

# Zbiory przybliżone, cz. 1

(wersja do druku)

dr. Piotr Szczuko

Katedra Systemów Multimedialnych

2009

# Plan wykładu

- Historia zbiorów przybliżonych
- System informacyjny i decyzyjny
- Reguły decyzyjne
- Tożsamość obiektów
  - Relacja równoważności
  - Klasa abstrakcji
  - Przykład
- Aproksymacja zbioru – przybliżenie zbioru
  - Dolna i górna aproksymacja zbioru
  - Przykład
- Obszar brzegowy i zewnętrzny, dokładność przybliżenia
- Własności zbiorów przybliżonych
- Kategorie zbiorów przybliżonych
  - Przykłady

# Zbiory przybliżone

Teoria zbiorów przybliżonych (Rough Set) –  
**Zdzisław Pawlak:**

- Z. Pawlak, (1982), *Rough sets*. International Journal of Computer and Information Sciences 11, pp. 341–356.
- W. Marek, Z. Pawlak (1984), *Rough sets and information systems*. Fundamenta Informaticae 17, pp. 105–115.
- Z. Pawlak (1991), *Rough Sets – Theoretical Aspects of Reasoning about Data*. Kluwer Academic Publishers, Dordrecht.

# Zbiory przybliżone

- Teoria zbiorów przybliżonych zajmuje się klasyfikacją danych zorganizowanych w postaci tabel. Dane uzyskane mogą być z pomiarów, testów lub od ekspertów.
- Głównym celem analizy danych jest wyznaczenie aproksymacji idei (koncepcji) na podstawie danych w celu:
  - Dokładnej analizy problemu, związków, zależności
  - Uzyskania narzędzia klasyfikującego nowe przypadki

# System informacyjny

System informacyjny  $\mathcal{A}$ :

- Wiersze to obiekty
- Kolumny to atrybuty

Inaczej:

$$\mathcal{A} = (U, A)$$

gdzie:

$U$  – zbiór obiektów (uniwersum)

$A$  – zbiór odwzorowań  $a: U \rightarrow V_a$

	<i>Age</i>	<i>LEMS</i>
$x_1$	16-30	50
$x_2$	16-30	0
$x_3$	31-45	1-25
$x_4$	31-45	1-25
$x_5$	46-60	26-49
$x_6$	16-30	26-49
$x_7$	46-60	26-49

(obiektowi przypisana jest wartość  
 $V_a$  atrybutu  $a$ )

$x_3$  i  $x_4$  nierozróżnialne

$x_5$  i  $x_7$  nierozróżnialne

# System decyzyjny

System decyzyjny =  
System informacyjny  
+ decyzja:

$$\mathcal{A} = (U, A \cup \{d\})$$

gdzie:

$d$  – atrybut decyzyjny

$$d \notin A$$

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

$x_3$  i  $x_4$  różne decyzje

$x_5$  i  $x_7$  takie same decyzje

# Reguły decyzyjne

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

Zdania logiczne o postaci:

IF *Age*="16-30" AND *LEMS*="0" THEN *Walk*="No"

# Tożsamość obiektów

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

Obiekty  $x_3$  i  $x_4$  (także  $x_5$  i  $x_7$ ) są nierozróżnialne (tożsame) względem pewnego zbioru atrybutów:

$$B \subseteq A$$



# Tożsamość obiektów(1)

Przyjmijmy system informacyjny:  $\mathcal{A} = (U, A)$

Z każdym zbiorem atrybutów:  $B \subseteq A$  związana jest relacja:

$$IND_{\mathcal{A}}(B) = \{(x, x') \in U^2 \mid \forall a \in B \ a(x) = a(x')\}$$

Jest to relacja równoważności

(ang. *Indiscernibility*)

Relacja  $R$  jest relacją równoważności:

$(xRx)$  lub  $(x, x) \in R$  – zwrotna,

jeżeli  $(xRy)$  to  $(yRx)$  – symetryczna,

jeżeli  $(yRx)$  i  $(yRz)$  to  $(xRz)$  – przechodnia.

# Tożsamość obiektów(2)

$$IND(B) = \{(x, x') \in U^2 \mid \forall a \in B \ a(x)=a(x')\}$$

Jeżeli:

$$(x, x') \in IND(B)$$

to  $x$  i  $x'$  są tożsame względem relacji  $IND(B)$ ,  
nierozróżnialne względem atrybutów  $B$ .

# Tożsamość obiektów(3)

$(x,x) \in IND(B)$  – zwrotna,

jeżeli  $(x,y) \in IND(B)$  to  $(y,x) \in IND(B)$  – symetryczna,

jeżeli  $(x,y) \in IND(B)$  i  $(y,z) \in IND(B)$  to  $(x,z) \in IND(B)$  –  
przechodnia.



$x$



$y$



$z$

*Jaki jest zbiór atrybutów  $B$  w tym przypadku?*

# Tożsamość obiektów(4)

$[x]_B$  – klasa abstrakcji (równoważności)  
obiektu  $x$  względem relacji  $IND(B)$

---



$x$



$y$

*Klasa równoważności  $[x]_B$  –  
wszystkie obiekty czerwone*

$$[x]_B \equiv [y]_B$$

---



$z$

*Klasa równoważności  $[z]_B$  –  
wszystkie obiekty zielone*



# Przykład

Niepuste podzbiory  $A$ :

$$B_1 = \{Age\}$$

$$B_2 = \{LEMS\}$$

$$B_3 = \{Age, LEMS\}$$

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

Sposoby podziału uniwersum  $U$ :

$$IND(\{Age\}) = \{\{x_1; x_2; x_6\}; \{x_3; x_4\}; \{x_5; x_7\}\}$$

$$IND(\{LEMS\}) = \{\{x_1\}; \{x_2\}; \{x_3; x_4\}; \{x_5; x_6; x_7\}\}$$


$$IND(\{Age, LEMS\}) = \{\{x_1\}; \{x_2\}; \{x_3; x_4\}; \{x_5; x_7\}; \{x_6\}\}$$

# Aproksymacja zbioru (1)

- Relacja równoważności prowadzi do podziału uniwersum na tzw. **zbiory elementarne**. Każda kombinacja zbiorów elementarnych – **zbiór definiowalny**. Rodzina zbiorów definiowalnych oznaczana jest  $Def(B)$ .
- Wyznaczone podziały posłużyć mogą do utworzenia podzbiorów uniwersum
- Zwykle poszukiwane są podzbiory definiowalne charakteryzujące się taką samą wartością atrybutu decyzyjnego.

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

Tożsame obiekty – różne atrybuty decyzyjne!



# Aproksymacja zbioru (2)

- Pomimo niejednoznaczności możliwe jest określenie, które obiekty na pewno **należą** do poszukiwanego podzbioru, które na pewno do niego **nie należą**, a które leżą na granicy między podzbiorami.

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

- Jeżeli jakiegokolwiek obiekty leżą na granicy, mamy do czynienia ze **zbiorem przybliżonym**

# Notacja

Przyjmijmy:

System informacyjny:  $\mathcal{A} = (U, A)$

Podzbiór atrybutów:  $B \subseteq A$

oraz podzbiór uniwersum:  $X \subseteq U$

Możliwa jest aproksymacja zbioru  $X$  wyłącznie przez wykorzystanie atrybutów ze zbioru  $B$ , poprzez określenie *B-dolnej* i *B-górnej* aproksymacji zbioru  $X$ :

$$\underline{B}X = \{ x \mid [x]_B \subseteq X \}$$

$$\overline{B}X = \{ x \mid [x]_B \cap X \neq \emptyset \}$$



# Przykład (1)

$$\underline{BX} = \{ x \mid [x]_B \subseteq X \}$$

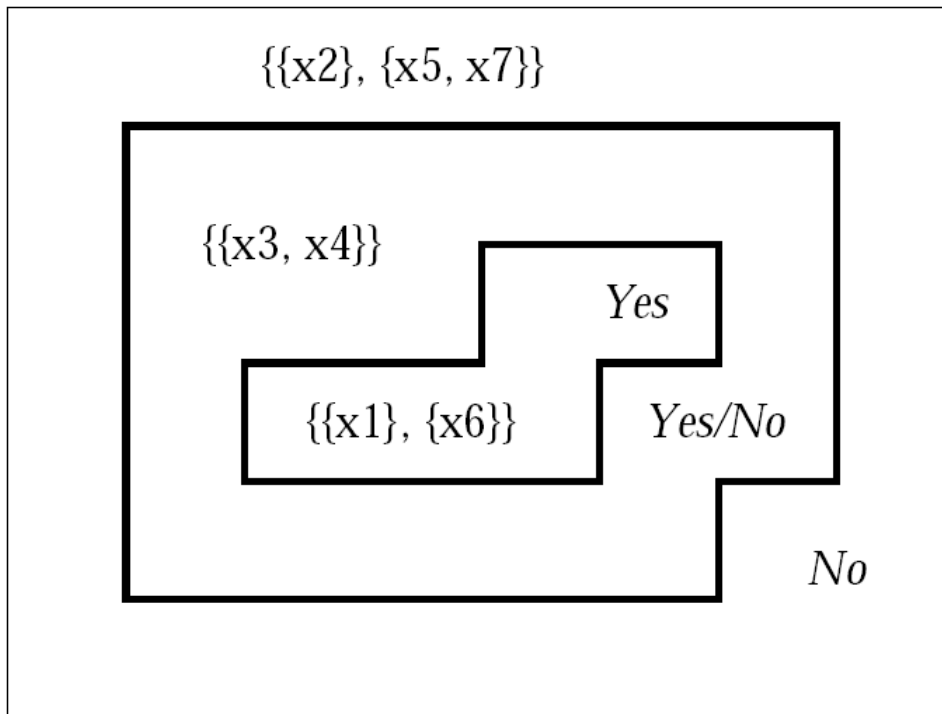
Te  $x$ , których klasy abstrakcji są zawarte w  $X$ . Obiekty  $x_1$  i  $x_6$ . Obiekty na pewno należące do  $X$  w oparciu o wiedzę zawartą w  $B$ .

$$\overline{BX} = \{ x \mid [x]_B \cap X \neq \emptyset \}$$

Te  $x$ , których klasy abstrakcji mają niepustą część wspólną z  $X$ . Obiekty  $x_1, x_3, x_4, i x_6$ .  
Obiekty prawdopodobnie należące do  $X$  w oparciu o wiedzę zawartą w  $B$ .

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

# Przykład (2)



	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

# Obszar brzegowy i zewnętrzny zbioru

$$BN_B(X) = \overline{BX} - \underline{BX}$$

„Boundry” - BN

Te  $x$ , co do których nie można jednoznacznie zdecydować czy należą czy też nie do zbioru  $X$ . Obiekty  $x_3, x_4$ .

$$EXT_B(X) = U - \overline{BX}$$

Te  $x$ , które z całą pewnością nie należą do zbioru  $X$ .

Obiekty  $x_2, x_5, x_7$ .

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

# Dokładność przybliżenia

$$\alpha_B(X) = \frac{|BX|}{|\bar{B}X|} \quad / \cdot / - \text{ moc zbioru}$$

$$0 \leq \alpha_B(X) \leq 1$$

Zbiór tradycyjny  $\alpha_B(X) = 1$

Zbiór przybliżony  $\alpha_B(X) < 1$

$$\alpha_B(X) = \frac{|BX|}{|BX| + |BN_B(X)|}$$

# Własności

$$1) \underline{BX} \subseteq X \subseteq \overline{BX}$$

$$2) \underline{BU} = U = \overline{BU}$$

$$3) \underline{B\emptyset} = \emptyset = \overline{B\emptyset}$$

$$4) \underline{BBX} = \overline{BBX} = \underline{BX}$$

$$5) \overline{BBX} = \underline{BBX} = \overline{BX}$$

$$6) \overline{B(-X)} = -\underline{BX}$$

$$7) \underline{B(-X)} = -\overline{BX}$$

$$8) \overline{B(X \cup Y)} = \overline{BX} \cup \overline{BY}$$

$$9) \overline{B(X \cap Y)} = \underline{BX} \cap \underline{BY}$$

$$10) \underline{B(X \cup Y)} \supseteq \underline{BX} \cup \underline{BY}$$

$$11) \underline{B(X \cap Y)} \subseteq \underline{BX} \cap \underline{BY}$$

$$12) BN(X \cup Y) \subseteq BNX \cup BNY$$

$$13) BNX = BN(-X)$$

$$14) \underline{B(BNX)} = \emptyset$$

$$15) \overline{B(BNX)} = BNX$$

$$16) BNX = \emptyset \Leftrightarrow \underline{BX} = X$$

$-X$  oznacza  $U-X$

# Kategorie zbiorów przybliżonych


- $X$  jest w przybliżeniu  $B$ -definiowalny, gdy:  
 $\underline{B}(X) \neq \emptyset$  i  $\overline{B}(X) \neq U$




---


- $X$  jest wewnętrznie  $B$ -**niedefiniowalny**, gdy:  
 $\underline{B}(X) = \emptyset$  i  $\overline{B}(X) \neq U$
- $X$  jest zewnątrznie  $B$ -**niedefiniowalny**, gdy:  
 $\underline{B}(X) \neq \emptyset$  i  $\overline{B}(X) = U$
- $X$  jest całkowicie  $B$ -**niedefiniowalny**, gdy:  
 $\underline{B}(X) = \emptyset$  i  $\overline{B}(X) = U$




# Przykład (1)

Zbiór definiowalny



-  Pola nienależące do figury F (obszar I)
-  Pola należące do brzegu figury F (obszar II)
-  Pola należące do dolnego ograniczenia figury F (obszar III)


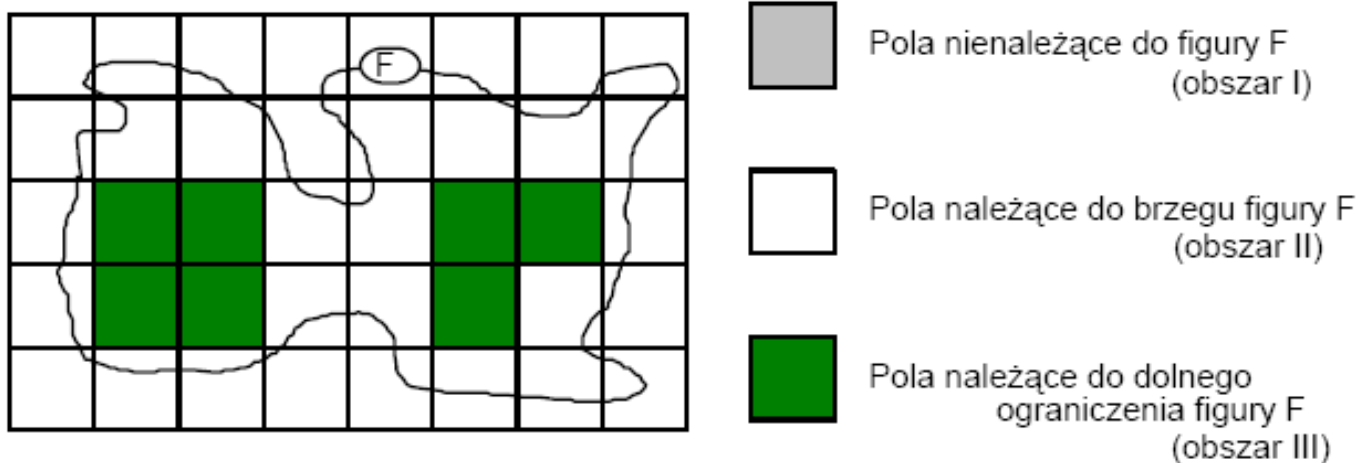


-  Pola nienależące do figury F (obszar I)
-  Pola należące do brzegu figury F (obszar II)
-  Pola należące do dolnego ograniczenia figury F (obszar III)

Zbiór przybliżony, w przybliżeniu B-definiowalny

# Przykład (2)

**Zbiór przybliżony, wewnątrznie B-definiowalny**

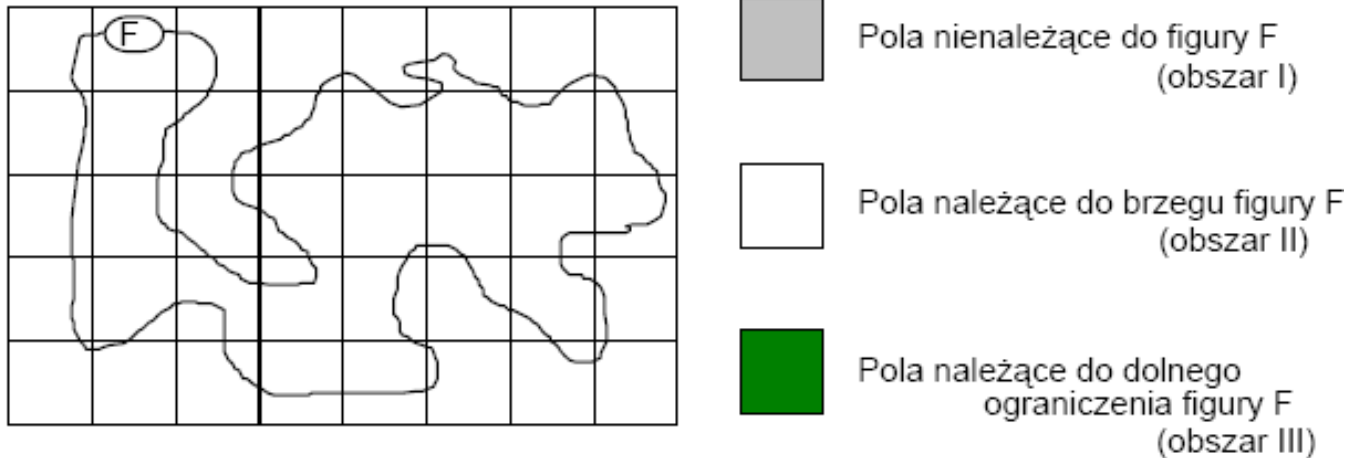


**Zbiór przybliżony, zewnątrznie B-definiowalny**



# Przykład (3)

Zbiór przybliżony, całkowicie B-niedefiniowalny



# Przykład (4)

	<i>Age</i>	<i>Walk</i>
$x_1$	16-30	Yes
$x_2$	16-30	No
$x_3$	31-45	No
$x_4$	31-45	Yes
$x_5$	46-60	No
$x_6$	16-30	Yes
$x_7$	46-60	No

***Walk=No*, zbiór przybliżony wewnątrznie *B*-definiowalny  
 $B=\{Age\}$**

	<i>LEMS</i>	<i>Walk</i>
$x_1$	50	Yes
$x_2$	0	No
$x_3$	1-25	No
$x_4$	1-25	Yes
$x_5$	26-49	No
$x_6$	26-49	Yes
$x_7$	26-49	No

***Walk=Yes*, zbiór przybliżony *B*-definiowalny,  $B=\{LEMS\}$ ,**

***Walk=No*, zbiór przybliżony *B*-definiowalny,  $B=\{LEMS\}$ ,**









Przykład pochodzi z: J. Komorowski, Z. Pawlak, L. Polkowski, A. Skowron: *Rough Sets: A Tutorial*. In S.K. Pal and A. Skowron, editors, *Rough Fuzzy Hybridization, A New Trend in and Decision Making*, pages 3-98. Springer-Verlag, Singapore, 1999.

# Przykład (5)

	<i>Age</i>	<i>LEMS</i>	<i>Walk</i>
$x_1$	16-30	50	Yes
$x_2$	16-30	0	No
$x_3$	31-45	1-25	No
$x_4$	31-45	1-25	Yes
$x_5$	46-60	26-49	No
$x_6$	16-30	26-49	Yes
$x_7$	46-60	26-49	No

# Przykład (6)

Subiektywne postrzeganie kolorów

	<b>R</b>	<b>G</b>	<b>B</b>	<b>Czerwony?</b>
	240	70	70	<b>TAK</b>
	255	0	60	<b>TAK</b>
	255	130	150	<b>NIE</b>
	180	0	0	<b>NIE</b>
	220	20	20	<b>TAK</b>
	220	40	80	<b>NIE</b>
	240	20	100	<b>TAK</b>
	240	20	130	<b>NIE</b>



# Zbiory przybliżone, cz. 2

(wersja do druku)

dr. Piotr Szczuko

Katedra Systemów Multimedialnych

2009

# Plan wykładu

- Redukty
- Macierz rozróżnialności
- Funkcja rozróżnialności
- Rozróżnialność względem k-tego obiektu
- Decyzja, klasa decyzyjna
- Obszar B-pozytywny
- Przybliżona przynależność do zbioru
- Zbiory przybliżone o zmiennej precyzji
- Dyskretyzacja parametrów
- Generowanie i wykorzystanie reguł decyzyjnych do klasyfikacji
- Systemy decyzyjne - RSES

# Wprowadzenie

Pokazano (cz.1 wykładu), że:

- Obiekty pozostające w relacji  $IND(B)$  są ze sobą tożsame
- Grupa obiektów tożsamych, reprezentowana może być przez klasę abstrakcji  $[x]_B$ ,  
( $B$ -kolor,  $x$  – obiekt czerwony,  $[x]_B$  – wszystkie obiekty o kolorze  $x$ 'a, czyli wszystkie czerwone)
- Podzbiór atrybutów  $B \subseteq A$  dzieli uniwersum na zbiory elementarne, wykorzystywane do aproksymacji zbioru  $X$ , charakteryzującego się poszukiwaną cechą  
(wartością atrybutu decyzyjnego, np. Walk=Yes)
- Atrybuty  $B$  generują  $B$ -dolną i  $B$ -górną aproksymację zbioru



# Notacja

Przyjmijmy:

System informacyjny:

$$\mathcal{A} = (U, A)$$

Podzbiór atrybutów:

$$B \subseteq A$$

oraz podzbiór uniwersum:

$$X \subseteq U$$

Możliwa jest aproksymacja zbioru  $X$  wyłącznie przez wykorzystanie atrybutów ze zbioru  $B$ , poprzez określenie  $B$ -dolnej i  $B$ -górnjej aproksymacji zbioru  $X$ :

$$\underline{BX} = \{ x \mid [x]_B \subseteq X \}$$

$$\overline{BX} = \{ x \mid [x]_B \cap X \neq \emptyset \}$$

$$BNB(X) = \overline{BX} - \underline{BX}$$

$$EXT_B(X) = U - \overline{BX}$$

$$\alpha_B(X) = \frac{|\underline{BX}|}{|\overline{BX}|}$$

# Redukt

- Różne podzbiory atrybutów  $B \subseteq A$  i  $C \subseteq A$  mogą prowadzić do identycznych podziałów uniwersum,  $IND_B(X) = IND_C(X)$
- Redukt to taki podzbiór atrybutów, który ma najmniejszą liczbę atrybutów, a ponadto zachodzi:  $IND_B(X) = IND_A(X)$  (generuje taki sam podział jak cały zbiór atrybutów  $A$ )
- Wyznaczenie reduktu polega na pozostawieniu w podzbiorze tylko tych atrybutów, które zachowują relację równoważności, czyli nie zmieniają aproksymacji zbioru i usunięciu pozostałych
- Zwykle dla danego systemu decyzyjnego istnieć może wiele reduktów

# Wyznaczanie reduktów

- Problem NP-trudny
- Liczba możliwych reduktów:  
 $\binom{m}{\lfloor m/2 \rfloor}$ , gdzie  $m$  – liczba atrybutów
- „wąskie gardło” w systemach RoughSet
- Często stosowane są metody genetyczne do wyznaczania reduktów dla dużych systemów decyzyjnych

# Macierz rozróżnialności

- Komórki  $c_{ij}$  macierzy zawierają te atrybuty, którymi różnią się obiekty  $x_i$  i  $x_j$

$$c_{ij} = \{a \in A \mid a(x_i) \neq a(x_j)\}, \quad j, i = 1, 2, \dots, n$$

$n$  - liczba obiektów

$$c_{ij} = c_{ji}$$

$$a_i^* = \{1 \text{ jeżeli } a_i \in c_{ij}; 0 \text{ w przeciwnym przypadku}\}$$

(zmienna logiczna)

$$c_{ij}^* = \{a^* \mid a \in c_{ij}\}$$

# Funkcja rozróżnialności

- Funkcja logiczna:

$$f_{\mathcal{A}}(a_1^*, a_2^*, \dots, a_m^*) = \bigwedge \{ \bigvee c_{ij}^* \mid c_{ij} \neq \emptyset \}, \quad j, i = 1, 2, \dots, n$$

# Funkcja rozróżnialności

	<i>Diploma</i>	<i>Experience</i>	<i>French</i>	<i>Reference</i>	<i>Decision</i>
$x_1$	MBA	Medium	Yes	Excellent	Accept
$x_2$	MBA	Low	Yes	Neutral	Reject
$x_3$	MCE	Low	Yes	Good	Reject
$x_4$	MSc	High	Yes	Neutral	Accept
$x_5$	MSc	Medium	Yes	Neutral	Reject
$x_6$	MSc	High	Yes	Excellent	Accept
$x_7$	MBA	High	No	Good	Accept
$x_8$	MCE	Low	No	Excellent	Reject


$$f_A(d, e, f, r) = (e \vee r)(d \vee e \vee r)(d \vee e \vee r)(d \vee r)(d \vee e)(e \vee f \vee r)(d \vee e \vee f)$$

$$\begin{aligned} & (d \vee r)(d \vee e)(d \vee e)(d \vee e \vee r)(e \vee f \vee r)(d \vee f \vee r) \\ & (d \vee e \vee r)(d \vee e \vee r)(d \vee e \vee r)(d \vee e \vee f)(f \vee r) \\ & (e)(r)(d \vee f \vee r)(d \vee e \vee f \vee r) \\ & (e \vee r)(d \vee e \vee f \vee r)(d \vee e \vee f \vee r) \\ & (d \vee f \vee r)(d \vee e \vee f) \\ & (d \vee e \vee r) \end{aligned}$$

$x_{1,x_2}$  points to the first two terms of the expansion.  
 $x_{1,x_4}$  points to the third and fourth terms of the expansion.  
 $e \wedge r$  points to the last term of the expansion.

# Upraszczanie funkcji rozdzielności

$$(e \vee r) \wedge (d \vee e \vee r) \wedge (d \vee r) \wedge (d \vee e \vee f)$$



$$e \wedge r$$

$$e \wedge d$$

$$r \wedge d$$

~~$$r \wedge e$$~~

$$r \wedge f$$

$$\underline{(e \wedge r) \vee (e \wedge d) \vee (r \wedge d) \vee (r \wedge f)}$$

# Rozróżnialność względem k-tego obiektu

- Funkcja logiczna obliczana wyłącznie dla k-tej kolumny macierzy rozróżnialności

$$f_{\mathcal{A}}(a_1^*, a_2^*, \dots, a_m^*) = \bigwedge_{j=k} \{ \bigvee c_{ij}^* \mid c_{ij} \neq \emptyset \}, \quad i=1, 2, \dots, n,$$

- Uzyskiwana jest wiedza o atrybutach pozwalających rozróżnić k-ty obiekt (jego klasę abstrakcji) od innych obiektów uniwersum



# Decyzja, klasa decyzyjna, notacja

$r(d) = |d(U)| = \{k \mid d(x)=k, x \in U\}$  – liczba decyzji  
w systemie decyzyjnym  $\mathcal{A} = (U, A \cup \{d\})$

$v_d^i$  – wartość  $i$ -tej decyzji np. *Yes, No, Accept, Reject, ...*  $i=1, \dots, r(d)$

$V_d = \{v_d^1, \dots, v_d^{r(d)}\}$  – zbiór wszystkich wartości  
decyzji w systemie decyzyjnym, np.  $\{Yes, No\}$

# Decyzja, klasa decyzyjna, notacja

$X^k_{\mathcal{A}} = \{x \in U \mid d(x) = v^k_d\}$  – k-ta klasa decyzyjna,  
 $k=1, \dots, r(d)$

$CLASS_{\mathcal{A}}(d) = \{X^1_{\mathcal{A}}, \dots, X^{r(d)}_{\mathcal{A}}\}$  – zbiór wszystkich klas,  
klasyfikacja obiektów systemu  $\mathcal{A}$  wyznaczana  
wartością decyzji  $d$ .

$X_{\mathcal{A}}(x) = \{x_i \mid d(x_i) = d(x), x_i \in U\}$  – klasa decyzyjna  
obiektu  $x$ ,

# Obszar *B-positive*

- Decyzja  $d$  determinuje podział uniwersum na  $r(d)$  zbiorów, np.  $U = X^{\text{Yes}} \cup X^{\text{No}}$   
 $X^{\text{Yes}} = \{x_1, x_4, x_6\}$
- Niech  $X^1_{\mathcal{A}}, X^2_{\mathcal{A}}, \dots, X^{r(d)}_{\mathcal{A}}$ , będą klasami decyzyjnymi w  $\mathcal{A}$
- $\underline{B}X^1_{\mathcal{A}} \cup \underline{B}X^2_{\mathcal{A}} \cup \dots \cup \underline{B}X^{r(d)}_{\mathcal{A}}$ , nazywane jest obszarem B-pozytywnym i oznaczane  $POS_B(d)$
- $\mathcal{A}$  jest systemem decyzyjnym **deterministycznym** (zgodnym), jeżeli  $POS_B(d)=U$ , w przeciwnym wypadku jest **niedeterministyczny**

# Macierz rozróżnialności dla decyzji

	<i>Diploma</i>	<i>Experience</i>	<i>French</i>	<i>Reference</i>	<i>Decision</i>
$x_1$	MBA	Medium	Yes	Excellent	Accept
$x_4$	MSc	High	Yes	Neutral	Accept
$x_6$	MSc	High	Yes	Excellent	Accept
$x_7$	MBA	High	No	Good	Accept
$x_2$	MBA	Low	Yes	Neutral	Reject
$x_3$	MCE	Low	Yes	Good	Reject
$x_5$	MSc	Medium	Yes	Neutral	Reject
$x_8$	MCE	Low	No	Excellent	Reject

Poszukiwane tylko redukty pozwalające odróżnić obiekty o różnych decyzjach, a nie wszystkie obiekty między sobą

	$[x_1]$	$[x_4]$	$[x_6]$	$[x_7]$	$[x_2]$	$[x_3]$	$[x_5]$	$[x_8]$
$[x_1]$	$\emptyset$							
$[x_4]$	$\emptyset$	$\emptyset$						
$[x_6]$	$\emptyset$	$\emptyset$	$\emptyset$					
$[x_7]$	$\emptyset$	$\emptyset$	$\emptyset$	$\emptyset$				
$[x_2]$	$e, r$	$d, e$	$d, e, r$	$e, f, r$	$\emptyset$			
$[x_3]$	$d, e, r$	$d, e, r$	$d, e, r$	$d, e, f$	$\emptyset$	$\emptyset$		
$[x_5]$	$d, r$	$e$	$e, r$	$d, e, f, r$	$\emptyset$	$\emptyset$	$\emptyset$	
$[x_8]$	$d, e, f$	$d, e, f, r$	$d, e, f$	$d, e, r$	$\emptyset$	$\emptyset$	$\emptyset$	$\emptyset$

Tylko gdy:  
 $POS_B(d)=U$

# Przybliżona przynależność

- $\mu^X_B: U \rightarrow [0;1]$
- $$\mu^X_B(x) = \frac{|[x]_B \cap X|}{|[x]_B|}$$

względna miara nakładania się klasy równoważności obiektu  $x$  ze zbiorem  $X$ .


- Wprowadza się przybliżenia o **zmiennej precyzji** (dla  $\pi=1$ , przypadek klasyczny):

$$\underline{B}_\pi X = \{x \mid \mu^X_B(x) \geq \pi\} \quad \overline{B}_\pi X = \{x \mid \mu^X_B(x) \geq 1-\pi\}$$

# Zmienna precyzja

$$\underline{B}_\pi X = \{x \mid \mu^X_B(x) \geq \pi\} \quad \bar{B}_\pi X = \{x \mid \mu^X_B(x) \geq 1 - \pi\}$$

- $\pi = 0.33$



Pola nienależące do figury F  
(obszar I)




Pola należące do brzegu figury F  
(obszar II)



Pola należące do dolnego  
ograniczenia figury F  
(obszar III)

# Dyskretyzacja parametrów (1)

<b>A</b>	<i>a</i>	<i>b</i>	<i>d</i>
$u_1$	0.8	2	1
$u_2$	1	0.5	0
$u_3$	1.3	3	0
$u_4$	1.4	1	1
$u_5$	1.4	2	0
$u_6$	1.6	3	1
$u_7$	1.3	1	1



<b>A<sup>P</sup></b>	<i>a<sup>P</sup></i>	<i>b<sup>P</sup></i>	<i>d</i>
$u_1$	0	2	1
$u_2$	1	0	0
$u_3$	1	2	0
$u_4$	1	1	1
$u_5$	1	2	0
$u_6$	2	2	1
$u_7$	1	1	1

$$\mathbf{P} = \{(a; 0.9); (a; 1.5); (b; 0.75); (b; 1.5)\}$$

Partycjonowanie dziedzin parametrów – zbiór cięć

# Dyskretyzacja parametrów (2)

<b>A</b>	<i>a</i>	<i>b</i>	<i>d</i>
$u_1$	0.8	2	1
$u_2$	1	0.5	0
$u_3$	1.3	3	0
$u_4$	1.4	1	1
$u_5$	1.4	2	0
$u_6$	1.6	3	1
$u_7$	1.3	1	1

Niech:  $V_a = \langle 0; 2 \rangle$  ;  $V_b = \langle 0; 4 \rangle$

$\langle 0.8; 1 \rangle$ ;  $\langle 1; 1.3 \rangle$ ;  $\langle 1.3; 1.4 \rangle$ ;  $\langle 1.4; 1.6 \rangle$  dla *a*

$\langle 0.5; 1 \rangle$ ;  $\langle 1; 2 \rangle$ ;  $\langle 2; 3 \rangle$  dla *b*

Środki przedziałów przyjmowane za miejsca cięć:

$(a; 0.9)$ ;  $(a; 1.15)$ ;  $(a; 1.35)$ ;  $(a; 1.5)$ ;

$(b; 0.75)$ ;  $(b; 1.5)$ ;  $(b; 2.5)$



# Dyskretyzacja parametrów (3)


Usuwane są te cięcia, które nie prowadzą do rozróżnienia choć jednej pary obiektów:

~~$(a; 0.9)$~~ ;  ~~$(a; 1.15)$~~ ;

~~$(a; 1.35)$~~ ;  $(a; 1.5)$ ;

$(b; 0.75)$ ;  $(b; 1.5)$ ;

~~$(b; 2.5)$~~




$$\mathbf{P} = \{(a; 0.9); (a; 1.5); (b; 0.75); (b; 1.5)\}$$

# Dyskretyzacja parametrów (4)

- Minimalny zestaw cięć uzyskany algorytmem MD-Heuristics,



J. Komorowski, L. Polkowski, A. Skowron: *Rough Set: A Tutorial*



# Generowanie reguł decyzyjnych

	<i>Diploma</i>	<i>Experience</i>	<i>French</i>	<i>Reference</i>	<i>Decision</i>
$x_1$	MBA	Medium	Yes	Excellent	Accept
$x_2$	MBA	Low	Yes	Neutral	Reject
$x_3$	MCE	Low	Yes	Good	Reject
$x_4$	MSc	High	Yes	Neutral	Accept
$x_5$	MSc	Medium	Yes	Neutral	Reject
$x_6$	MSc	High	Yes	Excellent	Accept
$x_7$	MBA	High	No	Good	Accept
$x_8$	MCE	Low	No	Excellent	Reject

$$f_{\mathcal{A}}(d, e, f, r) = (d \wedge e) \vee (e \wedge r)$$

IF *Diploma*=MBA AND *Experience*=Medium THEN *Decision*=Accept

Podstawiać kombinacje atrybutów w regule:

IF *Diploma*=... AND *Experience*=... THEN *Decision*=...

Poprzednik reguły

Następnik reguły

# Wykorzystanie reguł do klasyfikacji

1. Obliczenie atrybutów nowego obiektu
2. Poszukiwanie reguł pasujących do wartości atrybutów
3. Jeżeli brak pasujących reguł, wynikiem jest najczęstsza decyzja w  $\mathcal{A}$
4. Jeżeli pasuje wiele reguł mogą one wskazywać na różne decyzje, wówczas:

Przeprowadzane jest głosowanie – wybierana jest odpowiedź pojawiająca się najczęściej

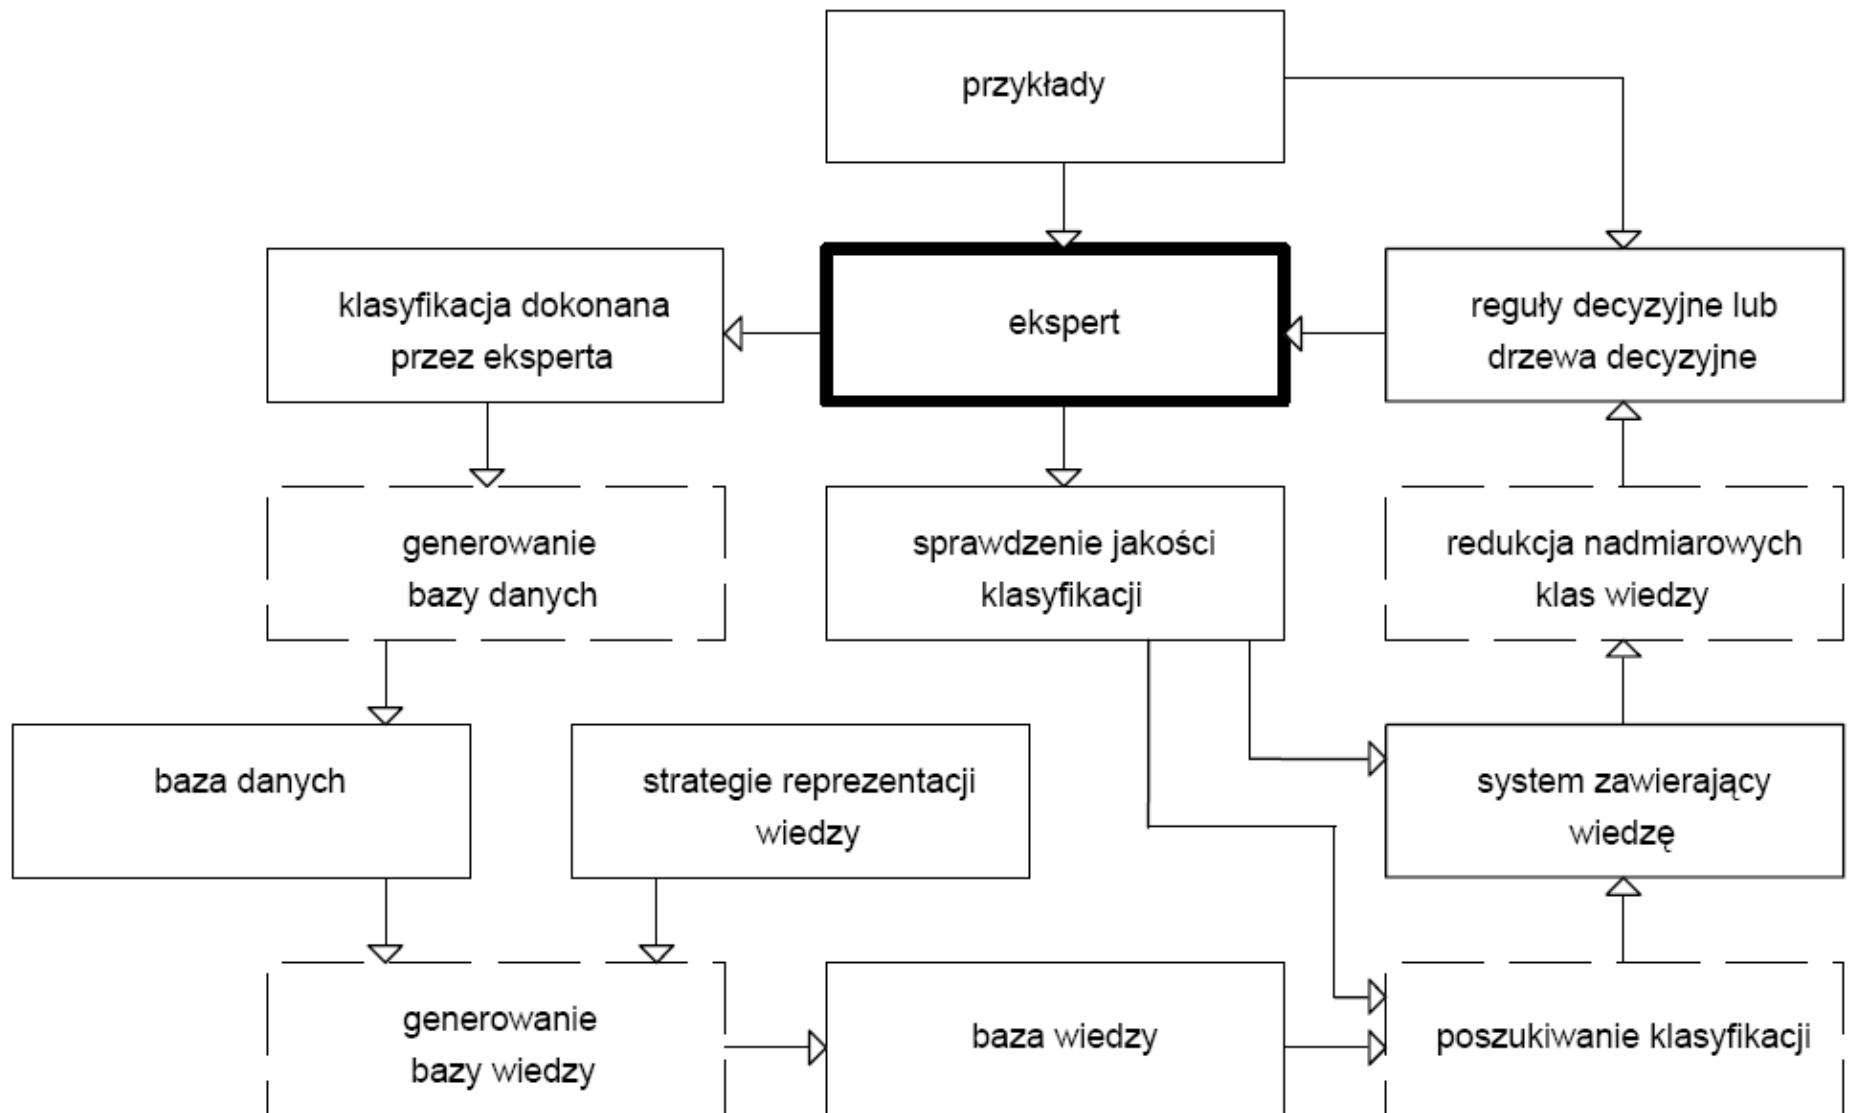
# Klasyfikacja (1)

- niesklasyfikowany obiekt pasuje dokładnie do jednej **deterministycznej** reguły - jest to sytuacja najbardziej pożądana, gdyż wtedy od razu uzyskuje się wiadomość, że obiekt należy do zadanej klasy - a więc do **dolnego przybliżenia zbioru**
- niesklasyfikowany obiekt pasuje dokładnie do jednej, **niedeterministycznej** reguły - sytuacja ta jest nadal pozytywna, gdyż nadal daje jednoznaczną klasyfikację, choć tym razem uzyskuje się jedynie wiadomość, że obiekt *prawdopodobnie* należy do zbioru - a więc, że należy do jego **górnego przybliżenia**

# Klasyfikacja (2)

- niesklasyfikowany obiekt pasuje do **więcej niż jednej** reguły - kilka potencjalnych przynależności obiektu (**jednocześnie do różnych klas**), a więc decyzja nie jest jednoznaczna
- zazwyczaj w takim przypadku stosuje się **dodatkowe kryteria** dla oceny, do której z klas z największym prawdopodobieństwem należy obiekt.

# System informacyjny



# Przykład aplikacji

- Rough Set Exploration System:  
<http://logic.mimuw.edu.pl/~rses/>

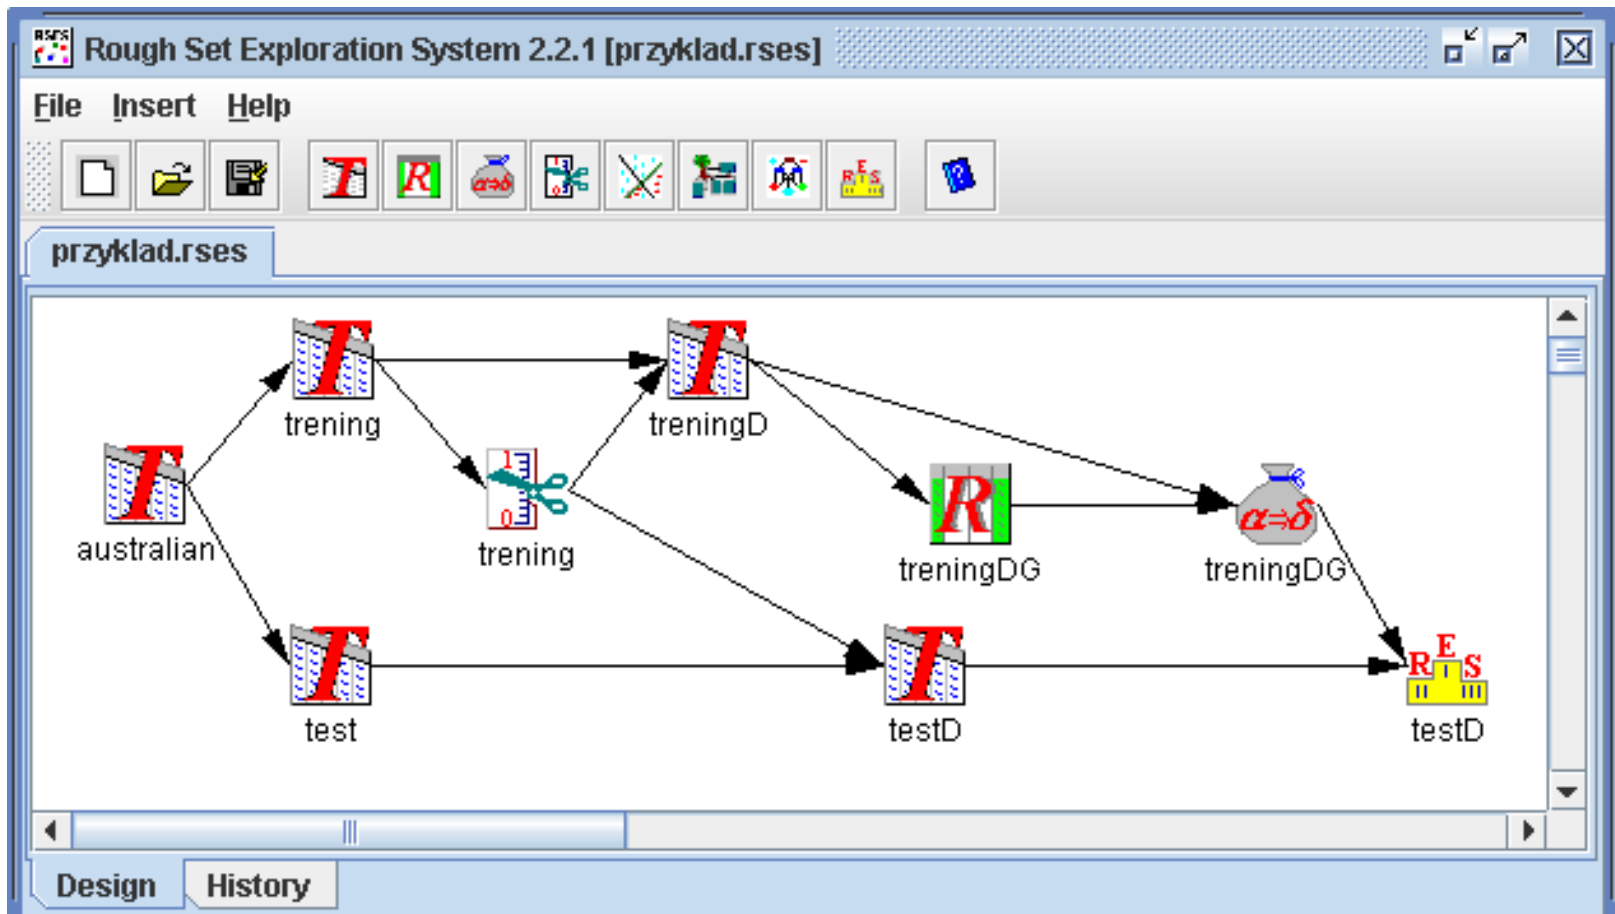




Table: trening

A8	A9	A10	A11	A12	A13	A14	CLASS
0	0	0	1	2	100	1213	0
0	0	0	0	2	160	1	0
0	0	0	1	2	280	1	0
1	1	11	1	2	0	1	1
1	1	14	0	2	60	159	1
1	1	6	0	2	43	561	1
0	0	0	0	2	176	538	0
1	1	3	1				
1	1	4	1				
1	1	6	1				
1	1	6	1				

Cut set: trening

(1-14)	Attribute	Size	Description
1	A1	0	*
2	A2	8	21.04; 21.21; 23.04; 24.0; 27.915; 31.125; 37.25; 45.58
3	A3	5	0.555; 2.23; 4.48; 6.02; 8.54
4	A4	0	*
5	A5	0	*
6	A6	0	*
7	A7	3	0.1875; 1.02; 3.1675
8	A8	0	*
9	A9	0	*
10	A10	0	*
11	A11	0	*
12	A12	0	*
13	A13	0	*
14	A14	0	*

Table: treningD

A8	A9	A10	A11	A12	A13	A14	CLASS
0	0	"(-Inf,0.5)"	1	2	"(75.5,111.0..."	"(309.0,Inf)"	0
0	0	"(-Inf,0.5)"	0	2	"(111.0,172...."	"(-Inf,13.5)"	0
0	0	"(-Inf,0.5)"	1	2	"(172.0,296...."	"(-Inf,13.5)"	0
1	1	"(2.5,Inf)"	1	2	"(-Inf,75.5)"	"(-Inf,13.5)"	1
1	1	"(2.5,Inf)"	0	2	"(-Inf,75.5)"	"(13.5,309.0..."	1
1	1	"(2.5,Inf)"	0	2			
0	0	"(-Inf,0.5)"	0	2			
1	1	"(2.5,Inf)"	1	2			
1	1	"(2.5,Inf)"	1	2			
1	1	"(2.5,Inf)"	1	2			
1	1	"(2.5,Inf)"	1	2			
0	0	"(-Inf,0.5)"	0	2			
0	0	"(-Inf,0.5)"	0	2			

Reduct set: treningDG

(1-10)	Size	Pos.Reg.	SC	Reducts
1	6	1	1	{ A2, A3, A7, A10, A13, A14 }
2	7	1	1	{ A2, A3, A5, A7, A8, A10, A13 }
3	7	1	1	{ A1, A2, A3, A4, A5, A7, A13 }
4	7	1	1	{ A1, A2, A3, A5, A7, A8, A13 }
5	7	1	1	{ A1, A2, A3, A5, A7, A9, A13 }
6	7	1	1	{ A1, A2, A3, A5, A7, A10, A13 }
7	7	1	1	{ A2, A3, A4, A5, A7, A10, A13 }
8	7	1	1	{ A2, A3, A5, A10, A12, A13, A14 }
9	7	1	1	{ A2, A3, A5, A8, A10, A13, A14 }
10	7	1	1	{ A2, A3, A5, A8, A9, A13, A14 }

...	Match	Decision rules
1	1	(A2="(21.21,23.04)")&(A3="(8.54,Inf)")&(A7="(1.02,3.1675)")&(A10="(-Inf,0.5)")&(A13="(75.5,111.0)")&(A14="(309.0,Inf)")=>(CLASS={0 1D})
2	1	(A2="(21.21,23.04)")&(A3="(6.02,8.54)")&(A7="(-Inf,0.1875)")&(A10="(-Inf,0.5)")&(A13="(111.0,172.0)")&(A14="(-Inf,13.5)")=>(CLASS={0 1D})
3	2	(A2="(27.915,31.125)")&(A3="(0.555,2.23)")&(A7="(1.02,3.1675)")&(A10="(-Inf,0.5)")&(A13="(172.0,296.0)")&(A14="(-Inf,13.5)")=>(CLASS={0 2D})
4	1	(A2="(21.21,23.04)")&(A3="(8.54,Inf)")&(A7="(-Inf,0.1875)")&(A10="(2.5,Inf)")&(A13="(-Inf,75.5)")&(A14="(-Inf,13.5)")=>(CLASS={1 1D})
5	1	(A2="(-Inf,21.04)")&(A3="(6.02,8.54)")&(A7="(1.02,3.1675)")&(A10="(2.5,Inf)")&(A13="(-Inf,75.5)")&(A14="(13.5,309.0)")=>(CLASS={1 1D})
6	1	(A2="(45.58,Inf)")&(A3="(2.23,4.48)")&(A7="(1.02,3.1675)")&(A10="(2.5,Inf)")&(A13="(-Inf,75.5)")&(A14="(309.0,Inf)")=>(CLASS={1 1D})
7	1	(A2="(24.0,27.915)")&(A3="(0.555,2.23)")&(A7="(1.02,3.1675)")&(A10="(-Inf,0.5)")&(A13="(172.0,296.0)")&(A14="(309.0,Inf)")=>(CLASS={0 1D})
8	1	(A2="(45.58,Inf)")&(A3="(6.02,8.54)")&(A7="(3.1675,Inf)")&(A10="(2.5,Inf)")&(A13="(75.5,111.0)")&(A14="(13.5,309.0)")=>(CLASS={0 1D})
9	1	(A2="(31.125,37.25)")&(A3="(0.555,2.23)")&(A7="(3.1675,Inf)")&(A10="(2.5,Inf)")&(A13="(172.0,296.0)")&(A14="(309.0,Inf)")=>(CLASS={1 1D})
10	2	(A2="(37.25,45.58)")&(A3="(4.48,6.02)")&(A7="(3.1675,Inf)")&(A10="(2.5,Inf)")&(A13="(296.0,Inf)")&(A14="(-Inf,13.5)")=>(CLASS={1 2D})
11	1	(A2="(31.125,37.25)")&(A3="(4.48,6.02)")&(A7="(3.1675,Inf)")&(A10="(2.5,Inf)")&(A13="(-Inf,75.5)")&(A14="(309.0,Inf)")=>(CLASS={1 1D})
12	1	(A2="(45.58,Inf)")&(A3="(6.02,8.54)")&(A7="(-Inf,0.1875)")&(A10="(-Inf,0.5)")&(A13="(-Inf,75.5)")&(A14="(309.0,Inf)")=>(CLASS={1 1D})
13	1	(A2="(-Inf,21.04)")&(A3="(0.555,2.23)")&(A7="(-Inf,0.1875)")&(A10="(-Inf,0.5)")&(A13="(111.0,172.0)")&(A14="(-Inf,13.5)")=>(CLASS={0 1D})
14	1	(A2="(27.915,31.125)")&(A3="(0.555,2.23)")&(A7="(-Inf,0.1875)")&(A10="(-Inf,0.5)")&(A13="(172.0,296.0)")&(A14="(309.0,Inf)")=>(CLASS={0 1D})
15	1	(A2="(-Inf,21.04)")&(A3="(0.555,2.23)")&(A7="(0.1875,1.02)")&(A10="(-Inf,0.5)")&(A13="(111.0,172.0)")&(A14="(-Inf,13.5)")=>(CLASS={0 1D})
16	4	(A2="(37.25,45.58)")&(A3="(0.555,2.23)")&(A7="(-Inf,0.1875)")&(A10="(-Inf,0.5)")&(A13="(111.0,172.0)")&(A14="(-Inf,13.5)")=>(CLASS={0 4D})
17	1	(A2="(37.25,45.58)")&(A3="(0.555,2.23)")&(A7="(0.1875,1.02)")&(A10="(-Inf,0.5)")&(A13="(111.0,172.0)")&(A14="(-Inf,13.5)")=>(CLASS={0 1D})
18	1	(A2="(-Inf,21.04)")&(A3="(8.54,Inf)")&(A7="(0.1875,1.02)")&(A10="(-Inf,0.5)")&(A13="(75.5,111.0)")&(A14="(309.0,Inf)")=>(CLASS={0 1D})
19	1	(A2="(31.125,37.25)")&(A3="(0.555,2.23)")&(A7="(3.1675,Inf)")&(A10="(2.5,Inf)")&(A13="(-Inf,75.5)")&(A14="(-Inf,13.5)")=>(CLASS={1 1D})
20	2	(A2="(21.21,23.04)")&(A3="(-Inf,0.555)")&(A7="(-Inf,0.1875)")&(A10="(-Inf,0.5)")&(A13="(172.0,296.0)")&(A14="(13.5,309.0)")=>(CLASS={0 2D})

Results of experiments by train&test method: testD

		Predicted				
		0	1	No. of obj.	Accuracy	Coverage
Actual	0	23	10	99	0.697	0.333
	1	4	18	74	0.818	0.297
True positive rate		0.85	0.64			

Total number of tested objects: 173  
 Total accuracy: 0.745  
 Total coverage: 0.318

Dziękuję za uwagę