

KIWIEL



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

# **WSPOMAGANIE DECYZJI**

# **SYSTEMY EKSPERCKIE**

pod redakcją

**Romana Kulikowskiego i Lucyny Bogdan**

Warszawa 1995

# **WSPOMAGANIE DECYZJI**

## **SYSTEMY EKSPERCKIE**

pod redakcją

**Romana Kulikowskiego i Lucyny Bogdan**

Warszawa 1995

Wydano z wykorzystaniem dotacji  
KOMITETU BADAŃ NAUKOWYCH

Materiały konferencji: "Analiza Decyzyjna, Systemy Ekspertskie, Zastosowania Systemów Komputerowych",  
Warszawa, 25-27 maja 1994r.

Komitet Programowy Konferencji:

Andrzej Ameljańczyk, Zdzisław Bubnicki, Wiesław Grudzewski, Olgierd Hryniewicz, Janusz Kacprzyk, Lech Kruś, Roman Kulikowski (przewodniczący), Kazimierz Mańczak, Ireneusz Nykowski, Zdzisław Pawlak, Roman Słowiński, Andrzej Straszak, Andrzej Weryński, Andrzej Wierzbicki.

Wykonano z oryginałów tekstowych dostarczonych przez autorów

© Instytut Badań Systemowych PAN, Warszawa 1995

ISBN 83-85847-85-5

# Rozróżnialność i macierze decyzyjne

Jarosław Stepaniuk  
Instytut Informatyki  
Politechnika Białostocka  
Wiejska 45A, 15-351 Białystok  
e-mail: jstepan@ii.pb.bialystok.pl

## WPROWADZENIE

Baza wiedzy jest zbiorem reguł decyzyjnych w postaci if-then. Celem standardowego modelu uczenia się na podstawie istniejących przykładów jest automatyczne wygenerowanie bazy wiedzy, która jest następnie wykorzystywana do klasyfikacji nowych przypadków [1]. Generowanie reguł jest ważnym aspektem metody zbiorów przybliżonych [2,3]. Reguły decyzyjne są otrzymywane bezpośrednio z tablic decyzyjnych (bez dodatkowych założeń o danych). W pracach [4,5,6,7] zostały zaprezentowane efektywne algorytmy generowania reguł decyzyjnych w oparciu o metody wnioskowania boolowskiego i metody zbiorów przybliżonych. Przedstawione we wspomnianych pracach podejście jest oparte na konstrukcji funkcji boolowskiej z macierzy rozróżnialności lub macierzy decyzyjnej. Na przykład funkcja decyzyjna jest konstruowana z macierzy decyzyjnej. Następnie przez przekształcenie takiego wyrażenia do alternatywnej postaci normalnej oraz zastosowanie prawa pochłaniania otrzymujemy uproszczoną funkcję decyzyjną. Na podstawie implikantów pierwszych uproszczonej funkcji decyzyjnej otrzymujemy reguły decyzyjne o minimalnej liczbie przesłanek.

W prezentowanej pracy proponujemy pewną heurystyczną metodę generowania reguł decyzyjnych bazującą na wynikach przedstawionych w pracach [4,5,6,7].

# GENEROWANIE REGUŁ DECYZYJNYCH

Na początku przypomnimy kilka pojęć, które są wykorzystywane w proponowanej metodzie generowania reguł decyzyjnych.

Przez tablicę decyzyjną będziemy rozumieli parę  $(U, A \cup \{d\})$ , gdzie  $U$  jest niepustym i skończonym zbiorem przykładów, natomiast  $A$  jest niepustym i skończonym zbiorem atrybutów warunkowych oraz  $d$  jest atrybutem decyzyjnym.

Tablica decyzyjna jest sprzeczna gdy istnieją co najmniej dwa takie przykłady  $x, y$ , że dla każdego atrybutu warunkowego  $a \in A$ ,  $a(x) = a(y)$  oraz  $d(x) \neq d(y)$ . W przeciwnym przypadku tablica decyzyjna jest niesprzeczna.

Uogólnionym atrybutem decyzyjnym dla tablicy decyzyjnej  $(U, A \cup \{d\})$  nazywamy funkcję  $\delta_A(x) = \{v : v \text{ jest klasą decyzyjną (wartością atrybutu } d) \text{ i istnieje przykład } y \text{ taki, że dla każdego atrybutu warunkowego } a \in A, a(x) = a(y) \text{ oraz } d(y) = v\}$ .

$\{d\}$  – macierzą rozróżnialności tablicy decyzyjnej  $(U, A \cup \{d\})$  o zbiorze przykładów  $U = \{x_1, \dots, x_n\}$  nazywamy macierz symetryczną  $(c_{ij})_{i,j=1,\dots,n}$  określoną następująco  $c_{ij} = \{a \in A : a(x_i) \neq a(x_j)\}$  gdy  $d(x_i) \neq d(x_j)$  oraz  $c_{ij} = \emptyset$  gdy  $d(x_i) = d(x_j)$ , czyli  $c_{ij}$  jest zbiorem atrybutów warunkowych odróżniających  $x_i$  od  $x_j$  o ile należą te przykłady do różnych klas decyzyjnych.

Niech  $B$  będzie podzbiorem zbioru atrybutów  $A$ . Atrybut  $a \in B$  jest niezbędny w  $B$  wtedy, gdy dla pewnego elementu  $c_{ij}$  macierzy rozróżnialności zachodzi warunek  $B \cap c_{ij} = \{a\}$ . W przeciwnym przypadku mówimy, że atrybut  $a$  jest zbędny w zbiorze atrybutów  $B$ . Zbiór  $B$  nazywamy reduktom zbioru atrybutów  $A$ , gdy dla dowolnego elementu  $c_{ij}$  macierzy rozróżnialności zachodzą warunki, jeżeli  $c_{ij} \neq \emptyset$ , to  $B \cap c_{ij} \neq \emptyset$  oraz  $B$  nie zawiera atrybutów zbędnych.

Oznaczmy przez  $x_1, \dots, x_k$  przykłady dla których jest decyzja  $v$ , natomiast przez  $y_1, \dots, y_{n-k}$  przykłady dla których decyzja jest inna niż  $v$ . Macierz decyzyjna  $(m_{ij})_{i=1,\dots,k,j=1,\dots,n-k}$  dla klasy  $v$  jest to macierz prostokątna zdefiniowana następująco

$$m_{ij} = \{(a, a(x_i)) : a(x_i) \neq a(y_j)\}.$$

Proponowany schemat postępowania jest następujący:

1. Jeżeli tablica decyzyjna jest sprzeczna to przechodzimy do punktu 2, w przeciwnym przypadku do punktu 3.
2. Konstruujemy niesprzeczną tablicę decyzyjną i przechodzimy do punktu 3.
3. Na podstawie niesprzecznej tablicy decyzyjnej wyznaczamy macierz rozróżnialności.
4. Korzystając z macierzy rozróżnialności wyznaczamy redukt złożony z najważniejszych atrybutów.
5. Uwzględniając tylko atrybuty z wybranego reduktu konstruujemy macierze decyzyjne dla poszczególnych klas decyzyjnych.
6. Na podstawie poszczególnych wierszy macierzy decyzyjnych wyznaczamy najistotniejsze pary (atrybut, wartość).

7. Tworząc koniunkcję wybranych par (atrybut, wartość) otrzymujemy przesłanki reguł decyzyjnych.

Niektóre z powyższych punktów wymagają komentarza.

ad.2 Przejście od sprzecznej tablicy decyzyjnej do niesprzecznej jest wykonywane przez wprowadzenie jak to zostało przedstawione w pracach [4,5,6] dodatkowego atrybutu decyzyjnego  $\delta$  nazywanego uogólnionym atrybutem decyzyjnym.

ad.4 Wybieramy kolejno atrybuty o maksymalnej wadze. Waga atrybutu jest określona następująco:  $w(a) = \sum_{i=1}^n \sum_{j=1}^{i-1} w_{ij}(a)$ , przy czym zostały sprawdzone dwie metody wyznaczania współczynników  $w_{ij}(a)$

a)  $w_{ij}(a) = 1$  gdy  $a \in c_{ij}$  oraz  $w_{ij}(a) = 0$  gdy  $a \notin c_{ij}$ ,

b)  $w_{ij}(a) = 1/\text{card}(c_{ij})$  gdy  $a \in c_{ij}$  oraz  $w_{ij}(a) = 0$  gdy  $a \notin c_{ij}$ , gdzie  $\text{card}(c_{ij})$  oznacza liczbę elementów zbioru  $c_{ij}$ .

W przypadku zastosowania metody a) wybieramy atrybut najczęściej występujący w istniejących elementach macierzy rozróżnialności. W metodzie b) uwzględniamy również ile atrybutów oprócz rozważanego atrybutu występuje w danym elemencie macierzy rozróżnialności. Po wybraniu atrybutu o maksymalnej wadze, usuwamy z macierzy rozróżnialności wszystkie elementy do których ten atrybut należy. Następnie wyznaczamy wagi atrybutów, które jeszcze występują w macierzy. Powtarzamy takie postępowanie dopóki macierz nie będzie pusta. Następnie z otrzymanego zbioru atrybutów usuwamy atrybuty zbędne [2,3].

ad.6 Waga pary (atrybut, wartość) na podstawie jednego wiersza macierzy decyzyjnej jest określona analogicznie jak waga atrybutu na podstawie macierzy rozróżnialności. Zatem przyjmujemy, że  $w((a, a(x_i))) = \sum_{j=1}^{n-k} w_{ij}((a, a(x_i)))$  i rozważamy dwie możliwości

a)  $w_{ij}((a, a(x_i))) = 1$  gdy  $(a, a(x_i)) \in m_{ij}$  oraz  $w_{ij}((a, a(x_i))) = 0$  gdy  $(a, a(x_i)) \notin m_{ij}$ ,

b)  $w_{ij}((a, a(x_i))) = 1/\text{card}(m_{ij})$  gdy  $(a, a(x_i)) \in m_{ij}$  oraz  $w_{ij}((a, a(x_i))) = 0$  gdy  $(a, a(x_i)) \notin m_{ij}$ .

Proponowana metoda generowania reguł decyzyjnych działa znacznie szybciej niż algorytmy zaprezentowane w pracach [4,5,6,7]. Oprócz tego liczba otrzymanych reguł decyzyjnych jest znacznie mniejsza niż w wyniku zastosowania cytowanych algorytmów. Stosując tę metodę opieramy się na założeniu, że wygenerowane reguły decyzyjne mogą wprowadzać nieznaczne pogorszenie jakości klasyfikacji znanych już przypadków, ale ze względu na ich większą ogólność powinny prowadzić do istotnego wzrostu jakości klasyfikacji przypadków dotąd nieznanymi. Prawdziwość tej hipotezy jest weryfikowana przez system komputerowy analizy danych. W szeregu przypadków tablic decyzyjnych trafność tej hipotezy została potwierdzona eksperymentalnie. Można traktować proponowane podejście jako, w pewnym sensie, metodę eliminacji szumów lub nietypowych przypadków z tablicy danych.

# LITERATURA

- [1] Kodratoff Y., Michalski R.: Machine learning: An Artificial Intelligence Approach, Vol.3. San Mateo: Morgan Kaufmann 1990.
- [2] Pawlak Z.: Rough sets: Theoretical Aspects of Reasoning About Data. Dordrecht: Kluwer 1991.
- [3] Slowiński R. (ed.): Intelligent Decision Support- Handbook of Applications and Advances of the Rough Sets Theory. Dordrecht: Kluwer 1992.
- [4] Skowron A.: Boolean Reasoning for Decision Rules Generation. Proceedings of the 7-th International Symposium ISMIS'93, Trondheim, Norway 1993, In: J.Komorowski and Z.Ras (eds.): Lecture Notes in Artificial Intelligence, vol.689. Springer- Verlag 1993, 295-305.
- [5] Skowron A.: A Synthesis of Decision Rules: Applications of Discernibility Matrices, Proceedings of the Workshop on Intelligent Information Systems, Augustow, Poland, June 7-11, 1993, 30-46.
- [6] Skowron A.: Management of Uncertainty in AI: A Rough Set Approach, Proceedings of the Workshop on Incompleteness and Uncertainty in Information Systems, Montreal, Canada, October 8-9, 1993, 36-61.
- [7] Shan N., Ziarko W.: An Incremental Learning Algorithm for Constructing Decision Rules, Proceedings of the International Workshop on Rough Sets and Knowledge Discovery, Banff, Canada, October 12-15, 1993, 335-346.

**ISBN 83-85847-85-5**

---

**W celu uzyskania bliższych informacji i zakupu dodatkowych egzemplarzy  
prosimy o kontakt**

**z Instytutem Badań Systemowych PAN  
ul. Newelska 6, 01-447 Warszawa**

**tel. 36-19-01 w. 241 e-mail: kotuszew@ibspan.waw.pl**