

Mariusz TOPOLSKI*

ROZMYTE STEROWANIE SYGNALIZACJĄ ŚWIETLNA W NEWRALGICZNYCH PUNKTACH MIEJSKICH

W pracy zaprezentowano metodę rozmytą, którą można zastosować do sterowania sygnalizacją świetlną. Pokazano, dlaczego metody rozmyte są bardziej adekwatne do danego problemu niż czysto probabilistyczne. Zaprezentowano reguły rozmyte i sposób ich wyznaczania na podstawie zbioru uczącego.

1. WSTĘP

Praca ma charakter eksperymentalny. Zawiera ona przykładowy model systemu rozmytego do sterowania sygnalizacją świetlną w obrębie newralgicznych punktów miejskich, takich jak szkoły, przedszkola, zakłady pracy, w których to bezpieczeństwo jest rzeczą najważniejszą. Niewłaściwa sygnalizacja świetlna przy panujących warunkach, nadmierna prędkość pojazdów oraz niebezpieczne zachowania dzieci, młodzieży na drogach są przyczyną wielu niebezpiecznych wypadków drogowych. Powyższy problem stał się inspiracją autora do zbudowania modelu systemu, który będzie analizował sytuację panującą na drogach, tj. gęstość pojazdów na danym odcinku drogi, gęstość pieszych (np. dzieci idących do szkoły, bądź z niej wracających) oraz maksymalną prędkość pojazdów na tym odcinku drogi. Owe parametry, czyli trzy cechy są wartościami podawanymi na wejście sterownika rozmytego, a na wyjściu bloku wnioskowania otrzymujemy konkluzję w postaci konkretnej sytuacji sygnalizacji świetlnej w zależności od wartości tych cech. Ruch pieszych ma charakter nieprecyzyjny, tzn. niekoniecznie na zadanym odcinku chodnika piesi chcą przebyć jezdnię na drugą stronę - mogą oni iść wzdłuż chodnika. Mimo powyższej sytuacji w danej chwili system radarowy zliczy te osoby przed przejściem dla pieszych, dlatego został wybrany model rozmyty, który doskonale radzi sobie z nieprecyzyjnością. Wstęp niniejszej pracy zawiera wprowadzenie do problemu zadania rozpoznawania. W części drugiej znajduje się opis zadania rozpoznawania na podstawie reguł rozmytych, ale wyznaczonych przez ekspertów. W tej części znajduje się metoda

* Mgr inż. Mariusz TOPOLSKI, Politechnika Wrocławska, Wydział Elektroniki, Katedra Systemów i Sieci Komputerowych.

tworzenia bazy reguł rozmytych. Klasy decyzyjne są wartościami dyskretnymi, zawierającymi informacje o stanie sygnalizacji świetlnej.

Głównym założeniem pracy były badania symulacyjne. Symulacje przeprowadzono na podstawie wygenerowanych reguł ekspertów. Wartości cech gęstości pojazdów generowane były z rozkładów normalnych [10]. Wybrano taką funkcję, gdyż w przypadku ograniczenia prędkości np. do 40 km/h większość pojazdów będzie dostosowywała się do ograniczenia. Rozkład Gaussa pozwala na zamodelowanie takiej sytuacji, dopuszczając z coraz mniejszym prawdopodobieństwem pojazdy, które prędkość przekraczają. Oprócz trzech cech wprowadzono w badaniach czwartą zależność, która jest czasem trwania aktualnego stanu sygnalizacji świetlnej. Ma to znaczenie w przypadku, gdy piesi ciągle podążają licznymi grupami w stronę przejścia, a dla pojazdów pali się światło czerwone, co w konsekwencji może spowodować długi ciąg pojazdów i tamowanie ruchu. W związku z zatrzymaniem ruchu pojazdów wytraciły one prędkość i nawet puszczenie ich do dalszego ruchu w przypadku większej liczby grup pieszych nie zwiększa znacząco niebezpiecznej sytuacji na drogach. System w sytuacji warunkowego dopuszczenia pojazdów do ruchu analizuje tylko prędkość, natomiast po pewnym zadany czasie zaczyna analizować powtórnie zmienną gęstości pojazdów na drodze.

Zbudowany symulator zawierał moduły, tj. wprowadzenie ręczne wartości cech obiektu, automatyczną symulację, generowanie sytuacji na drogach, wizualizację wyników.

W badaniach symulacyjnych oprócz wprowadzania ręcznie ustawień na 24 godziny uruchomiono automatyczne generowanie płynnego ruchu pieszych i pojazdów i dokonano końcowej analizy. Uzyskano wysoką skuteczność. Okazało się, że model rozmyty doskonale radzi sobie ze sterowaniem sygnalizacją. Oprócz wysokiej sprawności w podejmowaniu decyzji usprawnia on płynny ruch pojazdów, co może mieć duże znaczenie w poprawieniu płynności przejazdu przez następne skrzyżowania.

System taki można stosować w warunkach rzeczywistych. Ponieważ badania są czysto symulacyjne, dlatego należałoby rozszerzyć je o próby w warunkach rzeczywistych. Dzięki zgromadzonej wiedzy w warunkach rzeczywistych, można dokonać pełnego opisu rzeczywistej sytuacji na drogach, dostroić kształt funkcji przynależności w modelu rozmytym oraz stworzyć reguły rozmyte adekwatne do konkretnego punktu neuralgicznego.

Ocena stanu ruchu na drogach przy subiektywnym jej wyznaczaniu może okazać się nieprecyzyjna, niepełna. Rozpatrując ją w kategoriach czysto probabilistycznych, może okazać się, że oszacowanie prawdopodobieństw warunkowych wystąpienia pewnej zmiennej pod warunkiem zaistnienia innej zmiennej może okazać się nieprecyzyjne. Każdy, kto kiedykolwiek był uczony kantorowskiej teorii mnogości, wie doskonale, że wiąże się ona niezwykle ściśle z klasycznym rachunkiem zdań; mówiąc dokładniej, formalizm klasycznego rachunku zdań jest po prostu tym samym formalizmem, który rządzi algebrą zbiorów; jest to zupełnie ta sama algebra Boole'a. Chwila zastanowienia powinna nam nasunąć myśl, że istnienie takiej logiki ma głęboki sens: stwierdziliśmy wszak, że nasze zwykłe codzienne wypowiedzi typu „możliwe, że...”, „około...” lub „prawdopodobnie...” są nauce i technice bardzo potrzebne [3,4,5,8,11,12,13].

W analizowanym przypadku można mówić o systemie ekspertowym, stwierdzającym na podstawie pewnych cech obiektu o zastosowaniu pewnego sterowania. Istnieją różne podejścia do zadania wnioskowania. Można potraktować wektor cech wejściowych (ciągłe wartości) i klasę decyzyjną jako konkretną wartość ciągłą otrzymaną na podstawie tych cech. Można przyjąć, że klasa decyzyjna świadcząca o sterowaniu ma charakter dyskretny, a klasa decyzyjna świadczyć będzie o zastosowaniu konkretnego sterowania sygnalizacją świetlną. Dla tego ostatniego przypadku w niniejszej pracy zaprezentowano algorytm decyzyjny.

W symulacjach przyjęto sytuację zaprezentowaną na rysunku 1.

2. OPIS ZADANIA ROZPOZNAWANIA


Na wstępie przyjmijmy podział na 2 klasy decyzyjne, gdzie klasa $j=1$ (światło zielone dla pojazdów), klasa $j=2$ (światło zielone dla pieszych). Niech dana będzie para ucząca w postaci:

$$S = (\bar{X}, j) = (x_1, x_2, \dots, x_n, j), \tag{2.1}$$

w naszym przypadku $j=1,2$.

Wektor cech x oznacza wartości opisujące sytuacje na drogach. Schemat systemu wnioskowania zaprezentowano na rys. 2.

Rys. 1. Mapa analizowanej sytuacji.
Fig. 1. Map of analysed situation.



Rys. 2. Przykładowe funkcje przynależności.
Fig. 2. The instances of pertained functions.



Przejdźmy teraz do metody wyznaczania reguł rozmytych (2.2) za pomocą reguł ustalonych przez ekspertów:

$$IF (x_1 \text{ jest } A \text{ AND } x_2 \text{ jest } B) \text{ THEN } y \text{ jest } C). \quad (2.2)$$

Przykład algorytmu pokażemy dla uproszczenia dla przestrzeni dwóch cech. Niech (maksymalna prędkość pojazdów) (gęstość pieszych) będą danymi ciągłymi podawanymi na wejście sterownika, a (dane uczące dyskretne) jest zadaną (wzorcową) wartością sygnału wyjściowego.

2.1 ALGORYTM BUDOWY BAZY REGUŁ ROZMYTYCH ORAZ WNIOSEKOWANIA

Do celów analizy skorzystano z wiedzy eksperta.

A. Wyznaczanie przedziału zmienności dla przesłanek.



W powyższym celu wyznaczamy wartości najmniejsze i największe dla zmienności cech.

$$\begin{aligned} x_1 \min (s) &= 0 \text{ km/h,} \\ x_1 \max (s) &= 150 \text{ km/h,} \end{aligned}$$

$$\begin{aligned} x_2 \min (s) &= 0 \% , \\ x_2 \max (s) &= 100 \% . \end{aligned}$$

Pokrywanie przedziałów zmienności zbiorami rozmytymi przedstawiono na rys 3.

Rys. 3. Przykładowe funkcje przynależności.
Fig. 3. The instances of pertained functions.



2.2 GENEROWANIE REGUŁ

W bazie reguł rozmytych obok klasy znajduje się pewna wartość, która wskazuje na ilość diagnoz o stanie sygnalizacji świetlnej w zadanych warunkach wyznaczonych przez 20 ekspertów.

Tablica 1. Baza reguł rozmytych
Table 1. The rule base fuzzy

	M	S	D
M	Klasa 1 - 16 Klasa 2 - 4	Klasa 1 - 9 Klasa 2 - 11	Klasa 1 - 8 Klasa 2 - 12
S	Klasa 1 - 11 Klasa 2 - 9	Klasa 1 - 16 Klasa 2 - 4	Klasa 1 - 18 Klasa 2 - 2
D	Klasa 1 - 9 Klasa 2 - 11	Klasa 1 - 5 Klasa 2 - 15	Klasa 1 - 0 Klasa 2 - 20

MM	Jeśli $x_1 < 0, 40 >$ i $x_2 < 0, 25 >$ to $(1/(16/20), 2/(4/20))$.
SM	Jeśli $x_1 < 0, 80 >$ i $x_2 < 0, 25 >$ to $(1/(11/20), 2/(9/20))$.
DM	Jeśli $x_1 < 40, 150 >$ i $x_2 < 0, 25 >$ to $(1/(9/20), 2/(11/20))$.
MS	Jeśli $x_1 < 0, 40 >$ i $x_2 < 0, 50 >$ to $(1/(9/20), 2/(11/20))$.
SS	Jeśli $x_1 < 0, 80 >$ i $x_2 < 0, 50 >$ to $(1/(16/20), 2/(4/20))$.
DS	Jeśli $x_1 < 40, 150 >$ i $x_2 < 0, 50 >$ to $(1/(5/20), 2/(15/20))$.
MD	Jeśli $x_1 < 0, 40 >$ i $x_2 < 25, 100 >$ to $(1/(8/20), 2/(12/20))$.
SD	Jeśli $x_1 < 0, 80 >$ i $x_2 < 25, 100 >$ to $(1/(18/20), 2/(2/20))$.
DD	Jeśli $x_1 < 40, 150 >$ i $x_2 < 25, 100 >$ to $(1/0, 2/1)$.

Baza reguł rozmytych składa się z pól utworzonych przez zmienne lingwistyczne np., MM - MałyMały... W każdym polu znajdują się liczności klas decyzyjnych, które w wyniku oszacowania ekspertów znalazły się w tych obszarach.

- Wyznaczanie stopnia spełnienia każdej z reguł.

$$k(x_1, x_2) = \min(\mu_{A1}^{(k)}(x_1), \mu_{A2}^{(k)}(x_2)), \quad (2.3)$$

k - numer reguły $k = \{1, 2, \dots, 8\}$.

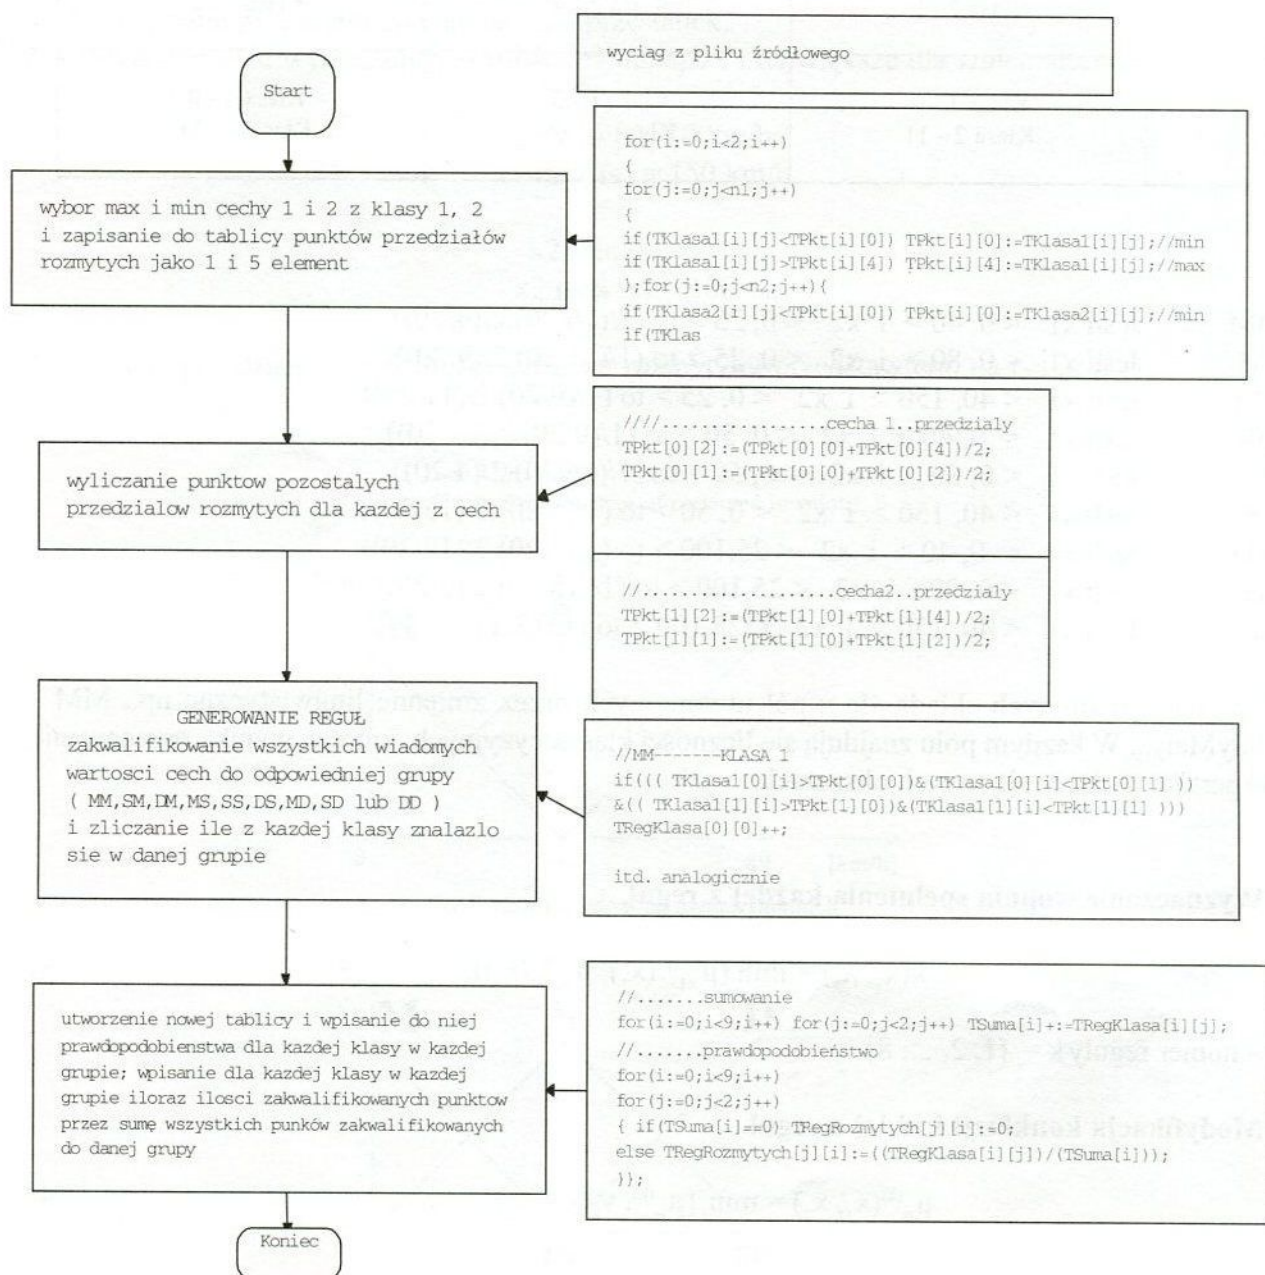
- Modyfikacja konkluzji każdej z reguł.

$$\mu_B^{(k)}(x_1, x_2) = \min\{\mu_B^{(k)}, v_k(x_1, x_2)\} \quad (2.4)$$


Tablica 2. Reguły rozmyte.
Table2. Fuzzy rules

	ZMIENNE LINGWISTYCZNE								
	MM	SM	DM	MS	SS	DS	MD	SD	DD
klasa 1	0,8	0,55	0,45	0,45	0,8	0,25	0,4	0,9	0
klasa 2	0,2	0,45	0,55	0,55	0,2	0,75	0,6	0,1	1

Rys. 4. Realizacja programu komputerowego- tworzenie bazy reguł.
Fig. 4. Realization of computer programme- creating the rule base.



Rys. 5. Realizacja programu komputerowego- wnioskowanie
Fig. 5. Realization of computer programme- inference



- Wyznaczanie konkluzji wypadkowej.

$$\mu_B(x_1, x_2) = \max \{ \mu_{B1}(x_1, x_2), \mu_{B2}(x_1, x_2), \dots, \mu_{B9}(x_1, x_2) \} \quad (2.5)$$

- Defuzyfikacja (wyostrzenie).


$$b(x_1, x_2) = \max \mu_B(x_1, x_2) \quad (2.6)$$

Schemat realizacji algorytmu zaproponowano na rys. 4 i 5.

Powyżej został zaprezentowany uproszczony model sterowania sygnalizacją świetlną. W naszym przypadku mamy jednak trzy cechy wejściowe - rys. 6. W przypadku symulacji wykorzystane zostały wszystkie parametry układu.

Rys. 6. Przykładowe funkcje przynależności.

Fig. 6. The instances of pertained functions.



Rys. 7. Wygląd interfejsu użytkownika.

Fig. 7. Appearance of the user's interface.

SYMULACJA ROZMYTEGO STEROWANIA SYGNALIZACJĄ ŚWIETLNA

Reczne ustawienia

Gęstość [%] pojazdów na radarze 1: Max. symulna prędkość [km/h] pojazdów na radarze 1:

Gęstość [%] pojazdów na radarze 2: Max. symulna prędkość [km/h] pojazdów na radarze 2:

Gęstość [%] pieszych na radarze 3:

Gęstość [%] pieszych na radarze 4:

Czas [s] trwania aktualnego stanu sygnalizacji świetlnej:

Automatyczne sterowanie

Gęstość [%] pojazdów na radarze 1: Maksymalna prędkość [km/h] pojazdów na radarze 1:

Gęstość [%] pojazdów na radarze 2: Maksymalna prędkość [km/h] pojazdów na radarze 2:

Gęstość [%] pieszych na radarze 3:

Gęstość [%] pieszych na radarze 4:

Czas [s] trwania aktualnego stanu sygnalizacji świetlnej:

3. PRZYKŁADOWA SYTUACJA NA DRODZE I ZASTOSOWANE DO NIEJ STEROWANIE

W rozważaniach przyjęto sytuację z rys 7.

W analizowanym przypadku łączna gęstość pojazdów na radarze 1 i radarze 2 wynosi 17,3%, łączna gęstość pieszych na radarze 3 i radarze 4 wynosi 28,8%. Maksymalna prędkość pojazdów na radarze 1 i radarze 2 wynosi 54 km/h. Nanieśmy teraz powyższe wartości na funkcje przynależności rys. 8 i zastosujmy mechanizm wnioskowania z punktu 2.

Na rysunku 8 otrzymaliśmy dla łącznej gęstości pojazdów na radarach dla pojazdów, dla 17.8%, wartości funkcji przynależności $\mu_M(x_1)=0,4$, $\mu_S(x_1)=0,7$. Dla prędkości pojazdów na dwóch radarach dla 54%, wartości funkcji przynależności $\mu_S(x_2)=0,75$, $\mu_D(x_2)=0,44$. Dla łącznej gęstości pieszych na radarach dla pieszych, dla 28.8%, wartości funkcji przynależności $\mu_S(x_3)=0,78$, $\mu_D(x_3)=0,39$.


Na podstawie zależności (2.3), (2.4), (2.5) i (2.6) na podstawie trójwymiarowej bazy reguł, w której znajduje się 27 reguł rozmytych otrzymano konkluzję w postaci reguły:

IF (x_1 jest S AND x_2 jest D AND x_3 jest D) THEN y jest 2).

Reguła ta wskazuje na zapalenie się zielonego światła dla pieszych, a czerwonego dla pojazdów. W tym przypadku główną przyczyną takiego sterowania jest przekroczona prędkość przez pojazdy.

Rys. 8. Przykładowe funkcje przynależności.

Fig. 8. The instances of pertained functions.



4. PODSUMOWANIE

W badaniach symulacyjnych uzyskano wysoką skuteczność algorytmu. Badając skuteczność w podejmowaniu decyzji, brano pod uwagę bezpieczeństwo pieszych oraz płynność ruchu transportu kołowego. System taki może być stosowany do oceny sytuacji na drogach i do sterowania sygnalizacją świetlną. Ze względu na duży koszt urządzeń elektronicznych niezbędnych do budowy

systemu zaleca się, aby system taki znalazł się w miejscach newralgicznych, takich jak szkoły, przedszkola, zakłady pracy.

Przedmiotem rozważań był rozmyty system wnioskujący o strukturze omawianej w rozdziale drugim niniejszej pracy. Istnieją inne struktury takich algorytmów. Różnią się one w zależności od zastosowanej metody rozmywania, wnioskowania oraz wyostrażania, a także postaci reguł.

Bardzo dobrym rozwiązaniem problemu symulacji niezbędnej do projektowania układów rozmytych w postaci reguł rozmytych jest stworzenie odpowiedniego, specjalistycznego oprogramowania. Aplikację do symulacji komputerowej napisano w języku programowania C++. Zaleca się, aby do tego typu aplikacji stworzyć własny język opisu zagadnienia, ekstrakcji wiedzy w postaci reguł rozmytych na podstawie np. danych od ekspertów bądź danych numerycznych. Utworzona baza reguł rozmytych służy jako sterownik rozmyty, jak również może być podstawą do automatycznej generacji sterownika rozmytego w postaci sieci neuronowej. W takiej aplikacji początkowe rozmieszczenie funkcji przynależności mogłoby zostać dokonywane w sposób automatyczny lub odczytane z pliku. W przypadku rozmieszczenia automatycznego wystarczające byłoby jedynie wybranie kształtu tych funkcji (trójkątne lub gaussowskie), minimalnej i maksymalnej wartości sygnału na wejściach oraz liczby funkcji przynależności.

5. LITERATURA:

- [1] CISKOWSKI P., *Learning context-dependebt neural nets Raport PRE /2002*, Politechnika Wroclawska May 2002 (praca doktorska).
- [2] HAYES-ROTH F., WAQTERMAN D.A., LENAT D.B., *Building Expert Systems*, Addison-Wesley Publishing Company, Massachusetts, 1983.
- [3] KACPRZYK J., *Wieloletapowe sterowanie rozmyte*, Wydawnictwa Naukowo Techniczne, Warszawa 2001.
- [4] KULIKOWSKI J., *Cybernetyczne układy rozpoznające*, PWN, Warszawa, 1972
- [5] KURZYŃSKI M., *Złożone metody rozpoznawania w: M. NAŁĘCZ [red.], Problemy Biocybernetyki i Inżynierii Biomedycznej*, tom V: Informatyka Medyczna, s.159, WKiŁ, Warszawa 1990.
- [6] MULAWKA J.J., *Systemy ekspertowe*, WNT, Warszawa 1996.
- [7] PEARL J., *Probabilistic Reasoning in Intelligent Systems: Network of Plausible Inference*, Morgan Kaufmann Pub. Inc., San Francisco, California, 1991.
- [8] PIEGAT A., *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999.
- [9] TADEUSIEWICZ R., FLASIŃSKI M., *Rozpoznawanie obrazów*, PWN, Warszawa, 1991.
- [10] WIECZORKOWSKI R., ZIELIŃSKI R., *Komputerowe generatory liczb losowych*. Wydawnictwa Naukowo-Techniczne, Warszawa 1997.
- [11] ZADEH L.A. *On fuzzy algorithms. Memo. ERL-M325*. Iniv. of California. Berkeley 1972.
- [12] ZHU H., BASIR O., *Feature Region-Merging Based Fuzzy Rules Extraction for Pattern Classification*, IEEE international Conference on Fuzzy Systems(FUZZ-IEEE2003), pp.696-701, 2003.
- [13] ZHU H., BASIR O., *Adaptive Fuzzy Evidential Reasoning with Information Theoretic Discounting for Robust Brain Tissue Classification*, 5th International Symposium on Soft Computing for Industry (WAC-ISSCI), SEVILLE, Spain, June 28 - July 1, 2004.

FUZZY CONTROLLING OF TRAFFIC LIGHTS IN NEURALGIC CITY POINTS

In this paper fuzzy methods which can be used in steering traffic lights are presented. It is shown, why fuzzy methods are more adequate for specified problems than probabilistic methods. The fuzzy methods and way of their determination are based on a learning set.