

Aleksander JASTRIEBOW<sup>1,2</sup>  
Grzegorz SŁOŃ<sup>1</sup>

### **MODELOWANIE SŁABOSTRUKTURALNYCH SYSTEMÓW LOGISTYCZNYCH OPARTE NA ROZMYTYCH RELACYJNYCH MAPACH KOGNITYWNYCH**

*W pracy przedstawiono pewne aspekty tworzenia rozmytej relacyjnej mapy kognitywnej, służącej do monitorowania otwartych systemów słabostrukturalnych o dowolnym charakterze. Przeprowadzono analizę doboru określonych kształtów funkcji charakterystycznych oraz stopnia dyskretyzacji. Dokonano również porównania działania przykładowego modelu rozmytego z odpowiadającym mu modelem ostrym.*

### **MODELLING LOW-STRUCTURAL LOGISTIC SYSTEMS BASED ON FUZZY RELATIONAL COGNITIVE MAPS**

*In the paper, certain aspects of creating fuzzy relational cognitive map, designed for monitoring any type of open low-structural systems are presented. There were carried out analysis of selection of characteristic functions specific shapes and discretization degree. There was also made a comparison of work of hypothetical fuzzy model and equivalent crisp model.*

#### **1. WSTĘP**

Złożone systemy logistyczne, obejmujące liczne powiązane ze sobą i wzajemnie oddziałujące elementy o zróżnicowanej strukturze, rzadko dają się opisać przy użyciu dokładnych modeli matematycznych. Systemy takie można nazywać słabostrukturalnymi, ponieważ monitorowanie ich działania musi, siłą rzeczy, opierać się na doświadczeniu personelu zarządzającego. Jest to spowodowane znaczącym udziałem niepewności co do rzeczywistego charakteru wzajemnych oddziaływań pomiędzy poszczególnymi elementami danego systemu. Podobnie wartości wpływających na siebie czynników są przeważnie trudne do precyzyjnego zmierzenia i mogą być jedynie szacowane z większą lub mniejszą dokładnością. Powyższe powody sprawiają, że wciąż aktualne jest zagadnienie efektywnego modelowania matematycznego tego rodzaju systemów. Występują tu dwa

<sup>1</sup> Politechnika Świętokrzyska, Wydział Elektrotechniki, Automatyki i Informatyki; 25-314 Kielce; Al. Tysiąclecia P. P. 7. Tel.: 41 34-24-331, faks: 41 34-24-331

<sup>2</sup> Politechnika Radomska, Wydział Nauczycielski; 26-600 Radom; ul. Malczewskiego 29.

problemy, które można rozwiązywać stosując odpowiednie podejścia. Pierwszy problem, polegający na niedostatecznej znajomości struktury powiązań, można przezwyciężyć, zastępując tradycyjny model różniczkowy relacyjną mapą kognitywną, która jest konstrukcją matematyczną opisującą siły wzajemnych powiązań (relacji) pomiędzy kluczowymi czynnikami systemu [1-5]. Znaczenie drugiego, wynikającego z niemożności dokładnego określenia zarówno poziomów relacji, jak i wartości przepływających sygnałów, można do pewnego stopnia zniwelować, wprowadzając technikę arytmetyki rozmytej [6].

Stosowanie powyższego podejścia wymaga nie tylko stworzenia rozmytego modelu, który w jakiś sposób odwzorowywałby wewnętrzne powiązania (relacje) pomiędzy kluczowymi czynnikami, ale także wypracowania metody oceny wyników działania tego modelu, co ma wielkie znaczenie przy monitorowaniu stanu obiektu. Tradycyjne podejście rozmyte bazuje wyłącznie na wiedzy ekspertowej, na podstawie której tworzy się zbiory reguł decyzyjnych, jednakże subiektywizm takiej metodologii zwiększa ryzyko niewłaściwego działania oraz wymusza stałe zaangażowanie personelu. Ponadto, przy dużej liczbie oddziałujących ze sobą czynników, tworzenie sztywnego zbioru reguł może być trudne lub niewystarczające. Istnieje więc potrzeba wypracowania podejścia pozwalającego na większe zautomatyzowanie procesu monitorowania. Niniejszy referat zawiera propozycję takiego podejścia zilustrowaną przykładem z zakresu logistyki hydraulicznej, w odniesieniu do otwartego modelu mapy kognitywnej.


## 2. BUDOWA MODELU MAPY KOGNITYWNEJ

W sytuacji braku możliwości dokładnego opisu matematycznego badanego systemu bądź procesu, jedyną dostępną wiedzą są ekspertowe informacje na temat wzajemnych oddziaływań kluczowych czynników. W układzie otwartym mogą być to oddziaływania (relacje) pomiędzy czynnikami wejściowymi (np. symptomami uszkodzeń) oraz wyjściowymi (np. uszkodzeniami). Wybór konkretnych czynników zależy od bieżących potrzeb systemu monitorowania oraz możliwości pomiarowych. Przykładowy zestaw czynników pewnego systemu hydraulicznego przedstawia tab. 1.

*Tab. 1. Zestaw symptomów i przyczyn niezdatności przykł. systemu hydraulicznego*

Zestawienie symptomów	Zestawienie uszkodzeń
C <sub>1</sub> – ubytek wody w systemie	C <sub>7</sub> – korozja rury
C <sub>2</sub> – wilgoć wokół rury	C <sub>8</sub> – pęknięcie rury
C <sub>3</sub> – stopniowa zmiana ciśnienia	C <sub>9</sub> – nadmierny przyrost osadu solnego
C <sub>4</sub> – spadek temperatury	C <sub>10</sub> – zużycie armatury
C <sub>5</sub> – skokowa zmiana ciśnienia	
C <sub>6</sub> – widoczna para wodna	

System monitorowania stanu obiektu charakteryzowanego przez czynniki z tab. 1 można przedstawić graficznie w postaci zespołu powiązań, jak na rys. 1. Normalizacja, wymieniona jako jeden z etapów działania systemu, ma na celu przekształcenie rzeczywistych (np. zmierzonych) wartości sygnałów symptomowych do bezwymiarowej, znormalizowanej postaci z zakresu [-1, 1].



Rys. 1. Ogólny schemat systemu monitorowania obiektu z tab. 1, {r<sub>ij</sub>} – współczynniki relacji pomiędzy czynnikami wejściowymi (symptomami) a wyjściowymi (uszkodzeniami)

Siły (współczynniki) relacji, podobnie jak wartości czynników, mogą być szacowane w sposób subiektywny, a więc zależny od doświadczenia eksperta, możliwości pomiarowych, warunków środowiskowych i innych elementów. Niezależnie od tego typu ograniczeń, podstawowym problemem przy budowie modelu jest próba określenia poziomu sił oddziaływań wzajemnych (współczynników relacji) w postaci odpowiednich liczb rzeczywistych, przy czym, dla zachowania spójności procesu monitorowania, należy dobrać ich wartości z określonego, wspólnego dla wszystkich parametrów, przedziału (np. [-1, 1]). Tak stworzony zestaw powiązań, zwany mapą kognitywną, można przedstawić w postaci (1) lub (2).

$$\langle \mathbf{C}, \mathbf{X}, \mathbf{r} \rangle \tag{1}$$

$$\langle \mathbf{X}, \mathbf{r} \rangle \tag{2}$$

gdzie:  $\mathbf{C} = [C_1, \dots, C_N]^T$  – zbiór czynników (concepts),  
 $\mathbf{X} = [X_1, \dots, X_N]^T$  – zbiór wartości czynników mapy (wektor stanu),  
 $\mathbf{r} = \{r_{ij}\}$  – macierz relacji pomiędzy zmiennymi  $X_i$  i  $X_j$  ( $i, j = 1, \dots, N$ ).

W tab. 2 pokazano wartości wzajemnych relacji dla zestawu czynników z tab. 1, przy czym, z uwagi na otwarty charakter przykładowego systemu, uwzględniono jedynie relacje pomiędzy czynnikami wejściowymi, a wyjściowymi.

Tab. 2. Przykładowe zestawienie wartości skalnych wsp. relacji pomiędzy czynnikami

<b>r</b>	X <sub>7</sub>	X <sub>8</sub>	X <sub>9</sub>	X <sub>10</sub>
X <sub>1</sub>	0,5	0,8	0	0
X <sub>2</sub>	0,6	0	0	0,4
X <sub>3</sub>	0,5	0	0,6	0,6
X <sub>4</sub>	0	0	0,6	0,2
X <sub>5</sub>	0	1	0	0,3
X <sub>6</sub>	0,5	0,5	0	0,2

Dla obiektu, w którym zarówno współczynniki relacji, jak i wartości samych czynników są dokładnie określone, można zastosować podejście tzw. ostre, polegające na wyznaczeniu wartości czynników wyjściowych na podstawie równania (3).

$$X_j = \sum_{i=1}^6 r_{ij} X_i, \quad j = 7, \dots, 10 \quad (3)$$

gdzie:  $X_j$  – wartość j-tego czynnika (wyjściowego),

$X_i$  – wartość i-tego czynnika (wejściowego) – po normalizacji,

$r_{ij}$  – skalarny współczynnik relacji pomiędzy i-tym i j-tym czynnikiem.

#### Uwaga 1.

Określanie stanu poszczególnych czynników wyjściowych za pomocą metody (3) polega na sprawdzeniu, w jakim przedziale zawiera się w danym momencie wartość danego czynnika. Jeśli sprawdzenie wykaże, że wartość ta przekroczyła granice uznane za poprawne, obsługa powinna podjąć działania korygujące (np. próbę naprawy danego uszkodzenia).

Bezpośrednie stosowanie równania (3) stwarza zagrożenie przekroczenia przez niektóre czynniki granic zakresu normalizacji (np. czynnik  $C_{10}$  może w takim ujęciu osiągać wartości  $X_{10}$  z zakresu od  $-1,7$  do  $1,7$ ), co może prowadzić do niewłaściwego działania automatycznego systemu monitorowania. Dlatego też wartości czynników wyjściowych powinny być dopasowywane do założonych granic zakresu monitorowania. Można to osiągnąć stosując różne funkcje korygujące. W takiej sytuacji równanie (3) przybiera postać (4):

$$X_j = f_j \left( \sum_{i=1}^6 r_{ij} X_i \right), \quad j = 7, \dots, 10 \quad (4)$$

gdzie:  $f(x)$  – funkcja korygująca.

Funkcja korygująca z równania (4) może przybierać różne formy (np.: (5) lub (6)), należy jednak pamiętać, że jej głównym zadaniem jest ograniczenie wartości argumentu do założonych granic.

$$f(x) = \frac{1}{1 + e^{-\lambda x}}, \quad \lambda \geq 0 \quad (5)$$

$$f(x) = \frac{1 - e^{-\lambda x}}{1 + e^{-\lambda x}}, \quad \lambda \geq 0 \quad (6)$$

Funkcje korygujące (5) i (6) mają charakter nieliniowy, zdążający asymptotycznie do 1, co oznacza, że właściwie nie można ich stosować w systemach z dużą liczbą oddziałujących czynników, ponieważ nie zapewniają wystarczającej rozróżnialności poszczególnych stanów (powyżej pewnego poziomu duże przyrosty argumentu wywołują

coraz mniejsze przyrosty wartości funkcji). W związku z tym autorzy proponują zastosowanie innej metody korekcji, opartej na modyfikacji wartości współczynników relacji.

W proponowanej metodzie pierwotne wartości współczynników relacji  $r_{ij}$  zostają zastąpione wartościami skorygowanymi  $r'_{ij}$ , wyznaczonymi zgodnie z równaniem (7).

$$r'_{ij} = r_{ij} \cdot w_j \tag{7}$$

gdzie:

$$w_j = \begin{cases} \frac{1}{\max\{S_j^+, S_j^-\}} & \text{dla } \max\{S_j^+, S_j^-\} > 1 \\ 1 & \text{dla } \max\{S_j^+, S_j^-\} \leq 1 \end{cases}$$

$$S_j^+ = \sum_{i=1}^k r_{ij} \quad \text{dla } r_{ij} \geq 0 \quad ; \quad S_j^- = -\sum_{i=1}^k r_{ij} \quad \text{dla } r_{ij} < 0$$

przy czym: j – nr czynnika wyjściowego, k – liczba czynników wejściowych.

Uwaga 2.

Metodę korekcji  $r_{ij}$  za pomocą (7) można traktować jako pewien algorytm adaptacji (uczenia) mapy kognitywnej typu „off-line”.

Zastosowanie korekcji macierzy współczynników relacji wg (7) pozwala na budowę systemu monitorowania w oparciu o równanie (8).

$$X_j = \sum_{i=1}^6 r'_{ij} X_i, \quad j = 7, \dots, 10 \tag{8}$$

Takie podejście właściwie uniezależnia rozróżnialność stanów monitorowanego obiektu od liczby oddziałujących czynników. Wymusza jedynie odpowiednie dostosowanie granic przedziałów oceny stanu. Przykładowe współczynniki relacji z tab. 2, po przekształceniu wg (8), otrzymają wartości przedstawione w tab. 3.

Tab. 3. Współczynniki relacji z tab. 2 po przekształceniu zgodnie z (8)

$r'$	$X_7$	$X_8$	$X_9$	$X_{10}$
$X_1$	0,24	0,35	0	0
$X_2$	0,29	0	0	0,24
$X_3$	0,24	0	0,5	0,35
$X_4$	0	0	0,5	0,12
$X_5$	0	0,43	0	0,18
$X_6$	0,24	0,22	0	0,12

W sytuacji niepewności co do założonych sił oddziaływań (relacji) pomiędzy czynnikami oraz wartości czynników wejściowych, model ostry może być zastąpiony przez


model rozmyty, w którym ostre wartości czynników zastępuje się funkcjami przynależności rozmytymi wokół tych wartości (czynnikami rozmytymi), natomiast w miejsce skalarnych współczynników relacji wprowadza się przestrzenne relacje rozmyte zbudowane w oparciu o te współczynniki. W takim modelu rozmyte wartości czynników wyjściowych wyznacza się na podstawie równania (9):

$$X_j = \bigoplus_{i=1}^6 X_i \circ R_{i,j}, \quad j = 7, \dots, 10 \quad (9)$$


gdzie:  $\bigoplus$  – operacja sumowania rozmytego,

- $R_{i,j}$  – pojedyncza rozmyta relacja pomiędzy rozmytymi czynnikami o numerach  $i$  oraz  $j$  (z uwzględnieniem korekty wg (7)),
- $\circ$  – operacja maksymalnej kompozycji rozmytej.

Wybór sposobu rozmywania wartości czynników oraz dobór parametrów poszczególnych relacji rozmytych zależą od charakteru monitorowanego obiektu oraz możliwości systemu obliczeniowego. Ogólnie rzecz biorąc można się posłużyć jednym z trzech typów funkcji przynależności (rys. 2 i 3).



Rys. 2. Przykłady funkcji przynależności, które można wykorzystać do rozmywania czynników mapy kognitywnej,  $u$  – nośnik,  $\mu(u)$  – funkcja przynależności



Rys. 3. Przykłady relacji rozmytych budowanych w oparciu o różne rodzaje funkcji przynależności;  $u_1, u_2$  – zmienne nośnika,  $\mu(r, u_1, u_2)$  – funkcja przynależności relacji


Zakres nośnika zależy głównie od granic zakresu normalizacji dla wartości czynników. Jeżeli zakres ten wynosi  $[-1, 1]$ , to, dla zachowania symetrii funkcji charakterystycznych, dogodnie jest przyjąć nośnik o zakresie  $[-2, 2]$  (jak na rys. 2 i 3).

### 3. DOBÓR PARAMETRÓW MODELU ROZMYTEJ MAPY KOGNITYWNEJ

Głównymi parametrami rozmytej mapy kognitywnej są: funkcje przynależności rozmytych czynników, funkcje przynależności rozmytych relacji, zakres nośnika liczb i relacji rozmytych, liczba wartości lingwistycznych (równoważna liczbie kroków próbkowania nośnika) oraz poziomy odniesienia do wnioskowania o stanie czynników wyjściowych. Dobór poszczególnych parametrów zależy od różnych czynników, z których przynajmniej część ma subiektywny charakter. Szerokość zakresu nośnika powinna pozwalać na prawidłowe wyostwienie wszystkich występujących w systemie wartości czynników rozmytych. W praktyce oznacza to, że wartości funkcji przynależności czynników rozmytych powinny być bliskie zeru po każdym kolejnym kroku wnioskowania, co z kolei oznacza powiązanie zakresu nośnika z przyjętym stopniem rozmycia czynników, a więc pośrednio z poziomem niepewności co do odczytu ich wartości rzeczywistych. Liczba punktów próbkowania nośnika zależy głównie od możliwości sprzętowych. Gęstsze próbkowanie zwiększa dokładność modelu ale wydłuża czas obliczeń. Ma to duże znaczenie z uwagi na złożony charakter operacji arytmetycznych na liczbach rozmytych. Rodzaje wybranych funkcji przynależności zależy przede wszystkim od charakteru systemu i dobór tych parametrów jest najbardziej subiektywny, ponieważ zależy w zasadzie wyłącznie od wiedzy ekspertowej. Tym niemniej właśnie rodzaj funkcji przynależności ma kluczowe znaczenie dla prawidłowego działania modelu. Co do poziomów odniesienia dla systemu wnioskującego, to zależą one od bieżących potrzeb i celów monitorowania i mogą być zmieniane zależnie od znaczenia monitorowanych procesów.

### 4. ANALIZA SYMULACYJNA

Przedmiotem analizy był obiekt z rys. 1, którego parametry opisano w tab. 1 i 2. Dla potrzeb porównawczych zbudowano dwa typy modeli: ostry (będący modelem odniesienia) oraz kilka rozmytych (o różnych parametrach). W każdym modelu wykorzystano ten sam zestaw czynników wejściowych (przedstawiony na rys. 4), przy czym w modelach rozmytych znormalizowane wartości czynników stanowiły centra rozmywania. Podobnie zastosowano macierz współczynników relacji z tab. 2, tym, że w modelu ostrym współczynniki te (po korekcie wg (7)) stosowano w formie bezpośredniej, a w modelach rozmytych stanowiły one bazę do budowy odpowiednich relacji rozmytych.

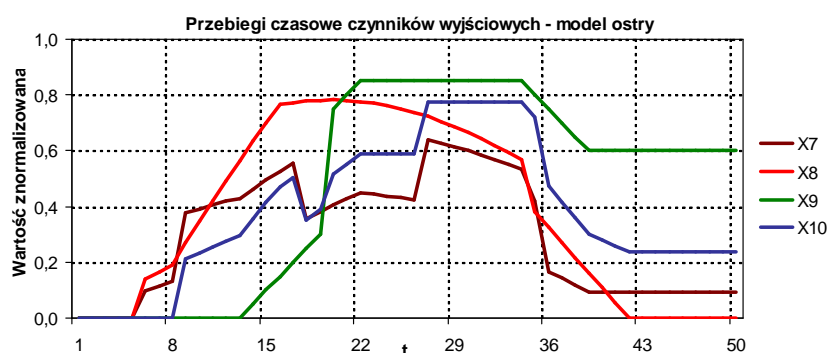


Rys. 4. Wartości czynników wejściowych  $X_1 \div X_6$  po normalizacji bezwymiarowej do zakresu  $[-1, 1]$  – model ostry

Dla lepszego wyróżnienia wniosku końcowego założono, że w pewnym momencie wartości części czynników wejściowych (symptomów) wzrosły, następnie (na skutek reakcji systemu monitorującego) podjęto działania naprawcze, po których jednak niektóre czynniki zachowały wartości większe od zera.

#### 4.1 Model ostry

Rys. 5 przedstawia przebiegi czasowe wartości czynników wyjściowych uzyskanych w modelu ostrym.



Rys. 5. Wartości czynników wyjściowych  $X_7 \div X_{10}$  otrzymane przez system monitorujący – model ostry

Do celów interpretacji wskazań systemu monitorującego przyjęto szczególne przedziały wartości odniesienia (jednakowe dla wszystkich czynników wyjściowych), zestawione w tab. 4.

Tab. 4. Przedziały odniesienia dla wartości czynników wyjściowych

Zakres przedziału	< 0.4	[0.4, 0.6)	$\geq 0.6$
Interpretacja wskazania	wartość poprawna (brak uszkodzenia)	wartość niepewna (możliwe uszkodzenie)	wartość niepoprawna (uszkodzenie)


Zgodnie z tab. 4 interpretacja przebiegów z rys. 5 jest następująca. W pewnym momencie wystąpiły symptomy wskazujące na możliwość wystąpienia kilku uszkodzeń jednocześnie. Pierwszy etap działań naprawczych spowodował zmniejszenie wartości niektórych symptomów, co pozwoliło wyeliminować dwa uszkodzenia. Umożliwiło to skoncentrowanie działań naprawczych na pozostałych dwóch możliwych uszkodzeniach. W końcowym etapie system monitorujący wskazuje już tylko na jedno uszkodzenie (czynnik  $C_9$ ).

Model ostry skonstruowano jedynie dla celów porównawczych. Zasadniczym celem pracy jest analiza działania modeli rozmytych.




## 4.2 Modele rozmyte

Modele rozmyte mogą znaleźć zastosowanie w sytuacjach braku wystarczającej pewności co do odczytanego poziomu wartości symptomów oraz współczynników relacji. Z badań wynika, że, w odniesieniu do obiektu z rys. 1, nie ma większego znaczenia, który rodzaj funkcji przynależności zostanie przyjęty jako podstawa rozmywania wartości czynników i konstruowania relacji rozmytych. Warunkiem jest zachowanie symetrii funkcji charakterystycznych wokół centrum rozmywania. Pewne znaczenie ma dobór odpowiedniej liczby punktów dyskretyzacji nośnika. Jej zmniejszenie wydatnie skraca czas obliczeń, ale, poniżej pewnej granicy, następuje zafałszowanie wyników. Na rys. 6 i 7 pokazano przebiegi czasowe czynników wyjściowych w modelach rozmytych opartych na różnych funkcjach przynależności, przy czym rys. 6 przedstawia modele bazujące na  $K = 41$  punktach próbkowania nośnika, a rys. 7 – modele z  $K = 9$  punktami próbkowania. Dla obu prezentowanych modeli zastosowano nośnik o zakresie  $[-2, 2]$ .



Rys. 6. Wartości czynników wyjściowych  $X_7 \div X_{10}$  otrzymane przez rozmyty system monitorujący dla funkcji przynależności: gausoidalnych oraz trapezoidalnych –  $K = 41$




Rys. 7. Wartości czynników wyjściowych  $X_7 \div X_{10}$  otrzymane przez rozmyty system monitorujący dla funkcji przynależności: gausoidalnych oraz trapezoidalnych –  $K = 9$

Jak widać na rys. 6 i 7, znaczne zmniejszenie liczby punktów próbkowania  $K$  nie tylko zmienia wnioski końcowe, ale również wprowadza rozbieżności pomiędzy wynikami pracy modeli wykorzystujących różne funkcje przynależności.

Większy problem stanowi niesymetria funkcji przynależności, która może zostać wprowadzona na etapie tworzenia rozmytej mapy kognitywnej bądź rozmywania wartości czynników. Niesymetria wobec centrum ma duże znaczenie w procesie późniejszego wyostrzania wartości czynników, ponieważ jest ono realizowane metodą średniej ważonej,

co oznacza, że wyostzona wartość czynnika nie pokrywa się z centrum rozmytej funkcji charakterystycznej tego czynnika. Stwarza to dodatkową trudność przy korygowaniu współczynników relacji metodą (7), ponieważ w metodzie tej zmienia się jedynie relacje ostre bądź rozmyte, co w efekcie może prowadzić do przekroczenia założonych ograniczeń przez wyostzone wartości czynników wejściowych. Efekt niesymetrii pokazano rys. 8.



Rys. 8. Wartości czynników wyjściowych  $X_7 \div X_{10}$  otrzymane przez rozmyty system monitorujący dla niesymetrycznych trapezoidalnych funkcji przynależności –  $K = 41$

## 5. WNIOSKI

Z przeprowadzonej analizy wynika, że model rozmytej mapy kognitywnej może znaleźć zastosowanie w monitorowaniu otwartych obiektów logistycznych i jest w stanie dobrze odwzorować poszczególne stany obiektu. Warunkiem poprawnego działania jest odpowiedni dobór parametrów modelu. Obecnie trwają prace nad opracowaniem metody pozwalającej zniwelować niekorzystny wpływ niesymetrii funkcji przynależności stosowanych przy rozmywaniu wartości czynników oraz budowie relacji rozmytych.

## 6. BIBLIOGRAFIA

- [1] Borisow W. W., Krugłow W. W., Fiedułow A. C. *Rozmyte modele i sieci*. Wyd. „Telekom”, Moskwa 2007 (w j. rosyjskim).
- [2] Jastriebow A., Słoń G.: *Rozmyte mapy kognitywne w relacyjnym modelowaniu słabostrukturalnych systemów*. W: Jastriebow A. (red.) *Informatyka w dobie XXI wieku*. Technologie informatyczne w nauce, technice i edukacji. Wyd. Naukowe Instytutu Technologii Eksploatacyjnej – Państwowego Instytutu Badawczego, Radom 2009, str. 35-38.
- [3] Jastriebow A., Słoń G.: *Rozmyte mapy kognitywne w relacyjnym modelowaniu systemów monitorowania*. W: Kowalczyk Z. (red.) *Systemy wykrywające, analizujące i tolerujące usterki*. PWNT, Gdańsk 2009, str. 217-224.
- [4] Kandasamy W.B.V., Smarandache F.: *Fuzzy Cognitive Maps and Neutrosophic Cognitive Maps*. Xiquan, Phoenix, AZ, USA. 2003
- [5] Kosko B. *Fuzzy cognitive maps*. *Int. Journal of Man-Machine Studies*, Vol. 24. pp. 65-75, 1986.
- [6] Piegat A.: *Fuzzy Modelling and Control*. Physica-Verlag, Springer-Verlag Company, 2001.