

**Mirosław Kulawik**

# **ZASTOSOWANIE ZBIORÓW ROZMYTYCH W JEDNOETAPOWYM PROCESIE PODEJMOWANIA DECYZJI PRZEZ JEDNEGO DECYDENTA**

---

---

## **Wstęp**

Podjęcie odpowiednich decyzji jest uzależnione od stopnia wiedzy decydenta o stanach natury oraz jego preferencji. Pomijając na razie problem określenia preferencji decydenta można wyróżnić trzy sytuacje (Heilpern, 2001):

- podejmowanie decyzji w warunkach pewności,
- podejmowanie decyzji w warunkach ryzyka,
- podejmowanie decyzji w warunkach niepewności.

Sytuacje te różnią się stopniem posiadanej wiedzy o stanach natury. Pierwsza sytuacja występuje dosyć rzadko i zakłada, że wiadomo na pewno, jaki stan natury wystąpi w danym momencie. Druga sytuacja jest możliwa wtedy, gdy można opisać wszystkie potencjalne stany natury oraz oszacować prawdopodobieństwo ich wystąpienia. To prawdopodobieństwo utożsamia się ze stopniem ryzyka w procesie decyzyjnym (Nahotko, 1997). Z trzecią sytuacją można się spotkać, kiedy decydent nie ma pełnej informacji o stanach natury lub nie można określić prawdopodobieństwa ich wystąpienia. Dokonuje się wtedy pewnego przybliżenia, oszacowania na podstawie informacji, które są w posiadaniu (praktycznie nie zdarza się sytuacja, w której nie ma żadnych informacji), czyli buduje się model procesu podejmowania decyzji.

Jest oczywiste, że w sytuacjach niejednoznacznych, mając nawet identyczne informacje, można zbudować wiele różnych modeli. Zależy to głównie od tego, na jak bardzo skomplikowany obliczeniowo model zdecyduje się de-

cydent. Wiąże się to bezpośrednio z kosztami w relacji im bardziej skomplikowany model, tym większe ponosi koszty, oraz informacjami w tym sensie, że im więcej informacji zostanie wykorzystanych do budowy modelu, tym bardziej wzrasta jego złożoność. Widać więc wyraźnie, że należy się dobrze zastanowić nad wyborem narzędzi służących do budowy modelu. Dodatkowo należy pamiętać o tym, że dla decydenta „dobra” decyzja nie zawsze oznacza „idealną” decyzję, tzn. jeżeli znajdziemy „dobrą” decyzję, która spełnia poziom jego oczekiwań, to często koszt znalezienia „lepszej” decyzji przekracza zyski z tego płynące (oczywiście w sensie relacji preferencji decydenta). Na koniec zawsze należy pamiętać o tym, że wraz ze złożonością modelu wzrasta nie tylko koszt jego budowy, ale także błąd obliczeniowy, co w skrajnych wypadkach może prowadzić do fałszywych wyników.

Wobec powyższych faktów można użyć dwóch teorii służących do budowy takiego modelu: teorię rachunku prawdopodobieństwa oraz teorię zbiorów rozmytych. Pierwsza z nich wiąże się z utratą informacji zawartych np. w stwierdzeniach: „mniej więcej”, „prawie”, „około” itp., ale za to otrzymany model jest znacznie prostszy obliczeniowo niż model zbudowany na podstawie teorii zbiorów rozmytych. Z drugiej strony zbyt nagminne sięganie po zbiory rozmyte i zbytnie „rozmycie” modelu może prowadzić do złych wyników, które są sprzeczne ze zdrowym rozsądkiem. W rozdziale 1 pokażemy, w jaki sposób zbytnie „rozmycie” modelu prowadzi do wyników sprzecznych z oczekiwanymi.

## 1. Zbiory rozmyte

### Definicja 1

Zbiorem rozmytym  $A$  określonym na przestrzeni  $X$  nazywa się zbiór uporządkowanych par:

$$A = \{(\mu_A(x), x) : x \in X\} \quad (1)$$

gdzie  $\mu_A : X \rightarrow [0,1]$  jest funkcją przynależności. Nośnikiem zbioru rozmytego jest zbiór:

$$\text{supp } A = \{x : \mu_A(x) \neq 0\} \quad (2)$$

Funkcja przynależności jest więc pewnym rozszerzeniem funkcji charakterystycznej zbioru z tą różnicą, że każdemu elementowi  $x$  przypisana jest wartość liczbowa z przedziału  $[0,1]$ , która mówi o wiedzy lub przekonaniu, czy

element  $x$  należy do  $A$ . Jeśli  $\mu_A(x) = 0$ , to  $x$  na pewno nie należy do  $A$ ; jeśli  $\mu_A(x) = 1$ , to  $x$  z całą pewnością należy do  $A$ ; jeśli  $\mu_A(x) = \frac{1}{2}$ , to o przynależności  $x$  do  $A$  nie można nic powiedzieć. Zbiory nierozmyte często określa się jako ostre.

W przypadku gdy zbiór  $X = \{x_1, x_2, \dots, x_n\}$  jest skończony stosuje się notację:

$$A = \sum_{i=1}^n \frac{\mu_A(x_i)}{x_i}, \quad x_i \neq 0$$

### Definicja 2

Zbiór rozmyty  $A$  nazywa się normalnym wtedy, gdy istnieje  $x_0$ , takie że  $\mu_A(x_0) = 1$ . Oznacza to, że istnieje chociaż jeden element, który na pewno należy do  $A$ . Oczywiście jeżeli zbiór rozmyty nie jest normalny, można przeprowadzić jego normalizację przyjmując funkcję przynależności:

$$\bar{\mu}_A(x) = \frac{\mu_A(x)}{\max \mu_A(x)}$$

### Definicja 3

Zbiór rozmyty  $A$  nazywa się wypukłym, jeśli jego funkcja przynależności spełnia warunek:

$$\mu_A(\lambda x + (1 - \lambda)y) \geq \min\{\mu_A(x), \mu_A(y)\} \quad \forall x, y \in X \text{ i } \lambda \in [0,1] \quad (3)$$

### Definicja 4

Niech  $A, B$  będą zbiorami rozmytymi w  $X$ . Zbiór rozmyty  $A$  zawiera się w zbiorze rozmytym  $B$  ( $A \subseteq B$ )  $\Leftrightarrow$  gdy:

$$\forall x \in X \quad \mu_A(x) \leq \mu_B(x) \quad (4)$$

Zbiór rozmyty  $A$  jest równy zbiorowi rozmytemu  $B$  ( $A = B$ )  $\Leftrightarrow$  gdy:

$$\forall x \in X \quad \mu_A(x) = \mu_B(x) \quad (5)$$

Dopełnieniem zbioru rozmytego  $A$  nazywamy zbiór  $\bar{A}$  o funkcji przynależności:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (6)$$

Sumą zbiorów rozmytych  $A$  i  $B$  nazywamy zbiór  $A \cup B$  o funkcji przynależności:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad (7)$$

Przecięciem zbiorów rozmytych  $A$  i  $B$  nazywamy zbiór  $A \cap B$  o funkcji przynależności:

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad (8)$$

Powyższe definicje pochodzą od Zadeha, czasami jednak korzysta się z innych, mniej intuicyjnych (Kacprzyk, 1986; Czogała, Pedrycz, 1980). Szczególnie ważne są pewne definicje sumowania i mnożenia zbiorów rozmytych, nazywane miękkim przecięciem i miękką sumą, w przeciwieństwie do wyżej wymienionych, które czasem nazywa się twardym przecięciem i twardą sumą.

#### Definicja 5

Niech  $A, B$  będą zbiorami rozmytymi w  $X$ . Miękkim przecięciem nazywa się zbiór rozmyty  $AB$  o funkcji przynależności:

$$\mu_{AB}(x) = \mu_A(x)\mu_B(x) \quad (9)$$

Miękką sumą nazywa się zbiór rozmyty  $A + B$  o funkcji przynależności:

$$\mu_{A+B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x)\mu_B(x) \quad (10)$$

Z punktu widzenia pojęcia zmiennej lingwistycznej ważne są następujące definicje:

#### Definicja 6

Niech  $A$  będzie zbiorem rozmytym w  $X$ . Koncentrację  $A$  oznaczamy  $\text{CON}(A)$  i definiujemy jako zbiór rozmyty o funkcji przynależności:

$$\mu_{\text{CON}(A)}(x) = (\mu_A(x))^2 \quad (11)$$

Rozcieńczenie  $A$  jest to zbiór rozmyty  $DIL(A)$ , taki że:

$$\mu_{DIL(A)}(x) = (\mu_A(x))^{0,5} \quad (12)$$

Intensyfikacja kontrastu  $INT(A)$  jest to zbiór rozmyty o funkcji przynależności:

$$\mu_{INT(A)}(x) = \begin{cases} (\mu_A(x))^2 & \forall x \in X : \mu_A(x) < 0,5 \\ (\mu_A(x))^{0,5} & \forall x \in X : \mu_A(x) \geq 0,5 \end{cases} \quad (13)$$

Zmniejszenie kontrastu  $BLR(A)$  jest to zbiór rozmyty o funkcji przynależności:

$$\mu_{BLR(A)}(x) = \begin{cases} (\mu_A(x))^{0,5} & \forall x \in X : \mu_A(x) < 0,5 \\ (\mu_A(x))^2 & \forall x \in X : \mu_A(x) \geq 0,5 \end{cases} \quad (14)$$

Mówiąc potocznie: koncentracja wyostrza zbiór rozmyty, a rozcieńczenie go spłaszcza.

### Definicja 7

Niech  $A$  będzie zbiorem rozmytym w  $X$ , a  $B$  zbiorem rozmytym w  $Y$ . Iloczynem kartezjańskim zbiorów  $A$  i  $B$  nazywa się zbiór  $A \times B$  o funkcji przynależności:

$$\mu_{A \times B}(x, y) = \min\{\mu_A(x), \mu_B(y)\} \quad \forall x \in X, \forall y \in Y \quad (15)$$

Z definicji 7 wynika, że zbiór  $A \times B$  jest rozmyty w  $X \times Y$ .

### Definicja 8

Relację dwuargumentową  $R$  między dwoma ostrymi zbiorami  $X$  i  $Y$  definiuje się jako zbiór rozmyty w  $X \times Y$ , czyli:

$$R = \{(\mu_R(x, y), (x, y)) : x \in X, y \in Y\} \quad (16)$$

W przypadku gdy zbiory  $X$  i  $Y$  są skończone, można zapisać je jako:

$$R = \sum_{x,y} \frac{\mu_R(x, y)}{(x, y)} \quad (17)$$

W przypadku zwykłej nierozmytej relacji mówi się, że dwa elementy są ze sobą w relacji lub nie. Natomiast relacja rozmyta określa stopień od 0 do 1, w jakim te dwa elementy są ze sobą w relacji.

### Definicja 9

Niech  $X, Y, Z$  będą zbiorami ostrymi,  $R$  relacją rozmytą w  $X \times Y$ , a  $G$  relacją rozmytą w  $Y \times Z$  o funkcjach przynależności odpowiednio  $\mu_R(x, y)$  i  $\mu_G(y, z)$ . Złożeniem typu max-min relacji rozmytych  $R$  i  $G$  nazywa się relację rozmytą  $R \circ G$  w  $X \times Z$  o funkcji przynależności:

$$\mu_{R \circ G}(x, z) = \max_{y \in Y} \{ \min \{ \mu_R(x, y), \mu_G(y, z) \} \} \quad \forall x \in X, \forall z \in Z \quad (18)$$

Jeżeli zbiory  $X, Y, Z$  są nieskończenie wiele wymiarowe, to w powyższym złożeniu bierze się pod uwagę supremum zamiast maksimum. Podobnie jak w przypadku sumowania i mnożenia zbiorów rozmytych, tak i przy składaniu relacji można podać wiele definicji (Kacprzyk, 1986). Definicja 9 jest jednak najczęściej stosowana.

## 2. Podejmowanie decyzji

### Definicja 10

Niech  $S = \{s_1, s_2, \dots, s_n\}$  będzie zbiorem stanów natury,  $D = \{d_1, d_2, \dots, d_m\}$  zbiorem decyzji,  $l: D \times S \rightarrow R$  funkcją wypłaty, a  $P$  rozkładem prawdopodobieństwa określonym na przestrzeni stanów natury:

$$p_j = P(s_j) \quad (19)$$

Wtedy dla każdej decyzji  $d_i$  można policzyć średnie wartości oczekiwane  $E_i$ :

$$E_i = \sum_{j=1}^n l(d_i, s_j) p_j \quad (20)$$

oraz stosując kryterium maksymalnej wartości oczekiwanej wyznaczyć decyzję optymalną  $d_0$ , taką że:

$$E_0 = \max_{i=1, \dots, m} E_i \quad (21)$$

Powyższa definicja jest dobra tylko w przypadku, gdy decydent chce zmaksymalizować swój zysk, a funkcja wypłaty ściśle odpowiada jego preferencjom, np. kiedy określa ona zysk finansowy, który decydent chce osiągnąć jak najwyższy. W ogólnym przypadku jego oczekiwania mogą być jednak inne, dlatego wprowadza się pojęcia relacji preferencji oraz funkcji użyteczności (Heilpern, 1992; Krawczyk, 1990).

### Definicja 11

Niech  $X$  będzie zbiorem wartości funkcji wypłaty  $l$ ,  $O \subset X \times X$  relacją preferencji decydenta, taką że jeśli  $(x_i, x_j) \in O$ , to  $x_i$  jest preferowane w stosunku do  $x_j$ . Funkcją użyteczności nazywamy funkcję  $U : X \rightarrow R$ , taką że:

- 1)  $(x_i, x_j) \in O \Leftrightarrow U(x_i) > U(x_j)$ ,
- 2)  $U(\alpha x_i + (1 - \alpha)x_j) = \alpha U(x_i) + (1 - \alpha)U(x_j)$ ,  
gdzie  $\alpha \in [0,1]$  jest prawdopodobieństwem,
- 3) jeśli  $U_1$  i  $U_2$  spełniają 1) i 2), to  $U_1(x_i) = aU_2(x_i) + b$ ,  $a, b \in R$ ,  
 $a > 0$ .

W sytuacji gdy zbiory  $S$  i  $D$  są skończone, funkcję użyteczności przedstawia się często w postaci macierzy  $U = [u_{ij}]$ , gdzie  $u_{ij}$  odpowiada użyteczności wynikającej z decyzji  $d_i$ , przy stanie natury  $s_j$ . Gdy jest określona macierz użyteczności, analiza decyzyjna odbywa się identycznie jak w definicji 10 (do wzoru (20) podstawia się jednak  $u_{ij}$  zamiast  $l(d_i, s_j)$ ).

Czasami zdarza się, że nie można jednoznacznie określić zbioru stanów natury za pomocą liczb rzeczywistych lub określonego na nim rozkładu prawdopodobieństwa. Korzysta się wtedy z teorii zbiorów rozmytych.

Do dalszych obliczeń zostanie wykorzystana definicja sumowania miękkiego (10).

### Definicja 12

Niech  $S = \sum_{j=1}^n \frac{\mu_S(s_j)}{s_j}$  będzie rozmytym stanem natury,

$D = \{d_1, d_2, \dots, d_m\}$  zbiorem decyzji, a:

$$U = \begin{bmatrix} u_{11} & u_{12} & \dots & u_{1n} \\ u_{21} & u_{22} & \dots & u_{2n} \\ \dots & \dots & \dots & \dots \\ u_{m1} & u_{m2} & \dots & u_{mn} \end{bmatrix}$$

macierzą użyteczności ( $u_{ij} \in R$ ).

Użyteczność rozmytą  $U_i$ , wynikającą z podjęcia decyzji  $d_i$ , określa się jako zbiory rozmyte:

$$U_i = \sum_{j=1}^n \frac{\mu_{U_i}(u_{ij})}{u_{ij}}, \text{ gdzie } \mu_{U_i}(u_{ij}) = \mu_S(s_j) \quad (22)$$

Następnie wprowadza się zbiór:

$$Y = \bigcup_{i=1}^m \text{supp } U_i$$

oraz:

$$u_{\max} = \max_Y u_{ij}$$

Kolejno określa się zbiory rozmyte:

$$U_{im} = \sum_{j=1}^n \frac{\mu_{U_{im}}(u_{ij})}{u_{ij}}, \text{ gdzie } \mu_{U_{im}}(u_{ij}) = \frac{u_{ij}}{u_{\max}} \quad (23)$$

oraz:

$$U_{i0} = \sum_{j=1}^n \frac{\mu_{U_{i0}}(u_{ij})}{u_{ij}}, \text{ gdzie } \mu_{U_{i0}}(u_{ij}) = \min\{\mu_{U_i}(u_{ij}), \mu_{U_{im}}(u_{ij})\} \quad (24)$$

Przez decyzję rozmytą rozumie się zbiór:

$$D^* = \sum_{i=1}^m \frac{\mu_{D^*}(d_i)}{d_i}, \text{ gdzie } \mu_{D^*}(d_i) = \max_{j=1, \dots, n} \mu_{U_{i0}}(u_{ij}) \quad (25)$$

Każdej decyzji  $d_i$  przyporządkowany jest więc pewien stopień przynależności  $\mu_{D^*}(d_i)$ . Naturalną regułą jest to, że wybiera się decyzję o najwyższym stopniu przynależności.



W przypadku gdy istnieje wiele stanów rozmytych  $S_k$ , można postąpić na dwa sposoby. Pierwszy polega na tym, że dokonuje się pewnej agregacji zbiorów  $S_k$  w jeden rozmyty stan natury  $S$ ; w drugim sposobie dla każdego zbioru  $S_k$  przeprowadza się analizę z definicji 12 i wyznacza się nową macierz użyteczności, której elementami są rozmyte użyteczności  $U_{i0}$ . Rozwiązanie problemu decyzyjnego z rozmytymi użytecznościami wygląda następująco:

### Definicja 13

Niech  $S = \sum_{j=1}^n \frac{\mu_S(s_j)}{s_j}$  będzie rozmytym stanem natury,

$D = \{d_1, d_2, \dots, d_m\}$  zbiorem decyzji, a:

$$U = \begin{bmatrix} U_{11} & U_{12} & \dots & U_{1n} \\ U_{21} & U_{22} & \dots & U_{2n} \\ \dots & \dots & \dots & \dots \\ U_{m1} & U_{m2} & \dots & U_{mn} \end{bmatrix}$$

rozmytą macierzą użyteczności, której elementy są zbiorami rozmytymi w pewnym zbiorze  $P = \{u_1, u_2, \dots, u_p\}$ , czyli  $U_{ij} = \sum_{k=1}^p \frac{\mu_{U_{ij}}(u_k)}{u_k}$ .

Użyteczność rozmytą wynikającą z zastosowania decyzji  $d_i$  przy rozmytym stanie natury  $S$  określa się jako:

$$U_i^1 = \sum_{j=1}^n \frac{\mu_{U_i^1}(U_{ij})}{U_{ij}}, \text{ gdzie } \mu_{U_i^1}(U_{ij}) = \mu_S(s_j) \quad (26)$$

Zbiory  $U_i^1$  redukuje się do zbiorów  $U_i^2$  w następujący sposób:

$$U_i^2 = \sum_{k=1}^p \frac{\mu_{U_i^2}(u_k)}{u_k}, \text{ gdzie } \mu_{U_i^2}(u_k) = \min_j \{\mu_S(s_j), \mu_{U_{ij}}(u_k)\} \quad (27)$$

$$\forall j : s_j \in \text{supp } S$$

Dalej postępuje się identycznie jak w przypadku nierozmytych wartości funkcji użyteczności, tzn. określa się zbiory  $U_{im}^2$  z tą różnicą, że  $u_{\max} = \max_{k=1, \dots, p} u_k$ .

Następnie porównuje się te zbiory z  $U_i^2$ , w wyniku czego określa się zbiory  $U_{i0}^2$  i zgodnie ze wzorem (25) wyznacza się rozmytą decyzję optymalną  $D^*$ .

### 3. Rozwiązanie problemu metodą probabilistyczną

Rozważmy następujący prosty problem decyzyjny. Właściciel niewielkiej piekarni zastanawia się, jak zaplanować wypiek chleba w celu zmaksymalizowania swojego zysku. Jest oczywiste, że kluczową rolę odgrywa tu właściwe określenie popytu i dostosowanie do niego produkcji. Dla uproszczenia przyjął on następującą funkcję wypłaty, która odpowiada jego macierzy użyteczności:

Tabela 1

Dane obliczeniowe

$d_i \backslash s_j$	0	20	40	60	80	100
20	-20	10	10	10	10	10
40	-40	-10	20	20	20	20
60	-60	-30	0	30	30	30
80	-80	-50	-20	10	40	40

$s_j$  – popyt,

$d_i$  – wielkość produkcji.

W sytuacji gdy nie są dostępne żadne inne informacje, rozwiązanie zadania jest trywialne. Zakłada się, że każdy ze stanów natury jest jednakowo prawdopodobny i otrzymuje się najwyższe wartości oczekiwane dla decyzji  $d_1$  i  $d_2$  równe  $E_{\max} = 5$ .

Założmy, że piekarz ma informacje o możliwych stanach natury, pochodzące z różnych źródeł, ale mające jednakową wagę. Są one następujące:

$I_1$  – popyt wyniesie około 40

$I_2$  – popyt wyniesie około 60

$I_3$  – bardzo możliwe, że popyt wyniesie 40

$I_4$  – popyt wyniesie nieco mniej niż 80

$I_5$  – popyt wyniesie nieco więcej niż 60

$I_6$  – popyt wyniesie mniej więcej 60

Wszystkie informacje są jednakowo ważne. Po opuszczeniu „rozmytych” informacji, czyli „około”, „mniej więcej”, „nieco mniej” i „nieco więcej” otrzymuje się konkretne wskazania: dwa na 40, trzy na 60 i jedno na 80. Biorąc pod uwagę te wskazania, rozkład jednostajny  $\left\{\frac{1}{6}, \frac{1}{6}, \frac{1}{6}, \frac{1}{6}, \frac{1}{6}, \frac{1}{6}\right\}$  zamienia się

na rozkład  $\left\{0, 0, \frac{1}{3}, \frac{1}{2}, \frac{1}{6}, 0\right\}$ . Zmieniają się też wartości oczekiwane, które

są odpowiednio równe  $E_1 = 10$ ,  $E_2 = 20$ ,  $E_3 = 20$ ,  $E_4 = 5$ ,  $E_{\max} = 20$  dla decyzji  $d_2$  i  $d_3$ . Zadanie zostało rozwiązane, mimo pominięcia ważnych informacji rozmytych. Jak bardzo są one ważne, pokaże rozwiązanie zadania, w którym te informacje zostaną uwzględnione. Do jego rozwiązania zostanie wykorzystana teoria zbiorów rozmytych.

#### 4. Rozwiązania z wykorzystaniem teorii zbiorów rozmytych

Najpierw trzeba przedstawić informacje  $I_k$  jako odpowiednie zbiory rozmyte, posługując się pojęciem zmiennej lingwistycznej (Kacprzyk, 1986):

$$I_1 = 0,5/20+1/40+0,5/60$$

$$I_2 = 0,5/40+1/60+0,5/80$$

$$I_3 = 0,25/20+1/40+0,25/60$$

$$I_4 = 0,5/60+1/80$$

$$I_5 = 1/60+0,5/80$$

$$I_6 = 0,71/40+1/60+0,71/80$$

Następnie trzeba połączyć wszystkie rozmyte informacje w jeden rozmyty stan natury  $S = \sum \frac{\mu_S(s_j)}{s_j}$ . Ponieważ wszystkie  $I_k$  są jednakowo ważne,

można zrobić to w ten sposób, że  $\forall s_j \mu_S(s_j)$  będzie średnią arytmetyczną z wartości funkcji przynależności  $I_k$ . Wtedy:

$$S = 0,125/20+0,535/40+0,708/60+0,452/80 \quad (28)$$

Korzystając z algorytmu przedstawionego w definicji 10 wyznacza się kolejno użyteczności rozmyte  $U_i$  wynikające z decyzji  $d_i$ :

$$U_1 = 0,935/10$$

$$U_2 = 0,125/-10+0,926/20$$

$$U_3 = 0,125/-30+0,535/0+0,84/30$$

$$U_4 = 0,125/-50+0,535/-20+0,708/10+0,452/40$$

zbiory rozmyte  $U_{im}$ :

$$U_{1m} = 0,25/10$$

$$U_{2m} = 0/-10+0,5/20$$

$$U_{3m} = 0/-30+0/0+0,75/30$$

$$U_{4m} = 0/-50+0/-20+0,25/10+1/40$$

i zbiory  $U_{i0}$ :

$$U_{10} = 0,25/10$$

$$U_{20} = 0/-10+0,5/20$$

$$U_{30} = 0/-30+0/0+0,75/30$$

$$U_{40} = 0/-50+0/-20+0,25/10+0,452/40$$

Ostatecznie decyzją rozmytą jest zbiór  $D^*$  taki, że  $\mu_{D^*}(d_i) = \max_{jk} \{\mu_{U_{i0}}(u_{ij})\}$ ,

czyli:

$$D^* = 0,25/d_1 + 0,5/d_2 + 0,75/d_3 + 0,452/d_4 \quad (29)$$

W takiej sytuacji, zgodnie z definicją 10, wybiera się decyzję  $d_i$  o najwyższym stopniu przynależności w zbiorze rozmytym  $D^*$  (w naszym przykładzie optymalna jest decyzja  $d_3$ ).

Przy pominięciu rozmytego charakteru informacji  $I_k$ , decyzje  $d_2$  i  $d_3$  są nieodróżnialne, natomiast wykorzystując je można zauważyć, że decyzja  $d_3$  jest o wiele lepsza od pozostałych.

W modelu, który został przeanalizowany chodziło o określenie decyzji optymalnej, która maksymalizuje zysk właściciela piekarni. Często jest to właściwa i wystarczająca metoda, jednak nie bierze ona pod uwagę indywidualnych preferencji decydenta. W szczególnym przypadku mogą się one różnić od przyjętych założeń.

Rozpatrzmy następującą sytuację: decydent musiał określić swój poziom zadowolenia za pomocą określeń „niski”, „bardzo niski”, „średni”, „wysoki”, „bardzo wysoki”. Tabela 1 wygląda teraz następująco:

Tabela 2

Dane obliczeniowe

$d_i \backslash s_j$	0	20	40	60	80	100
20	N	Ś	Ś	Ś	Ś	Ś
40	BN	N	W	W	W	W
60	BN	BN	N	W	W	W
80	BN	BN	N	Ś	BW	BW

BN – poziom bardzo niski,  
 N – niski,  
 Ś – średni,  
 W – wysoki,  
 BW – bardzo wysoki.

Przyporządkujmy tym określeniom zbiory rozmyte. Niech:

$$BN = 1/1+0,36/2$$

$$N = 1/1+0,6/2$$

$$Ś = 0,4/2+1/3+0,4/4$$

$$W = 0,6/4+1/5$$

$$BW = 0,36/4+1/5$$

Postępując zgodnie z definicją 12 wyznacza się kolejno użyteczności rozmyte  $U_i^1$ :

$$U_1^1 = 0,935/Ś$$

$$U_2^1 = 0,125/N+0,926/W$$

$$U_3^1 = 0,125/BN+0,537/N+0,84/W$$

$$U_4^1 = 0,125/BN+0,537/N+0,708/Ś+0,453/BN$$

oraz zbiory rozmyte  $U_i^2$ :

$$U_1^2 = 0,4/2+0,935+0,4/4$$

$$U_2^2 = 0,125/1+0,125/2+0,6/4+0,926/5$$

$$U_3^2 = 0,595/1+0,595/2+0,6/4+0,86/5$$

$$U_4^2 = 0,595/1+0,757/2+0,708/3+0,616/4+0,453/5$$

Postępując teraz identycznie jak w przykładzie z ostrymi wartościami funkcji użyteczności, tworzy się zbiory rozmyte  $U_{im}^2$  i porównuje się je z  $U_i^2$ . Otrzymane zbiory  $U_{i0}^2$  wyznaczają w konsekwencji rozmytą decyzję:

$$D^* = 0,6/d_1 + 0,926/d_2 + 0,86/d_3 + 0,616/d_4 \quad (30)$$

W tej sytuacji optymalna jest decyzja  $d_2$ .

Otrzymany wynik różni się od poprzedniego, kiedy chodziło o zmaksymalizowanie zysku. Wynika to z tego, że dla decydenta wypłaty w wysokości 20 i 30 są jednakowo użyteczne i przypisany jest im taki sam poziom zadowolenia – wysoki.

## Wnioski

Podany przykład, mimo że bardzo prosty, pokazuje, jak ostrożnie należy korzystać z teorii zbiorów rozmytych. Zaletą jest wykorzystanie całości informacji zawartych w wyrażeniach werbalnych, które wcześniej były bądź pomijane, bądź przybliżane probabilistycznie. Wadą są skomplikowane obliczenia oraz pokusa nadmiernego rozmycia zadania. W przykładzie chęć uwzględnienia preferencji decydenta spowodowała wybór gorszej, czyli dającej mniejszy zysk decyzji, trudno się jednak spodziewać, że byłby on rzeczywiście zadowolony właśnie z takiej decyzji.

## Literatura

- Czogała E., Pedrycz W.: *Elementy i metody teorii zbiorów rozmytych*. Wydawnictwo Politechniki Śląskiej, Gliwice 1980.
- Heilpern S.: *Podejmowanie decyzji w warunkach niepewności*. AE, Wrocław 1992.
- Heilpern S.: *Podejmowanie decyzji w warunkach ryzyka i niepewności*. AE, Wrocław 2001.
- Kacprzyk J.: *Zbiory rozmyte w analizie systemowej*. PWN, Warszawa 1986.
- Krawczyk S.: *Matematyczna analiza sytuacji decyzyjnych*. PWE, Warszawa 1990.
- Metody ilościowe w ekonomii*. Red. W. Ostasiewicz. AE, Wrocław 1986.

Nahotko S.: *Ryzyko ekonomiczne w działalności gospodarczej*. PWN, Warszawa 1997.

Ostasiewicz W.: *Zastosowanie zbiorów rozmytych w ekonomii*. PWN, Warszawa 1986.

### **THE USAGE OF THE FUZZY SETS IN THE ONE-STAGE PROCESS OF DECISION MADE BY ONE PERSON**

#### **Summary**

Mathematics has served man as a tool for describing the reality ever since. This description should be as precise as possible because the conclusions will be drawn and decisions will be made on this basis. On the other hand it should be simple, so that the cost of its analysis will not exceed the benefits. The classic model of the decision making does not foresee such situation when a man defines some cases not precisely. For instance he uses such expression as „very”, „less”, „almost” which we leave up or approach of losing some information encoded in them. The fuzzy sets, which Zadeh defined in the 60's, help us to describe the reality allowing fuzzy (not sharp) information.

In the following paper I present the appliance of the fuzzy sets in the typical situation according to Zadeh's definition. This approach allows to obtain „better” results, however, in the further stage too much fuzzy may generate „worse” results.