




**POLSKA AKADEMIA NAUK**  
**Instytut Badań Systemowych**

**WSPOMAGANIE INFORMATYCZNE  
ROZWOJU  
SPOŁECZNO-GOSPODARCZEGO  
I OCHRONY ŚRODOWISKA**

**Redakcja:**  
**Jan Studziński**  
**Ludostław Drelichowski**  
**Olgierd Hryniewicz**





**WSPOMAGANIE INFORMATYCZNE  
ROZWOJU  
SPOŁECZNO-GOSPODARCZEGO  
I OCHRONY ŚRODOWISKA**

Polska Akademia Nauk Instytut Badań Systemowych

**Seria: BADANIA SYSTEMOWE**

**tom 36**

---

**Redaktor naukowy:**

**Prof. dr hab. Jakub Gutenbaum**

Warszawa 2004

**WSPOMAGANIE INFORMATYCZNE  
ROZWOJU  
SPOŁECZNO-GOSPODARCZEGO  
I OCHRONY ŚRODOWISKA**

Redakcja:

Jan Studziński  
Ludosław Drelichowski  
Olgierd Hryniewicz

**Książka wydana dzięki dotacji KOMITETU BADAŃ NAUKOWYCH**

Książka zawiera wybór artykułów poświęconych omówieniu aktualnego stanu badań w kraju w zakresie rozwoju modeli, technik i systemów zarządzania oraz ich zastosowań w różnych dziedzinach gospodarki narodowej. Wyodrębnioną grupę stanowią artykuły omawiające aplikacyjne wyniki projektów badawczych i celowych KBN.

Recenzenci artykułów:

Dr Lucyna Bogdan  
Prof. dr hab. inż. Olgierd Hryniewicz  
Dr Grażyna Petriczek  
Prof. dr hab. inż. Andrzej Straszak  
Dr inż. Jan Studziński



Senia 45187

Komputerowa edycja tekstu: Anna Gostyńska

© Instytut Badań Systemowych PAN, Warszawa 2004

**Wydawca: Instytut Badań Systemowych PAN**  
**ul. Newelska 6, 01-447 Warszawa**

Sekcja Informacji Naukowej i Wydawnictw IBS PAN  
tel. 836-68-22

Druk: Zakład Poligraficzny Urzędu Statystycznego w Bydgoszczy  
Nakład 110 egz.

**ISBN 83-85847-92-8**  
**ISSN 0208-8028**

# ZWIĘKSZENIE PRAWDOPODOBIENSTWA BŁĘDNEJ KLASYFIKACJI W ROZPOZNAWANIU WIELOETAPOWYM Z ROZMYTYMI OBSERWACJAMI CECH OBIEKTU

**Robert Burduk**

*Katedra Systemów i Sieci Komputerowych  
Wydział Elektroniki, Politechnika Wrocławska  
<robert.burduk@pwr.wroc.pl>*

*This paper deals with the decision rules of a multistage classifier based on a decision-tree scheme, under the assumption of complete probabilistic information. Additionally the information on object's features is assumed imprecise – its formal description uses fuzzy numbers. For this case of recognition the probability of misclassification is presented and compared with case when object's features are non-fuzzy. The obtained result is presented as a calculation example.*

**Keywords:** Probability of misclassification, multistage pattern recognition, fuzzy observations.

## 1. Wprowadzenie

Zadanie rozpoznawania polega na zaliczeniu obiektu do jednej z wcześniej określonych klas. Każdy z rozpoznawanych obiektów ma przypisane pewne mierzalne atrybuty zwane cechami. Cała procedura rozpoznawania obejmuje pomiar wartości cech, selekcję oraz klasyfikację. Celem selekcji jest wybór cech najbardziej istotnych z punktu widzenia przydatności w rozpoznawaniu. Dopiero taki zestaw cech, specjalnie dobranych w zależności od rozwiązywanego problemu, zostaje poddany klasyfikacji, która przypisuje obiekt do jednej z klas. Przykładowo w systemie zarządzania wiedzą dotyczącego budowy profili klientów, rozpoznawanym obiektem będzie klient, zaś klasami nazwy grup klientów (np. lojalni, mogący odejść, przejści od konkurencji itp.). Cechy w tym przypadku, to atrybuty opisujące klientów (np. ilość zakupionych towarów, czas trwania umowy, częstość transakcji kupna itp.).

W wielu przypadkach zadaniach rozpoznawania, tradycyjna pod względem przyjętego modelu i sposobu postępowania, jednoetapowa metoda klasyfikacji okazuje się mało efektywna lub niewystarczająca. Wynika to z dwóch powodów. Z jednej strony bowiem mamy często do czynienia ze złożonymi problemami, w których zarówno liczba klas, jak i liczba cech opisujących obiekty są duże. Z drugiej strony sama natura rozpatrywanej sytuacji wymaga specjalnego traktowania. W takich przypadkach jest uzasadnione stosowanie złożonych metod

rozpoznawania, w których bądź model zadania rozpoznawania jest bardziej skomplikowany i pełniej opisuje konkretną rzeczywistość, bądź złożony jest sam schemat decyzyjny klasyfikatora. Przykładem takiego podejścia jest rozpoznawanie wieloetapowe, w którym decyzja o przynależności obiektu do określonej klasy nie jest czynnością jednorazową, ale jest wynikiem bardziej złożonego procesu decyzyjnego.

W procesach rozpoznawania istotną rolę odgrywają takie czynniki, jak przypadkowość, niedokładność i niejednoznaczność, z którymi mamy do czynienia już na etapie tworzenia modelu matematycznego zadania klasyfikacji. Z przypadkowością (losowością) określonych zdarzeń utożsamiana jest niepewność, modelowana z wykorzystaniem aparatu teorii prawdopodobieństwa i statystyki matematycznej. Niepewność typu rozmytego, pozwalająca na rozważenie problemów niejednoznacznie (nieprecyzyjnie) sformułowanych, modelowana jest za pomocą teorii zbiorów rozmytych. W dalszej części pracy będziemy mówić o zadaniu rozpoznawania wieloetapowego, w którym wystąpi niepewność typu probabilistycznego jak i rozmytego. Celem pracy jest natomiast przedstawienie różnicy prawdopodobieństw błędnej klasyfikacji, jeśli dysponujemy precyzyjną lub nieprecyzyjną informacją opisującą cechy obiektu.

## 2. Rozpoznawanie wieloetapowe – opis matematyczny oraz przyjęte założenia

Rozważmy zadanie rozpoznawania obiektów, w którym liczba klas jest równa  $M$ . Załóżmy, iż klasy zostały zorganizowane w drzewo decyzyjne, którego struktura spełnia dwa następujące ograniczenia:

Długość ścieżki od korzenia do każdego węzła terminalnego jest taka sama i wynosi  $N$ .

Każda klasa jest związana z jednym i tylko jednym węzłem terminalnym.

Ponumerujmy dalej wszystkie węzły utworzonego drzewa decyzyjnego kolejnymi liczbami  $0, 1, 2, \dots$ , rezerwując  $0$  dla korzenia, a numery klas ze zbioru  $M = \{1, 2, \dots, M\}$  przyporządkujmy węzłom terminalnym tak, aby każdy z nich był oznaczony numerem tej klasy, która jest z tym węzłem związana. Pozwala to wprowadzić następujące oznaczenia (Kurzyński, 1997):

$M(n)$  – zbiór numerów węzłów, których odległość od korzenia wynosi  $n$ ,  
 $n=0, 1, 2, \dots, N$ . W szczególności  $M(0) = \{0\}$ ,  $M(N) = M$ ,

$\bar{M} = \bigcup_{n=0}^{N-1} M(n)$  – zbiór numerów węzłów wewnętrznych (nieterminalnych),

$M_i \subseteq M(N)$  – zbiór numerów węzłów terminalnych (numerów klas) osiągalnych z węzła  $i$  ( $i \in \bar{M}$ ),



$M^i$  – zbiór numerów bezpośrednich następników węzła  $i$  ( $i \in \overline{M}$ ),

$m_i$  – numer bezpośredniego poprzednika węzła  $i$  ( $i \neq 0$ ),

$s(i, j)$  – zbiór numerów węzłów na ścieżce od węzła  $i$  do węzła  $j$ ,

$s(j) = s(0, j)$  – zbiór numerów węzłów na ścieżce od korzenia do węzła  $j$ .

Przyjmijmy probabilistyczny model zadania rozpoznawania, to znaczy będziemy zakładać, że numer klasy rozpoznawanego obiektu  $j_N \in M(N)$  i jego zmierzone cechy  $x$  są realizacją pary zmiennych losowych  $J_N$  oraz  $X$ . Pełna informacja probabilistyczna oznacza teraz znajomość prawdopodobieństw *a priori* klas

$$p(j_N) = P(J_N = j_N), \quad j_N \in M(N) \quad (1)$$

oraz warunkowych gęstości prawdopodobieństwa cech w klasach

$$f_{j_N}(x) = f(x / j_N), \quad x \in X, \quad j_N \in M(N) \quad (2)$$

Z każdym węzłem wewnętrznym drzewa decyzyjnego są związane cechy, których zmierzone wartości są podstawą do podjęcia decyzji w tym węźle. Niech dalej

$$x_i \in X_i \subseteq R^{d_i}, \quad d_i \leq d, \quad i \in M \quad (3)$$

oznacza wektor wartości cech wykorzystywanych w węźle  $i$ , które zostały wyselekcjonowane z wektora  $x$ .

Z przyjętej struktury drzewa decyzyjnego wynikają następujące równości dla prawdopodobieństw *a priori*

$$p(j_n) = P(J_n = j_n) = \sum_{j_N \in M_{j_n}} p(j_N) \quad (4)$$

oraz dla warunkowych gęstości prawdopodobieństwa cech

$$f_{j_n}(x_i) = f(x_i / j_n) = \frac{1}{p(j_n)} \sum_{j_N \in M_{j_n}} p(j_N) f_{j_N}(x_i) \quad (5)$$

dla każdego  $i \in \overline{M}$  oraz  $j_n \in M(n)$ ,  $n = 1, 2, \dots, N-1$ .

Algorytm rozpoznawania w węźle  $i$ -tym, który odwzorowuje przestrzeń cech związanych z tym węzłem w zbiór jego bezpośrednich następników, oznaczmy przez

$$\Psi_i : X_i \rightarrow M^i, \quad i \in \overline{M} \quad (6)$$

Decyzja  $i_n$ , podjęta na  $n$ -tym etapie rozpoznawania ( $n=1,2,\dots,N$ ) jako funkcja zmierzonych wartości cech, jest realizacją dyskretnej zmiennej losowej  $\mathbf{I}_n$  przyjmującej wartości z zbiorze  $M(n)$ . Z mechanizmu klasyfikacji wieloetapowej wynika dalej, że ciąg zmiennych losowych  $\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_{N-1}, \mathbf{I}_N$  tworzy, dla każdej wartości zmiennej losowej  $\mathbf{J}_N$ , łańcuch Markowa I rzędu o następujących prawdopodobieństwach przejścia

$$q(i_n / i_{n-1}, j_N) = P(\mathbf{I}_n = i_n / \mathbf{I}_{n-1} = i_{n-1}, \mathbf{J}_N = j_N) = \begin{cases} \int_{D_{i_{n-1}}^{(i_n)}} f_{j_N}(x_{i_{n-1}}) dx_{i_{n-1}}, & \text{gdy } i_{n-1} = m_{i_n} \\ 0, & \text{gdy } i_{n-1} \neq m_{i_n} \end{cases} \quad (7)$$

i prawdopodobieństwach początkowych  
 $i_n \in M(n), i_{n-1} \in M(n-1), n = 2, 3, \dots, N$

$$q(i_1 / j_N) = P(\mathbf{I}_1 = i_1 / \mathbf{J}_N = j_N) = \int_{D_{x_0}^{(i_1)}} f_{j_N}(x_0) dx_0, \quad i_1 \in M(1) \quad (8)$$

Otrzymujemy stąd następujące zależności dla dowolnych  $i_{n_1} \in M(n_1), i_{n_2} \in M(n_2), n_1 = 0, 1, \dots, N-1, n_1 < n_2$

$$q(i_{n_2} / i_{n_1}, j_N) = \prod_{i_k \in (i_{n_1}, i_{n_2}) - \{i_{n_1}\}} q(i_k / m_{i_k}, j_N) \quad (9)$$

W dalszych rozważaniach wykorzystywać będziemy zerojedynkową funkcję strat

$$L(i_N, j_N) = \begin{cases} 0, & \text{gdy } i_N = j_N \\ 1, & \text{gdy } i_N \neq j_N \end{cases} \quad (10)$$

przypisującą każdej błędnej decyzji wartość 1.

Za kryterium optymalności przyjmijmy wartość oczekiwaną funkcji strat

$$R[\Psi] = E_{\mathbf{I}_N, \mathbf{J}_N} [L(\mathbf{I}_N, \mathbf{J}_N)] = E_{\mathbf{X}, \mathbf{J}_N} [L(\Psi(\mathbf{X}), \mathbf{J}_N)] \quad (11)$$

którą będziemy nazywać ryzykiem średnim.

Dla przedstawionego powyżej problemu rozpoznawania wieloetapowego możemy wyznaczyć algorytmy rozpoznawania (Kurzyński, 1987), które prowadzą do separowalnej strategii, w przypadku warunkowo niezależnych cech. Oznacza to, że zmienne losowe  $X_{i_{n-1}}$  oraz  $J_N$  są warunkowo niezależne względem zmiennej

$J_n$

$$f_{j_N}(x_{i_{n-1}}) = f(x_{i_{n-1}} / j_N, j_n) = f_{j_n}(x_{i_{n-1}}) \quad (12)$$

Założmy teraz, że składowymi wektora wartości cech  $x$  opisującego rozpoznawany obiekt są liczby rozmyte. Stanowią one formalny opis wartości cech  $x$  traktowanych jako zmienne lingwistyczne. Z przyjętego modelu rozpoznawania wieloetapowego wynika, że z każdym węzłem wewnętrznym  $i$  ( $i \in \bar{M}$ ) utworzonego drzewa decyzyjnego związane są cechy, których zmierzone wartości są podstawą do podjęcia decyzji w tym węźle. Określmy wektor liczb rozmytych

$$\tilde{A}_i = \left[ \tilde{A}^{(1)}, \tilde{A}^{(2)}, \dots, \tilde{A}^{(k_i)} \right] \quad (13)$$

o funkcjach przynależności  $\mu_{\tilde{A}^{(l)}}(x_i^{(l)})$ , gdzie  $k_i$  jest liczbą cech wykorzystywanych w węźle  $i$ . Każda składowa wektora  $\tilde{A}_i$  ma przypisaną odpowiednią etykietę lingwistyczną. Etykiety te wyrażają takie sformułowania słowne jak: mały, średni, duży, bardzo duży lub też bezpośrednio odzwierciedlają przypisaną im liczbę rozmytą, czego przykładami są takie określenia jak: około 1, około 2 itd.

Przyjmijmy trapezową postać liczb rozmytych, tzn. postać opisaną czterema parametrami  $\tilde{A} = (a_1, a_2, a_3, a_4)_{Tr}$ .

Założmy dodatkowo, że dla każdej składowej  $k$  wektora cech  $x$  zbiory liczb rozmytych  $\tilde{A}^{(k)} = \left\{ \tilde{A}_1^{(k)}, \tilde{A}_2^{(k)}, \dots, \tilde{A}_{k_L}^{(k)} \right\}$  opisujące tą składową spełniają warunek ortogonalności (Pedrycz, 1990)

$$\sum_{l=1}^{k_L} \mu_{\tilde{A}_l^{(k)}}(x^{(k)}) = 1 \quad (14)$$

gdzie  $k_L$  oznacza ilość liczb rozmytych opisujących  $k$ -tą składową wektora  $x$ . Warunek ten narzuca taką postać liczb rozmytych, aby wartości ich funkcji przynależności sumowały się do jedności w każdym punkcie  $x^{(k)} \in X$ .

Prawdopodobieństwo zdarzenia rozmytego przyjmiemy w ujęciu Zadeha (Zadeh, 1968), co oznacza, że jest ono liczbą rzeczywistą wyrażoną następująco

$$p(\tilde{A}) = \int_{R^n} \mu_{\tilde{A}}(x) dP \quad (15)$$

### 3. Oszacowanie różnicy prawdopodobieństwa błędnej klasyfikacji w przypadku rozmytych i nie rozmytych cech obiektu

W przypadku pełnej informacji probabilistycznej, tj. wówczas, gdy znamy odpowiednie prawdopodobieństwa *a priori* klas (1) oraz warunkowe gęstości prawdopodobieństwa cech w klasach (2), prawdopodobieństwo błędnej klasyfikacji  $Pe(\pi_N^*)$  dla informacji nierozmytej oraz przyjętych przez nas założeń (10) oraz (12) wynosi (Kurzyński, 1987)

$$Pe(\pi_N^*) = 1 - \sum_{j_N \in M(N)} p(j_N) \prod_{i_k \in s(j_N) - \{0\}} q(i_k / m_{i_k}, i_k) \quad (16)$$

Wykorzystując analogiczne założenia możemy określić prawdopodobieństwo błędnej klasyfikacji  $Pe_R(\pi_N^*)$ , dla rozpoznawania wieloetapowego w przypadku znajomości informacji rozmytej zawartej w  $\tilde{A}_i$ ,  $i \in \bar{M}$ , w następujący sposób (Burduk, 2003)

$$Pe_R(\pi_N^*) = 1 - \sum_{j_N \in M(N)} p(j_N) \prod_{i_k \in s(j_N) - \{0\}} q_R(i_k / m_{i_k}, i_k) \quad (17)$$

gdzie

$$q_R(i_k / m_{i_k}, i_k) = \sum_{\tilde{A}_{m_{i_k}} \in D_{i_k}^{(i_k)}} \int_{\text{supp } \tilde{A}_{m_{i_k}}} \mu_{\tilde{A}_{m_{i_k}}}(x_{m_{i_k}}) f_{i_k}(x_{m_{i_k}}) dx_{m_{i_k}} \quad (18)$$

Rozmyta informacja o cechach związanych z danym węzłem  $i_n$  wiąże się ogólnie z utratą optymalności, tzn. powiększeniem średniego prawdopodobieństwa błędnej klasyfikacji. Oszacowanie różnicy, o ile dysponowanie informacją rozmytą zamiast dokładną o poszczególnych cechach obiektu pogarsza jakość rozpoznawania mierzoną średnim prawdopodobieństwem błędu dla przyjętych założeń wynosi (Burduk, 2003)

$$Pe_R(\pi_N^*) - Pe(\pi_N^*) \leq \sum_{j_N \in M(N)} p(j_N) \sum_{i_k \in s(j_N) - \{0\}} \varepsilon_{m_{i_k}} \quad (19)$$

gdzie, dla  $i \in \bar{M}$

$$\varepsilon_i = \sum_{\tilde{A}_i \in X_i} \left| \int_{\text{supp } \tilde{A}_i} \mu_{\tilde{A}_i}(x_i) \max_{k \in M^i} \{f_k(x_i)\} dx_i - \max_{k \in M^i} \left\{ \int_{\text{supp } \tilde{A}_i} \mu_{\tilde{A}_i}(x_i) f_k(x_i) dx_i \right\} \right| \quad (20)$$

Przedstawmy teraz otrzymany wynik na przykładzie rachunkowym.

## 5. Przykład rachunkowy

Przyjmijmy, dwuetapowy, binarny klasyfikator, którego drzewo decyzyjne przedstawione jest na rys.1. Obiekt opisany jest trójwymiarowym wektorem cech  $\mathbf{x} = [\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \mathbf{x}^{(3)}]$ , które są wykorzystywane do klasyfikacji w poszczególnych węzłach wewnętrznych według zasady:  $x_0 = x^{(1)}$ ,  $x_5 = x^{(2)}$ ,  $x_6 = x^{(3)}$ . Dla każdej składowej wektora cech  $\mathbf{x}$  określony jest zbiór liczb rozmytych  $\tilde{A}^{(k)}$ ,  $k = 1, 2, 3$ , który spełnia warunek (14). Przyjęto następujące przypadki opisu cech:

### Przypadek A


$$\begin{aligned} \tilde{A} = \{ & \tilde{A}_1 = (\infty, -9, -8), \tilde{A}_2 = (-9, -8, -8, -7)_{Tr}, \dots, \\ & \tilde{A}_{25} = (14, 15, 15, 16)_{Tr}, \tilde{A}_{26} = (15, 16, \infty) \}. \end{aligned}$$

### Przypadek B

$$\begin{aligned} \tilde{B} = \{ & \tilde{B}_1 = (\infty, -9, -8,5), \tilde{B}_2 = (-9, -8,5, 8,5, -8)_{Tr}, \dots, \\ & \tilde{B}_{50} = (15, 15,5, 15,5, 16)_{Tr}, \tilde{B}_{51} = (15,5, 16, \infty) \}. \end{aligned}$$

### Przypadek C

$$\begin{aligned} \tilde{C} = \{ & \tilde{C}_1 = (\infty, -9,25 - 8,75), \tilde{C}_2 = (-9,25 - 8,75, -8,25, -7,75)_{Tr}, \dots, \\ & \tilde{C}_{26} = (14,75, 15,25, 15,75, 16,25)_{Tr}, \tilde{C}_{27} = (15,75, 16,25, \infty) \}. \end{aligned}$$



Rysunek 1. Drzewo decyzyjne klasyfikatora

Prawdopodobieństwa *a priori* klas wynoszą

$$p(j_2) = 0,25, \quad j_2 \in M(2)$$

natomiast warunkowe gęstości prawdopodobieństw cech w klasach są równe:

**Przypadek I**

$$\mu_1 = [0, 0, 0] \quad \mu_2 = [0, 4, 0]$$

$$\mu_3 = [3, 0, 1] \quad \mu_4 = [3, 0, 8]$$

$$\sum_{j_2} = 4I, \quad j_2 \in M(2), \quad I - \text{macierz jednostkowa,}$$

**Przypadek II**

$$\mu_1 = [0, 0, 0] \quad \mu_2 = [0, 2, 0]$$

$$\mu_3 = [3, 0, 1] \quad \mu_4 = [3, 0, 8]$$

$$\sum_{j_2} = 4I, \quad j_2 \in M(2), \quad I - \text{macierz jednostkowa.}$$

Na podstawie przyjętych danych określono konkretne przypadki dotyczące przyjętych założeń, które podane są w poniższej tabelicy:

**Tablica 1.** Przyjęte założenia do przykładu rachunkowego

Przypadek	Rozkład cech w klasach - przypadek	Opis wektora cech obiektu - przypadek		
		$\mathbf{x}^{(1)}$	$\mathbf{x}^{(2)}$	$\mathbf{x}^{(3)}$
1	I	A	A	A
2	I	B	B	B
3	I	C	C	C
4	I	nierozmyty	A	A
5	I	nierozmyty	B	B
6	I	nierozmyty	C	C
7	II	A	A	A
8	II	B	B	B
9	II	C	C	C
10	II	nierozmyty	A	A
11	II	nierozmyty	B	B
12	II	nierozmyty	C	C

Na podstawie przyjętych założeń oraz wzoru (19) możemy teraz określić różnice średnich prawdopodobieństw błędnych klasyfikacji w zadaniu wieloetapowym dla przypadku dysponowania precyzyjnym i rozmytym opisem cech obiektu. Wyniki obliczeń zawarte są w tab. 2.

**Tablica 2.** Górne oszacowanie  $Pe_R(\pi_N^*) - Pe(\pi_N^*)$

Przypadek	1	2	3	4	5	6	7	8	9	10	11	12
oszac. róż. [%]	1,6	0,9	2,0	1,1	0,4	0,6	1,3	0,8	2,0	0,8	0,3	0,5

Otrzymane wyniki dotyczą przypadku pełnej informacji probabilistycznej, czyli sytuacji, gdy znamy wszystkie niezbędne charakterystyki zmiennych losowych.

## 6. Podsumowanie

Przedstawiony w pracy problem dotyczy złożonej metody rozpoznawania, a dokładniej rozpoznawania wieloetapowego. W przyjętym modelu zadania podejmowania decyzji dysponujemy dokładnym, bądź też nieprecyzyjnym opisem dotyczącym cech obiektu. Opis nieprecyzyjny formalizowany jest za pomocą liczb rozmytych określonych na danej przestrzeni cech. Przedstawione w pracy oszacowanie pokazuje o ile może pogorszyć się jakość rozpoznawania w przypadku dysponowania nieprecyzyjną informacją o cechach obiektu w porównaniu z przypadkiem, gdy dokładnie znamy wartości cech obiektu. Należy pamiętać jednak, że nie zawsze w realnych przypadkach wiedza o wartościach cech obiektu jest precyzyjna, co może wynikać z samej reprezentacji wiedzy podawanej w sformułowaniach języka naturalnego, dla którego formalnym opisem mogą być liczby rozmyte.

## Literatura

- Burduk R. (2003) *Komputerowe algorytmy rozpoznawania wieloetapowego z modelem probabilistyczno-rozmytym i ich zastosowanie w medycynie*. Raport 1/03, Katedra Systemów i Sieci Komputerowych, Wrocław.
- Kurzyński M. (1987) Algorytmy rozpoznawania wieloetapowego oraz ich zastosowania medyczne i techniczne. *Prace Naukowe Inst. Sterowania i Techniki Systemów Politech. Wr., 5, Seria Monografie, 3*, Wrocław.
- Kurzyński M. (1997) *Rozpoznawanie obiektów – metody statystyczne*. Ofic. Wyd. Politech. Wr., Wrocław.
- Pedrycz W. (1990) Fuzzy sets in pattern recognition: methodology and methods. *Pattern Recognition, 23*, 121-146.
- Zadeh L.A. (1968) Probability measures of fuzzy events. *Journal of Mathematical Analysis and Applications, 23*, 421-427.

IBS PAN *Seria*

45187

Bibl. podręczna

**ISSN 0208-8028**

**ISBN 83-85847-92-8**

---

---

**W celu uzyskania bliższych informacji i zakupu dodatkowych egzemplarzy  
prosimy o kontakt z Instytutem Badań Systemowych PAN  
ul. Newelska 6, 01-447 Warszawa  
tel. 837-35-78 w. 241 e-mail: [biblioteka@ibspan.waw.pl](mailto:biblioteka@ibspan.waw.pl)**