

## ROZMYTE MODELE DECYZYJNE POZYSKIWANE Z DANYCH EKSPERYMENTALNYCH

*W referacie przedstawiono sposób budowy rozmytych modeli regulowych, które pozwalają na modelowanie zagadnień decyzyjnych. W modelach wykorzystuje się dane numeryczne dla wyznaczenia rozkładów prawdopodobieństwa zmiennych lingwistycznych i rozmytych stanów procesów stochastycznych. Wartości prawdopodobieństw stanowią odpowiednie wagi w modelach regulowych.*

### DECISION-MAKING FUZZY MODELS DERIVED FROM EXPERIMENTAL DATA

#### *Abstract*

*In the paper the probability-based methods and fuzzy modelling are used for creating such a description of the system in which both measurements and experts' linguistic information are employing.*

### 1. WSTĘP

Budowa modeli decyzyjnych jest domeną eksperta, człowieka. Również wspomaganie podejmowania decyzji jest procesem zaplanowanym przez człowieka i podporządkowanym ogólnej koncepcji procesu decyzyjnego. Zatem, wybór strategii, celów, zmiennych, metod matematycznych, modeli, sposobu eksploracji danych i ich przetwarzania, komunikacji systemu informatycznego z decydemem itp. stanowią elementy składowe ogólnej koncepcji podejmowania decyzji, utworzonej przez człowieka. Wiedza ekspercka, niezbędna dla podejmowania decyzji inżynierskich bądź menedżerskich w znacznym obszarze wyrażana jest w języku naturalnym, a więc w formie lingwistycznej, w przeciwieństwie do sformalizowanego, matematycznego podejścia.

Zastosowanie teorii zbiorów rozmytych (Zadeh, 1965), zmiennych lingwistycznych (Zadeh, 1975) a zwłaszcza rozmytych modeli decyzyjnych (Bellmann i Zadeh, 1970) stanowiło przełomowe wydarzenia w teorii podejmowania decyzji, łącząc modele preskryptywne z ujęciem deskryptywnym. Wprowadzone przez Zadeha pojęcie prawdopodobieństwa zdarzenia rozmytego (Zadeh, 1968) pozwoliło na formułowanie zadań decyzyjnych w kategoriach rozmytej teorii decyzji statystycznych, zapoczątkowanej przez Okudę, Tanakę i Asai (Okuda, Tanaka, Asai, 1974). W polskiej literaturze przedmiotu, jako fundamentalne w tym zakresie, można wskazać prace Kacprzyka, np. (Kacprzyk, 1986), (Kacprzyk, 2001).

W referacie przedstawiono rozważania dotyczące wykorzystania danych numerycznych w modelowaniu zadań decyzyjnych, co stanowi aktywny nurt w literaturze poświęconej inteligentnym metodom obliczeń, np. (Nakoula i in., 1997).

## 2. OTOCZENIE ROZMYTE - PODEJŚCIE BELLMANNA I ZADEHA

Sformułowany przez Bellmanna i Zadeha typ zadań podejmowania decyzji uwzględnia tzw. niepewność otoczenia, w którym zachodzi proces podejmowania decyzji. Jest to inny niż probabilistyczny rodzaj indeterminizmu, niepewność reprezentują: cele rozmyte, ograniczenia rozmyte, decyzje rozmyte.

Otoczeniem rozmytym problemu podejmowania decyzji, według (Bellmann i Zadeh, 1970), także (Kacprzyk, 1986), jest uporządkowana czwórka

$$(X, G, C, D), \quad (1)$$

gdzie  $X=\{x\}$  jest zbiorem opcji postępowania,  $G$  jest celem rozmytym, tzn. zbiorem rozmytym określonym w zbiorze opcji  $X$  o funkcji przynależności

$$\mu_G(x) : X \rightarrow [0,1] \quad (2)$$

określającej stopień przynależności poszczególnych opcji  $x$  do zbioru celów;  $C$  jest ograniczeniem rozmytym, tzn. zbiorem rozmytym określonym w zbiorze opcji  $X$  o funkcji przynależności

$$\mu_C(x) : X \rightarrow [0,1] \quad (3)$$

która określa, w jakim stopniu poszczególne opcje  $x$  należą do zbioru ograniczeń [5].

Decyzja rozmyta  $D$ , jest zbiorem rozmytym określonym w zbiorze opcji  $X$ , jako wynik pewnej agregacji  $*$  na zbiorach  $G$  i  $C$ :

$$D = G * C \quad (4)$$

przy czym funkcja przynależności zbioru decyzji spełnia następujące warunki:

$$\mu_D(x) : [0,1] \times [0,1] \rightarrow [0,1], \quad (5)$$

$$\mu_D(x) = \mu_G(x) * \mu_C(x) \quad (6)$$

dla każdego  $x \in X$ .

Jest oczywiste, że postać funkcji przynależności zbiorów  $G$  i  $C$ , określających cel i ograniczenia rozmyte, a także wybór operacji agregującej  $*$ , decydują o wynikach, czyli o postaci zbioru decyzji  $D$ . Decyzja optymalna maksymalizująca, o ile istnieje, jest to takie  $x^* \in X$ , że

$$\mu_D(x^*) = \max \mu_D(x) \quad (7)$$

dla wszystkich  $x \in X$  (Bellman i Zadeh, 1970), (Kacprzyk, 1986).

## 3. POZYSKIWANIE WIEDZY Z BAZ DANYCH NUMERYCZNYCH

Podstawą tworzenia modeli decyzyjnych będą dane numeryczne, pochodzące z obserwacji wewnętrznych lub zewnętrznych badanych procesów. Systemy informatyczne wspierające zarządzanie różnorodnych przedsięwzięć, gromadzą na ogół duże ilości danych numerycznych. Są to obserwacje i pomiary dotyczące m. in.:

- parametrów specjalistycznych procesów technologicznych,
- monitoringu środowiska naturalnego,
- indeksów giełdowych, walut, akcji i innych papierów wartościowych,

- parametrów makroekonomicznych gospodarek światowych,
- finansów, wartości produkcji, kosztów i innych parametrów działalności przedsiębiorstw.

W rozdziale tym pokażemy, że zmienne lingwistyczne i odpowiadające im zbiory rozmyte, które występują w zadaniach decyzyjnych formułowanych przez ekspertów mogą być weryfikowane poprzez wykorzystanie danych numerycznych.

### 3.1. Przetwarzanie numerycznych danych eksperymentalnych

W tworzonych rozmytych modelach decyzyjnych będą wykorzystywane empiryczne rozkłady prawdopodobieństwa obserwowanych zmiennych losowych i procesów stochastycznych.

Niech  $X$  będzie obserwowana zmienną losową o  $r$  składowych  $(X_1, X_2, \dots, X_r) \in X = R^r$ . Zakłada się, że w pewnych rozłącznych przedziałach

$$\Delta x_{i,j_i} = [x_{i,j_i,\min}, x_{i,j_i,\max}) \quad j_i = 1, 2, \dots, J_i; \quad i = 1, 2, \dots, r \quad (8)$$

określonych dla każdej ze zmiennych, prawdopodobieństwo zdarzenia jednoczesnego

$$P((X_1 \in \Delta x_{1,j_1}), \dots, (X_r \in \Delta x_{r,j_r})) = P_{X_1, \dots, X_r}(\Delta x_{1,j_1}, \dots, \Delta x_{r,j_r}) \quad (9)$$

jest stałe i wyraża się jako iloraz

$$P_{X_1, \dots, X_r}(\Delta x_{1,j_1}, \dots, \Delta x_{r,j_r}) = \frac{n_{j_1, \dots, j_r}}{N} \quad (10)$$

$$j_i = 1, 2, \dots, J_i; \quad i = 1, 2, \dots, r$$

gdzie  $n_{j_1, j_2, \dots, j_r}$  jest liczbą obserwacji zdarzenia jednoczesnego (9), a  $N$  jest ogólną liczbą obserwacji. Tak zdefiniowany rozkład  $r$ -wymiarowej zmiennej losowej spełnia zależność:

$$\sum_{j_1=1}^{J_1} \sum_{j_2=1}^{J_2} \dots \sum_{j_r=1}^{J_r} \frac{n_{j_1, j_2, \dots, j_r}}{N} = 1 \quad (11)$$

W rozkładzie  $r$ -wymiarowej zmiennej losowej (10) można wyznaczyć dowolny  $(r-i+1)D$  rozkład brzegowy (np.  $2D$ ), jako

$$P_{X_1, X_2}(\Delta x_{1,j_1}, \Delta x_{2,j_2}) = \sum_{X_3, \dots, X_r} \frac{n_{j_1, j_2, \dots, j_r}}{N} \quad (12)$$

$$j_i = 1, 2, \dots, J_i; \quad i = 1, 2, \dots, r$$

oraz rozkłady warunkowe, jak np.

$$P_{X_3, \dots, X_r / X_1, X_2}(\Delta x_{3,j_3}, \dots, \Delta x_{r,j_r} / \Delta x_{1,j_1}, \Delta x_{2,j_2}) = \frac{P_{X_1, \dots, X_r}(\Delta x_{1,j_1}, \dots, \Delta x_{r,j_r})}{P_{X_1, X_2}(\Delta x_{1,j_1}, \Delta x_{2,j_2})} \quad (13)$$

$$j_i = 1, 2, \dots, J_i; \quad i = 1, 2, \dots, r$$

Niech teraz obserwowany proces  $X$  stanowi realizację pewnego wektorowego procesu stochastycznego

$$\{x(t, \omega): t \in T, x \in X, \omega \in \Omega\} \quad (14)$$

gdzie  $T$  reprezentuje dziedzinę czasu,  $X$  jest dziedziną wartości procesu  $X=R^p$  oraz  $\Omega$  jest przestrzenią zdarzeń elementarnych. Załóżmy, że badany proces jest procesem drugiego rzędu, tzn., że rozkłady prawdopodobieństwa rzędu 2D są wystarczającą charakterystyką procesu. W szczególności, może to oznaczać, że proces spełnia warunki Markowa, czyli dla rozkładów warunkowych ma miejsce zależność:

$$p(x_{t_k} / x_{t_{k-1}}, \dots, x_{t_2}, x_{t_1}) = p(x_{t_k} / x_{t_{k-1}}) \quad (15)$$

Zbiór obserwacji  $\{x_{t_k}\}$  wektora o  $p$ -składowych

$$x^T(t) = [x^1(t), \dots, x^p(t)] \quad (16)$$

stanowi macierz wartości wektora (16), obserwowanych w chwilach  $t_k, k=1, 2, \dots, K$ .

W myśl założeń o własnościach Markowa, warunkowy rozkład prawdopodobieństwa (15) stanowi wystarczającą charakterystykę procesu.

Podobnie jak w założeniach dla zmiennej losowej wektorowej, przyjmiemy, że dla rozłącznych przedziałów  $a_i = (a_i^1, \dots, a_i^p), i=1, \dots, I$  określonych w przestrzeni  $X$ , wartości prawdopodobieństwa w rozkładach empirycznych par  $(x_{t_{k-1}}, x_{t_k})$  w przestrzeni  $X \times X$

$$P(x_{t_{k-1}} \in a_i, x_{t_k} \in a_j) = p_{ij}(x_{t_{k-1}}, x_{t_k}), i, j=1, 2, \dots, I; \quad (17)$$

są stałe i równe ilorazom liczb obserwacji w odpowiednich przedziałach.

Dla poszczególnych zdarzeń  $x_{t_{k-1}} \in a_i, i=1, \dots, I$  empiryczne brzegowe oraz warunkowe rozkłady prawdopodobieństwa wynoszą:

$$P(x_{t_k} \in a_i) = \sum_{j=1}^I p_{ij}(x_{t_{k-1}}, x_{t_k}) = p_{i.}(x_{t_k}), i=1, 2, \dots, I. \quad (18)$$

$$P(x_{t_k} \in a_j / x_{t_{k-1}} \in a_i) = p_{ij}(x_{t_{k-1}}, x_{t_k}) / p_{i.}(x_{t_{k-1}}) = p_{j|i}(x_{t_k} / x_{t_{k-1}}) \quad (19)$$

$j=1, 2, \dots, I; i=const.$

Zachodzą przy tym następujące relacje, dla wyznaczonych rozkładów empirycznych:

$$\sum_{i=1}^I \sum_{j=1}^I p_{ij} = 1, \quad \sum_{i=1}^I p_{i.} = 1, \quad \sum_{j=1}^I p_{j|i} = 1, \quad i=const. \quad (20)$$

Należy zwrócić uwagę na fakt, że rozkład brzegowy (18) wektora  $x_{t_k}$  jest rozkładem empirycznym w przestrzeni  $R^p$ .

### 3.2. Zmienne lingwistyczne i ich rozkłady prawdopodobieństwa

Zmienne, ograniczenia i cele w modelach decyzyjnych Bellmanna i Zadeha a także Kacprzyka są zbiorami rozmytymi lub terminami (wartościami lingwistycznymi) zmiennych i wyrażeń lingwistycznych. Wykorzystując definicję zmiennej lingwistycznej (Zadeh, 1975), można zdefiniować wektorową zmienną lingwistyczną, a następnie oszacować prawdopodobieństwo wystąpienia poszczególnych jej wartości lingwistycznych.

Zmienną lingwistyczną definiujemy, za: (Zadeh, 1975), (Kacprzyk, 1986) oraz (Nakoula, 1997), jako czwórke

$$\langle x_{\text{nazwa}}, L(X), X, M \rangle \quad (21)$$

gdzie

$X$  – przestrzeń rozważań (opcji),  $X = \mathbb{R}^p$ ;

$x_{\text{nazwa}}$  – nazwa wektorowej zmiennej lingwistycznej, np. ‘stan procesu’, ‘stan rynku’;  
wektorowa zmienna lingwistyczna wyraża się poprzez  $p$  zmiennych

lingwistycznych:  $x_{\text{nazwa}}^T = (x_{\text{nazwa}}^1, \dots, x_{\text{nazwa}}^p)$ ;

$L(X)$  – zbiór wartości lingwistycznych, które przyjmuje  $x_{\text{nazwa}}$ , na przykład

$L(X) = \{\text{bardzo wysoki, wysoki, średni, niski}\}$ ;

$M$  – semantyka, przyporządkowująca każdej wartości lingwistycznej ze zbioru  $L(X)$ , zbiór rozmyty w przestrzeni  $X = \mathbb{R}^p$ .

Zbiory rozmyte  $A_1, \dots, A_J$  stanowiące numeryczny opis poszczególnych wartości lingwistycznych ze zbioru  $L(X)$  są definiowane poprzez odpowiednie funkcje przynależności

$$\mu_{A_j}(x): X \rightarrow [0,1], j=1, \dots, J \quad (22)$$

w taki sposób, że dla każdej wartości wektora  $x \in X$

$$\sum_{j=1}^J \mu_{A_j}(x) = 1. \quad (23)$$

W przypadku, gdy rozważany proces ma charakter losowy, każdy zbiór rozmyty  $A_j$ , który reprezentuje wartość lingwistyczną ze zbioru  $L(X)$ , winien być rozważany jako zdarzenie rozmyte. Jeśli w przestrzeni  $X$  każdemu elementowi  $x$  przypisano prawdopodobieństwo jego wystąpienia  $p(x) \in [0,1]$  to prawdopodobieństwo wystąpienia zdarzenia rozmytego  $A$ , jest równe:

$$P(A) = \sum_{x \in X} p(x) \mu_A(x) \quad (24)$$

a funkcja przynależności  $\mu_A(x)$  jest mierzalna po borelowsku (Zadeh, 1968). Należy zauważyć, że tak zdefiniowane prawdopodobieństwo zdarzenia rozmytego jest liczbą rzeczywistą i posiada podstawowe właściwości prawdopodobieństwa w znaczeniu klasycznym. Prawdopodobieństwo rozmyte natomiast, według definicji Yagera (Yager, 1979) jest zbiorem rozmytym, określonym na przedziale  $[0,1]$ .

Dla rozkładów prawdopodobieństwa zmiennej lingwistycznej określonej w przestrzeni  $\mathbb{R}^p$  istotne jest takie określenie funkcji przynależności, aby odpowiednie rozkłady brzegowe i warunkowe wartości rozmytych spełniały podstawowy warunek sumowania do jedności. Pewne wskazówki na ten temat można znaleźć w książce (Yager i Filev, 1995). W pracach autorskich, np. (Walaszek-Babiszewska, 2004a-b) a także (Walaszek-Babiszewska, 2005a-c) zaprezentowano metodykę wyznaczania rozkładów prawdopodobieństwa zmiennych i wektorów lingwistycznych w oparciu o empiryczne rozkłady prawdopodobieństwa danych numerycznych.

Niech  $X = \mathbb{R}$ , a  $\Delta x_i$  niech będą rozłącznymi przedziałami, w których założono stałe wartości prawdopodobieństw (10), (12) oraz stałe wartości funkcji przynależności  $\mu_{A_j}(\Delta x_i)$ , przy czym spełniony jest warunek

$$\sum_{j=1}^J \mu_{A_j}(\Delta x_i) = 1 \text{ dla każdego } \Delta x_i \quad i=1, \dots, I \quad (25)$$

oraz dla wszystkich zbiorów rozmytych  $A_j$ ,  $j=1, 2, \dots, J$  określonych w  $X$  i reprezentujących zbiór  $L(X)$  wartości zmiennej lingwistycznej. Prawdopodobieństwo zdarzenia rozmytego  $A_j$ ,  $j=1, 2, \dots, J$  jest równe

$$P(A_j) = \sum_{i=1, \dots, I} p_i(\Delta x_i) \mu_{A_j}(\Delta x_i) \quad (26)$$

gdzie  $p_i(\Delta x_i)$  jest prawdopodobieństwem wyznaczonym empirycznie, w myśl (14).

Można wykazać, że dla zbiorów rozmytych  $A_j$ ,  $j=1, \dots, J$  odpowiadających wartościom lingwistycznym, np. 'x jest wysoki', 'x jest niski' ze zbioru wartości  $L(X)$  przyjmowanych przez zmienną lingwistyczną  $x_{\text{nazwa}}$ , suma wartości prawdopodobieństw wszystkich zdarzeń wynosi 1.

Niech teraz zdarzenia  $A_j$ ,  $A_l$  odpowiadają pewnym wartościom lingwistycznym dwóch różnych zmiennych lingwistycznym o nazwach  $x_{1, \text{nazwa}}$ ,  $x_{2, \text{nazwa}}$  określonych w przestrzeniach  $X_1$ ,  $X_2$  odpowiednio. Dla każdej zmiennej lingwistycznej został zdefiniowany zbiór jej wartości lingwistycznych  $L(X_1)$  oraz  $L(X_2)$ . Ponadto, założmy, że znane są łączne rozkłady empiryczne (10) w  $X_1 \times X_2$ . Prawdopodobieństwo zdarzenia rozmytego  $A_j \cap A_l$  określonego w  $L(X_1) \times L(X_2)$  będzie obliczane następująco :

$$P(A_j \cap A_l) = \sum_{m=1, \dots, M} \sum_{i=1, \dots, I} p_{im}(\Delta x_{1,i}, \Delta x_{2,m}) \mu_{A_j}(\Delta x_{1,i}) \mu_{A_l}(\Delta x_{2,m}) \quad (27)$$

gdzie indeksy  $j=1, 2, \dots, J$ ,  $l=1, 2, \dots, L$  oznaczają numery zbiorów rozmytych reprezentujących wartości lingwistyczne w  $L(X_1)$  i  $L(X_2)$ , odpowiednio. Można również wykazać, że (27) daje nam empiryczny rozkład prawdopodobieństwa dwóch zmiennych lingwistycznych, których wartości zostały określone w  $L(X_1)$  i  $L(X_2)$ , odpowiednio.

Rozkłady warunkowe zdarzeń rozmytych wyznacza się w oparciu o (26) i (27) :

$$P(A_l / A_j) = \frac{P(A_l \cap A_j)}{P(A_j)}, \quad l=1, 2, \dots, L, \quad j=\text{const}; \quad (j=1, 2, \dots, J). \quad (28)$$

Każdy rozkład warunkowy zmiennej lingwistycznej, wyznaczony w oparciu o powyżej sformułowane zasady spełnia warunek

$$\sum_{l=1}^L P(A_l / A_j) = 1, \quad j=\text{const} \quad (j=1, 2, \dots, J). \quad (29)$$

### 3.3. Proces stochastyczny o rozmytych stanach

Zakładamy teraz, że obserwowany obiekt dynamiczny jest procesem stochastycznym (14) o własnościach Markowa (15). W przestrzeni  $X=R^p$  wartości procesu, określamy zbiór stanów rozmytych  $L(X)$  oraz odpowiadające im zbiory rozmyte  $A_j$ ,  $j=1, 2, \dots, J$  poprzez wprowadzenie funkcji przynależności. Współczynniki przynależności są tak dobrane, aby dla każdego z rozłącznych przedziałów  $a^T_i = (a^1_i, \dots, a^p_i)$ ,  $i=1, \dots, I$

określonych w przestrzeni  $X$ , suma współczynników przynależności do stanów rozmytych była równa jedności. Oznacza to, że dla każdego  $x_{t_k} \in a_i$  zachodzi relacja

$$\sum_{j=1, \dots, J} \mu_{A_j}(a_i) = 1; \quad i = 1, \dots, I \quad (30)$$

Prawdopodobieństwo wystąpienia rozmytego stanu  $A_j$  procesu stochastycznego (14) można wyznaczyć, stosując definicję prawdopodobieństwa zdarzenia rozmytego i metodykę podaną powyżej.

$$P(X_t \text{ jest } A_j) = \sum_i p_i(x_t) \mu_{A_j}(a_i) = P_{A_j}(x_t) \quad (31)$$

gdzie  $p_i$  jest prawdopodobieństwem w sensie (18), liczbą rzeczywista z przedziału  $[0,1]$  a sumowanie rozciąga się na przedziały  $a_i$ , na których określony został rozmyty stan  $A_j$  procesu stochastycznego (14). Uwzględniając (30), można wykazać, że dla stanów  $A_j$ ,  $j=1, \dots, J$  opisujących zbiór wartości lingwistycznych  $L(X)$  procesu stochastycznego (14), wzór (31) określa rozkład prawdopodobieństwa rozmytych stanów procesu stochastycznego, czyli

$$\sum_{j=1}^J P_{A_j}(x_t) = 1 \quad (32)$$

Rozkład 2D w przestrzeni wartości lingwistycznych procesu  $L(X) \times L(X)$  można wyznaczyć, obliczając prawdopodobieństwo jednoczesnego wystąpienia stanów  $A_j$  i  $A_k$ , odpowiednio dla procesu w chwilach  $t-1$  i  $t$ . Korzystając z metodyki wspomnianej już powyżej, mamy:

$$P((X_{t-1} \text{ jest } A_j) \cap (X_t \text{ jest } A_k)) = \sum_m \sum_i p_{im}(x_{t-1}, x_t) \mu_{A_j}(a_i) \mu_{A_k}(a_m) = P_{A_j \cap A_k}(x_t, x_{t-1}) \quad (33)$$

przy czym sumowanie rozciąga się na wszystkie przedziały  $a_i, a_m$ , w których określone zostały stany rozmyte  $A_j$  i  $A_k$ , a  $p_{im}(x_{t-1}, x_t)$  jest rozumianym w sensie (17) prawdopodobieństwem w rozkładach empirycznych par  $(x_{t_{k-1}}, x_{t_k})$  w przestrzeni  $X \times X$ .

Prawdopodobieństwo warunkowe wystąpienia w chwili  $t$  rozmytego stanu  $A_k$ , jeśli w chwili  $t-1$  wystąpił rozmyty stan  $A_j$  wyznaczymy w oparciu o formuły (31) i (33):

$$P((X_t \text{ jest } A_k) | (X_{t-1} \text{ jest } A_j)) = \frac{P_{A_k \cap A_j}(x_t, x_{t-1})}{P_{A_j}(x_{t-1})} = P_{A_k | A_j}(x_t / x_{t-1}) \quad (34)$$

$k=1, 2, \dots, J, \quad j=\text{const} (j=1, 2, \dots, J).$

Rozkłady (33) i (34) spełniają warunek sumowania do jedności.

## 4. PRZYKŁADOWE MODELE DECYZYJNE

### 4.1. Ogólna postać modeli

Zagadnienia podejmowania decyzji przy istnieniu niepewności o charakterze rozmytym i probabilistycznym wygodnie jest sprowadzić do postaci reguł:

$$R_i: \{ \text{JEŻELI (poprzednik) TO (następnik)} \}_{i=1,2,\dots,I}$$

w których poprzednik reguły zawiera zbiór warunków, następnik zawiera wniosek (Yager i Filev, 1995), (Hellendorn i Driankov, eds., 1997).

Wybrana reguła plikowa może mieć postać:

$$R^{(i)}: w_i(\text{Jeżeli } x \text{ jest } A_i \text{ To } y \text{ jest } M_i) \quad (35)$$

gdzie:

$x, y$  – zmienne lingwistyczne, odpowiednio wejścia i wyjścia systemu (modelu decyzyjnego),

$i$  – numer reguły plikowej związany z wartością lingwistyczną  $A_i$  zmiennej  $x$ ;  $i=1,2,\dots,I$ ;

$M_i$  – wiarygodna struktura następnika zawierająca zbiory rozmyte i ich wagi.

Uwzględniając we wzorze (35) strukturę następnika, otrzymujemy dla  $i$ -tej reguły plikowej zbiór reguł elementarnych o postaci:

$$\begin{aligned} R^{(i)}: w_i(\text{Jeżeli } x \text{ jest } A_i \text{ To } y \text{ jest } B_1 \text{ z wagą } P_{1/i} \\ \text{Także } y \text{ jest } B_2 \text{ z wagą } P_{2/i} \\ \dots\dots\dots \\ \text{Także } y \text{ jest } B_J \text{ z wagą } P_{J/i}) \end{aligned} \quad (36)$$

Wagi  $w_i$  oraz  $P_{j/i}$ ,  $i=1,2,\dots,I$ ;  $j=1,2,\dots,J$  w sposób istotny poprawiają jakość modelu rozmytego i są ważnym elementem w zadaniu wnioskowania przybliżonego. Wartości wag mogą być nadane przez ekspertów lub też wyznaczone w oparciu o analizę probabilistyczną zbioru danych doświadczalnych.

W podobny sposób można skonstruować rozmyty model systemu dynamicznego uwzględniając  $X_t, X_{t-1}$ . Pierwsza z reguł plikowych będzie miała postać:

$$\begin{aligned} R^{(1)}: w_1(\text{Jeżeli } x_{t-1} \text{ jest } A_1 \text{ To } x_t \text{ jest } A_1 \text{ z wagą } w_{1/1} \\ \text{Także } x_t \text{ jest } A_2 \text{ z wagą } w_{2/1} \\ \dots\dots\dots \\ \text{Także } x_t \text{ jest } A_J \text{ z wagą } w_{J/1}) \end{aligned} \quad (37)$$

gdzie  $A_1, A_2, \dots, A_J$  są zbiorami rozmytymi w przestrzeni  $\mathbf{X}$  a wagi są wartościami odpowiednich prawdopodobieństw.

Jeżeli  $\mathbf{X}=\mathbb{R}^p$ , to model regułowy zawiera zarówno w poprzedniku, jak i w następniku spójniki I, odpowiadające pewnej t-normie, zaś wagi reguł są odpowiednimi prawdopodobieństwami zdarzeń rozmytych w poprzedniku i w następniku:

$$\begin{aligned} R^{(l)}: w_l(\text{Jeżeli } x_{t_k-1}^1 \text{ jest } A_i^1 \text{ I } \dots \text{ I } x_{t_k-1}^p \text{ jest } A_i^p \\ \text{To } x_{t_k}^1 \text{ jest } A_i^1 \text{ I } \dots \text{ I } x_{t_k}^p \text{ jest } A_i^p \quad (w_{l/n}) \\ \text{Także } \dots\dots\dots \\ \text{Także } x_{t_k}^1 \text{ jest } A_j^1 \text{ I } \dots \text{ I } x_{t_k}^p \text{ jest } A_j^p \quad (w_{l/n}); \end{aligned} \quad (38)$$



Przy czym, wagi reguł są następującymi prawdopodobieństwami (Walaszek-Babiszewska, 2005b) :

$$w_l = P(x_{t_{k-1}} \text{ jest } A_l)$$

$$w_{j/l} = P((x_{t_k} \text{ jest } A_j) / (x_{t_{k-1}} \text{ jest } A_l)) \quad j, l = 1, 2, \dots, J. \quad (39)$$

#### 4.1. Przykład wnioskowania

Wnioskowanie, czyli poszukiwanie rozwiązania zadania zamodelowanego w postaci (35) – (38), można przeprowadzić poprzez przetwarzanie lingwistyczne, bądź numeryczne. Załóżmy model dynamiczny SISO i niech  $x_{t_{k-1}}^*$  będzie wartością numeryczną obserwacji, należąca do przedziału  $a_m \in X$ . Znajdźmy prognozowaną numeryczną wartość procesu. Przedział  $a_m$  należy do wielu zbiorów rozmytych  $A_j$ ,  $j=1, 2, \dots, J$  z różnymi współczynnikami przynależności, przy czym każdy  $j$ -ty zbiór, generuje odpowiednio  $j$ -tą regułę  $R^{(j)}$ . Z następnika tej reguły wyprowadzamy warunkową wartość oczekiwaną

$$E\{X_{t_k} / x_{t_{k-1}} \in A_j\} = \sum_{i=1}^J C_i^* w_{i/j} \quad (40)$$

gdzie  $C_i^*$  są centroidami zbiorów rozmytych odpowiadających wartościom lingwistycznym następnika, a  $w_{i/j}$  prawdopodobieństwami warunkowymi ich wystąpienia w  $j$ -tej regule. Prognoza numeryczna, na podstawie wszystkich reguł jest następującą wartością oczekiwaną

$$\overline{x_{t_k}} = \sum_{j=1}^J \mu_{A_j}(x_{t_{k-1}}^*) w_j \left( \sum_{i=1}^J C_i^* w_{i/j} \right) \quad (41)$$

gdzie  $\mu_{A_j}(x_{t_{k-1}}^*)$  jest poziomem zapłonu  $j$ -tej reguły dla zadanej wartości obserwacji numerycznej, a  $w_j$  - prawdopodobieństwem wystąpienia zdarzenia rozmytego  $A_j$  (waga  $j$ -tej reguły).

Tak wprowadzona prognoza uwzględnia sposób określania zbiorów rozmytych oraz rozkładów prawdopodobieństwa zmiennych lingwistycznych, omówionych w niniejszym artykule.

## 4. ZAKOŃCZENIE

W referacie nie podano przykładowych zadań decyzyjnych, które mogą być różnorodne ale przedstawiono głównie możliwości wykorzystania danych numerycznych i ich przetwarzania aby można było przy ich pomocy weryfikować lub rozbudowywać modele lingwistycznego eksperckie, budowane przez człowieka.

## LITERATURA

1. Bellman R.E., Zadeh L.A.: Decision making in a fuzzy environment. Management Science, 1970, nr 17, pp. 141-164.

2. Kacprzyk J.: Zbiory rozmyte w analizie systemowej. PWN, Warszawa, 1986.
3. Kacprzyk J.: Wieloetapowe sterowanie rozmyte. WNT, Warszawa, 2001.
4. Nakoula Y., Galichet S., Foulloy L.: Identification of linguistic fuzzy models based on learning, in: Fuzzy Model Identification, (H. Hellendoorn, D. Driankov, eds.), Springer - Verlag, Heidelberg, 1997.
5. Okuda T., Tanaka H., Asai K.: Decision-making and information in fuzzy events. Bull. University Osaka Prefect. 1974 Ser. A, vol. 23 pp.193-202. Bull. University Osaka Prefect. 1974 Ser. A, vol. 23 pp.193-202.
6. Walaszek-Babiszewska A.: Fuzzy probability for modelling of particle preparation processes, in: Intelligence in a Small World; (Selected Papers from IPMM-2003 The Fourth Int. Conf. Intelligent Processing and Manufacturing of Materials, Nanotechnology for the 21st Century. Sendai, Japan, May 2003); Meech J. A., Kawazoe Y., Kumar V., Maguire J. F. (Eds.); pp. 119-129; DEStech Publ. Inc. Lancaster, USA 2005 (+CD-ROM).
7. Walaszek-Babiszewska A.: Zbiory rozmyte jako narzędzie formalizacji wiedzy ekspertów w systemach informatycznych. Zeszyty Naukowe Politechniki Śląskiej, Organizacja i Zarządzanie. Mat. Krajowej Konferencji Naukowej Wiedza – Informacja – Marketing, Szczyrk 2004a (w druku).
8. Walaszek-Babiszewska A.: Statistical and fuzzy modelling of grain materials sampling and operations. Selected approaches. Wydawnictwo Politechniki Śląskiej, Seria Monografie, nr 62, s.118, Gliwice 2004b.
9. Walaszek-Babiszewska A.: Budowa rozmytej bazy wiedzy dla analizy eksperymentalnych danych rynkowych. Rozdział 8, w: Zarządzanie i Technologie Informacyjne, T. 2.: Metody sztucznej inteligencji. Józefowska J. (red.), str.168-178. Wyd. Uniwersytetu Śląskiego, Katowice 2005a.
10. Walaszek-Babiszewska A.: Measurements and expert knowledge for time-dependent stochastic systems. Proc. of IPMM 2005 The Fifth Int. Conf. on Intelligent Processing and Manufacturing of Materials; Meech J. A., Maguire J. F., Kawazoe Y. (Eds.); Monterey, California USA, 2005b (CD-ROM).
11. Walaszek-Babiszewska A.: Applications of Fuzzy and Probabilistic Methods in Financial Market Analyses. In: Issues in Intelligent Systems Models and Techniques; Editors: Dрамиński M., Grzegorzewski P., Trojanowski K., Zadrożny S., s.263-271. Problemy Współczesnej Nauki; Teoria i Zastosowania; Informatyka. Akad. Oficyna Wyd. EXIT, Warszawa 2005c.
12. Yager R.R.: A Note on Probabilities of Fuzzy Events, Inf. Sci., 1979, nr 18, pp. 113-129.
13. Yager R.R., Filev D.P.: Podstawy modelowania i sterowania rozmytego. WNT, Warszawa, 1995.
14. Zadeh L.A.: Fuzzy sets. Inform. Contr., 1965 vol. 8, pp.338-353.
15. Zadeh L.A.: Probability measures of fuzzy events. J.Math. Anal. Appl., 1968, vol. 23, pp. 421-427.
16. Zadeh L.A.: The concept of a linguistic variable and its application to approximate reasoning, Information Sciences, Part I: 8, 1975, pp. 199-240.
17. Zadeh L.A.: From computing with numbers to computing with words – from manipulation of measurements to manipulation of perceptions. IEEE Trans. on Circuits and Systems-I: Fundamental Theory and Applications, 1999, nr 1, pp. 105-119.