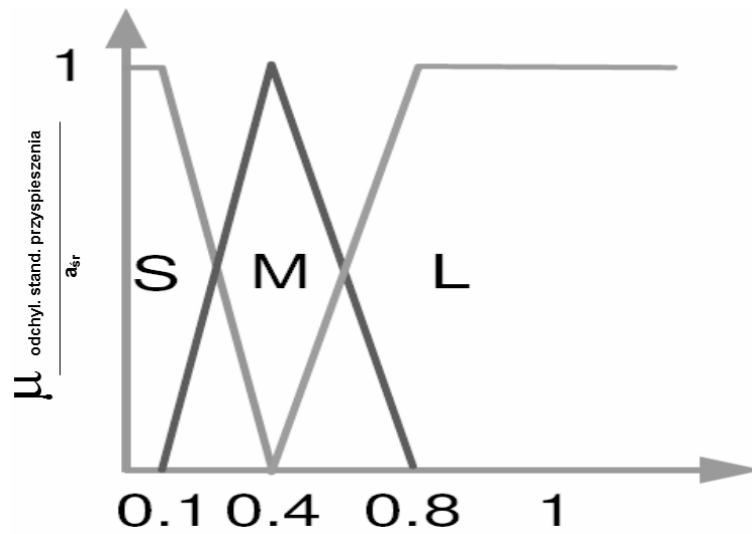
Baza reguł identyfikatora rozmytego [159]

		Odchyl. stand. przyspieszenia		
		a _{sr}		
		mały S 0 ÷ 0,4	średni M 0,1 ÷ 0,8	duży L powyżej 0,4
a _{sr} [m/s ²]	mały S 0 ÷ 0,65	spokojny C	spokojny C	normalny N
	średnie M 0,45 ÷ 0,85	normalny N	normalny N	agresywny A
	duże L powyżej 0,65	agresywny A	agresywny A	agresywny A

Funkcje przynależności zbiorów rozmytych dla poszczególnych zmiennych ustalono po analizie wyników z wcześniej wykonanych badań drogowych. Kształty oraz położenie funkcji przynależności zbiorów rozmytych przedstawiono na rys. 4.8 i 4.9, gdzie: S – mały, M – średni, L – duży.

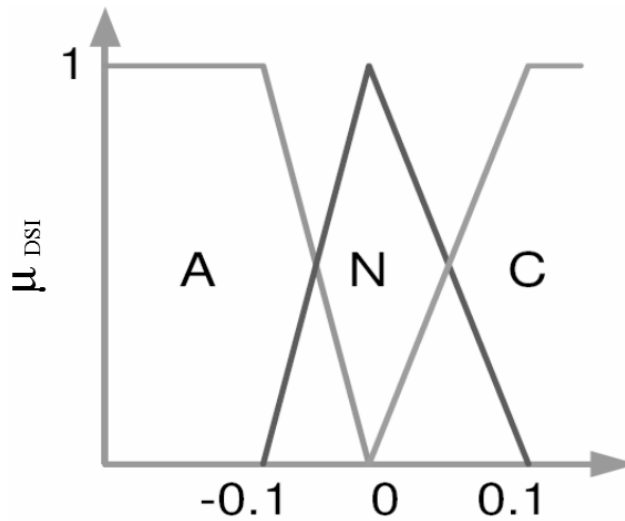


Rys. 4.8. Funkcje przynależności dla przyspieszenia średniego a_{sr} [159]




Rys. 4.9. Funkcje przynależności dla ilorazu odchylenia standardowego przyspieszenia do jego wartości średniej [159]

Identyfikator typu kierowcy DSI w postaci funkcji przynależności zbiorów rozmytych przedstawia rys. 4.10, gdzie: A – agresywny, N – normalny, C – spokojny.



Rys. 4.10. Funkcje przynależności dla identyfikatora typu kierowcy DSI [159]

Na rys. 4.11 przedstawiono wybrane wyniki badań w postaci przebiegów czasowych identyfikatora typu kierowcy DSI oraz prędkości liniowej samochodu i zmian położenia pedału przyspieszenia.



Rys. 4.11. Przebiegi czasowe identyfikatora typu kierowcy DSI na tle przebiegów prędkości liniowej samochodu oraz położenia pedału przyspieszenia [159]

5. PRZYKŁADY MODELOWANIA TECHNIKAMI SZTUCZNEJ INTELIGENCJI


Stały rozwój elektroniki pozwala na konstrukcję coraz bardziej rozbudowanych systemów sterowania, a proponowane algorytmy sterowania charakteryzują się coraz wyższym stopniem skomplikowania. Tradycyjne techniki sterowania przy współdziałaniu nawet szybko działających procesorów przetwarzających dane nie są w stanie spełnić w pełni tych oczekiwań. Proponowane algorytmy sterowania wymagają również stosowania wiedzy ekspertowej do sterowania układów. Wykorzystanie tej wiedzy przy zastosowaniu regulacji konwencjonalnej nie jest możliwe. Możliwość taką daje np. sterowanie rozmyte FLC (Fuzzy Logic Control) [46, 117, 150, 154].

Zbiór rozmyty A parametru x opisuje się przy wykorzystaniu funkcji przynależności $\mu(x)$ zmiennej x z zakresu $[0,1]$

$$A = \{(x, \mu(x)); x \in X\}. \quad (5.1)$$

Przykładową trójkątną funkcję przynależności μ_x , przedstawioną na rys. 5.1. opisuje się zależnością

$$\mu(x) = \frac{a - |x|}{a}. \quad (5.2)$$




Rys. 5.1. Przykładowa funkcja przynależności [150]

Na rys. 5.2 jest przedstawiony mechanizm wnioskowania rozmytego. Jeśli w wyniku pomiaru otrzymano wartość parametru x , to na podstawie funkcji przynależności, dla tego parametru określa się stopień przynależności $\mu(x)$ tego parametru. W bazie danych są zebrane reguły logiczne. Zazwyczaj reguły te


spełniają warunki *modus ponens*: IF...AND...THEN. Następnie na podstawie tego typu reguł dokonuje się wnioskowania (inferencji), określając stopień przynależności $\mu(y)$ [150].

Strojenie parametrów nawet najbardziej skomplikowanych modeli rozmytych umożliwiają algorytmy genetyczne, choć może to być związane z dużą pracochłonnością [117].




Rys. 5.2. Mechanizm wnioskowania rozmytego [150]

W metodzie algorytmów genetycznych przestrzeń rozwiązań zmiennej genetycznej dzieli się na skończoną liczbę przedziałów (rys. 5.3). Jeśli w danym przedziale znajduje się wierzchołek funkcji przynależności, przedział ten kodowany jest liczbą 1, jeżeli nie liczbą 0. Łańcuch kodujący funkcji przynależności jednej zmiennej nazywa się chromosomem (np. 10110001011), a jego elementy, 0 lub 1, genami. Podstawowe operatory genetyczne to mutacja i krzyżowanie [117].




Rys. 5.3. Przykład kodowania funkcji przynależności [117]

Mutacja polega na stworzeniu potomka danej pojedynczej reprezentacji, przez zmianę wartości jednego lub więcej genów. Przy strojeniu funkcji przynależności, mutacja powinna odbywać się tak, aby ilość genów jedynekowych (zbiorów rozmytych danej zmiennej) była stała (rys. 5.4):



Rys. 5.4. Operacja mutacji [117]

Krzyżowanie powoduje wymianę zawartości genetycznej pomiędzy rozwiązaniami. Polega to na zmianie jednego lub większej ilości genów między dwoma chromosomami (rodzicami) w celu uzyskania nowych chromosomów (potomków). Liczba genów jedynekowych (zbiorów rozmytych danej zmiennej) musi być stała (rys. 5.5).



Rys. 5.5. Operacja krzyżowania [117]

Dla każdej nowej wygenerowanej reprezentacji określa się odpowiadający jej stopień dopasowania, po czym włącza się ją do populacji pierwotnej, otrzymując w ten sposób nową populację. Odrzucanie reprezentacji o najgorszym (najniższym) stopniu dopasowania nazwano selekcją. Na pozostałych reprezentacjach dokonuje się operacji genetycznych w celu otrzymania nowego, lepszego potomstwa. Opisane postępowanie prowadzi się tak długo, aż wśród nowo wygenerowanych reprezentacji znajdzie się taka, której stopień dopasowania spełnia postawione wymagania dotyczące dokładności modelu.

5.1. STEROWANIE PRĘDKOŚCIĄ SAMOCHODU OPARTE NA LOGICE ROZMYTEJ

Przesłanki do powstania i rozwoju teorii zbiorów rozmytych wynikły z potrzeby opisanego złożonych zjawisk lub słabo zdefiniowanych pojęć, trudnych do opisanego za pomocą klasycznego aparatu matematycznego. Jest to teoria w szczególności sposobu przydatna w przypadku systemów, w których czynnik ludzki odgrywa zasadniczą rolę.

Sterowanie elementami systemu jakim jest samochód, gdy oparte jest na logice rozmytej, bazuje na zachowaniu człowieka jako operatora [13, 21, 22, 23, 48, 64, 93]. Obszary zastosowań takiego sterowania w dziedzinie samochodowej to np.:

- kontrola emisji z ciągłym monitorowaniem oraz możliwością regulacji stężenia,
- regulacja klimatyzacji samochodu z dostosowaniem działania do liczby pasażerów,
- regulacja ciśnienia płynu hamulcowego w układzie hamulcowym wyposażonym w system antyblokowy kół w zależności od ich chwilowego poślizgu,
- wybór optymalnego chwilowego przełożenia w układzie napędowym w zależności od wyboru sposobu jazdy przez kierowcę (ekonomiczna, sportowa),
- ograniczanie prędkości samochodu.

5.2. BADANIA UKŁADU STEROWANIA OGRANICZNIKA PRĘDKOŚCI SAMOCHODU METODĄ SYMULACJI KOMPUTEROWEJ

Celem badań symulacyjnych było dokonanie oceny porównawczej zastosowania układu regulacji ogranicznika prędkości podróźnej samochodu z wykorzystaniem regulatora w postaci przekaźnika z korekcją PID oraz regulatora rozmytego. W tym celu posłużono się pakietem SIMULINK® programu MATLAB® [45, 104], umożliwiającym symulację układów dynamicznych. Dzięki niemu zbudowano dwa układy regulacji, które przedstawiono na rys. 5.8 i 5.9. Do celów symulacyjnych założono uproszczoną dynamikę samochodu wyrażoną równaniem różniczkowym I-rzędu

$$T \frac{dv(t)}{dt} + v(t) = K\alpha(t) \quad (5.3)$$

gdzie: t – czas, s, v – prędkość samochodu, km/h, α – położenie pedału przyspieszenia, %. Dla parametrów T oraz K przyjęto wartości: $T = 15$ s, natomiast $K = 2$ ((km/h)/%). Wartość żądanej prędkości jazdy przyjęto na poziomie 120 km/h, natomiast wartość pracy ogranicznika na poziomie 90 km/h. Odpowiedź układu regulacji ogranicznika prędkości z wykorzystaniem regulacji w postaci przekładnika z korekcją typu PID przedstawiono na rys. 5.10.

W tle czasowego przebiegu prędkości znajdują się poziome linie stałej prędkości wynoszącej odpowiednio 95, 91.5, 90 i 88.5 km/h w celu prezentacji efektów regulacji. Uzyskany przebieg prędkości regulowanej ma charakter niestabilny, gdzie w pierwszej fazie regulacji dochodzi do przeregulowania wartości prędkości powyżej 95 km/h.

Przy projektowaniu układu regulacji ogranicznika z regulatorem rozmytym FLC posłużono się przybornikiem Fuzzy Logic Toolbox programu MATLAB®. Następnie dokonano wyboru zmiennych wejściowych e i de (uchybu prędkości v i zmiany uchybu prędkości dv) oraz zmiennej wyjściowej $d\alpha$ sterowania przepustnicą). Dobór powyższych zmiennych pozwolił na realizację przyrostowego algorytmu sterowania PI, zapewniającego zerową wartość uchybu w stanie ustalonym. Prawo sterowania, będące opisem relacji między wejściem a wyjściem regulatora typu PI można wyrazić następującym wzorem

$$d\alpha(k) = f(e(k), de(k)). \quad (5.4)$$

Prawo to opisuje za pomocą reguł rozmytych JEŻELI - TO relacje między zmienną sterowania $d\alpha(k) = \alpha(k) - \alpha(k-1)$ i uchybem $e(k)$ oraz jego zmianą $de(k) = e(k) - e(k-1)$. Ponadto da się zauważyć podobieństwo między algorytmem sterowania realizowanym przez rozważany regulator FLC i algorytmem przyrostowym konwencjonalnego regulatora PI (kombinacja sterowania proporcjonalnego i całkowania)

$$d\alpha(k)K_p de(k) + K_i e(k). \quad (5.5)$$

K_p i K_i są parametrami regulatora PI. Przy projektowaniu regulatora FLC typu PI przyrostowego jest przyjęcie jako zmienne wejściowe $e(k)$ i $de(k)$ oraz jako zmienną wyjściową $d\alpha(k)$. Zakres działania zmiennych dobrano następująco:

- uchybu $e[-30, 120]$,
- zmiany uchybu $de[-10, 10]$,
- zmiany sterowania $d\alpha[0, 100]$,
który przeskalowano do przedziału $[0, 1]$.

Bazę reguł regulatora rozmytego przedstawiono w tabeli 5.1.


Tabela. 5.1

Baza reguł regulatora rozmytego [21, 22, 23]


		e				
		MU	Z	MD	SD	DD
de	U	Z	M	D	BD	BD
	Z	Z	M	S	BD	BD
	D	Z	M	M	D	BD

gdzie: BD – bardzo duży, DD – duży dodatni, SD – średni dodatni, MD – mały dodatni, D – duży, Z – zero, M – mały, S – średni, U – ujemny, MU – mały ujemny.

Kształty oraz położenie funkcji przynależności zbiorów rozmytych przedstawiono na rys. 5.6 i 5.7.



Rys. 5.6. Funkcje przynależności dla zmiennej:
a) uchybu e, b) zmiana uchybu de [21, 22, 23]



Rys. 5.7. Funkcje przynależności dla zmiennej: zmiana sterowania da [21, 22, 23]

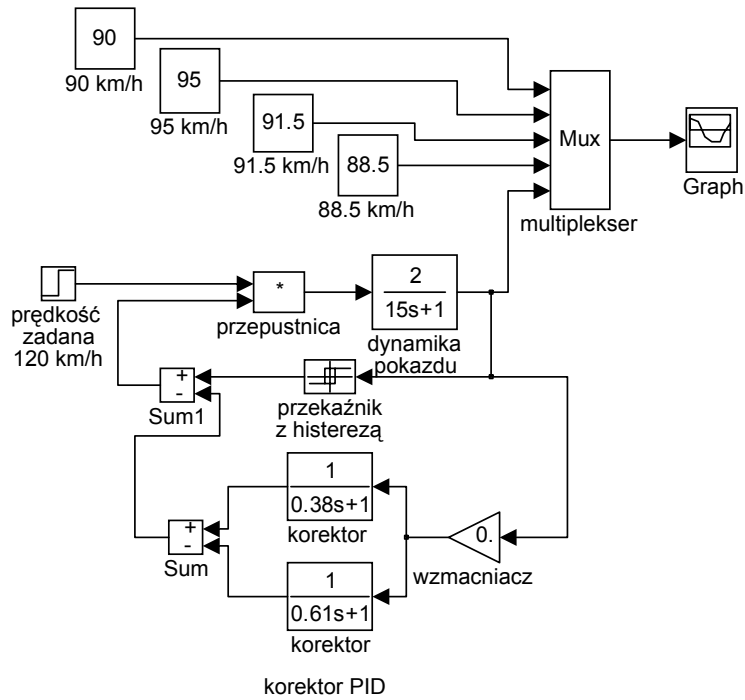
Typ, kształt oraz położenie funkcji przynależności zbiorów rozmytych dla poszczególnych zmiennych wybrano stosując metodę prób i błędów, wielokrotnie powtarzając eksperymentalne symulacje, aż do uzyskania zadowalających wyników. Spowodowane to jest bardzo elastyczną strukturą systemu rozmytego oraz brakiem systematycznych narzędzi do projektowania optymalnych regulatorów rozmytych.

W zaprojektowanym wyżej regulatorze rozmytym, w przypadku rozmywania (fuzyfikacji) zastosowano metodę wnioskowania każdej reguły z osobna. Do wnioskowania, zastosowano implikację Mamdaniego, polegającej na wyznaczeniu iloczynu logicznego poziomu wnioskowania reguły poprzednika i zbioru rozmytego następnika reguły, a w przypadku wyostrzania (defuzyfikacji) metodę środka obszaru.

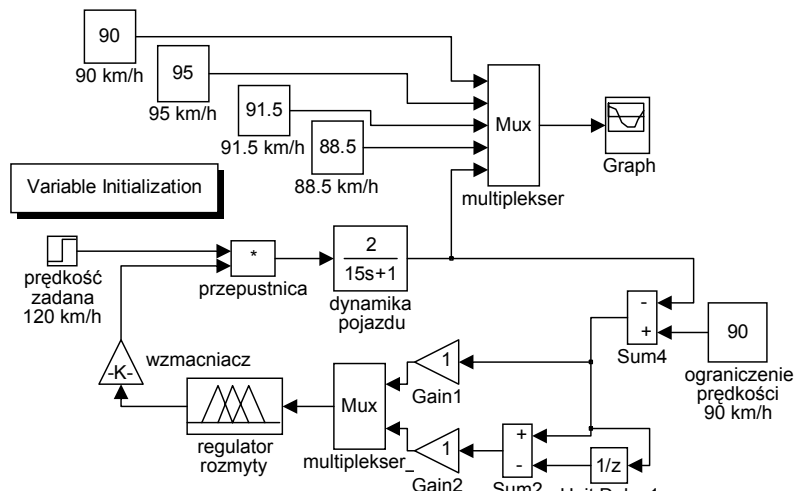
Dodatkowo, w celu poprawy jakości regulacji, wprowadzono do układu regulacji rozmytej trzy blozki będące elementami wzmacniającymi. Zawierają one współczynniki skalujące, służące do strojenia regulatora rozmytego. Mają one istotny wpływ na modyfikację przestrzeni wielkości zmiennych wejścia/wyjścia regulatora FLC, a co ściśle wiąże się z możliwością uzyskania poprawy jakości regulacji.

Wartości współczynników skalujących zostały dobrane metodą prób i błędów i wynoszą odpowiednio: $k_{da}=1.49$, $k_e=1.0$ oraz $k_{de}=1.0$. Schemat układu regulacji z regulatorem rozmytym przedstawiono na rys. 5.9 odpowiedź układu regulacji ogranicznika prędkości z wykorzystaniem regulatora rozmytego przedstawiono na rys. 5.11.


Uzyskany przebieg prędkości regulowanej ustala się szybciej niż ten przedstawiony na rys. 5.10 i nie wykracza poza założony w symulacji przedział.




Rys. 5.8. Układ regulacji ogranicznika prędkości przy wykorzystaniu przełącznika z korekcją PID [22, 23]



Rys. 5.9. Układ regulacji ogranicznika prędkości przy wykorzystaniu regulatora rozmytego [22, 23]



Rys. 5.10. Odpowiedź układu regulacji z wykorzystaniem przekaźnika z korekcją PID [22, 23]



Rys. 5.11. Odpowiedź układu regulacji z wykorzystaniem regulatora rozmytego [22, 23]

Jak wynika z rys. 5.11, sposób sterowania, polegający na zastosowaniu regulatora rozmytego do sterowania profilem prędkości daje korzyści w postaci obniżenia inercji jej przebiegu. Możliwość łagodniejszego sposobu ograniczania prędkości pojazdu, a także utrzymywania jej wartości w obrębie mniejszego przedziału przy zastosowaniu takiego rozwiązania, w porównaniu z uzyskiwanym metodami tradycyjnymi wiązać się musi z mniejszą częstością uchyleń przepustnicy silnika spalinowego.

5.3. ZASTOSOWANIE ALGORYTMU GENETYCZNEGO DO STROJENIA REGULATORA ROZMYTEGO

Jak pokazano wyżej, do układu regulacji rozmytej wprowadzono trzy blozki zawierające współczynniki skalowania, które służą do strojenia regulatora rozmytego. Ich wartości zostały dobrane metodą prób i błędów w trakcie badań symulacyjnych. Dodatkowo podjęto próbę znalezienia optymalnych wartości współczynników skalowania z wykorzystaniem algorytmu genetycznego, który działa w oparciu o cechy naturalnej ewolucji oraz stosuje probabilistyczne, a nie deterministyczne metody poszukiwań optimum globalnego. Algorytm prowadzi poszukiwanie rozwiązania dla pewnej liczby punktów w ramach populacji i korzysta tylko z funkcji celu, a nie z jej pochodnej lub innej informacji, a następnie przetwarza zakodowaną postać parametrów działania. Jako funkcję celu w zadaniu optymalizacji zastosowano wskaźnik jakości o postaci

$$I = \int_0^{\infty} |e(t)| dt. \quad (5.6)$$

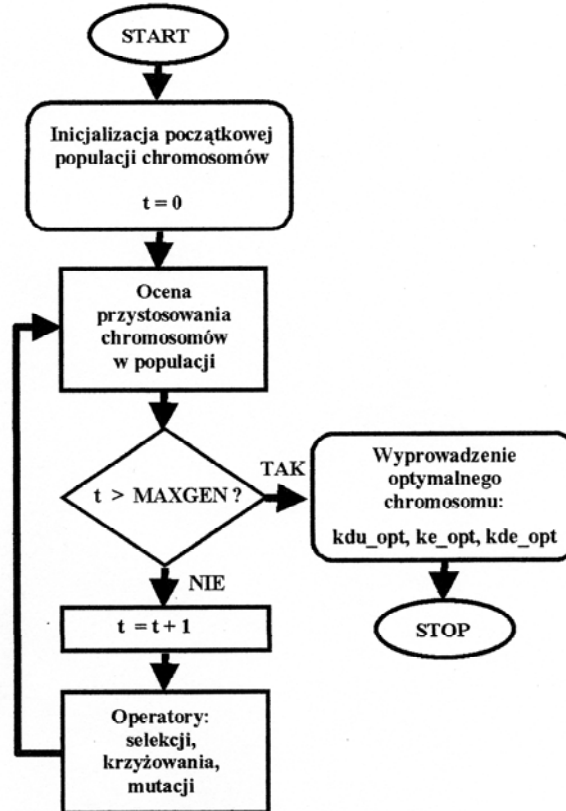
Na rys. 5.12 przedstawiono, w uproszczonej postaci, algorytm realizujący poszukiwanie, za pomocą algorytmu genetycznego, optymalnych wartości współczynników skalujących: k_{da_opt} , k_{e_opt} oraz k_{de_opt} .

Zadanie poszukiwania optymalnych wartości współczynników skalujących dla regulatora rozmytego zrealizowano w oparciu o przyborek Genetic Algorithm Toolbox ver. 1.2 dla programu MATLAB® [41].

W powyższym algorytmie genetycznym zastosowano następujące parametry:

- liczbę chromosomów 10,
- liczbę pokoleń 10,
- „dziurę pokoleniową” 1 chromosom,
- sposób kodowania zmiennych - kod Graya,
- precyzja kodowania zmiennych 16 bitowa,
- zakres zmiennych [0 10],


- operator krzyżowania jednopunktowy z prawdopodobieństwem $P_c=0.75$,
- operator mutacji z prawdopodobieństwem $P_m=0.07$.




Rys. 5.12. Schemat algorytmu genetycznego realizującego poszukiwanie optymalnych wartości współczynników skalujących [21]

W wyniku przeprowadzonego zadania optymalizacyjnego uzyskano następujące wartości współczynników skalujących: $kda_{opt} = 6.5069$, $ke_{opt} = 0.0356$, $kde_{opt} = 2.0504$.

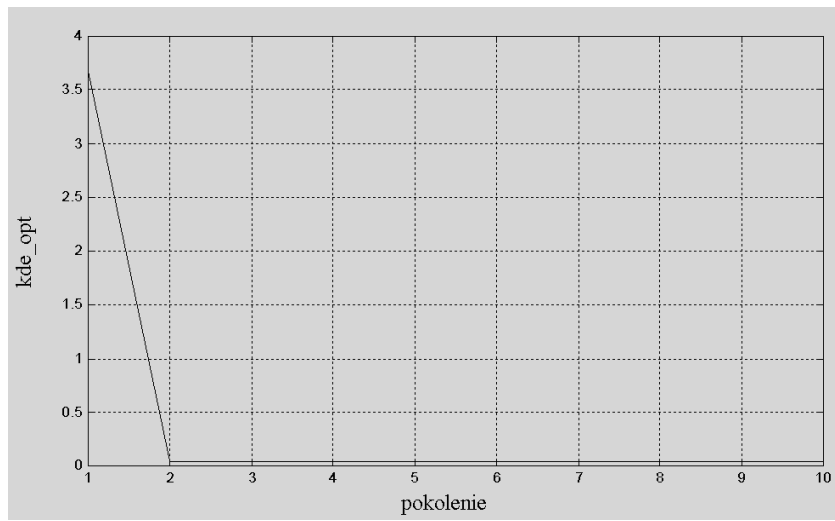
Na rysunkach 5.13 – 5.16 przedstawiono przebiegi zmian: wskaźnika jakości I oraz współczynników ke_{opt} , kde_{opt} i kda_{opt} , uzyskanych w trakcie procesu optymalizacji, tj. przez 10 pokoleń.




Rys. 5.13. Przebiegi zmian wskaźnika jakości I w funkcji 10 pokoleń [21]




Rys. 5.14. Przebiegi zmian wskaźnika ke_opt w funkcji 10 pokoleń [21]



Rys. 5.15. Przebiegi zmian wskaźnika kde_opt w funkcji 10 pokoleń [21]



Rys. 5.16. Przebiegi zmian wskaźnika kdalfa_opt w funkcji 10 pokoleń [21]



Rys. 5.17. Odpowiedź układu regulacji ogranicznika prędkości z wykorzystaniem optymalnego regulatora rozmytego [21]

Tak wyznaczone współczynniki wprowadzono do układu regulacji z rys. 5.9, a następnie przeprowadzono symulację, w wyniku czego uzyskano przebieg prędkości przedstawiony na rys. 5.17. Porównując przebiegi z rys. 5.11 oraz z rys. 5.17 daje się zauważyć krótszy czas regulacji w przypadku zastosowanego nastrojonego regulatora rozmytego. Widoczny na rys. 5.17 czas narastania prędkości docelowej, wynoszący około 2 s, w rzeczywistości jest dłuższy z uwagi na bezwładność układu napędowego.

Przedstawione wyniki badań pozwalają na sformułowanie następujących wniosków:

- zaproponowany sposób sterowania, polegający na zastosowaniu regulatora rozmytego do sterowania profilem prędkości daje istotne korzyści w postaci szybkiej reakcji przebiegu odpowiedzi,
- możliwość łagodniejszego sposobu ograniczania prędkości pojazdu, a także utrzymania zadanej wartości w obrębie mniejszego przedziału, w porównaniu z uzyskanymi metodami tradycyjnymi wiąże się z mniejszą częstością uchyleń przepustnicy silnika spalinowego samochodu (mniejszymi zmianami w dawkowaniu paliwem). Zatem można przyjąć, że ogranicznik prędkości sterowany regulatorem rozmytym, w porównaniu do tradycyjnego, będzie dawał korzyści również w postaci obniżenia zużycia paliwa,
- dodatkowo przeprowadzone strojenie regulatora rozmytego za pomocą algorytmu genetycznego poprawia efektywność regulacji.

6. KLASYFIKACJA TYPU KIEROWCY METODĄ RANKINGU

W różnych sferach ludzkiej aktywności występuje duża liczba zjawisk, które można określić mianem złożonych. Porównanie różnych obiektów położonych w przestrzeni w zakresie zjawisk złożonych stwarza konieczność sporządzenia ich ocen, a w dalszej kolejności konstrukcji rankingu. Zjawiska złożone, jak wynika z definicji, są zwykle charakteryzowane wieloma różnorodnymi cechami, które mają różne miana i wykazują różne rzędy wielkości [80].

Wielokryterialna ocena zjawiska w różnych obiektach staje się możliwa, gdy dokonamy przekształcenia wartości cech oryginalnych celem ich ujednoczenia. Przekształcone zmienne są pozbawione mian i przybierają wartości zbliżonego rzędu wielkości. Sposoby transformacji wartości oryginalnych cech diagnostycznych są nazywane metodami normowania. Unormowane wartości zmiennych diagnostycznych mogą być poddane procesowi agregacji, co prowadzi do uzyskania zmiennej syntetycznej (agregatywnej) charakteryzującej każdy obiekt ze względu na oceniane zjawisko złożone. Znajomość ocen obiektów pozwala na konstrukcję ich rankingu, czyli układu, w którym obiekty są uporządkowane w kolejności od najlepszego do najgorszego ze względu na wartość zmiennej syntetycznej [80].

Materiał poddany analizie to efekt wykonanych badań drogowych. Obejmował on jazdy testowe samochodem osobowym, w warunkach ruchu miejskiego.

6.1. BADANIA DROGOWE

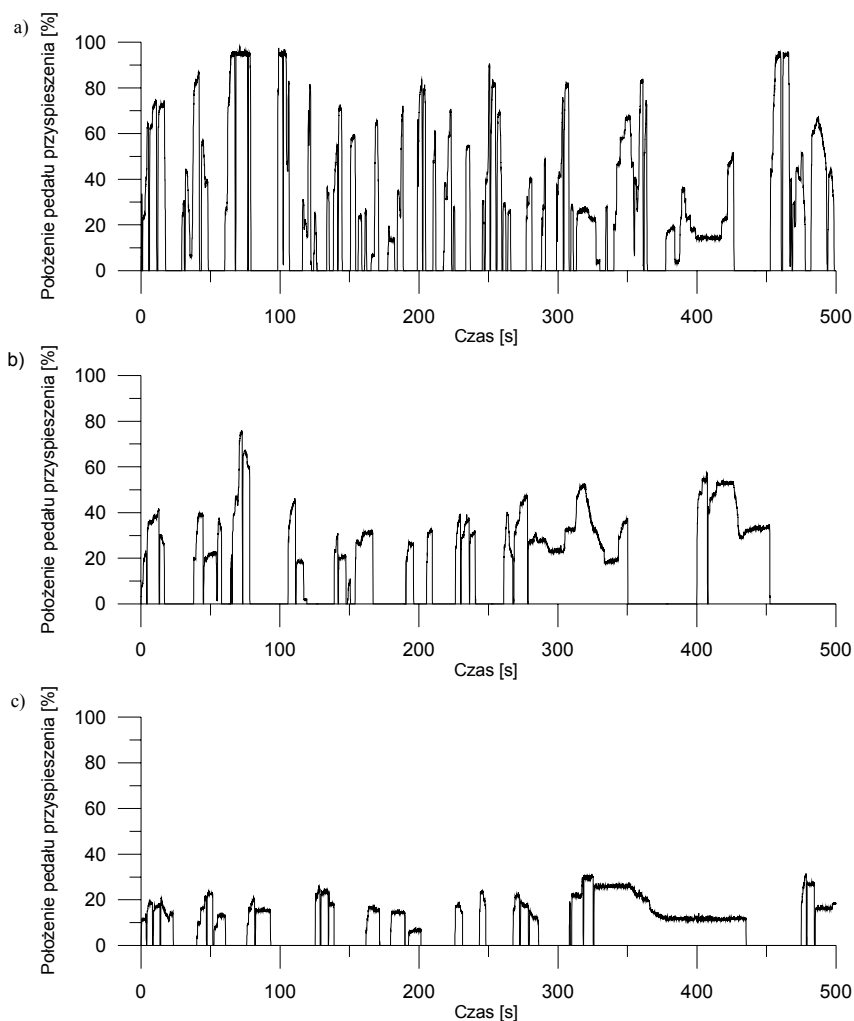
Obiektem badań był samochód osobowy klasy średniej, wyposażony w silnik benzynowy o pojemności 1.6 dm³ i pięciostopniową manualną skrzynię biegów. Samochód wyposażono w Datron LS3 - optyczny czujnik służący do pomiaru parametrów kinematycznych ruchu metodą bezstykową, umożliwiającą pomiary prędkości w zakresie (0,5÷400) km/h, generując ok. 400 impulsów na metr przebytej drogi. Poza pomiarem prędkości i przebytej przez samochód drogi rejestrowano chwilowe położenie pedału przyspieszenia i przyspieszenie wzdłużne samochodu.

Dane napływające z interfejsu pomiarowego Daqbook przetwarzano przy użyciu komputera klasy PC obsługiwane przez operatora siedzącego obok kierowcy. System ten umożliwiał rejestrację, z częstością około 33 razy na sekundę, mierzonych parametrów.

W ramach badań doświadczalnych przeprowadzono 76 jazd testowych samochodem osobowym w typowych warunkach ruchu miejskiego, przy czym długość odcinka drogi wynosiła około 7 kilometrów. Wybrani kierowcy

przejeżdżali ten odcinek dwukrotnie, starając się pokonać go na różne pod względem stylu jazdy sposoby. Każdy z przejazdów poddano następnie klasyfikacji, określając jego charakter jako: „spokojny” bądź „aktywny”. Dla zapewnienia zbliżonych warunków pomiaru, przejeżdżano tę samą trasę o porze dnia charakteryzującej się minimalnym natężeniem ruchu innych pojazdów. Na rys. 6.1. przedstawiono wybrane przebiegi czasowe, ilustrujące zmiany położenia pedału przyspieszenia w trakcie rozpędzania samochodu.

Charakter przedstawionych przebiegów wskazuje, że kierowca preferujący jazdę „aktywną” w przeciwieństwie do kierowcy jadącego „spokojnie”, wciska pedał przyspieszenia głębiej i czyni to intensywniej.



Rys. 6.1. Zmiany położenia pedału przyspieszenia dla kierowcy a) „aktywnego”, b) „neutralnego” i c) „spokojnego” [11]

Wstępna ocena zebranych wyników pozwala z dużą dozą prawdopodobieństwa przypuszczać, iż istnieje możliwość oceny stylu jazdy w oparciu o charakter realizowanego profilu prędkości, a także na podstawie analizy sygnału generowanego przez kierowcę za pomocą pedału przyspieszenia.

Z punktu widzenia teorii sterowania wielkość ta pełni rolę sygnału wejściowego dla obiektu dynamicznego, jakim jest pojazd, podczas gdy np. prędkość czy przyspieszenie pojazdu reprezentują zmienne stanu i są silnie skorelowane z tą wielkością wejściową.

6.2. BUDOWA RANKINGU

W przedmiotowym rankingu poszukiwani byli kierowcy najbardziej „agresywni”, którzy w sensie analizy dwukryterialnej zmieniali w czasie jazd testowych najintensywniej położenie pedału przyspieszenia, a prędkość, z którą się poruszali, również się często zmieniała.

Analizowane kryteria (zwane zmiennymi syntetycznymi) to odchylenie standardowe położenia pedału przyspieszenia oraz odchylenie standardowe prędkości samochodu. Obliczone oba wskaźniki dla 76 kierowców przedstawiono w tabeli 6.1. Wyniki przedstawiono również w postaci wykresu, rys. 6.2.

Na rys. 6.2 jednoznacznie można wskazać przejazd o numerze 38, który znajduje się najbliżej punktu charakteryzującego się najwyższymi wartościami odchylenia standardowego położenia pedału przyspieszenia oraz odchylenia standardowego prędkości samochodu.

Można zatem stwierdzić, że wyznaczony graficznie przejazd odpowiada kierowcy charakteryzującemu się największymi skłonnościami do jazdy „aktywnej” spośród całej badanej populacji.

Podobnie można wyznaczyć punkt odpowiadający kierowcy, który wykonał przejazd najbardziej „spokojnie” – punkt 15. Uszeregowanie pozostałych przejazdów w postaci rankingu wykonano metodą analityczną, szeroko opisywaną w literaturze [4, 80].

Z uwagi na to, iż oba analizowane kryteria podawane są w różnych jednostkach, a więc by były porównywalne należało w pierwszej kolejności ustalić dla nich miernik syntetyczny, przedstawiający ich realizacje. Ponieważ oba kryteria są maksymalizowane to w obu przypadkach zastosowano zależność (6.1) na unormowaną zmienną diagnostyczną z_{ij}

$$z_{ij} = \frac{x_{ij} - \min_i x_{ij}}{\max_i x_{ij} - \min_i x_{ij}} \quad \left(\begin{array}{l} i = 1, 2, \dots, r \\ j = 1, 2, \dots, s \end{array} \right) \quad x_j \in S, \quad (6.1)$$

gdzie:

- x_{ij} – zmienne diagnostyczne,
- i – liczba obiektów,
- j – liczba zmiennych syntetycznych,
- $\max x_{ij}$ – największa realizacja danego kryterium w analizowanym zbiorze,
- $\min x_{ij}$ – najmniejsza realizacja danego kryterium w analizowanym zbiorze.

Następnie obiekty są szeregowane ze względu na średnią stopnia realizacji. Wartość zmiennej syntetycznej, która o tym decyduje, przedstawia zależność (6.2). Im wartość zmiennej syntetycznej Q_i jest wyższa, tym obiekt staje się lepszy.

$$Q_i = \frac{1}{s} \sum_{j=1}^s z_{ij} \quad (i = 1, 2, \dots, r). \quad (6.2)$$

6.3. WYNIKI RANKINGU [11]

Jak wspomniano wcześniej, analizie poddano $i = 76$ przejazdów, wykorzystując dwie zmienne syntetyczne, zatem $j = 2$. Przedstawia to tabela 6.1.


Na podstawie uzyskanych z obliczeń rezultatów oceny dwukryterialnej sporządzono ranking dla wszystkich kierowców. Przedstawiono go graficznie w postaci szeregu, porządkując numery przejazdów od najbardziej agresywnego do najspokojniejszego (rys. 6.3).

W tabeli 6.2 zestawiono wybrane parametry dwóch przejazdów, odpowiadające dwóm skrajnym typom kierowców wyłonionych w ranking. Przedstawione w niej dane potwierdzają fakt, że kierujący prowadząc pojazd w sposób „aktywny” – nr 38 (w porównaniu z osobą jadącą najspokojniej – nr 15), uzyskiwał wyższe chwilowe wartości prędkości i przyspieszenia samochodu. Zmieniał przy tym położenie pedału przyspieszenia z relatywnie znacznie większą intensywnością. Wskazuje na to statystyczny wskaźnik zmienności, jakim jest odchylenie standardowe.


Tabela. 6.1

Wskaźniki dla 76 kierowców przyjęte do rankingu [11]

numer przejazdu	prędkość średnia samochodu	odchylenie standardowe		numer przejazdu	prędkość średnia samochodu	odchylenie standardowe	
		prędkości samochodu	prędkości pedalu przyspieszenia			prędkości samochodu	prędkości pedalu przyspieszenia
	m/s	m/s	%/s		km/h	km/h	%/s
1	13,3	5,7	26,2	39	12,8	6,9	45,9
2	13,5	5,3	11,2	40	13,8	6,1	48,9
3	15,2	7,4	43,1	41	12,8	5,4	42,0
4	12,5	5,6	38,0	42	12,5	5,8	41,5
5	13,8	5,8	23,0	43	13,8	7,5	51,7
6	14,3	5,5	27,9	44	13,6	5,2	38,3
7	12,0	3,7	16,1	45	14,3	6,0	44,0
8	12,1	4,0	17,1	46	13,2	5,4	41,9
9	13,8	5,0	21,5	47	12,6	6,1	50,3
10	14,2	6,0	24,5	48	13,8	6,8	40,6
11	16,1	6,0	49,7	49	12,2	6,3	45,1
12	13,8	5,6	27,1	50	8,3	6,2	41,0
13	14,9	6,0	34,9	51	9,3	8,7	37,9
14	11,3	4,2	18,2	52	13,9	5,6	51,0
15	12,3	3,9	8,6	53	11,3	6,6	44,4
16	13,0	5,1	20,0	54	11,3	6,1	45,4
17	13,0	6,0	19,4	55	9,0	6,6	43,2
18	13,4	6,9	37,9	56	9,7	6,6	40,8
19	11,1	4,9	23,4	57	10,7	5,0	18,4
20	11,9	6,0	27,0	58	8,7	4,7	17,1
21	11,3	5,8	26,6	59	7,6	5,5	17,8
22	13,5	5,8	54,8	60	9,6	5,0	16,1
23	11,7	4,4	36,3	61	8,4	4,3	18,1
24	13,3	6,6	52,0	62	8,2	4,7	16,7
25	11,9	4,9	36,7	63	9,5	5,8	18,1
26	12,0	5,0	28,8	64	7,4	4,6	18,2
27	11,5	6,5	28,8	65	9,3	4,3	18,7
28	12,5	5,6	26,8	66	12,4	5,7	17,1
29	12,0	6,4	24,5	67	8,0	5,5	22,1
30	12,9	5,7	48,9	68	7,6	5,6	19,6
31	11,9	5,6	39,9	69	8,3	4,7	25,3
32	11,9	5,8	36,7	70	8,9	5,9	25,0
33	13,0	5,5	38,6	71	7,7	6,7	22,8
34	14,1	6,8	42,8	72	9,2	5,7	31,4
35	11,7	5,3	41,4	73	9,6	5,0	21,6
36	14,0	5,6	46,4	74	9,0	7,6	21,7
37	12,9	5,2	41,2	75	6,2	4,5	26,2
38	15,9	7,3	61,0	76	8,6	6,6	25,1



Rys. 6.2. Graficzny ranking 76 kierowców [11]



Rys. 6.3. Zestawienie kierowców od najbardziej „aktywnego” do skrajnie „spokojnego” [11]

Tabela. 6.2

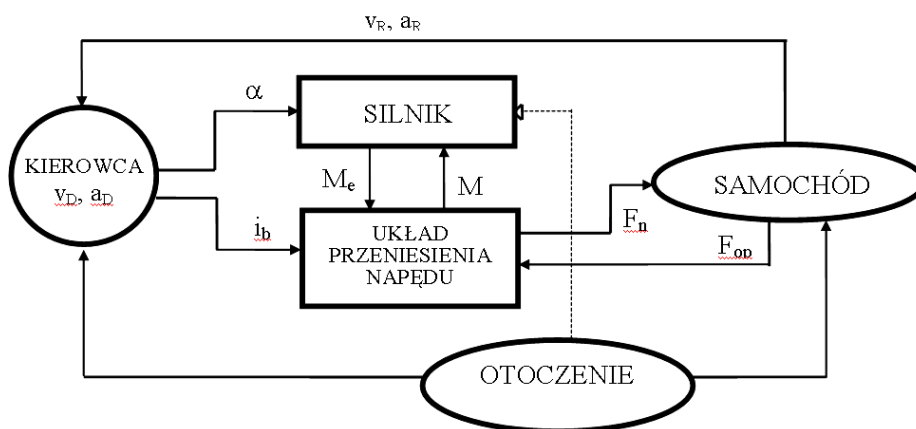
Wybrane parametry przejazdów dla skrajnie różnych stylów jazdy [11]

	Styl jazdy	
	„spokojny” nr 15	„aktywny” nr 38
Średnia prędkość samochodu [m/s]	12,3	15,9
Maksymalna prędkość samochodu [m/s]	22,6	29,7
Odchylenie standardowe prędkości samochodu [m/s]	3,9	7,3
Średnie przyspieszenie wzdłużne samochodu [m/s ²]	0,54	0,92
Maksymalne przyspieszenie wzdłużne samochodu [m/s ²]	1,61	3,28
Odchylenie standardowe przyspieszenia wzdłużnego samochodu [m/s ²]	0,50	0,79
Średnie położenie pedału przyspieszenia [%]	12,9	35,7
Maksymalne położenie pedału przyspieszenia [%]	44,6	100
Odchylenie standardowe położenia pedału przyspieszenia [%]	12,3	34,2
Maksymalna prędkość zmian położenia pedału przyspieszenia (przy naciskaniu) [%/s]	219	601
Maksymalna prędkość zmian położenia pedału przyspieszenia (przy zwalnianiu) [%/s]	369	594
Odchylenie standardowe prędkości zmian położenia pedału przyspieszenia [%/s]	8,6	61

7. ANALIZA SYGNAŁU GENEROWANEGO PEDALEM PRZYSPIESZENIA

Kierowca oddziałuje na samochód przez układy sterujące kierunkiem jazdy i prędkością, wymuszając odpowiednie parametry ruchu. Z kolei ruch samochodu wywołuje u kierowcy odczucia obciążenia, spowodowane działaniem sił bezwładności przy zmianie prędkości i kierunku. Te odczucia, obok obserwacji wzrokowej, stanowią podstawowe źródło informacji o ruchu, gdyż (z wyjątkiem prędkościomierza) pojazd nie jest wyposażony w urządzenia sygnalizujące bezpośrednio zmiany parametrów ruchu (rys. 7.1).

Podobnie o ustawieniu kół kierowca orientuje się pośrednio, na podstawie obserwacji toru jazdy. Charakterystyczną cechą ruchu samochodu są częste zmiany prędkości i kierunku narzucone przez otoczenie, głównie zaś przez właściwości drogi i obecność innych jej użytkowników. Największym zakresem i częstością tych zmian charakteryzuje się jazda miejska, najmniejszym zaś jazda na autostradzie i na wielopasmowej drodze szybkiego ruchu. Zawsze jednak, nawet najlepsze drogi, składają się z odcinków prostych połączonych łukami o różnej krzywiznie i pochyleniu; zawsze też w ruchu drogowym występują okoliczności zmuszające kierowcę do zmiany prędkości. Przebieg prędkości w funkcji czasu dla przejazdu danego odcinka drogi nazywa się profilem prędkości [137, 139, 140].



Rys. 7.1. Schemat regulacyjny samochodu osobowego [138],
 F_n – siła napędowa [N], F_{op} – sumaryczna siła oporów ruchu [N], i_b – przełożenie skrzyni biegów, M – moment obrotowy [Nm], M_e – moment użyteczny silnika [Nm],
 v_R, v_D – rzeczywista, docelowa prędkość liniowa samochodu [km/h], a_R, a_D – rzeczywiste, docelowe przyspieszenie wzdłużne samochodu [m/s^2],
 α – położenie pedału przyspieszenia [%]

Realizowanie profilu prędkości narzuconego przez otoczenie i wymagania bezpieczeństwa wymagają odpowiedniej zmiany położenia urządzeń sterujących mocą silnika, jak również odpowiedniej zmiany biegów. Szacuje się, że w ruchu drogowym o średnim natężeniu zmiana położenia pedału przyspieszenia jest dokonywana 120-350 razy w ciągu godziny, co odpowiada 6-17 zmianom na kilometr przebytej drogi. W tym przypadku aż 25% łącznej liczby tych zmian dotyczy szybkich zmian położenia pedału przyspieszenia związanych z intensywnym przyspieszaniem samochodu. Znaczącym składnikiem ruchu samochodu jest przyspieszanie, które np. wg badań prowadzonych w USA zajmuje do 29% czasu jazdy w ruchu drogowym i aż 42% w ruchu miejskim [137].


Profil prędkości samochodu przebywającego odpowiednio długi odcinek drogi składa się z podstawowych faz ruchu, do których zalicza się przyspieszanie, jazdę ze stałą prędkością i ruch opóźniony. Przyspieszanie i opóźnianie stanowią fazy przejściowe między różnymi poziomami prędkości. Do typowych przypadków zmiany prędkości, zwłaszcza w ruchu miejskim, zalicza się rozpędzanie, tj. przyspieszanie do określonej prędkości podróźnej, oraz hamowanie, aż do zatrzymania. Z reguły w profilu prędkości realizowanym przez samochód na odpowiednio długim odcinku drogi można wyróżnić powtarzające się okresowo moduły, złożone z trzech podstawowych faz ruchu uszeregowanych w kolejności: przyspieszanie, stała prędkość, hamowanie. Profile prędkości każdego z modułów różnią się czasem trwania poszczególnych faz, a także zakresem i intensywnością zmiany prędkości. W ruchu miejskim moduły te są z reguły krótkie i oddzielone okresami postoju, np. na skrzyżowaniach [137].

7.1. PROFIL PRĘDKOŚCI – EFEKT DZIAŁANIA KIEROWCY

Na rys. 7.2 przedstawiono wycinek czasowego przebiegu prędkości samochodu dla dwóch sposobów przejazdu wytyczonej na potrzeby badań drogowych trasy [12].

Kierujący w przykładowych przejazdach, w przedziale czasu około 18 sekund, wykonywał rozpędzania samochodu z różną intensywnością. Jadąc według jego oceny, w sposób „aktywny” przejechał w tym czasie odcinek drogi o długości około 210 m, rozwijając prędkość około 75,2 km/h (20,9 m/s). Jadąc drugi raz i czyniąc to „spokojnie”, przejechał odcinek drogi około 195 m i rozwinął prędkość około 66,6 km/h (18,5 m/s).

Zmiany położenia pedału przyspieszenia w funkcji czasu zilustrowano na rys. 7.3. Z przebiegów tych jednoznacznie wynika, że kierujący chcąc pokonać szybciej wytyczony odcinek drogi, realizował swoją wolę wciskając głębiej pedał przyspieszenia.



Rys. 7.2. Przebiegi czasowe prędkości samochodu dla jazdy „aktywnej” i „spokojnej” [12]

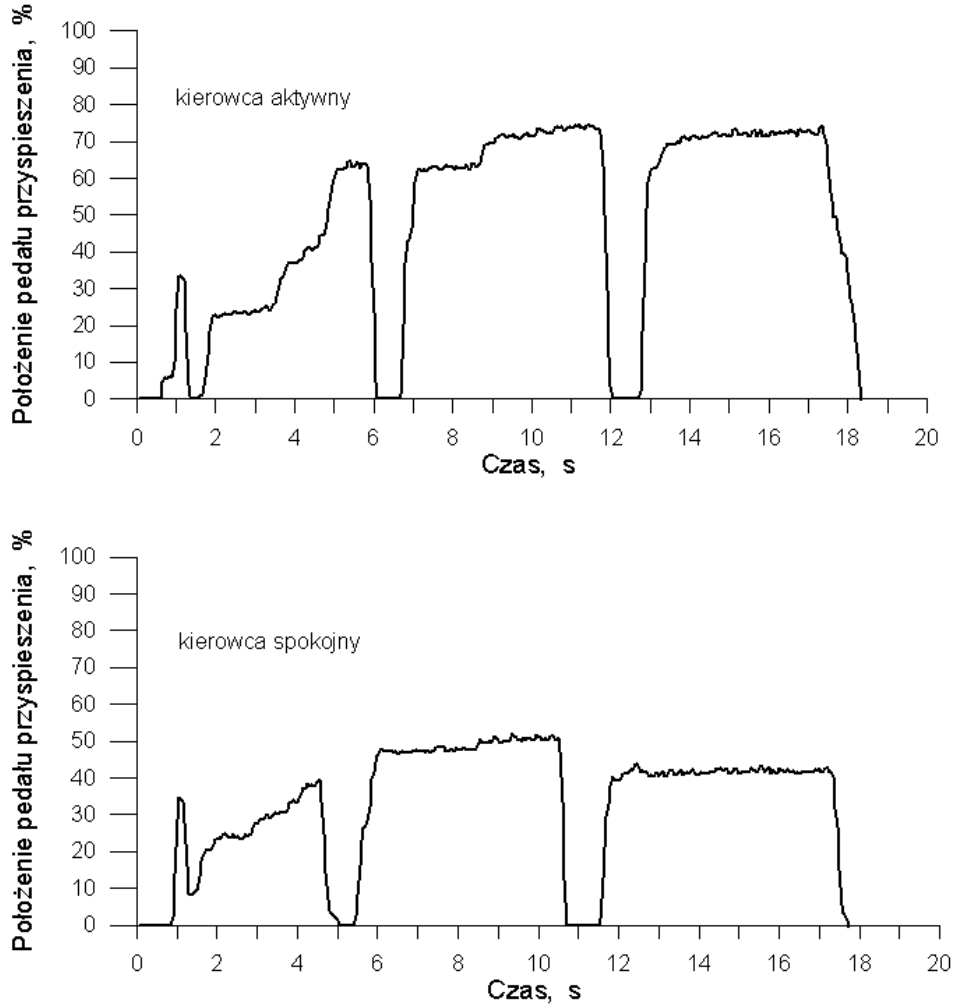
7.2. ANALIZA CZĘSTOTLIWOŚCIOWA SYGNAŁU GENEROWANEGO PEDAŁEM PRZYPIESZENIA

Prosta analiza sygnału w dziedzinie częstotliwości polega na wyodrębnieniu poszczególnych składowych sygnału i zobrazowaniu ich amplitudy w funkcji częstotliwości. Podstawową cechą funkcyjną sygnałów wyznaczaną w dziedzinie częstotliwości jest gęstość widmowa mocy. Metody jej wyznaczania dla sygnałów okresowych bazują na teorii Fouriera, która zakłada, że każdy sygnał realizowany fizycznie można reprezentować w postaci liniowej kombinacji funkcji harmonicznycch [119, 121, 141, 143, 162].

Celem analizy autora było dokonanie oceny porównawczej szeregów czasowych położenia pedału przyspieszenia w dziedzinie częstotliwości, a w szczególności analizy gęstości widmowej PSD (Power Spectral Density), przy zastosowaniu przybornika Signal Processing Toolbox zawartego w środowisku obliczeniowym Matlab [104].

Analiza widmowa pozwala na wyznaczenie częstotliwościowej zawartości procesu, bazując na skończonych zbiorach danych. Estymacja widmowej gęstości mocy jest użyteczna w różnych zastosowaniach, włączając detekcję sygnałów zakłóconych szumem o szerokim paśmie. Funkcja gęstości widmowej mocy posiada taką własność, że jej całka w danym paśmie częstotliwości jest

równa mocy sygnału w tym paśmie. Istnieje wiele różnych metod estymacji PSD. Można jednak zgrupować je w dwóch kategoriach: estymacji parametrycznej i nieparametrycznej. Technika zastosowana na potrzeby publikacji był nieparametryczny algorytm, opracowany przez Burga [33].




Rys. 7.3. Przebiegi czasowe położenia pedału przyspieszenia jazdy „aktywnej” i „spokojnej” [12]

Widmowa gęstość mocy (PSD) stacjonarnego procesu losowego jest związana z funkcją korelacji sygnału dyskretnego poprzez dyskretną transformację Fouriera. Funkcja gęstości widmowej mocy posiada taką własność, że jej całka w danym paśmie częstotliwości jest równa mocy sygnału w tym

paśmie. Wymiar gęstości widmowej mocy jest równy kwadratowi wymiaru badanej funkcji pomnożonemu przez czynnik wyrażony jednostką - s/rad.


Przybornik Signal Processing Toolbox (SPT) jest zbiorem algorytmów, wyrażonych głównie w postaci m-plików. Algorytmy te są zbudowane w otoczeniu środowiska Matlaba. Dostarczają one, wykorzystując jego cechy obliczeniowe i graficzne, specjalizowanych funkcji do analizy i przetwarzania sygnałów. Funkcje przybornika estymują widmową gęstość mocy używając jednej z dwóch technik: parametrycznej bądź nieparametrycznej.

Przyjmując założenie, że uzyskane z badań przebiegi czasowe położenia pedału przyspieszenia mogą stanowić podstawę do oceny sposobu jazdy kierowcy, poddano je analizie. W tym celu sygnał przeliczono i przefiltrowano uzyskując czasowe przebiegi przyspieszenia pedału przyspieszenia (rys. 7.4).




Rys. 7.4. Przebiegi czasowe przyspieszenia pedału przyspieszenia [12]

W efekcie analizy otrzymano widmową gęstość mocy w funkcji częstotliwości, której wymiar określono jako $[cm^2/(s^3 \cdot rad)]$. Wyniki tych analiz przedstawiono na rys. 7.5 i 7.6.




Rys. 7.5. Gęstość widmowa mocy dla funkcji przyspieszenia pedału przyspiesznika, odpowiadającej przejazdowi kierowcy, którego styl jazdy określono jako „aktywny” [12]



Rys. 7.6. Gęstość widmowa mocy dla funkcji przyspieszenia pedału przyspieszenia, odpowiadającej przejazdowi kierowcy, którego styl jazdy określono jako „spokojny” [12]

Obliczenia numeryczne wykazały, że widmowa gęstość mocy PSD funkcji przyspieszenia pedału przyspieszenia może być parametrem służącym do oceny sposobu jazdy kierowcy. Przedstawione przebiegi, powtórzone na charakterystyce zbiorczej (rys. 7.7) potwierdzają tę tezę. Bowiem estymator PSD, odpowiadający „aktywnemu” zachowaniu kierowcy przyjmuje wartości wyższe od obliczonego dla kierowcy „spokojnego”, szczególnie w przedziale częstotliwości $0,3 \div 0,4$ Hz.



Rys. 7.7. Charakterystyka zbiorcza gęstości widmowych mocy [12]

8. ESTYMACJA I KLASYFIKACJA TYPU KIEROWCY

Estymacja to działanie, którego celem jest szacowanie wartości parametru rozkładu własności w populacji na podstawie próbki pobranej z tej populacji. Metody estymacji parametrycznej można w zależności od sposobu szacowania szukanego parametru podzielić na dwie grupy:

- estymacja punktowa,
- estymacja przedziałowa.

W estymacji punktowej oceną wartości szukanego parametru jest konkretna wartość uzyskana z próby (estymator), natomiast w estymacji przedziałowej operuje się pojęciem przedziału ufności, czyli przedziału, do którego z pewnym prawdopodobieństwem należy szukana wartość. Przez pojęcie rozpoznawania i klasyfikacji wzorca należy rozumieć jego identyfikację i przypisywanie do odpowiedniej klasy.

8.1. KLASYFIKATOR NEURONOWY

Sieć neuronowa może pełnić funkcje zarówno ekstraktora cech, jak i klasyfikatora, dokonującego przypisania wzorca do odpowiedniej klasy. Najczęściej ekstrakcja cech wzorca odbywa się oddzielnie, na etapie wstępnego przetworzenia sygnałów pomiarowych [111, 112].

Sieci neuronowe mogą być stosowane w systemach diagnostyki procesów i obiektów do rozwiązywania problemów modelowania oraz klasyfikacji. Opracowano wiele architektur o właściwościach dynamicznych, które charakteryzują się dobrą efektywnością przy modelowaniu diagnozowanych procesów. Wśród nich można wyróżnić sieci jednokierunkowe wielowarstwowe z liniami opóźniającymi, sieci rekurencyjne czy też sieci typu GMDH (opartej na grupowej obróbce danych) [130, 131, 132].

Sztuczne sieci neuronowe są zbudowane z pewnej liczby elementów przetwarzających zwanych neuronami. Podstawowy model neuronu opisano następującym równaniem [147]

$$y = F \left(\sum_{p=1}^P w_p u_p + u_o \right), \quad (8.1)$$


gdzie:

- F – funkcja aktywacji,
- w_p – wagi synaptyczne,
- $u_p, p = 1, 2, \dots, P$ – wejścia neuronu,
- u_o – próg.

Perceptron wielowarstwowy jest siecią, której neurony są pogrupowane w warstwy (rys. 8.1). Można tutaj wyróżnić warstwę wejściową, jedną lub więcej warstw ukrytych oraz warstwę wyjściową. Zadaniem warstwy wejściowej jest wstępne przetwarzanie danych wejściowych, np. skalowanie, filtracja czy normalizacja sygnałów oraz przekazywanie ich do elementów pierwszej warstwy przetwarzania neuronowego. Główne przetwarzanie neuronowe odbywa się w kolejnych warstwach ukrytych i warstwie wyjściowej. Ogólnie proces przetwarzania neuronowego można opisać zależnością [119]:

$$Y = F_3 \{ W_3 F_2 [W_2 F_1 (W_1 u)] \}, \quad (8.2)$$

gdzie: F_1 , F_2 i F_3 są nieliniowymi operatorami opisującymi transformację neuronową sygnału przez kolejne warstwy neuronowe, W_1 , W_2 i W_3 oznaczają macierze współczynników wagowych, które określają przepustowość połączeń między neuronami dwóch sąsiednich warstw oraz u i y oznaczają odpowiednio wektory wejściowy i wyjściowy.



Rys. 8.1. Perceptron trójwarstwowy z P wejściami i N wyjściami [119]

Podstawową własnością sieci neuronowych jest ich zdolność do uczenia się i adaptacji. Z technicznego punktu widzenia proces uczenia sieci neuronowej sprowadza się do wyznaczenia wartości współczynników wagowych sieci w_p . Podstawowym algorytmem uczenia sieci perceptronowych jest algorytm wstecznej propagacji błędów [119, 147]. Algorytm ten określa zasady

uaktualniania wartości wagowych połączeń międzyneuronowych sąsiednich warstw sieci. Jest to procedura iteracyjna rozwiązująca zadanie minimalizacji przyjętego wskaźnika jakości, wykorzystując metodę gradientową największego spadku. Modyfikacja wartości współczynników wagowych odbywa się zgodnie z zależnością [112]

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \eta \nabla E(\mathbf{w}(k)), \quad (8.3)$$

gdzie: $\mathbf{w}(k)$ oznacza wektor współczynników wagowych w chwili k , η jest krokiem uczenia oraz $\nabla E(\mathbf{w}(k))$ oznacza gradient wskaźnika jakości E względem wektora wag \mathbf{w} .

8.1.1. Rekurencyjne sieci neuronowe

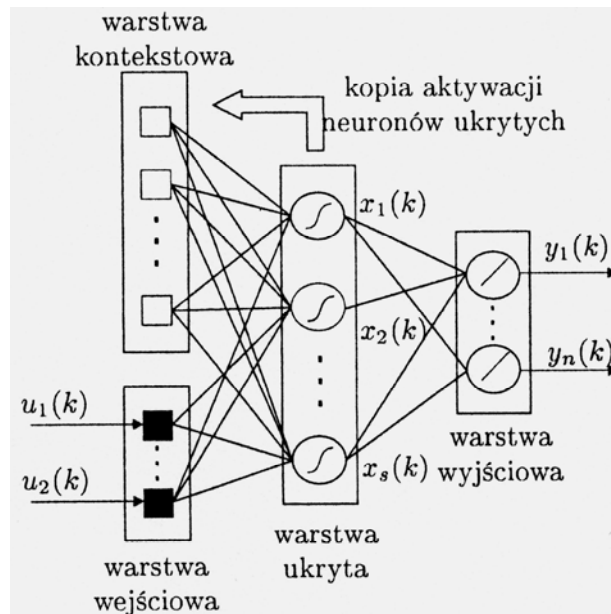
Standardowe sieci jednokierunkowe mogą jedynie reprezentować statyczne odwzorowania. Ich zastosowanie do modelowania dynamicznych zależności wymaga wprowadzenia informacji o sygnałach wejściowych i wyjściowych z przeszłych chwil czasu [119]. Niestety takie rozwiązanie ma szereg ograniczeń, między innymi potrzebę posiadania wiedzy o modelowanym obiekcie. Ponadto wzrasta znacznie przestrzeń sygnałów wejściowych, co zwiększa złożoność struktury sieci i czas jej uczenia. W przypadkach gdy nie ma możliwości określenia dokładnego rzędu obiektu, liczba opóźnionych wejść i wyjść powinna być ustalana eksperymentalnie, co oczywiście prowadzi do wydłużenia czasu wyznaczania modelu. Kolejną wadą są problemy z uzyskaniem wystarczająco dobrego modelu w przypadku uczenia długich zależności czasowych pomiędzy wejściem a wyjściem obiektu. Wymienione niedogodności mogą rozwiązać sieci rekurencyjne, o wbudowanych właściwościach dynamicznych [119].

Rekurencyjne sieci neuronowe posiadają bardzo ważne własności do modelowania, bowiem wprowadzone do ich architektury sprzężenia zwrotne dają im możliwość gromadzenia informacji oraz późniejszego ich wykorzystania. Ze względu na sposób realizacji sprzężeń zwrotnych, sieci rekurencyjne można podzielić na [114]:

- sieci lokalnie rekurencyjne – sprzężenia zwrotne znajdują się wewnątrz pojedynczych modeli neuronów. Cała sieć neuronowa jest strukturą wielowarstwową, jednokierunkową analogiczną do perceptronu wielowarstwowego,
- sieci globalnie rekurencyjne – sprzężenia zwrotne występują pomiędzy neuronami różnych warstw lub pomiędzy neuronami tej samej warstwy. Ogólna struktura sieci tego typu posiada wszystkie możliwe sprzężenia zwrotne pomiędzy neuronami.

Podstawową zaletą sieci rekurencyjnej jest możliwość aproksymacji szerokiej klasy zależności dynamicznych. Jednakże proces uczenia takich sieci może być bardzo długi. Pewnym kompromisem w tej materii jest sieć, która posiada architekturę częściowo rekurencyjną, zaproponowana w 1990 przez J.L. Elmana [47]. W sieci takiej (rys. 8.2) oprócz warstwy ukrytej znajduje się dodatkowa warstwa neuronów (warstwa kontekstowa), w której przechowuje się bieżące wartości sygnałów wyjściowych neuronów warstwy ukrytej. Zadaniem warstwy dodatkowej jest opóźnianie sygnałów o jeden takt, a następnie przesyłanie ich na wejście neuronów warstwy ukrytej. Można pokazać, że sieci tego typu posiadają zdolność modelowania systemów dynamicznych s -tego rzędu, gdzie s oznacza liczbę neuronów w warstwie ukrytej [112].

Podstawowym problemem związanym z siecią jest jej nauczenie. Często praktyką jest to, że wyjścia jednostek kontekstowych traktuje się jako dodatkowe wejścia do sieci, a do wyznaczania parametrów wagowych wykorzystuje się standardowy algorytm wstecznej propagacji błędów. Należy jednak pamiętać, że takie uproszczenie może być wadą ograniczającą modelowanie obiektów dynamicznych wyższych rzędów [111].



Rys. 8.2. Przykład sieci rekurencyjnej Elmana [119]

8.1.2. Struktura rekurencyjnej sieci typu Elmana

Sieć rekurencyjna Elmana charakteryzuje się częściową rekurencją w postaci sprzężenia zwrotnego między warstwą ukrytą a warstwą wejściową, realizowaną za pośrednictwem jednostkowych opóźnień z^{-1} . Strukturę szczegółową takiej sieci przedstawiono na rys. 8.3. Każdy neuron ukryty ma swój odpowiednik w warstwie tzw. kontekstowej, stanowiącej wspólnie z wejściami zewnętrznymi sieci warstwę wejściową. Warstwę wejściową tworzą neurony połączone jednokierunkowo tylko z neuronami warstwy ukrytej. Wektor wejściowy sieci w chwili t ma postać

$$\begin{aligned} \mathbf{x}(k) &= [x_0(k), x_1(k), \dots, x_N(k), v_1(k-1), v_2(k-1), \dots, v_K(k-1)], \\ \mathbf{v} &\in \mathbb{R}^K, \quad \mathbf{y} \in \mathbb{R}^M, \end{aligned} \quad (8.4)$$

gdzie: \mathbf{x} to wektor wymuszający sieci, do jego składu należy także sygnał jednostkowy polaryzacji, \mathbf{v} opisuje stany neuronów ukrytych, zaś \mathbf{y} sygnały wyjściowe sieci. Wagi połączeń synaptycznych sieci warstwy pierwszej (ukrytej) oznaczono jako $w_{ij}^{(1)}$, warstwy drugiej (wyjściowej) jako $w_{ij}^{(2)}$. Oznaczając sumę wagową i -tego neuronu warstwy ukrytej przez u_i , a jego sygnał wyjściowego przez v_i , otrzymuje się

$$u_i(k) = \sum_{j=0}^{N+K} w_{ij}^{(1)} x_j(k), \quad (8.5)$$


$$v_i(k) = f_1(u_i(k)). \quad (8.6)$$

Wagi $w_{ij}^{(1)}$ tworzą macierz $W^{(1)}$ połączeń synaptycznych neuronów w warstwie ukrytej, a $f_1(u_i)$ jest funkcją aktywacji i -tego neuronu warstwy. Podobnie można oznaczyć przez g_i sumę wagową i -tego neuronu warstwy wyjściowej, a przez y_i odpowiadający mu i -ty sygnał wyjściowy sieci. Sygnały te opisane są wzorami:

$$g_i(k) = \sum_{j=0}^K w_{ij}^{(2)} v_j(k) \quad (8.7)$$

oraz

$$y_i(k) = f_2(g_i(k)). \quad (8.8)$$



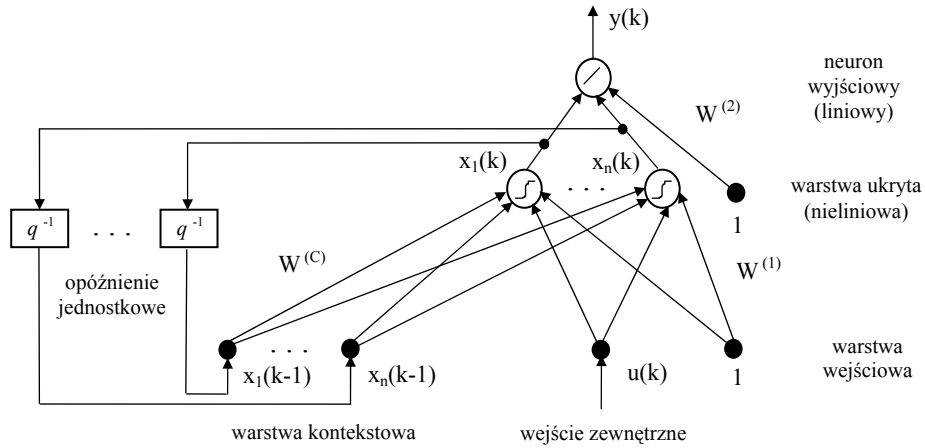
Rys. 8.3. Struktura sieci Elmana [112]

Wagi $w_{ij}^{(2)}$ tworzą z kolei macierz $W^{(2)}$, opisującą wagi połączeń synaptycznych neuronów warstwy wyjściowej, a $f_2(g_i)$ jest funkcją aktywacji i -tego neuronu warstwy wyjściowej.

8.1.3. Klasyfikator neuronowy typu kierowcy

W roli klasyfikatora, którego zadaniem jest ocena stylu jazdy, zastosowano częściowo rekurencyjną sieć Elmana. Zastosowania tego typu sieci dotyczą zazwyczaj modelowania ciągów czasowych (47, 151). Typowym przykładem jest tu detekcja amplitudy sygnału okresowego (45, 112). Sieć taka jest w stanie poprawnie realizować zadanie detekcji, nawet w sytuacji zmian częstotliwości sygnału wejściowego oraz w przypadku jego zakłóceń. Charakterystyczną cechą sieci Elmana, o czym wspomniano już wcześniej, jest występowanie częściowego sprzężenia zwrotnego, obejmującego neurony warstwy ukrytej, poprzez tzw. jednostki kontekstowe. Na rys. 8.4. przedstawiono strukturę sieci

Elmana, zastosowaną przez autora, z pojedynczym liniowym neuronem wyjściowym.



Rys. 8.4. Struktura sieci rekurencyjnej Elmana z pojedynczym wyjściem [14, 15, 30]

Równania przedstawionej na rys. 8.4. sieci można zapisać następująco:

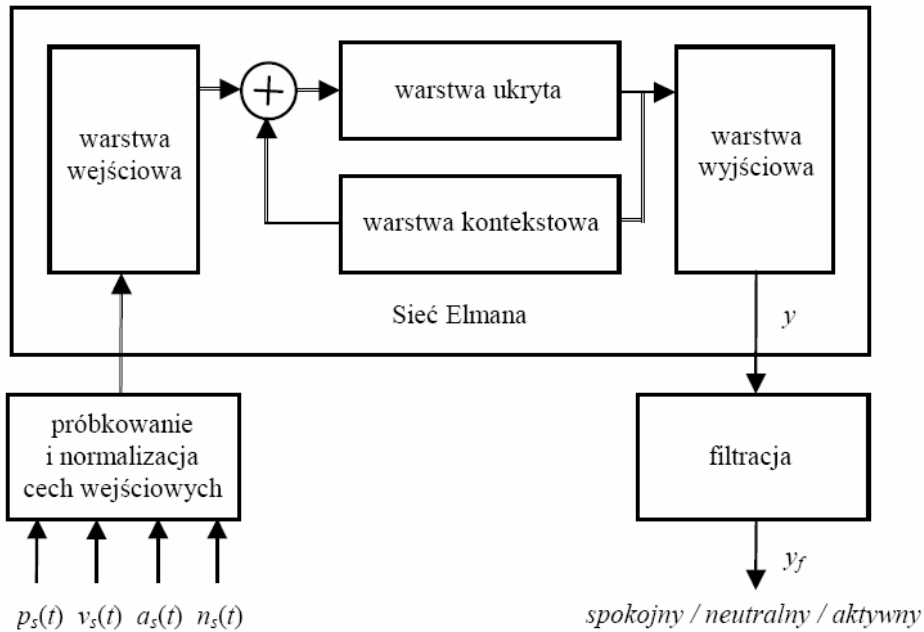
$$\begin{aligned} \mathbf{x}(k) &= f\left(W^{(C)}\mathbf{x}(k-1), W^{(1)}\mathbf{u}(k)\right) \\ y(k) &= W^{(2)}\mathbf{x}(k) \end{aligned} \quad (8.9)$$

gdzie:

- $\mathbf{u}(k)$ – sygnał wejściowy sieci, $\mathbf{u}(k) = [u_1(k) \ u_2(k) \ \dots \ u_n(k)]^T$,
- $\mathbf{x}(k)$ – wektor sygnałów wyjściowych warstwy ukrytej,
 $\mathbf{x}(k) = [x_1(k) \ x_2(k) \ \dots \ x_n(k)]^T$,
- $(\cdot)^T$ – operator transponowania wektorów lub macierzy,
- $y(k)$ – sygnał wyjściowy sieci,
- $W^{(1)}$ – macierz $n \times (m+1)$ współczynników wagowych warstwy ukrytej,
- $W^{(C)}$ – macierz $(n \times n)$ współczynników wagowych warstwy kontekstowej,
- $W^{(2)}$ – wektor $(n+1)$ współczynników wagowych warstwy wyjściowej,
- $f(\cdot)$ – nieliniowa funkcja aktywacji neuronów warstwy ukrytej.

Zależność (8.9) może być interpretowana jako opis nieliniowego, dyskretnego modelu obiektu dynamicznego w przestrzeni stanu. Wynika stąd, że w ogólnym przypadku ilość neuronów w warstwach: wejściowej oraz wyjściowej zależy od wymiarowości modelowanego zagadnienia, zaś ilość neuronów w warstwie ukrytej (i jednocześnie kontekstowej) odpowiadać będzie rzędowi modelu.

W pierwszej kolejności zastosowano sieć z czterema wejściami ($m = 4$) oraz z jednym neuronem wyjściowym (rys. 8.5)



Rys. 8.5. Schemat blokowy klasyfikatora stylu jazdy kierowcy opartego na sieci rekurencyjnej Elmana z czterema wejściami i jednym wyjściem [14, 15, 30]

Na wejście sieci podawane są spróbkowane wartości sygnałów, odpowiadających wybranym zmiennym stanu pojazdu:

- położenie pedału przyspieszenia - $p_s(t)$,
- prędkość samochodu - $v_s(t)$,
- przyspieszenie samochodu - $a_s(t)$,
- prędkość obrotowa silnika - $n_s(t)$.

Na wyjściu z sieci otrzymuje się sygnał y , a po procesie filtracji y_f .


Wielkość te, przed podaniem na wejście sieci poddawane były normalizacji, polegającej na przeskalowaniu ich do wartości z przedziału $(-1, 1)$. W podobny

sposób zakodowane zostały wzorce wyjściowe d : „spokojnemu” stylowi jazdy przyporządkowano wartość -1, „neutralnemu” – 0, zaś wartość 1 na wyjściu sieci odpowiada jeździe „aktywnej”. W trakcie działania sieci wielkość wyjściowa podlegała filtracji, mającej na celu uniknięcia gwałtownych zmian sygnału wyjściowego modelu.

Uczenie sieci polegało na modyfikacjach współczynników wagowych sieci w oparciu o znajomość gradientu funkcji celu E , definiowanej jako suma kwadratów różnic między wartościami sygnałów wyjściowych sieci y a ich wartościami zadanymi d , dla całego zbioru uczącego złożonego z N wzorców [112]

$$E = \frac{1}{N} \sum_{i=1}^N e_i^2 = \frac{1}{N} \sum_{i=1}^N [y_i - d_i]^2. \quad (8.10)$$

Proces minimalizacji błędu sieci w trakcie procesu uczenia ilustruje rys. 8.6.




Rys. 8.6. Przebieg minimalizacji funkcji błędu sieci w trakcie procesu uczenia [14, 15, 30]


Wagi warstwy wyjściowej sieci Elmana podlegają adaptacji w ten sam sposób, jak ma to miejsce w przypadku sieci jednokierunkowej. Natomiast dla warstwy ukrytej odpowiednie zależności są bardziej złożone ze względu na istnienie sprzężenia zwrotnego. Jako dane uczące wykorzystano sekwencje odpowiadające sześciu przejazdom testowym (po dwa dla każdego stylu jazdy). Dane uzyskane z pozostałych przejazdów przeznaczono dla potrzeb testowania klasyfikatora, w celu umożliwienia oceny jego właściwości generalizacyjnych.

Wybrane wyniki działania rozpatrywanej sieci Elmana przedstawiono na rys. 8.7 ÷ 8.10. Na rysunkach zaprezentowano przebiegi sygnału wyjściowego sieci y , sygnału po filtracji y_f oraz „wzorcowego” sygnału wyjściowego d , w odpowiedzi na cztery sekwencje wejściowe odpowiadające czterem różnym pod względem stylu jazdom testowym. Dwie pierwsze wykorzystane zostały w procesie uczenia sieci, natomiast kolejne dwie nie były „znane” sieci z procesu uczenia. Były użyte do jej testowania.


Dodatkowo linią przerywaną na wykresach zaznaczono umowne linie decyzyjne, oddzielające obszary odpowiadające różnym stylom jazdy. Ich poziom był dobrany w zależności od wartości stałej czasowej T_f filtru sygnału wyjściowego, ze względu na tłumienie amplitudy sygnału wyjściowego sieci.




Rys. 8.7. Wyniki weryfikacji klasyfikatora neuronowego (2 neurony ukryte)
Stała czasowa filtru $T_f = 25$ s [14, 15, 30]



Rys. 8.8. Wyniki weryfikacji klasyfikatora neuronowego (2 neurony ukryte)
Stała czasowa filtra $T_f = 100$ s [14, 15, 30]



Rys. 8.9. Wyniki weryfikacji klasyfikatora neuronowego (8 neuronów ukrytych)
Stała czasowa filtra $T_f = 25$ s [14, 15, 30]



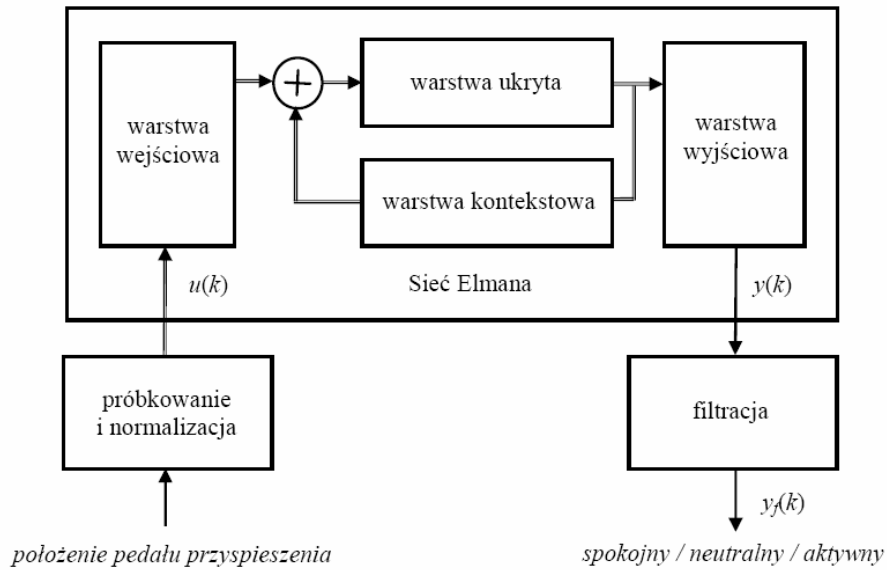
Rys. 8.10. Wyniki weryfikacji klasyfikatora neuronowego (8 neuronów ukrytych)
Stała czasowa filtru $T_f = 100$ s [14, 15, 30]

W celu ograniczenia wartości sygnału wyjściowego sieci, jako funkcję aktywacji neuronu wyjściowego wybrano, w odróżnieniu od sieci przedstawionej na rys. 8.4, funkcję tangens hiperboliczny. Wykonano również dodatkową modyfikację sieci polegającą na ograniczeniu liczby wejść do sieci z czterech do jednego, ograniczając się jedynie do podawania sygnału pedału przyspieszenia.


Schemat blokowy klasyfikatora stylu jazdy kierowcy ze zmodyfikowaną siecią Elmana przedstawiono na rys. 8.11. Efekt działania zmodyfikowanej sieci przedstawiono na rys. 8.12.

Wizualna ocena uzyskanych przebiegów pozwala na sformułowanie stwierdzenia, że rozpatrywana sieć Elmana posiada stosunkowo dobre właściwości klasyfikacyjne, także w przypadku danych nie wykorzystanych w procesie uczenia. Uznano tak mimo tego, że klasyfikator przyjmuje wartości niższe od założonego $[+1, -1]$ czyli z przedziału $[+0,3, -0,2]$.

Warunkiem poprawnej klasyfikacji jest dobór odpowiedniej ilości jednostek kontekstowych. Istotne znaczenie ma także dobór odpowiedniej wartości stałej czasowej T_f filtru sygnału wyjściowego, zapobiegającego zbyt gwałtownym jego zmianom.



Rys. 8.11. Schemat blokowy klasyfikatora stylu jazdy kierowcy opartego na sieci rekurencyjnej Elmana z czterema wejściami i jednym wyjściem [14, 15, 30]



Rys. 8.12. Wybrane wyniki weryfikacji klasyfikatora neuronowego. (10 neuronów kontekstowych, stała czasowa filtra wyjściowego $T_f = 50$ s) [14, 15, 30]

8.1.4. Ocena działania klasyfikatora neuronowego

Podsumowując stwierdzono, iż zastosowanie rekurencyjnej sieci neuronowej Elmana spełnia rolę klasyfikatora, mającego za zadanie ocenę bieżącego stylu prowadzenia samochodu na podstawie podawanych na jego wejście kolejnych próbek, reprezentujących aktualne położenie pedału przyspieszenia.

Badania symulacyjne, przeprowadzone z wykorzystaniem danych pomiarowych uzyskanych w trakcie rzeczywistych jazd testowych wskazują na poprawność klasyfikacji oraz stosunkowo dobre właściwości generalizacyjne sieci. Jednak ze względu na fakt, iż analizę przeprowadzono na podstawie sygnałów uzyskanych w ściśle określonych (rozdział 6), warunkach otoczenia (jazda miejska, małe natężenie ruchu, dobre warunki pogodowe), należy się spodziewać, że dla danych wejściowych odpowiadających innym warunkom zewnętrznym, odpowiedzi sieci mogą się różnić. Z tego względu niezbędne jest przeprowadzenie dalszych badań, mających na celu uwzględnienie poza działaniem kierowcy również aktualnych warunków otoczenia.

8.2. KLASYFIKATOR FALKOWY

8.2.1. Definicje i własności transformaty falkowej [5, 31, 35, 86, 99, 125, 126]

Tradycyjna analiza widmowa Fouriera jako superpozycja funkcji sinus i cosinus jest niemal wszechobecna w dziedzinie identyfikacji i analizy sygnałów pomiarowych. Użyteczność transformaty Fouriera zawiera się w jej zdolności do analizy przebiegu czasowego sygnału pod kątem jego „zawartości częstotliwościowej”.

Należy podkreślić, że tradycyjna analiza częstotliwościowa nie nadaje się do obserwacji właściwości sygnałów niestacjonarnych. Wymagana jest tutaj analiza wykorzystująca łączne czasowo-częstotliwościowe (t/f) reprezentacje sygnałów. Tego rodzaju analizę zapewnia krótkoczasowa transformata Fouriera, czy też transformata Gabora.

Rodzajem analizy czasowo-częstotliwościowej jest również transformacja falkowa. Najbardziej charakterystyczne dla transformaty falkowej jest to, że indywidualne funkcje falkowe są dobrze zlokalizowane w czasie (lub przestrzeni – dla obrazów) i jednocześnie dobrze opisują sygnał w dziedzinie częstotliwości, ściśle biorąc tzw. skali. Ponadto w odróżnieniu od funkcji sinus i cosinus, które definiują unikalną transformatę Fouriera, nie ma pojedynczego, unikalnego zbioru falkowych funkcji bazowych.

Falki różnią się między sobą zawartością lokalizacji czasowej oraz płynnością i gładkością kształtów. Wynikająca stąd zdolność falek do opisu sygnałów „z nieciągłościami”, przy ograniczonej liczbie współczynników oraz z lokalizacją w czasie, stanowi o jej przewadze nad transformatą Fouriera.

Krótkoczasowa transformata Fouriera (STFT – Short-Time Fourier Transform) stanowi wzorcowy przykład algorytmu analizy czasowo-częstotliwościowej. Umożliwia ona wydobycie z sygnału informacji o tym, jak zmienia się jego widmo w czasie, czyli jednoczesną obserwację jego właściwości zarówno w dziedzinie czasu jak i częstotliwości. Wycinek sygnału przeznaczony do analizy jest sukcesywnie dzielony na segmenty, z których każdy podlega analizie widmowej niezależnie.

Podobnie jak w przypadku tradycyjnym, aby usunąć gwałtowne zmiany (cięcia) sygnału na krańcach przedziałów, stosuje się różne okna czasowe w odniesieniu do wspomnianych segmentów. Przesuwając okno w czasie, wzdłuż sygnału, wyznacza się jego zawartość widmową wewnątrz przedziału czasowego, którego długość jest określona szerokością okna.

Krótkoczasową transformatą Fouriera, opisującą sygnał ciągły wyraża się zależnością

$$X(t, f) = \int_{-\infty}^{+\infty} x(\tau) w(\tau - t) e^{-j\omega\tau} d\tau, \quad (8.11)$$

natomiast dla sygnału dyskretnego:

$$X(n, k) = \int_{m=0}^{N-1} w(m) x(n - m) e^{-jm\left(\frac{2\pi k}{N}\right)}. \quad (8.12)$$

W zależnościach (8.11) i (8.12) czynnik czasu jest reprezentowany przez składową $w(\tau - t)$ lub $w(m)$, gdzie τ lub m jest przesunięciem okna czasowego o szerokości Δt (odpowiednio może być też przesuwane okno w dziedzinie częstotliwości).

Rezultat analizy STFT, czyli zmienności sygnału zarówno w dziedzinie czasu jak i częstotliwości może być pokazywany jako wykres trójwymiarowy lub w postaci spektrogramu.


Kształt okna czasowego Δt rozmieszczonego na płaszczyźnie t/f odgrywa kluczową rolę w przypadku STFT. Iloczyn szerokości okna w dziedzinie czasu Δt szerokości okna w dziedzinie częstotliwości $\Delta \omega$ jest wielkością stałą dla danego okna

$$\Delta t \cdot \Delta \omega = const . \quad (8.13)$$

Stąd też, poprawiając rozdzielczość w dziedzinie czasu, będzie się ją pogarszać w dziedzinie częstotliwości i odwrotnie. Przy sygnale wolnozmiennym okno czasowe powinno być duże, natomiast przy sygnale szybkozmiennym duże powinno być okno częstotliwościowe. Zatem szerokość okna wybierana jest na drodze kompromisu.


Ten problem rozwiązuje między innymi transformata falkowa (wavelet transform WT), w której okna czasowe i częstotliwościowe mają zmienne szerokości. W przypadku rozkładu falkowego iloczyn promieni okien, czasowego i częstotliwościowego, ma wartość stałą na całej płaszczyźnie.

Na rys. 8.13, dla celów porównawczych, zilustrowano ideę czasowo-częstotliwościowej (STFT) oraz falkowej metody analizy sygnałów. Widać na nim wyraźnie, że w odróżnieniu od metody STFT, gdzie rozdzielczość czasowo-częstotliwościowa jest ustalona na całej płaszczyźnie t/f , w metodzie falkowej rozmiary okna czasowo-częstotliwościowego są funkcją jego położenia na tej płaszczyźnie.



Rys. 8.13. Wymiary okna w dziedzinie czasu i częstotliwości w przypadku STFT i transformaty falkowej [126]

Transformata falkowa pozwala na przeprowadzenie analizy czasowo-częstotliwościowej, przy czym częstotliwość jest tu reprezentowana przez skalę zagęszczenia falki. Jest to więc właściwie analiza czas-skala. Rodzina falek dyskretnych różni się skalą i przesunięciem zmiennym co 2. Przykład takiego zestawu falek przedstawia rys. 8.14. Na tymże rysunku przedstawiono również przykłady skalowania funkcji dla pewnej (typowej) falki. Proces skalowania falki może przebiegać w dwu kierunkach, określa się je mianem kompresji (ściskania) i rozciągania.




Rys. 8.14. Przykłady skalowania falek [126]

W przykładzie zamieszczonym w części górnej rys. 8.14 do skalowania falki zastosowano kompresję. Drugi parametr rozkładu falkowego to przesunięcie. Sposób przesuwania falki w czasie przedstawiono w części dolnej rysunku 8.14.

Istnieje wiele rodzin i odmian falek analizujących takie, jak: Meyera, Morleta, Daubechies, Haara czy „meksykański kapelusz” [Misiti]. Falka analizująca musi mieć skończoną energię oraz wartość średnią równą zero. W efekcie ma ona postać krótkotrwałej oscylacji jak na rysunkach 8.15a i 8.15b. W zależności od użytej falki analizującej można określić różne właściwości badanego sygnału [16].

Falka „meksykański kapelusz” jest przydatna do oceny rozkładu i wartości lokalnych minimów i maksimów sygnału, a falka Morleta do rozkładu amplitud i częstotliwości wchodzących w skład sygnału [102].



Rys. 8.15. Falki analizujące: a) Morleta, b) „meksykański kapelusz” [102]

Analiza falkowa dekomponuje proces na składowe ortogonalne, będące przesuniętymi i przeskalowanymi wersjami tak zwanej falki analizującej.

Przekształcenie falkowe opiera się na schemacie, w którym falkę analizującą skaluje się i przesuwa wzdłuż analizowanego sygnału zgodnie z zależnością (8.14), wyznaczając iloczyn skalarny dla każdej skali i przesunięcia falki analizującej.

$$CTF_f(\tau, s) = \langle f(t), \psi_{\tau, s}(t) \rangle = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-\tau}{s}\right) dt, \quad (8.14)$$

gdzie: $\psi(t)$ – falka podstawowa, s – skala, τ – przesunięcie czasowe,

s i τ – są dziedziną transformaty falkowej.

W wyniku jednowymiarowego ciągłego przekształcenia falkowego otrzymuje się półpłaszczyznę w układzie skala i czas. Zmienna s odpowiada skali falki przyjmowanej podczas kolejnych etapów wyznaczania transformaty. Jej odwrotnością jest częstotliwość chwilowa [102].

8.2.2. Analiza falkowa sygnału pedału przyspieszenia

Analizę sposobu uchylania pedału przyspieszenia przeprowadzono za pomocą ciągłej transformaty falkowej (CTF), przy zastosowaniu przyborka Wavelet Toolbox zawartego w środowisku obliczeniowym Matlab® [102]. Do oceny charakteru zmian położenia pedału przyspieszenia wykorzystano falkę „Morleta” – rys. 8.16, 8.17 i 8.18. Natomiast do oceny rozkładu ekstremów położenia pedału przyspieszenia wykorzystano falkę „meksykański kapelusz” – rys. 8.19, 8.20 i 8.21.


Analiza widm przedstawionych na rys. 8.16 i 8.17 wskazuje na to, że w przypadku kierowcy „spokojnego” i „neutralnego” zwraca uwagę występowanie wstęg lokalnych maksimów macierzy CTF - Morlet w paśmie od 0,1 Hz do 0,7 Hz, dla fragmentu testu, który odpowiada rozpędzaniu pojazdu. Można to interpretować, jako preferowaną przez kierowców „spokojnego” i „neutralnego” częstotliwość zmiany położenia pedału przyspieszenia.

Dokonując dalszych przybliżeń stwierdzono, iż kierowcy „spokojny” i „neutralny” preferują częstotliwości ok. 0,2-0,4 Hz i zmieniają położenie pedału przyspieszenia rytmicznie w fazie przyspieszania.


Dla kontrastu kierowca „aktywny”, rys. 8.18, nie ma ustalonej preferencji w analizowanym paśmie i nie można wyodrębnić wyraźnych wstęg lokalnych maksimów o określonej stałej częstotliwości. Wstęgi występują przy wyższych częstotliwościach powyżej 0,7 Hz, dla których częstotliwość jest zmienna w czasie, co może świadczyć o „chaotycznych” ruchach pedałem przyspieszenia.

Analiza rozkładu i kształtu ekstremów widma, macierzy CTF - „meksykański kapelusz”, przedstawionych na rys. 8.19 wskazuje, że kierowca „spokojny” wykonuje krótkie szybkie ruchy o małej amplitudzie (wąskie pionowe wstęgi lokalnych maksimów współczynników falkowych), kierowca „neutralny” ruchy nieco wolniejsze i o wyższej amplitudzie (rys. 8.20) natomiast „aktywny” zarówno gwałtowne, jak i o dużej amplitudzie (rys. 8.21).


Na podstawie tych testów nie sposób stwierdzić, że prędkość zmian położenia pedału przyspieszenia jest parametrem pozwalającym jednoznacznie określić sposób jazdy kierowcy, natomiast istotnymi wydają się wartości położenia pedału przyspieszenia oraz częstotliwość zmian jego położenia.




Rys. 8.16. Ciągłe przekształcenie falkowe z wykorzystaniem falki Morleta dla sygnału uchylenia pedału przyspieszenia dla kierowcy „spokojnego” [16]




Rys. 8.17. Ciągłe przekształcenie falkowe z wykorzystaniem falki Morleta dla sygnału uchylenia pedału przyspieszenia dla kierowcy „neutralnego” [16]




Rys. 8.18. Ciągłe przekształcenie falkowe z wykorzystaniem falki Morleta dla sygnału uchylenia pedału przyspieszenia dla kierowcy „aktywnego” [16]



Rys. 8.19. Ciągłe przekształcenie falkowe z wykorzystaniem falki „meksykański kapeluszy” dla sygnału uchylenia pedału przyspieszenia dla kierowcy „spokojnego” [16]



Rys. 8.20. Ciągłe przekształcenie falkowe z wykorzystaniem falki „meksykański kapeluszy” dla sygnału uchylenia pedału przyspieszenia dla kierowcy „neutralnego” [16]



Rys. 8.21. Ciągłe przekształcenie falkowe z wykorzystaniem falki „meksykański kapeluszy” dla sygnału uchylenia pedału przyspieszenia dla kierowcy „aktywnego” [16]

8.2.3. Falkowy klasyfikator typu kierowcy

Na podstawie powyższych rozważań opracowano algorytm, za pomocą którego można określić styl jazdy kierowcy. Bazuje on na przekształceniu falkowym z wykorzystaniem falki Morleta.

Kolejne kroki algorytmu to:

1. Rejestracja wartości sygnału położenia pedału przyspieszenia, co 0,1 s przez okres 60 s (macierz 600 wartości).
2. Zróżniczkowanie cyfrowe sygnału z odstępem 0,1 s i zapamiętanie go w osobnej macierzy.
3. Przesunięcie sygnału zróżniczkowanego o 0,1 s w celu wyeliminowania przesunięcia fazowego między sygnałem zróżniczkowanym a zmierzonym.
4. Obliczenie ciągłej transformaty falkowej z wykorzystaniem falki analizującej Morleta dla sygnału zróżniczkowanego.
5. Uśrednienie po czasie wartości współczynników falkowych i zapamiętanie ich wartości średnich w funkcji częstotliwości.
6. Wyznaczenie częstotliwości f_{max} , przy której wartość średnia współczynników falkowych była największa.
7. Obliczenie wartości wskaźnika jazdy za pomocą zależności

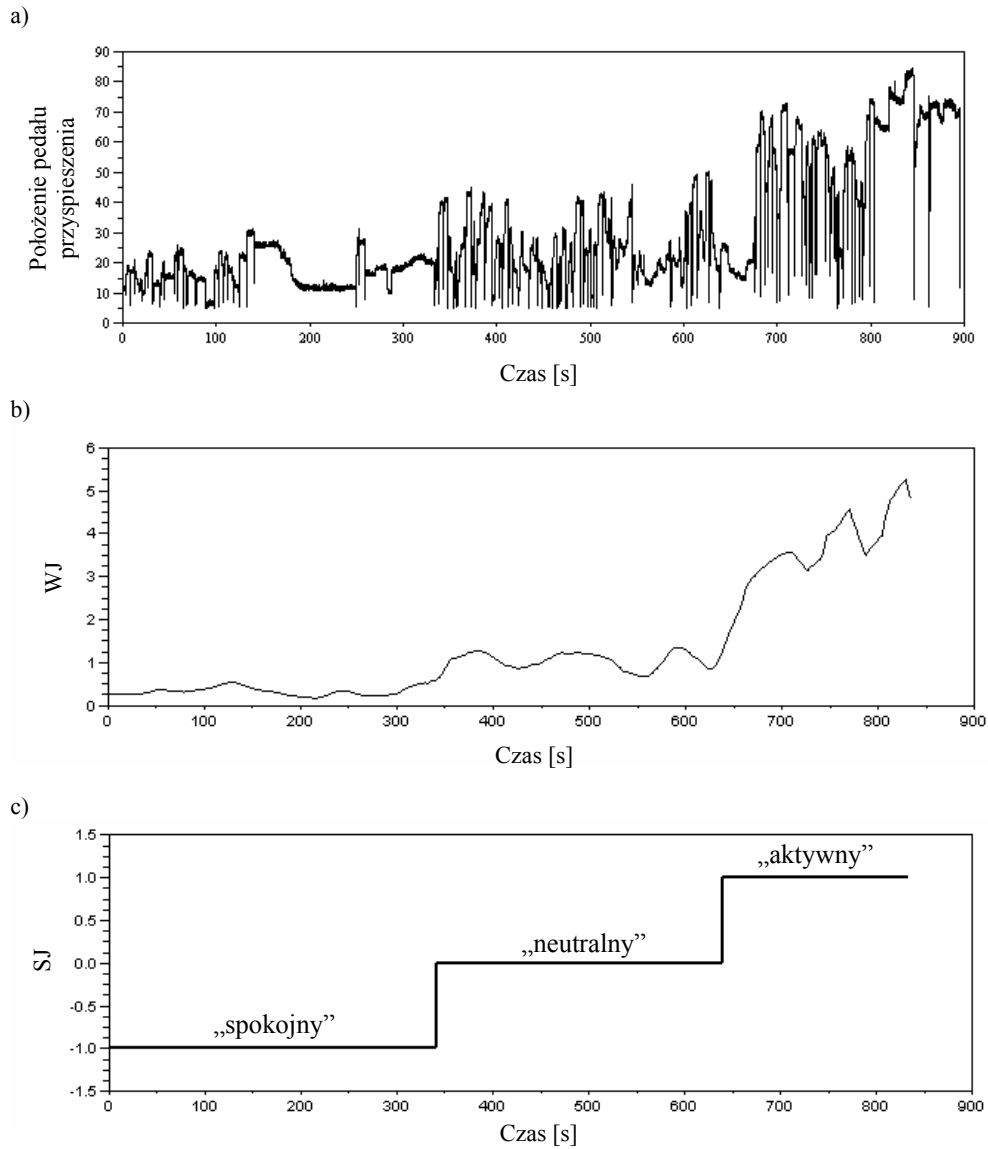
$$WJ = f_{max} * a_{max} * pp_{sr}, \quad (8.15)$$

gdzie: WJ – wskaźnik jazdy,
 f_{max} – częstotliwość, przy której wartość średnia współczynników falkowych była największa,
 a_{max} – największa wartość średnia współczynników falkowych w analizowanej macierzy,
 pp_{sr} – wartość średnia położenia pedału przyspieszenia w analizowanej macierzy.

8. Przypisanie wartości klasyfikatora stylu jazdy SJ do przedziałów wartości wskaźnika jazdy WJ na podstawie zależności

$WJ \leq 0,6$	SJ = (-1) – kierowca „spokojny”
$WJ \in (0,6 \div 1,35)$	SJ = (0) – kierowca „neutralny”,
$WJ > 1,35$	SJ = (1) – kierowca „aktywny”,
9. Powtórzenie cyklu obliczeń od kroku 1 po upływie arbitralnie wybranego czasu, w tym przypadku po 5 sekundach.

Algorytm przetestowano na zbiorach danych, które uzyskano w trakcie badań. Na rys. 8.22 przedstawiono wartości **WJ** oraz **SJ** dla zsyntetyzowanych przejazdów, pochodzących od kierowcy „spokojnego”, „neutralnego” oraz „aktywnego”.



Rys. 8.22. Zmiany w czasie: a) położenia pedału przyspieszenia, b) wartości wskaźnika jazdy WJ, c) wartości klasyfikatora stylu SJ [16]

Przełączenie stylu jazdy następuje wówczas, gdy stwierdzona zostanie zmiana wartości SJ trwająca dłużej niż 1 minutę. Oznacza to, że algorytm pozwala wtedy na relatywnie szybkie wykrycie zmiany stylu jazdy.

W trakcie analizy za pomocą wskaźników **WJ** i **SJ** stwierdzono, że sklasyfikowani w trzech grupach kierowcy zmieniają styl jazdy na krótkie (mniej niż 1 minuta) okresy. Z wywiadów przeprowadzonych po jazdach testowych wynikało, że były to najczęściej reakcje na zmienne warunki ruchu. Szczególnie dotyczy to kierowców „aktywnych”, którzy zmieniali chwilowo styl jazdy na „neutralny” oraz „spokojnych”, których styl jazdy zmieniał się na krótki okres czasu na „neutralny”, a nawet „aktywny”.

Uznano, że dobór przełożeń bądź parametrów pracy silnika nie może odbywać się wprost z ustaleń powyższego algorytmu, bowiem istnieje przypuszczenie, że w niektórych sytuacjach drogowych mogłoby dojść do niepożądanego reakcji układu napędowego na gwałtowne wymuszenia kierowcy reagującego na zmienne warunki drogowe. Oznacza to, że w rzeczywistym pojeździe wymagany będzie dodatkowo algorytm eliminujący takie przypadki, oczywiście za wyjątkiem reakcji typu „kick down”.

8.2.4. Ocena działania klasyfikatora falkowego

W zaproponowanym algorytmie wyznaczania wartości **WJ** i **SJ** oparto się tylko na jednym sygnale – wartości wychylenia pedału przyspieszenia w czasie. Przedstawiony algorytm jest elastyczny i można go dostosować praktycznie do każdego samochodu. Szczególną rolę w jego adaptacji pełnią dwa parametry określone w kroku 1 i 9, czyli rozmiar analizowanej tablicy i czas oczekiwania do następnego cyklu obliczeń. Charakter zmian wartości wychylenia pedału przyspieszenia zarejestrowany w trakcie jazdy miejskiej wskazuje, że jest to sygnał niestacjonarny. Uznano, że odpowiednim narzędziem do określenia wartości **WJ** i **SJ** będzie - ciągła transformata falkowa (CTF). Przyjęte wskaźniki pozwalają klasyfikować styl jazdy na trzy kategorie „aktywny”, „neutralny” i „spokojny”.

Wykazano, że wykorzystanie analizy falkowej nie tylko z powodzeniem pozwala na klasyfikację stylu jadącego kierowcy. Śledząc przebieg zmian położenia pedału przyspieszenia możliwe będzie wykrywanie ewentualnych zmian stylu, np. z „aktywnego” na „spokojny”, w relatywnie krótkim czasie.

8.3. KLASYFIKATOR CHAOTYCZNY TYPU KIEROWCY

Teoria chaosu pozwala ująć w sposób ilościowy dynamikę niepewności i odnaleźć porządek w jej nieregularnościach. Teoria chaosu to pojęcie potoczne, w literaturze naukowej nazywana analizą nieliniowych układów dynamicznych [1, 29, 43, 87, 90, 113, 136].

Studia nad nieliniowymi systemami dynamicznymi oraz nad teoriami złożoności to studia nad „turbulencją”, a ściślej mówiąc nad przejściem od stabilności do „turbulencji”. System dynamiczny z istoty swej nie poddaje się długoterminowym prognozom. Istnieją dwa powody tej nieprzewidywalności. W systemach dynamicznych działa sprzężenie zwrotne oraz występują poziomy krytyczne. Reasumując można powiedzieć, że system dynamiczny to system nieliniowego sprzężenia zwrotnego. Jego najistotniejszymi własnościami są: wrażliwość na zmiany warunków początkowych, obecność poziomów krytycznych oraz wymiar fraktalny [90, 113].

Nieliniowe systemy dynamiczne mają na ogół więcej niż jedno rozwiązanie. A zdarza się, że liczba rozwiązań jest bardzo duża lub wręcz nieskończona. Wizualne przedstawienie takich danych tworzy skończoną przestrzeń nazywaną fazową. Liczba wymiarów przestrzeni zależy od liczby zmiennych obecnych w systemie. Jeśli zmienne są dwie lub trzy, możemy badać dane wizualnie. Jeśli wymiarów jest więcej, badamy dane matematycznie [103, 116].

Kolejnym pojęciem stosowanym w dynamice nieliniowej jest atraktor. Jest to obszar poziomu równowagi systemu nieliniowego szeregu czasowego. Układ dążący do stabilnej równowagi określonej jedną wartością ma atraktor punktowy. Bywają też atraktory fazowe, które w przestrzeni tworzą cykle okresowe lub orbity. Atraktor, którego punkty w przestrzeni nigdy nie powtarzają się, a orbity nigdy się nie przecinają, ale zarówno jedne jak i drugie powstają w tym samym obszarze przestrzeni fazowej, nazywany jest dziwnym atraktorem. Atraktory te w przeciwieństwie do atraktora punktowego czy fazowego są nieokresowe i na ogół mają wymiar fraktalny. Przykładowe atraktory przedstawiono na rys. 8.23 [28].

8.3.1. Wymiar fraktalny szeregu czasowego

Wymiar fraktalny dostarcza ważną informację o systemie. Jest to liczba stanowiąca ilościowy sposób, w jaki obiekt wypełnia swoją przestrzeń. Najbliższa liczba całkowita wyższa od wymiaru fraktalnego mówi nam jaka minimalna liczba dynamicznych zmiennych potrzebna jest do sporządzenia modelu dynamiki systemu. Jednocześnie wymiar fraktalny jest dolną granicą liczby możliwych stopni swobody [110].

Rodzaj atraktora / charakterystyka	Punkt	Orbita okresowa	Orbita quasiokresowa	Dziwny atraktor chaotyczny
Przebieg czasowy				
Portret fazowy				
Widmo częstości				
Funkcja autokorelacji				

Rys. 8.23. Przykładowe wartości wykładników dla różnych przebiegów czasowych [28]

Praktyczną procedurą wyznaczania wymiaru fraktalnego jest metoda opracowana przez Grassbergera i Procaccia w 1983 roku [55]. Polega ona obliczaniu wymiaru korelacyjnego, stanowiącego przybliżenie wymiaru fraktalnego przy użyciu całki korelacyjnej $C(R)$. Całka ta wyraża prawdopodobieństwo znalezienia się pary punktów atraktora w odległości R od siebie. Całkę korelacyjną $C(R)$ oblicza się według następującego równania

$$C(R) = \frac{1}{N} \cdot \sum_{\substack{i,j=1 \\ i \neq j}}^N H(R - |x_i - x_j|), \quad (8.16)$$

gdzie:

$$H(x) = 1 \quad \text{dla} \quad R - |x_i - x_j| \geq 0,$$

$$H(x) = 0 \quad \text{dla} \quad R - |x_i - x_j| < 0,$$

N – liczba punktów pomiarowych,

R – odległość.

$H(x)$ jest funkcją Heaviside'a która przyjmuje wartość 1, gdy odległość między x_i a x_j jest mniejsza od R lub 0, gdy odległość ta jest większa. Całka korelacyjna jest prawdopodobieństwem tego, że losowo wybrane punkty będą od siebie oddalone o mniej niż R jednostek. W miarę zwiększania wartości R , $C(R)$ powinna rosnąć w tempie R^D , gdzie D jest wymiarem korelacyjnym. Daje to następujące zależności

$$C(R) \sim R^D \quad (8.17)$$

oraz

$$\log(C(R)) = D \log(R) + const . \quad (8.18)$$

Dla danego wymiaru pojemnościowego m oblicza się $C(R)$ zwiększając wartość R , ustalając nachylenie wykresu $\log(C(R))$ w stosunku od $\log(R)$. Za pomocą regresji liniowej można wyznaczyć wymiar korelacyjny D . W miarę powiększania wartości wymiaru pojemnościowego m wymiar korelacyjny D będzie zbliżać się do swojej prawdziwej wartości.

Przed przystąpieniem do właściwego obliczania całki korelacyjnej szeregu czasowego wymagane jest przetworzenie danych celem rekonstrukcji przestrzeni fazowej, a w szczególności ustalenie wymiaru pojemnościowego oraz opóźnienia czasowego.

8.3.2. Rekonstrukcja przestrzeni fazowej szeregu czasowego

Celem analizy nieliniowej jest zrekonstruowanie dla danego sygnału $s(t)$ właściwej przestrzeni stanu oraz odtworzenie jej dynamiki. W podejściu klasycznym współrzędnymi przestrzeni stanu są przesunięcie i prędkość. Jednak w praktyce trudno je zmierzyć, a ponadto z reguły nic nie wiadomo o wymiarze oryginalnej przestrzeni stanu. Nowoczesne metody analizy sygnałów, oparte na teorii chaosu deterministycznego, umożliwiają rekonstrukcje przestrzeni stanu równoważnej oryginalnej, bez potrzeby znajomości pochodnych (prędkości) oraz wymiaru przestrzeni oryginalnej. Dokonuje się tego przez „zanurzenie” (embedding) szeregu czasowego z wykorzystaniem metody opóźnienia czasowego (time – delay embedding). Identyfikuje się przestrzeń formalnie równoważną oryginalnej przestrzeni stanu układu i do tej identyfikacji używa się współrzędnych utworzonych z obserwowanych zmiennych oraz ich opóźnień. Charakterystyczny czas opóźnienia czasowego τ znajduje się jako pierwsze miejsce zerowe funkcji autokorelacji sygnału $K(\tau)$ [1, 29, 36, 82].

Wybór odpowiedniego czasu opóźnienia τ ma istotne znaczenie dla całości procesu dynamiki. Wybór zbyt małej wartości τ powoduje, że czas ewolucji będzie niewystarczający, aby dostatecznie eksplorować całość przestrzeni stanu. Zrekonstruowany atraktor będzie skupiony wzdłuż głównej przekątnej lub wzdłuż linii identyczności przestrzeni zanurzenia. Wybór zbyt małej wartości τ , powoduje, że współrzędne mogą znaleźć się tak daleko od siebie, iż staną się nieskorelowane [36].

Wobec wewnętrznej niestabilności układów chaotycznych zbyt długi czas opóźnienia spowoduje, że związek pomiędzy pomiarem $s(n)$ i $s(n+T)$ będzie numerycznie równoznaczny przypadkowości. Funkcję autokorelacji $K(\tau)$ można zapisać jako:

$$K(\tau) = \sum \left[S_n - \bar{S} \right] \left[S_{n+T} - \bar{S} \right], \quad (8.19)$$

gdzie: $\bar{S} = \frac{1}{N} \sum_{n=1}^N S_n$.

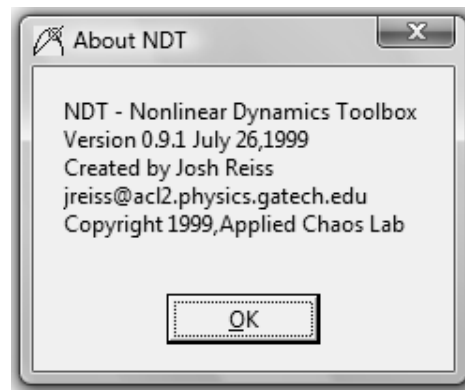
Mając dane opóźnienie czasowe τ szacuje się wymiar przestrzeni stanu, w której odtwarza się dynamikę stanu. W tym celu, z użyciem metody najbliższych fałszywych sąsiadów FNN (False Nearest Neighbour metod) próbuje się odtworzyć dynamikę w kolejnych przestrzeniach stanu o coraz wyższym wymiarze. Ostateczna liczba wymiarów jest określona przez odpowiedź na pytanie, kiedy struktura geometryczna utworzona w kolejnych przestrzeniach stanu dwa-, trzy- i więcej wymiarowych będzie całkowicie „odfałdowana”, czyli kiedy bliska odległość między punktami będzie wynikiem jedynie dynamiki, a nie rzutowania w przestrzeni o mniejszym wymiarze [36].

Najniższy wymiar, który odfałduje atraktor w wyniku czego wszystkie „nałożenia” znikają, jest nazywany globalnym wymiarem zanurzenia d_G . Każdy sygnał pomiarowy stanowi inną nieliniową kombinację oryginalnych zmiennych dynamicznych i może wytworzyć różne globalne odwzorowanie z oryginalnej przestrzeni do zrekonstruowanej przestrzeni o wymiarze d_G . Nadto d_G jest wymiarem globalnym i może się różnić od lokalnych wymiarów danej dynamiki. Aby znaleźć właściwy wymiar, można zastosować metodę najbliższych fałszywych sąsiadów, odpowiadającą „odfałdowaniu” atraktora. Należy uwzględnić kolejne wymiary $d = 1, 2, 3, \dots$, sprawdzać kolejno dla wszystkich wektorów danych oraz dla ich sąsiadów, czy sąsiedztwa są wynikiem rzutowania, czy też geometrii dynamiki systemu. Te sąsiadujące punkty, które okazują się wynikiem rzutowania, nazywają się fałszywymi sąsiadami. To czy sąsiad jest fałszywy, sprawdza się, dokonując ewolucji i obserwując, czy odległość pomiędzy wektorami wzrasta, czy też pozostaje stała lub maleje [36].

Mając odpowiedni wymiar i czas opóźnienia można utworzyć wektory rekonstruujące przestrzeń stanu systemu i odtworzyć jego dynamikę. Dalsze postępowanie może polegać na analizie trajektorii w przestrzeni stanu oraz na badaniu wartości wymiaru fraktalnego.

8.3.3. Wymiar korelacyjny sygnału pedału przyspieszenia

Sygnaly zarejestrowane podczas badan drogowych, pomiarow polozenia pedału przyspieszenia zostaly poddane analizie nieliniowej, a w szczegolności do wyznaczenia wymiaru korelacyjnego, przy wykorzystaniu dostępnego w Internecie oprogramowania NDT (Nonlinear Dynamics Toolbox) (rys. 8.24) [107].



Rys. 8.24. Autoryzacja programu NDT [107]


Podobnie jak to uczyniono we wcześniejszych przypadkach poszukiwano metody estymacji typu kierowcy, opierając się na założeniu, że jest możliwe wykorzystanie wymiaru korelacyjnego jako estymatora typu kierowcy.

W tym celu poddano analizie nieliniowej przebiegi czasowe sygnałów generowanych pedałem przyspieszenia przez badanych kierowców. Mając na uwadze uzyskany ranking, przedstawiony w rozdziale 6, w którym badani kierowcy zostali sklasyfikowani od najbardziej aktywnego do skrajnie spokojnego poszukiwano korespondencji pomiędzy typem kierowcy a wymiarem korelacyjnym.


Jak wspomniano wcześniej w celu obliczenia wymiaru korelacyjnego trzeba było najpierw wyznaczać wartości czasu opóźnienia τ oraz wymiary przestrzeni zanurzenia d . Były to wartości wyjściowe do dalszych obliczeń.

Czas opóźnienia τ był obliczany jako pierwsze miejsce zerowe funkcji autokorelacji $K(\tau)$. Przykładowe zależności funkcji autokorelacji $K(\tau)$ przedstawiono na rys. 8.25. Jak widać z rysunku przejście przez zero funkcji $K(\tau)$ następowało dla znacząco różnych wartości opóźnienia. Nie stwierdzono korespondencji pomiędzy typem kierowcy a opóźnieniem τ .


Na rysunku 8.26 przedstawiono wyznaczone pierwsze miejsca zerowe dla dwóch skrajnie różniących się typów kierowców.



Rys. 8.25. Przykładowo wyznaczone opóźnienia z przebiegu funkcji autokorelacji $K(\tau)$,
a) $\tau = 187$, b) $\tau = 1009$



a)



b)

Rys. 8.26. Wyznaczone opóźnienia z przebiegu funkcji autokorelacji $K(\tau)$,
a) kierowca aktywny $\tau = 239$, b) kierowca spokojny $\tau = 432$

Natomiast wymiar zanurzenia d wyznaczano metodą najbliższych fałszywych sąsiadów. W tym celu analizowano wykresy zależności procentu fałszywych sąsiadów od wymiaru d . Wykresy te okazywały się zawsze monotonicznie malejące i nie sprawiały większych trudności obliczeniowych. Jako wymiar zanurzenia przyjmowano taką wartość d , przy której procent fałszywych sąsiadów osiągał wartość zero.

Przykładowe zależności funkcji procentu fałszywych sąsiadów od wymiaru przestrzeni zanurzenia d przedstawiono na rys. 8.27. Jak widać z rysunku osiąganie zera następowało dla znacząco różnych wartości wymiaru zanurzenia d . W przypadku analizy tego parametru nie stwierdzono korespondencji pomiędzy typem kierowcy a wymiarem d .

Na rysunku 8.28 przedstawiono wyznaczone wymiary przestrzeni zanurzenia d dla dwóch skrajnie różniących się typów kierowców.

Reasumując stwierdzono, że dla wszystkich przebadanych sygnałów pedału przyspieszenia, pochodzących od 76 kierowców wartości τ i d były zróżnicowane. Czas opóźnienia τ zawierał się w przedziale 146÷1171. Z kolei wartość wymiaru zanurzenia d w przedziale 7÷20.

Otrzymane wyżej wartości pozwoliły przystąpić do obliczania wymiaru korelacyjnego. Wykres zależności $\log(C(R))$ od $\log(R)$ wykazywał charakterystyczne zbrocza. Do oszacowania wymiaru korelacyjnego D brano pod uwagę jedynie liniową część tego wykresu. Bowiern wartość D jest współczynnikiem nachylenia tej części.



Uzyskane dla 76 kierowców wymiary korelacyjne pogrupowano na 3 zbiory. Przedstawia to tabela 8.1

Tabela 8.1


Wyniki obliczeń wymiaru korelacyjnego

Wymiar korelacyjny	Liczba kierowców	Typ kierowców
$2 < D$	4 (5,3%)	najbardziej „aktywni”
$1 \leq D \leq 2$	66 (86,8%)	pozostali
$D < 1$	6 (7,9%)	najbardziej „spokojni”


Dla kierowców zakwalifikowanych metodą rankingu jako najbardziej „aktywnych” uzyskano wymiar korelacyjny dużo większy niż 2 (rys. 8.29). Z kolei dla kierowców scharakteryzowanych jako najbardziej „spokojni” wymiar ten nie przekraczał wartości 1 (rys. 8.30). Obie grupy stanowiły około 13% zbadanej populacji kierowców. Pozostała część kierowców 87% to grupa, dla których wymiar korelacyjny zawierał się w przedziale $1 \leq D \leq 2$ (rys. 8.31).




Rys. 8.27. Przykładowe wymiary zanurzenia d wyznaczone metodą najbliższych fałszywych sąsiadów, a) $d = 5$, b) $d = 20$




Rys. 8.28. Wyznaczone metodą najbliższych fałszywych sąsiadów wymiary zanurzenia d ,
 a) dla kierowcy „aktywnego” $d = 19$, b) dla kierowcy „spokojnego” $d = 15$



Rys. 8.29. Wykres zależności funkcji $\log(C(R))$ od $\log(R)$ dla kierowcy „aktywnego”



Rys. 8.30. Wykres zależności funkcji $\log(C(R))$ od $\log(R)$ dla kierowcy „spokojnego”



Rys. 8.31. Wykres zależności funkcji $\log(C(R))$ od $\log(R)$ dla kierowcy „neutralnego”

Podsumowując przeprowadzoną analizę stwierdzono, że zaproponowany estymator chaotyczny w postaci wymiaru korelacyjnego Grassberga-Procaccia, oparty o analizę sygnału generowanego przez kierowcę pedałem przyspieszenia pozwala identyfikować styl jazdy kierowcy. Wadą tej metody jest to, że identyfikuje ona tylko skrajnie różne style jazdy, co nie pozwala zastosować wielostopniowej klasyfikacji typu kierowcy.

8.3.4. Interpretacja graficzna uzyskanych wyników

W celu zilustrowania różnic w charakterze badanych atraktorów, wykorzystując technikę zaproponowaną przez Takensa [113, 149], a określoną dla tych badań zależnością (8.20), dokonano ich graficznej rekonstrukcji.

$$v(t, \tau) = \{u(t), u(t + \tau), u(t + 2\tau)\}, \quad (8.20)$$

gdzie:

- $v(t, \tau)$ – wektor określający współrzędne zrekonstruowanego atraktora,
- $u(t)$ – badana seria czasowa położenia pedału przyspieszenia,
- t – czas,
- τ – opóźnienie czasowe.

Kolejne punkty określone przez współrzędne wektora $v(t, \tau)$ przedstawiono w przestrzeni trójwymiarowej. Opóźnienie czasowe τ ustalono jako stałe i wynosiło dla wszystkich analizowanych przebiegów czasowych $u(t)$ $\tau = 60$ s. Jak widać na rysunku 8.32 ÷ 8.34, zrekonstruowane atraktory mają charakterystyczny kształt kłębków przestrzennych o różnej strukturze. Kierowcy scharakteryzowanemu jako najbardziej „aktywny” odpowiada obraz o najwyższym stopniu zagęszczenia (rys. 8.32). Jego skrajne przeciwieństwo, typ „kierowcy spokojnego”, ilustruje rys. 8.33. Typ pośredni kierowcy „neutralnego” przedstawiono na rys. 8.34.



Rys. 8.32. Obrazy zrekonstruowanego atraktora dla kierowcy skrajnie „aktywnego”


Kolejnym etapem była rekonstrukcja atraktora z opóźnieniem czasowym τ określonym dla każdego przypadku indywidualnie na podstawie funkcji autokorelacji przebiegu czasowego $u(t)$. Jako τ przyjmowano najmniejsze przesunięcie czasowe funkcji autokorelacji, przy którym jej wartość wynosiła zero. Uzyskano różne opóźnienia τ dla badanych przebiegów czasowych uchylenia przepustnicy. W efekcie otrzymano rekonstrukcje atraktorów, które jeszcze dobitniej wykazują różnice odpowiadających różnym typom kierowcy (rys. 8.35 ÷ 8.37). Przedmiotowe atraktory, podobnie jak omawiane wcześniej przedstawiono w przestrzeni trójwymiarowej, oznaczonej jako x_1, x_2, x_3




Rys. 8.33. Obrazy zrekonstruowanego atraktora dla kierowcy skrajnie „spokojnego”



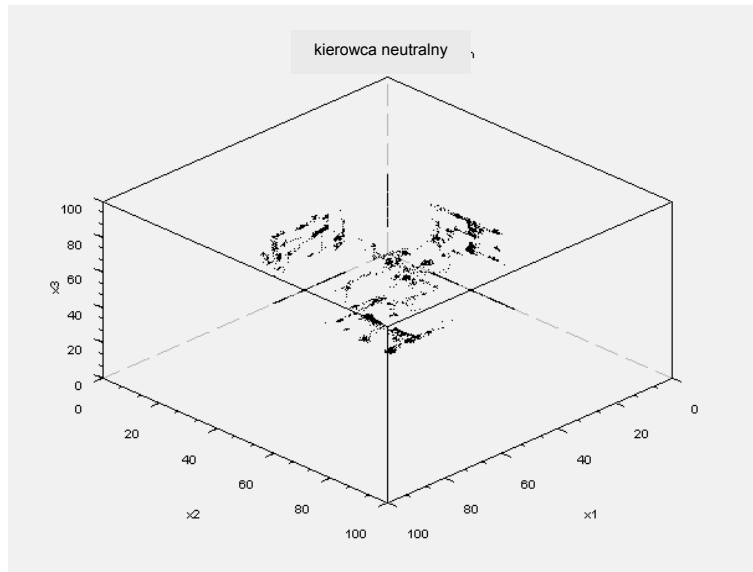
Rys. 8.34. Obrazy zrekonstruowanego atraktora dla kierowców o skłonnościach do jazdy „neutralnej”



Rys. 8.35. Rekonstrukcja atraktora z odrębnie określonym opóźnieniem czasowym $\tau = 537$, dla kierowcy skrajnie „aktywnego”



Rys. 8.36. Rekonstrukcja atraktora z odrębnie określonym opóźnieniem czasowym $\tau = 508$, dla kierowcy skrajnie „spokojnego”



Rys. 8.37. Rekonstrukcja atraktora z odrębnie określonym opóźnieniem czasowym $\tau = 456$, dla kierowcy „neutralnego”

Wyraźnie widoczne są preferencje manipulacji pedałem przyspieszenia przyporządkowane do poszczególnych typów kierowców. Kierowca skrajnie spokojny podczas jazdy utrzymuje w przybliżeniu stałe (około 35%) położenie pedału przyspieszenia, podczas gdy kierowca neutralny zmienia je w zakresie od 20% do 60%, natomiast aktywny manewruje pedałem chaotycznie pokrywając cały praktycznie możliwy do uzyskania zakres położzeń.

9. KONCEPCJA SYSTEMU KOMPLEKSOWEJ OCENY PRACY KIEROWCY SAMOCHODU CIĘŻAROWEGO

Samochody ciężarowe wyposażane są w coraz bardziej rozbudowane pokładowe systemy diagnostyczne, które powstają poprzez integrację wielu oddzielnych urządzeń i procedur samodiagnostyki. Wykorzystanie magistrali komunikacyjnych jako sieci do przesyłania informacji pozwala na realizację zintegrowanego systemu diagnostycznego, który może być znacznie prostszy niż połączenie wielu urządzeń indywidualnej diagnostyki poszczególnych układów i zespołów.

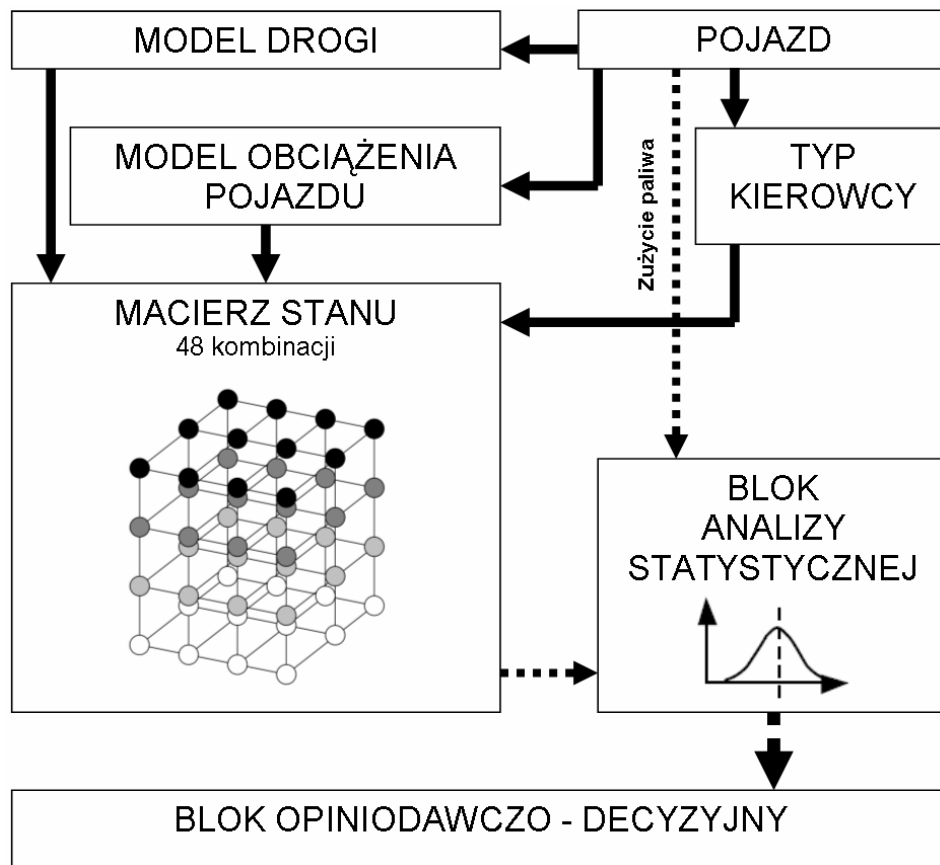
Oczywiście zintegrowane systemy diagnostyczne w dalszym ciągu pełnią funkcje pokładowego systemu diagnostycznego. Dają jednak dodatkową możliwość podłączenia wysokospecjalizowanych, zewnętrznych urządzeń do analizy napływających z magistrali informacji diagnostycznych. Analiza tak pozyskanych informacji pozwala nie tylko wykryć niesprawności, ale także rejestrować parametry ruchu pojazdu i działania kierowcy.

Systemy ciągłej rejestracji najważniejszych parametrów ruchu pojazdu, stanu ładunku i warunków jego transportu oraz działania kierowcy są intensywnie rozwijane. Ich zadaniem jest gromadzenie oraz przechowywanie istotnych wyników pomiarów, które następnie mogą być wykorzystywane w różnorodnych celach. Takim przykładem jest system kompleksowej oceny pracy pojazdu i kierowcy samochodu ciężarowego [9, 17, 18, 20].

Ma on charakter warstwowy. W pierwszej kolejności identyfikuje się pojazd pod kątem jego obciążenia ładunkiem i warunków drogowych, w jakich się porusza oraz ustala się typ jazdy kierującego pojazdem.

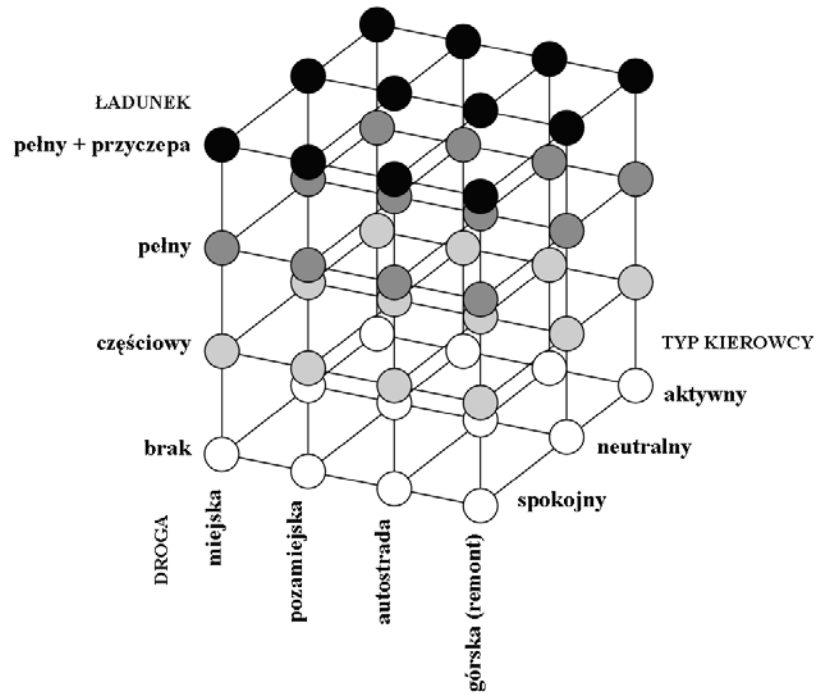
Identyfikacja pozwala przyporządkować pojazdowi i kierującemu jeden z 48 punktów kombinacji trójwymiarowej. Po tych czynnościach możliwe jest przejście do kolejnego etapu pracy systemu, gdzie dokonywana jest ocena porównawcza pracy samochodu i kierowcy w odniesieniu do zgromadzonego w czasie badań drogowych i przetworzonego statystycznie materiału bazowego, uwzględniającego wszystkie 48 kombinacji. Po dokonaniu oceny możliwe jest przejście do trzeciego i ostatniego etapu wystawienia opinii. Schemat projektu przedstawiono na rys. 9.1.

Jak widać z przedstawionego projektu, poszczególne jego etapy wymagają szczegółowych rozwiązań, które jak się można domyślać, będą charakteryzować się znacząco różnym stopniem skomplikowania.




Rys. 9.1. Schemat projektu kompleksowej oceny pracy pojazdu i kierowcy [9]

Jak wynika z przedstawionego na schemacie systemu integralną jego częścią jest macierz określająca stan pojazdu oraz nim kierującego. Czynniki wpływającymi na wybór jednego z 48 elementów macierzy są: stopień załadowania pojazdu (4 warianty), rodzaj drogi, po której pojazd się porusza (4 warianty) oraz typ kierowcy (3 warianty). Ilustrują to rys. 9.2, 9.3, i 9.4.



Rys. 9.2. Macierz stanu pojazdu [9]



Rys. 9.3. Warianty zapełniania pojazdu ładunkiem [9]



Rys. 9.4. Warianty rodzaju drogi i typu kierowcy [9]

Współczesne systemy pomiarowo-rejestrujące samochodów ciężarowych są na tyle wydajne, że dają rozległe możliwości zapisu dużej liczby parametrów ich pracy. Możliwe jest również sprawne przesyłanie całego zarejestrowanego zbioru informacji poza monitorowany pojazd celem dalszej jego analizy.

Problemem jest sposób przetwarzania danych, szczególnie pod kątem poszukiwania receptury na minimalizację zużycia paliwa przez samochód czy też ograniczanie kosztów jego eksploatacji. Dlatego też istotne jest równoległe śledzenie poczynąń kierującego pojazdem i dokonanie trafnej jego oceny.

W efekcie finalnym, całokształt przeprowadzonych działań może skutkować systemem wspomagającym kierującego samochodem ciężarowym oraz opracowaniem specjalistycznych programów szkoleniowych, dzięki którym każdy kierowca będzie mógł nauczyć się optymalnie eksploatować pojazd.

10. PODSUMOWANIE

Złożoność działania kierowcy oraz duża liczba czynników wpływających na to działanie jest główną przyczyną tego, iż stworzenie w pełni zadowalającego modelu kierowcy jest celem ciągle odległym, a obecny stan wiedzy z obszaru tego tematu sprawia, że modelowanie kierowcy jest zagadnieniem otwartym.

Modelowanie kierowcy przez współczesnych badaczy sprowadza się w większości przypadków do tworzenia modeli cząstkowych ukierunkowanych na określone zastosowania. Najliczniej reprezentowane są modele przeznaczone do badania, a następnie zapewniania szeroko pojmowanego bezpieczeństwa. W szczególności dotyczy to kierowalności i stateczności ruchu samochodu.

Podobną opinię można wyrazić w odniesieniu do modeli wspomagających pracę kierowcy. Niektóre z nich są stosowane w układach wykorzystywanych w samochodach na skalę masową. Przykładem takim są układy zapobiegające blokowaniu kół przy hamowaniu lub ich poślizgowi przy napędzaniu.

Niezależnie od układów wspomagających pracę kierowcy wyłania się odrębny obszar zainteresowań w kwestii sterowania samochodem, polegającym na spełnianiu oczekiwań kierowcy jako operatora. Cechą pożądaną dla algorytmów sterujących jest możliwość uczenia się i zapamiętywania zachowań kierowcy w powiązaniu z realizowanym profilem prędkości jazdy, traktowanym jako efekt wybranego przez kierowcę stylu jazdy, jakim pokonuje drogę.

System energetyczny samochodu dysponując taką wiedzą o chwilowym oczekiwaniu kierowcy mógłby dostosowywać się do jego oczekiwań, dobierając jednocześnie optymalne parametry pracy układu napędowego oraz i w razie potrzeby innych układów.

Dokonując ostatecznego podsumowania pracy należy podkreślić, iż głównym jej celem było zbadanie możliwości modelowania typu kierowcy przy zastosowaniu współczesnych narzędzi matematycznych.

Na podstawie przeprowadzonej analizy literaturowej oraz badań własnych zaproponowano różne metody estymacji typu kierowcy. Opisano je posługując się najnowszymi narzędziami matematycznymi.

Uzyskane efekty upoważniają do sformułowania następujących wniosków:

1. Zastosowanie takich narzędzi matematycznych jak: sieci neuronowe (neural network), logika rozmyta (fuzzy logic), transformata falkowa oraz stosowany w teorii chaosu wymiar fraktalny daje zadowalające wyniki. Proponowane w pracy modele, cechujące się możliwością dalszego podnoszenia stopnia ich skomplikowania mogą dać jeszcze bardziej wymierne korzyści w hierarchii zintegrowanego systemu sterowania systemem energetycznym całego pojazdu.

2. Zastosowanie rekurencyjnej sieci neuronowej Elmana bardzo dobrze spełnia rolę klasyfikatora, mającego za zadanie ocenę bieżącego stylu prowadzenia samochodu na podstawie podawanych na jego wejście kolejnych próbek, reprezentujących aktualne położenie pedału przyspieszenia. Badania symulacyjne, przeprowadzone z wykorzystaniem danych pomiarowych uzyskanych w trakcie rzeczywistych jazd testowych wskazują na poprawność klasyfikacji oraz stosunkowo dobre właściwości generalizacyjne sieci. Uzyskany estymator pozwala klasyfikować styl jazdy na trzy kategorie „aktywny”, „neutralny” i „spokojny”.
3. Estymator typu kierowcy oparty na ciągłej transformacie falkowej, mimo to, że bazuje tylko na jednym sygnale – wartości wychylenia pedału przyspieszenia w czasie jest elastyczny i można by go dostosować praktycznie do każdego samochodu. W zaproponowanym algorytmie niezbędne jest wyznaczenie dodatkowego wskaźnika jazdy. Po jego ustaleniu możliwe jest klasyfikowanie stylu jazdy kierowcy na podobne, jak to miało miejsce przy estymatorze neuronowym, kategorie.
4. Trzeci, zaproponowany w pracy estymator chaotyczny w postaci wymiaru korelacyjnego Grassbergera - Procaccia, również pozwala identyfikować styl jazdy kierowcy. Jego wadą jest to, że identyfikuje on tylko skrajnie różne style jazdy, co nie pozwala zastosować wielostopniowej klasyfikacji typu kierowcy.

Podczas dalszych badań nad problematyką podjętą w pracy należałoby:

- uwzględnić wpływ otoczenia, które ma wpływ na realizowany profil prędkości, zatem i na proces estymacji typu kierowcy, a w przypadku samochodu ciężarowego również wpływ obciążenia ładunkiem,
- dokonać analizy zakłóceń badanego sygnału, problematyka ta nie została wyjaśniona,
- wykonać dodatkowe próby zbudowania modelu na bazie rozmytych sieci neuronowych, z nadzieją pozyskania estymatora dającego wielostopniową klasyfikację typu kierowcy,
- uwzględnić do estymacji typu kierowcy więcej parametrów nieliniowych – oprócz wykładników Lagunowa, również wszystkie inne wymiary fraktalne.

LITERATURA

- [1] AKAY M.(Edited): Nonlinear Biomedical Signal Processing, Vol. 2: Dynamic Analysis and Modeling. John Wiley & Sons 2001.
- [2] ALIEFENDIOGLU O., KÜÇÜKAY F.: Real-Time Statistical-Based Test Environment for Transmission Control Unit of Passenger Cars. SAE Technical Paper Series, 1999-01-1047, 1999. s. 243-250
- [3] ANDREASSON J., LAINE L.: Driving Dynamics for Hybrid Electric Vehicles Considering Handling and Control Architecture. Vehicle System Dynamics Supplement 41. 2004. s. 497-506.
- [4] ANHOLCER M. GASPARS H. OWCZARKOWSKI A.: Przykłady i zadania z badań operacyjnych i ekonometrii. Wydawnictwo Akademii Ekonomicznej w Poznaniu. Poznań 2005.
- [5] AUGUSTYNIAK P.: Transformacje falkowe w zastosowaniach elektrodiagnostycznych, WNT, Warszawa 2004.
- [6] AUGUSTYNOWICZ A.: Badanie możliwości sterowania profilem prędkości samochodu. Teka Komisji Naukowo-Problekowej Motoryzacji, ISSN 1642-1639, Kraków 2001, zeszyt 22, str. 26-30
- [7] AUGUSTYNOWICZ A.: Badania symulacyjne układu sterowania prędkością samochodu, Materiały konferencyjne VI Międzynarodowej Konferencji Naukowo-Technicznej Transport samochodowy: problemy i perspektywy, Sewastopol 2003, str. 127-131
- [8] AUGUSTYNOWICZ A.: Badanie wybranych wskaźników pracy silnika z zapłonem iskrowym w nieustalonych warunkach pracy. Rozprawa doktorska. Politechnika Śląska w Gliwicach. Wydział Inżynierii Środowiska i Energetyki. 12 grudnia 1997.
- [9] AUGUSTYNOWICZ A.: Koncepcja estymacji typu kierowcy samochodu ciężarowego, Bezpieczeństwo i ekonomika użytkowania samochodów ciężarowych i autobusów pod redakcją naukową R. Wołoszyna i G. Pawlaka, Instytut Eksploatacji Pojazdów i Maszyn, Wydział Mechaniczny Politechniki Radomskiej. Radom 2007, str. 15-22
- [10] AUGUSTYNOWICZ A.: Możliwość zmniejszenia zużycia paliwa przez samochodowy silnik ZI w wyniku zastosowania elektronicznego sterowania profilem prędkości samochodu. Teka Komisji Naukowo-Problekowej Motoryzacji PAN, Kraków 2000, zeszyt 20, str. 211-220
- [11] AUGUSTYNOWICZ A.: Preliminary classification of driving style with object rank method, proceeding of International Scientific Conference Modern Safety Technologies in Transportation Mosatt 2007, Košice Słowacja, s. 13-18
- [12] AUGUSTYNOWICZ A.: Rozpoznawanie intencji kierowcy na bazie analizy chwilowego położenia pedału przyspiesznika. Międzynarodowa Konferencja Motoryzacyjna KONMOT-AUTOPROGRES, Zakopane 2004, tom 1 „Pojazdy samochodowe”, str. 59-66

- [13] AUGUSTYNOWICZ A.: Wybrane problemy modelowania kierowcy na potrzeby sterowania odstępem od poprzedzającego samochodu. Zeszyt Naukowy Politechniki Opolskiej nr 303, seria Mechanika z. 81, Opole 2005.
- [14] AUGUSTYNOWICZ A., BARTECKI K.: Estimation of driving characteristics by the application of Elman's recurrent neural network. The Archives of Transport. Vol. XVIII, nr 4. s. 5-13
- [15] AUGUSTYNOWICZ A., BARTECKI K.: Rozpoznawanie typu kierowcy przy zastosowaniu rekurencyjnej sieci neuronowej Elmana, X Międzynarodowa Konferencja Naukowa „Badania symulacyjne w technice samochodowej” – Kazimierz Dolny 2005, str. 25-32.
- [16] AUGUSTYNOWICZ A., BROL S.: Zastosowanie ciągłego przekształcenia falkowego do estymacji typu kierowcy w warunkach ruchu miejskiego, Archiwum Motoryzacji No 4, 2007, Wydawnictwo Naukowe Polskiego Towarzystwa Naukowego Motoryzacji, s. 293-307
- [17] AUGUSTYNOWICZ A., HEPNER W., HETMAŃCZYK, MAMALA J.: Koncepcja systemu kompleksowej oceny pracy pojazdu i kierowcy samochodu ciężarowego. VI Konferencja Naukowa „Telematyka i bezpieczeństwo transportu”. Tom 1: Telematyka transportu. Katowice 2006, s.187-196.
- [18] AUGUSTYNOWICZ A., HEPNER W, MAMALA J.: Idea of system of thorough assessment of vehicle and transmission performance In trucks. Machine design. University of Novi Sad Faculty of Technical Sciences ADECO – association for design, elements and constructions. Monograph on the occasion of the 47th anniversary of the Faculty of Technical Sciences 1960 – 2007, s. 179-184.
- [19] AUGUSTYNOWICZ A., JANTOS J.: Analiza możliwości zmniejszenia zużycia paliwa w samochodowym silniku ZI przez zastosowanie elektronicznego sterowania przepustnicą, V Międzynarodowe Sympozjum Instytutu Pojazdów Mechanicznych Wojskowej Akademii Technicznej nt. „Doskonalenie konstrukcji oraz metod eksploatacji pojazdów mechanicznych”, Warszawa 1993, str. 23-28.
- [20] AUGUSTYNOWICZ A., JANTOS J., MAMALA J., GOMÓŁKA L.: Koncepcja systemu wspomagania pracy kierowcy, Studia i Monografie nr 217 pod red. J.Jantosa - Transport drogowy przyjazny środowisku, Politechnika Opolska, Opole 2008. s. 67- 77
- [21] AUGUSTYNOWICZ A., KORNIAK J.: Genetyczna optymalizacja regulatora rozmytego sterującego ogranicznikiem prędkości samochodu, Materiały konferencyjne VI Międzynarodowej Konferencji Naukowo-Technicznej „Transport samochodowy: problemy i perspektywy”, Sewastopol 2003, str. 131-136

- [22] AUGUSTYNOWICZ A., KORNIAK J.: Sterowanie profilem prędkości samochodu przy użyciu logiki rozmytej. Materiały konferencyjne Międzynarodowej Konferencji Motoryzacyjnej AUTOPROGRES-KONMOT 2002, Pasym 2002, tom 1, str. 27-36
- [23] AUGUSTYNOWICZ A., KORNIAK J.: Sterowanie profilem prędkości samochodu przy użyciu logiki rozmytej. Materiały konferencyjne Krajowej Konferencji Automatyki, Zielona Góra 2002, tom II, str. 1059-1068
- [24] AUGUSTYNOWICZ A., MAMALA J.: Modelowanie intencji kierowcy na potrzeby sterowania odstępem od poprzedzającego samochodu (Modeling of driver's intention for automotive distance control to leading vehicle) International Scientific Conference Modern Safety Technologies In Transportation MOSATT 2005, 27- 28 September 2005, Košice Słowacja
- [25] AUGUSTYNOWICZ A., MAMALA J., HEPNER W.: Idea of system of thorough assessment of vehicle and transmission performance in trucks, Machine design. University of Novi Sad, Faculty of Technical Sciences Adeko – association for design, elements and constructions, Monograph on the occasion of the 47th anniversary of the Faculty of Technical Sciences 1960 – 2007, s. 179-184
- [26] AUGUSTYNOWICZ A., SKŁADZIEN J.: Analiza możliwości i celowości wykorzystania alternatywnych napędów samochodowych. Materiały konferencyjne Seminarium Naukowego „Układ silnik-samochód jako obiekt energetyczny”, Opole 2002, s. 21-33
- [27] AUGUSTYNOWICZ A., SKŁADZIEN J.: Termodynamiczno-ekologiczna analiza efektów wykorzystania ogniw paliwowych w napędach samochodowych. Materiały konferencyjne III. Ogólnopolskiej Konferencji Naukowo-Technicznej „Pojazd a środowisko”, Radom 2001, str. 7-14
- [28] AWREJCEWICZ J.: Matematyczne metody mechaniki. Wydawnictwo Politechniki Łódzkiej. Łódź 1995.
- [29] BAKER G.L., GOLUB J.P.: Wstęp do dynamiki układów chaotycznych. Wydawnictwo Naukowe PWN. Warszawa 1998.
- [30] BARTECKI K., AUGUSTYNOWICZ A.: Zastosowanie częściowo rekurencyjnej sieci neuronowej do klasyfikacji stylu jazdy kierowcy, Diagnostyka procesów i systemów, pod red. naukową J. Korbicza, K. Patana, M. Kowala, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2007, str. 417-424
- [31] BATKO W., ZIÓŁKO A.: Zastosowanie teorii falek w diagnostyce technicznej. WNT Warszawa 2002.
- [32] BEER A.: X-by-Wire – die sichere Alternative? Auto und Elektronik, 2000, Heft 2.

- [33] BENDAT J., PIERSOL A.: Metody analizy i pomiaru sygnałów losowych. PWN, Warszawa 1976.
- [34] BENGTTSSON J.: Adaptive Cruise Control and Driver Modeling. Department of Automatic Control Lund Institute of Technology, Lund 2001.
- [35] BIAŁASIEWICZ J.T.: Falki i aproksymacje. Wydawnictwo Naukowe PWN. Warszawa 2000.
- [36] BOGUŚ P.: Wykorzystanie nieliniowych metod analizy sygnałów w diagnostyce silników spalinowych. Wydawnictwo Politechniki Poznańskiej. Poznań 2006.
- [37] BOOS M., MOZER H.: Ecotronic – The continuously Variable ZF Transmission (CVT). SAE Technical Paper Nr 970685, 1997.
- [38] BREUER K., WEILKES M.: A Versatile Test-Vehicle for ACC-Systems and Components, Euromotor, Aachen 8th and 9th February 1999.
- [39] BUBNICKI Z.: Teoria i algorytmy sterowania. Wydawnictwo Naukowe PWN. Warszawa 2002.
- [40] CHANDLER R.E., HERMAN R., MONTROLL E.: Traffic dynamics - studies in car following. Operation Research, No 6, 1958.
- [41] CHIPPERFIELD A.: *Genetic Algorithm Toolbox (Version 1.2)*, Sheffiled MATLAB by Andy Chipperfield, 1994
- [42] CHOROMANSKI W., KISIŁOWSKI J.: Human-vehicle system modeling - focus on heuristic modeling of driver-operator reactions and mechatronic suspension. Vehicle System Dynamics, Jun2004 Supplement, Vol. 41.
- [43] CICHOCKI A., AMARI S.: Adaptive blind signal and image processing. John Wiley & Sons, Ltd. 2002.
- [44] COSTACHE G., SIRETEANU T., COSTACHE M., LEUCIUC D.: Driver – vehicle behavior – intelligent vehicle. FISITA-World Automotive Congress 2000, Korea. F2000I406.
- [45] DEMUTH H., BEALE M.: Neural Network Toolbox For Use with MATLAB, The MathWorks Inc., Natick. 1998.
- [46] DRIANKOV D., HELLENDORF H., REINFRANK M.: Wprowadzenie do sterowania rozmytego. WNT. Warszawa 1993.
- [47] ELMAN J.: Finding Structure in time. Cognitive Science nr 14, 1990. s. 179-211.
- [48] EMBRECHTS M.J. i inni: Fuzzy Logic and Neural Net Control for the "Smarter Car". IEEE 1995.
- [49] FILLINGS J.H.: The adaptive vehicle. Joint Program Office for Intelligent Transportation Systems 19860000 UC Berkeley Transportation Library. Path Record Number 27944. October 1986.
- [50] GILZ G., WOKAN A.: Elektronisches Gaspedal für Nutzfahrzeuge. Automobiltechnische Zeitschrift 95 (2/1993) s. 80-88.

-
- [51] GOODRICH M.A., BOER E. R.: Multiple Mental Models, Automation Strategies, and Intelligent Vehicle Systems. IEEE/IEEJ/JSAI Conference on Intelligent Transportation Systems. Tokyo - Japan 1999.
- [52] GOODRICH M.A., BOER E. R.: Semiotics and Mental Models: Modeling Automobile Driver Behavior. IEEE ISIC/CIRA/ISAS Joint Conference. Gaithersburg - Maryland USA. 1998.
- [53] GONG J., ZHAO D., CHEN Y., CHEN N.: Study on shift schedule saving energy of automatic transmission of ground vehicles. Journal of Zhejiang University SCIENCE. 2004 Vol. 5 Issue 7.
- [54] GRAF F., WEIL H.G.: Advanced Transmission Control with Fuzzy Logic. ATA 1995, s. 378-389.
- [55] GRASSBERGER P., PROCACCIA I.: Characterization of Strange Attractors. Physical Review Letters 50, 346-349, 1983.
- [56] GRISWOLD N.C., KEHTARNAVAZ N. D., MILLER K.M.: A transportable neural network controller for autonomous vehicle following. In Intelligent Vehicles '94 Symposium, s. 195-200. 1999.
- [57] GUIHE Q., YULONG L., MINGKUI N., ANLIN G. YISONG D.: Estimation of road situations and driver's intention in automotive electronic control system, Proceedings of the IEEE International Vehicle Electronics Conference, Changchun, China, September 6-9, 1999. s. 199-201.
- [58] GUO K., CHENG Y., DING H.: Analytical Method for Modeling Driver in Vehicle Directional Control, Vehicle System Dynamics Supplement 41/2004.
- [59] GUO K., PAN F., CHENG Y., DING H.: Driver Model Based on the Preview Optimal Artificial Neural Network. Proceedings of the 6 International Symposium on Advanced Vehicle Control, Hiroshima, 2002.
- [60] HAGAN M.T., MENHAJ M.: Training feed forward networks with the marquardt algorithm. IEEE Transactions on Neural Networks 1999, s. 989-993.
- [61] HAYAKAWA K., OSAWA M. i inni: Real Time Estimation of Driver's Intention and Environment Based on Operational Signals. FISITA World Automotive Congress, Paris 1998, nr F98S204.
- [62] HIROSE T., OGUCHI Y., SAWADA T.: Framework of tailor made driving support system and neural network driver model. IATSS Research vol. 28 nr 1. 2004. s. 108-114.
- [63] HJÄLMDAHL M., VÁRHELYI A.: Speed regulation by in-car active accelerator pedal. Effects on driver behavior. Transportation Research Part F. Traffic Psychology and Behavior. Elsevier Volume 7, Issue 2, 2004. s. 77-94.

- [64] HOLVE R., PROTZEL P., BERNASCH J., NAAB K.: Adaptive Fuzzy Control for Driver Assistance in Car Following, Proceedings of the 3rd European Congress on Intelligent Techniques and Soft Computing - EUFIT '95. Aachen, Germany, Aug. 1995, s. 1149-1153.
- [65] IACOVONI D.H.: Vehicle Driver Simulation for w Cross Wind Disturbance Condition. SAE Technical Paper 670609. 1967.
- [66] ISERMANN R.: Diagnosis Methods for Electronic Controlled Vehicles. Vehicle System Dynamics, 2001, Vol. 36. Issue 2/3. s. 77-117.
- [67] ISERMANN R.: Fehlertolerante Komponenten für Drive by Wire Systeme. Automoblitechnische Zeitschrift 4/2002, s. 382-391.
- [68] IVAKI R., KANEKO T., KAGEYAMA I.: A study on a driver model for longitudinal control on heavy duty vehicle. Vehicle System Dynamics, 2004, Vol. 41. s. 332-340.
- [69] JAMES D.J.G., BOEHRINGER F., BURNHAM K.J.: Adaptive Driver Model using Neural Network. Control Theory and Application Centre. Coventry University 2001.
- [70] JANTOS J.: Charakterystyka pedału przyspieszenia w stopniowym automacie napędowym. Journal of Kones, Internal Combustion Engines, Vol. 7, No 1-2, 2000, str. 237-246
- [71] JANTOS J.: Interpretation and scaling of acceleration pedal in passenger car. Materiały konferencyjne 8th European Automotive Congress, Bratislava 2001, SAITS 01007
- [72] JANTOS J.: Interpretacja położenia pedału przyspieszenia w układzie napędowym z przekładnią bezstopniową. Teza Komisji Naukowo-Problemovej Motoryzacji PAN, ISSN 1642-1639, Kraków 2001, zeszyt 22, str. 192-198
- [73] JANTOS J.: Metoda przestrzeni sterowań do rozwiązywania problemu współdziałania automatu napędowego z kierowcą w samochodzie osobowym. Materiały konferencyjne Seminarium Naukowego „Układ silnik-samochód jako obiekt energetyczny”, Opole 2002, str. 47-67
- [74] JANTOS J.: Nowa koncepcja systemu sterowania napędu w samochodzie osobowym z silnikiem ZI. Czasopismo Techniczne-Mechanika INTERKONMOT'98, Wydawnictwo Politechniki Krakowskiej z. 6-M/1998, Kraków 1998, str. 142-153
- [75] JANTOS J.: Zintegrowane sterowanie samochodowym, spalinowym układem napędowym o przełożeniu zmiennym w sposób ciągły. Monografia z. 141, Oficyna Wydawnicza Politechniki Opolskiej, Opole 2003.
- [76] JANTOS J., MAMALA J.: Zintegrowany system sterowania napędu samochodu osobowego. Zeszyty Naukowe Politechniki Opolskiej, 1998, seria Mechanika z. 56 nr 241, str. 33-46

- [77] JANTOS J., KORNIĄK J., SIŁKA W.: The fuel consumption and driveability improvement by fuzzy logic control of the continuously variable transmission in a passenger car. Materiały sympozjum niemiecko-chińskiego-polskiego Z ochroną środowiska i oszczędzaniem energii w przyszłość, Stuttgart 2003 str. 463-473
- [78] JANTOS J., SIŁKA W., MAMAŁA J.: Wpływ sterowania w samochodzie osobowym na własności ruchowe i zużycie paliwa. Teza Komisji Naukowo-Problemovej Motoryzacji PAN, Konstrukcja, badania, eksploatacja, technologia pojazdów samochodowych i silników spalinowych, Kraków 1997, zeszyt 12, str. 49-54
- [79] JANUŁA J., SZCZECIŃSKI J., SZCZECIŃSKI S.: Poprawa ekonomiczności i dynamiki samochodów osobowych, WKiŁ, Warszawa 1989.
- [80] JĘDRZEJCZYK Z., KUKUŁA K., SKRZYPEK J., WALKOSZ A.: Badania operacyjne w przykładach i zadaniach. Wydawnictwo Naukowe PWN. Warszawa 2004.
- [81] KAILASH P.T.: Simulation of Driver Behavior as a Function of Driver Error and Driver Daydream Factor, New Zealand Institute for Industrial Research.
- [82] KANTZ H., SCHREIBER T.: Nonlinear time series analysis. Cambridge University Press 1997
- [83] KAWASHIMA A., KOBAYASHI K., WATANABE K.: Implementation of Human-like Driving for Autonomous Vehicle, SAE 2001 World Congress.
- [84] KĘDZIERSKI J., WIDERSKI T.: Inteligentne skrzynie biegów Mitsubishi INVECS. Auto Moto Serwis 12/2003, s. 44-47.
- [85] KONDO K., GOKA H.: Adaptive Shift Scheduling Strategy Introduced Neural Network in Automatic Transmission. JSAE Review 16/1995. s. 411-414.
- [86] KOSEK W.: Metody analiz widmowych, filtracji i prognozowania. Centrum Badań Kosmicznych PAN, www.cbk.waw.pl/~kosek/tsa/wyklad3.html.
- [87] KOSIŃSKI R.A.: Sztuczne sieci neuronowe - dynamika nieliniowa i chaos, WNT, Warszawa 2002
- [88] KRAISS K.F.: Implementation of user-adaptive assistants with neural operator models. Control Engineering Practice. Vol. 3, Issue 2, February 1995, s. 249-256.
- [89] KÜCÜKAY F., BERGHOLZ J.: Driver Assistant Systems. ICAT 2004 International Conference on Automotive Technology "Future Automotive Technologies on Powertrain and Vehicle" Istanbul /Turkey
- [90] KUDREWICZ J.: Fraktale i chaos, WNT, Warszawa 1996
- [91] KUGE N., YAMAMURA T., SHIMOYAMA O., LIU A.: A driver behavior recognition method based on a driver model framework. SAE Technical Paper Series, 2000 Nr 2000010349.

- [92] LIU A., SALVUCCI D.: Modeling and prediction of human driver behavior .To appear in Proc. of the 9th Intl. Conference on Human-Computer Interaction, New Orleans, LA, Aug, 2001.
- [93] LOHRENZ. F.: TAFFIN. C.: Industrialization of a Fuzzy Logic Transmission Controller. VDI Tagung: Getriebe in Fahrzeugen. Friedrichshafen. 1999.
- [94] LUDMAN J., WEILKES M.: Driver Models as a Development Tool for ACC Systems, Automoblitechnische Zeitschrift 5/1999, s. 306-312.
- [95] LUDMANN J., DIRK NEUNZIG D., WEILKES M.: Traffic Simulation with Consideration of Driver Models, Theory and Examples. Institut für Kraftfahrwesen Aachen (IKA), RWTH Aachen, 2001
- [96] MACADAM CH.C.: Understanding and modeling the human driver. Vehicle System Dynamics 2003, vol. 40 Nos. 103. s. 101-134.
- [97] MAMALA J., AUGUSTYNOWICZ A.: Dynamics influence of changes throttle inclination on exhaust emission in spark ignition engine, Magazine, Machinebuilding and Electrotechnics Magazine, Sofia 2005
- [98] MERKISZ J., PIELECHA I.: Alternatywne napędy pojazdów. Wydawnictwo Politechniki Poznańskiej. Poznań 2006.
- [99] MERTINS A.: Signal Analysis: Wavelets, Filter Banks, Time-Frequency Transforms and Application. John Wiley & Sons, Inc. New York, USA 1999.
- [100] MICKNASS W., POPIOL R., SPRENGER A.: Sprzęgła, skrzynki biegów wały i półosie napędowe. WKiŁ. Warszawa 2005.
- [101] MIERLO J., MAGGETTO G., BURGWAL E., GENSE R.: Driving style and traffic measures - influence on vehicle emissions and fuel consumption. Proceedings of the Institution of Mechanical Engineers, Part D, Journal of Automobile Engineering, Volume 218, Nr 1/2004, s. 43-50.
- [102] MISITI M., MISITI T., OPPENHEIM G., POGGI J.M.: Wavelet toolbox. User's Guide. The MathWorks 2002.
- [103] MORRISON F.: Sztuka modelowania układów dynamicznych. Deterministycznych, chaotycznych stochastycznych. WNT.1996.
- [104] MROZEK B., MROZEK Z.: Matlab i Simulink. Poradnik użytkownika. Wydawnictwo HELION. Gliwice 2004.
- [105] MÜLLER J. P., KÜÇÜKAY F.: Statistical driving simulation of longitudinal vehicle dynamics. FISITA-World Automotive Congress 2002, Helsinki. F02V172. s. 18.
- [106] NAOHIRO Y., JUN T.: Advanced Steering System Adaptable to Lateral Control Task and Driver's Intention. Vehicle System Dynamics, Sep2001, Vol. 36 Issue 2/3, p119.
- [107] NDT Nonlinear Dynamics Toolbox. Version 0.9.1. Created by Josh Reiss. School of Physics. Atlanta – Georgia. USA. 1999.

- [108] NIEDERBACHER G.: Vehicle simulation as a special tool for an efficient drive train development. FISITA World Automotive Congress, Paris 1998, nr F98T226.
- [109] NIKUJ C.: Probabilistic Models of Driver Behavior. Computer Science Division University of California.
- [110] OCZERETKO E.S.: Wymiar fraktalny w analizie sygnałów i obrazów biomedycznych. Wydawnictwo Uniwersytetu w Białymstoku. Białystok 2006.
- [111] OSSOWSKI S.: Modelowanie układów dynamicznych z zastosowaniem języka SIMULINK. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa 1999.
- [112] OSSOWSKI S.: Sieci neuronowe do przetwarzania danych. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa 2000.
- [113] OTT E.: Chaos w układach dynamicznych, WNT, Warszawa 1997
- [114] PATAN K.: Artificial dynamic neural networks and their applications in modeling of industrial processes. Rozprawa doktorska. Politechnika Warszawska. Wydział Mechatroniki. 2000.
- [115] PENTLAND A., LIU A.: Modeling and Prediction of Human Behavior. Massachusetts Institute of Technology. Neural Computation 11/1999, s. 229–242.
- [116] PETERS E.E.: Chaos and Order in the Capital Markets: A New View of Cycles, Prices, and Market Volatility. John Wiley and Sons, Inc, 1996
- [117] PIEGAT A.: Modelowanie i sterowanie rozmyte. Akademicka Oficyna Wydawnicza EXIT. Warszawa 1999.
- [118] POLNAR J., AUGUSTYNOWICZ A., HETMAŃCZYK I.: Badania przebiegu i zakresu zmienności parametrów pracy samochodowego silnika o zapłonie iskrowym. Zeszyt naukowy nr 241, Politechniki Opolskiej, seria Mechanika nr 56, Opole 1998. s. 23-32.
- [119] Praca zbiorowa: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. WNT Warszawa. 2002.
- [120] Praca zbiorowa: Elektroniczne sterowanie skrzynką biegów EGS. Informatory techniczne Bosch. WKiŁ Warszawa. 2005.
- [121] PROAKIS J.G., MANOLAKIS D.G.: Digital Signal Processing: Principles, Algorithms, and Applications. Englewood Cliffs, NJ: Prentice Hall, 1996.
- [122] PROKOP G.: Modeling Human Vehicle Driving by Model Predictive Online Optimization. Vehicle System Dynamics, 2001, Vol. 35 Issue 1.
- [123] PROTZEL P., HOLVE R., BERNASCH J., NAAB K.: Fuzzy Distance Control for Intelligent Vehicle Guidance. Proc. of the 12th Annual Meeting of the North American Fuzzy Information Processing Society, Allentown PA, Aug. 22-25, 1993, 87-91.

- [124] RAJCHEL K., WIECZOREK S.: Prawno-ergonomiczne zagadnienia bezpieczeństwa w ruchu drogowym, Oficyna Wydawnicza Politechniki Rzeszowskiej, Rzeszów 2000.
- [125] RAK R., MAKOWSKI A.: Czasowo-częstotliwościowa analiza sygnałów. Przegląd Elektrotechniczny 5/2004, s. 515-520.
- [126] RAK R., MAKOWSKI A.: Czasowo-częstotliwościowa analiza sygnałów. Laboratorium wirtualne Instytutu Elektrotechniki Teoretycznej i Systemów Informatycznych-Pomiarowych, <http://wazniak.mimuw.edu.pl/>.
- [127] REŃSKI A.: Modelowanie działania kierowcy w układzie kierowca – pojazd - otoczenie. Prace Naukowe. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [128] RICHARD B.: Intelligent Vehicle Technology and Trends. ARTECH HOUSE, INC. Boston London 2005
- [129] ROHR S.N., LIND R.C., MYERS R.J., BAUSON W.A., KOSIAK W.K., YEN H.: An Integrated Approach to Automotive Safety Systems. Delphi Automotive Systems. SAE Technical Paper Nr 2000-01-0346, 2000
- [130] 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 2000
- [131] RUTKOWSKA D., PILIŃSKI M., RUTKOWSKI L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwo Naukowe PWN. Warszawa 1997.
- [132] RUTKOWSKI L.: Metody i techniki sztucznej inteligencji. Wydawnictwo Naukowe PWN. Warszawa 2005.
- [133] SAWAMURA K., YOSHIHARU S., SIGETAKA K., AKIRA K.: Development of an integrated powertrain control system with an electronically controlled throttle. JSAE Review 19/1998. s. 39-48.
- [134] SHUIWEN S., GUOZHENG Y., GUANGQIANG W.: Study on intelligent shift strategy with the humachine technology. SAE Technical Paper Nr 973279. 1997.
- [135] SCHOUTEN N., SALMAN M., KHEIR N.: Energy management strategies for parallel hybrid vehicles using fuzzy logic, Int. Fed. Autom. Control (IFAC) J., Control Engineering Practice. 11/2003 s. 171-177.
- [136] SCHUSTER H.G.: Chaos deterministyczny, PWN, Warszawa 1993
- [137] SIŁKA W.: Teoria ruchu samochodu. Wydawnictwo Naukowo-Techniczne. Warszawa 2002
- [138] SIŁKA W., AUGUSTYNOWICZ A.: Badanie systemu energetycznego samochodu w rzeczywistych warunkach ruchu. Czasopismo Techniczne - Mechanika INTERKONMOT'98, Wydawnictwo Politechniki Krakowskiej z. 6-M/1998, Kraków1998, str. 89-99
- [139] SIŁKA W., JANTOS J.: A new idea of the automatic control system for the driving units in cars with spark-ignition engine. FISITA World Automotive Congress, Paris 1998, nr F98T629

- [140] SIŁKA W., JANTOS J.: The integrated system of drive control. EAEC European Automotive Congress, Vehicle Systems Technology for the Next Century, Barcelona 1999, str. 269-276
- [141] SMITH S.W.: Cyfrowe przetwarzanie sygnałów. Praktyczny poradnik dla inżynierów i naukowców, BTC, Warszawa 2007
- [142] STEPHEN N., RICHARD C. LIND, ROBERT J., WILLIAM A., WALTER K. KOSIAK AND HUAN YEN: Integrated Safety Systems. Published by Delphi, document DD-03-E-047, September 2003
- [143] STRANNEBY D.: Cyfrowe przetwarzanie sygnałów. Metody, algorytmy, zastosowania, BTC, Warszawa 2004
- [144] STREIB H., BISCHOF H.: Electronic Throttle Control (ETC). A Coast Effective System for Omproved Emissions. Fuel Economy, and Driveability. SAE Technical Paper Nr 960338.1996.
- [145] SZCZEPANIAK C.: Podstawy modelowania systemu człowiek – pojazd – otoczenie, PWN, Warszawa – Łódź 1999
- [146] SZOSLAND A.: Analiza modeli matematycznych kierowcy. Technika Motoryzacyjna 9/1980.
- [147] TADEUSIEWICZ R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza RM. Warszawa 1993.
- [148] TAKAHASHI, H., KURODA, K.: A study on mental model for inferring driver's intention. Proceedings of the 35th IEEE Conference - Decision and Control. 1996 Kobe – Japan.
- [149] TAKENS F.: Detecting strange attractors in turbulence. D. A. Rand and L.-S. Young Dynamical Systems and Turbulence, Lecture Notes in Mathematics, vol. 898: 366–381, Springer-Verlag, 1981.
- [150] TUMAŃSKI S.: Technika pomiarowa. WNT. Warszawa 2007.
- [151] TAN H., JIA K., DE SILVA L.: Human activities recognition by head movement using partial recurrent neural network. Visual Communications and Image Processing. Proceedings of the SPIE, Vol. 5150, 2003. s. 2007-2014.
- [152] UNGOREN A.Y., PENG H. An adaptive lateral preview driver model. Vehicle System Dynamics Vol. 43. Nr 4. 2004. s. 243-259.
- [153] VARHELYI A., HJÄLMDAHL M., HYDEN C., DRASKOCZY M: Effects of an active accelerator pedal on driver behaviour and traffic safety after long-term use in urban areas. Accident analysis and prevention. Elsevier 2004, Volume 36, Issue 5, s. 729-737.
- [154] VON ALTROCK C.: Fuzzy Logic & Neurofuzzy Application Explained, Prentice Hall PTR, New Jersey, 1995.
- [155] WELTER A., KRAGL R.: The Adaptive Transmission Control for the Automatic Transmission of BMW 12-cylinder Vehicles (in Germany), Automoblitechnische Zeitschrift 9/1992, s. 428-436, 1992.

-
- [156] WICHER J.: Kilka uwag o modelu kierowcy w analizie bezpiecznego ruchu drogowego. Zeszyty Naukowe Instytutu Pojazdów Politechniki Warszawskiej, 4/1994, s. 35-42.
 - [157] WICHER J.: Zagadnienia bezpieczeństwa samochodu. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1998.
 - [158] WILLUMEIT H.P., JÜRGENSOHN T.: Driver Models – A Critical Survey, Automoblitechnische Zeitschrift, Part 1 nr 7/8-1997, s. 424-428, Part 2 nr 9-1997, s. 552-560.
 - [159] WON J.S: Intelligent energy management agent for a parallel hybrid vehicle. Dissertation. Texas A&M University 2003.
 - [160] WON J.S., LANGARI R.: Fuzzy torque distribution control for a parallel hybrid vehicle, Expert Systems: The International Journal of Knowledge Engineering and Neural Networks, vol. 19, no. 1, February 2002. s. 4-10.
 - [161] YOSHIMOTO K.; TANABE H.; TANAKA M.: Speed Control Algorithm for an Automated Driving Vehicle. JSAE Review, vol. 16, nr 2, 4/1995, s. 219-219.
 - [162] ZIELIŃSKI T.P.: Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań. WKiŁ. Warszawa 2005.

MODELOWANIE TYPU KIEROWCY SAMOCHODU

W pracy przedstawiono zagadnienia modelowania właściwości kierowcy. Dokonując przeglądu literatury dotyczącej estymacji typu kierowcy, stwierdzono, że właściwie przeprowadzona analiza sygnałów, poprzez które prowadzący oddziałuje na samochód, daje możliwość rozpoznania typu kierowcy i stosowną interpretację jego zachowań w różnych sytuacjach drogowych. Na podstawie tych informacji system sterowania samochodem może wybierać najbardziej korzystny algorytm i związane z nim parametry pracy silnika oraz układu przeniesienia napędu, dostosowując się jednocześnie do oczekiwań prowadzącego. Można wyodrębnić trzy obszary zainteresowań w kwestii sterowania samochodem, których strategię uwzględniają rozpoznawanie i ocenę typu kierowcy. Dziedzinami tymi są: elektroniczne sterowanie skrzynią biegów, adaptacyjna regulacja prędkości jazdy, elektroniczne zarządzanie źródłami energii w samochodach z napędem hybrydowym.

W pierwszej części pracy omówiono jej cel i zakres, a następnie przedstawiono wybrane z literatury modele kierowcy opisujące zachowanie kierowcy jako operatora, decydującego o charakterze profilu prędkości kierowanego pojazdu. Wskazano na stosowane przez badaczy do opisu modeli najnowsze metody matematyczne oparte na sieciach neuronowych czy też zbiorach rozmytych. Następnie zaprezentowano kilka przykładów praktycznego wykorzystania modelu kierowcy opisującego jego styl jazdy do sterowania pracą zespołem napędowym. Przytoczone przykłady dotyczą zarówno sterowania adaptacyjnego ograniczającego się jedynie do doboru przełożenia w skrzyni biegów, a także strategii zarządzania źródłami energii w samochodzie z napędem hybrydowym.

W dalszej części pracy przedstawiono przykłady własne autora wykorzystane do modelowania kierowcy technikami sztucznej inteligencji. Należy do nich ogranicznik wybranej przez kierowcę prędkości samochodu, oparty na logice rozmytej. Dodatkowo zaprezentowano strojenie rozmytego regulatora prędkości jazdy przy użyciu algorytmu genetycznego. Zaproponowano sposób sklasyfikowania zbadanych przez autora kierowców pod względem ich typu, stosowaną powszechnie w badaniach operacyjnych metodą rankingu. Podstawą wykonanego rankingu były zarejestrowane w ramach badań drogowych przebiegi czasowe wybranych parametrów ruchu samochodu, a także reakcje nim kierujących na pedale przyspieszenia. Dokonano analizy sygnału generowanego pedałem przyspieszenia. Wykazano, że gęstość widmowa mocy (PSD) funkcji przyspieszenia pedału przyspieszenia może być parametrem służącym do oceny sposobu jazdy kierowcy.

Rozdział ósmy stanowi oryginalne osiągnięcie autora, bowiem przedstawia trzy metody estymacji typu kierowcy. Pierwsza z nich to estymacja przy zastosowaniu rekurencyjnej sieci neuronowej typu Elmana. W metodzie drugiej zaproponowano transformatę falkową do estymacji opartej na przebiegu sygnału generowanego pedałem przyspieszenia. W metodzie trzeciej posłużono się zaś teorią chaosu do estymacji typu kierowcy.

W części końcowej pracy zaproponowano koncepcję kompleksowej oceny pracy kierowcy samochodu ciężarowego obejmującą estymację typu kierowcy. Prace zakończono podsumowaniem – wykazem osiągniętych celów.

MODELLING OF A CAR DRIVER TYPE

This thesis undertakes the discussion of modeling driver's characteristics. An overview of the references regarding the estimation of driver types leads to the conclusions that an adequate analysis of the signals communicated by the driver during their interaction with the car makes it possible to distinguish various driver types and interpret their behavior in various circumstances on the road. On the basis of this information the system of vehicle control is capable of selecting the most adequate algorithm of engine and drivetrain control and follows the parameters resulting from this algorithm while simultaneously being able to adapt to the person's style of driving. Three areas of scientific interest can be distinguished in the studies of car control which account for the recognition and assessment of driver's type. These areas include: electronic control of the transmission, adaptive control of driving speed, electronic management of energy sources in cars with hybrid drives.

The first section of the thesis begins with the scope and objective of the paper. Later, it undertakes the discussion of driver models from references familiar in the context of an operator deciding on the speed profile of the driven car. The use of up-to-date mathematical methods based on neural networks and fuzzy sets is emphasized. Subsequently, the thesis presents several examples of practical application of the driver's model accounting for driving style in order to control the operation of the powertrain. The examples refer both to adaptive control limiting the control to the selection of an appropriate transmission ratio and strategies of managing sources of energy in a car with the hybrid drive.

In the latter part of the thesis practical examples of modeling driver types with artificial intelligence techniques are presented in the form in which they have been developed by the current author. In addition, the adjustment of a fuzzy speed regulator using genetic algorithm is presented. The presented technique of classification of researched drivers according to the developed types with rank method commonly applied in operational studies. The basis for the developed rank were the registered curves for selected parameters of car movement as well as the reactions of drivers performed on the accelerator pedal. The analysis of the signal was based on the measurement of the displacement of the accelerator pedal. It was revealed that the power spectral density of the function of the acceleration of accelerator pedal may constitute the parameter for the assessment of the driving technique.

Chapter eight contains original contribution of the current author in the form of three methods to be used for the estimation of driver characteristics. The first one involves the estimation based on recurrent Elman type neural network. Method two proposes the use of wavelet transform for the estimation based on the signal generated by the accelerator pedal. Method three applies chaos theory in order to estimate driver's characteristics.

The final section of the paper proposes the concept of comprehensive assessment of a truck driver's characteristics involving the estimation of the driver's type. Paper is concluded with a summary of the attained goals.