

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

REGUŁOWY SYSTEM WSPOMAGANIA KLASYFIKOWANIA WYKORZYSTUJĄCY WARTOŚCIOWANĄ RELACJĘ BLISKOŚCI

Roman Słowiński, Jerzy Stefanowski
Instytut Informatyki
Politechnika Poznańska
60-965 Poznań

1. Wstęp

Jednym z podstawowych działań w podejmowaniu decyzji jest klasyfikowanie. W pracy rozważa się problematykę budowy systemu wspomaganie klasyfikowania w oparciu o wiedzę pozyskaną z zapisu doświadczenia.

Doświadczenie reprezentowane jest często w postaci zbioru przykładów rzeczywistych lub hipotetycznych decyzji o klasyfikowaniu obiektów (przypadków, osób, procesów itp.) na podstawie ich opisu. Zbiór przykładów, nazywanych przykładami uczącymi, przedstawiany jest najczęściej w postaci *tablicy decyzyjnej*. Tablica decyzyjna utożsamiana jest ze skończoną tabelą, której wiersze odpowiadają obiektom, a kolumny atrybutom (cechom, zmiennym charakterystycznym itp.) opisującym obiekty. Jedna z kolumn wyraża decyzję klasyfikacyjną podjętą wobec danego obiektu. Kolumna ta nazywa się *atrybutem decyzyjnym*, podczas gdy pozostałe kolumny zwać się *atrybutami warunkowymi*.

Zbiór przykładów uczących jest punktem wyjścia do procesu uczenia się, w wyniku którego pozyskuje się wiedzę o klasyfikowaniu. Problematyka uczenia się z przykładów jest przedmiotem zainteresowania wielu metod wywodzących się głównie z uczenia maszynowego, metod statystycznych, w szczególności analizy dyskryminacyjnej, czy sieci neuronowych (por. np. [24]). W przypadku uczenia maszynowego opis decyzji wyrażany jest na ogół za pomocą *drzew* lub *reguł decyzyjnych*.

W pracy rozważa się podejście, w którym wiedza o klasyfikowaniu reprezentowana jest za pomocą reguł decyzyjnych. Reguły decyzyjne prezentują istotne regularności w zapisie doświadczenia oraz są często łatwiejsze do zrozumienia przez

decydentów niż inne formy reprezentacji wiedzy (por. np. roz. 5 [14] oraz [8]). Reguły decyzyjne mają następującą postać:

$if (atr_1, v_1) \& \dots \& (atr_n, v_n) \text{ then } (d, v_d)$

gdzie atr_i oznacza atrybut warunkowy, v_i jest wartością tego atrybutu, $i=1,2,\dots,n$; d oznacza decyzję klasyfikacyjną a v_d jest wartością tej decyzji.

Ważnym problemem związanym z odkrywaniem wiedzy o klasyfikowaniu jest możliwość istnienia *sprzeczności* w rzeczywistych zbiorach przykładów uczących. Sprzeczności polegają na tym, że obiekty opisane w identyczny sposób za pomocą zbioru atrybutów warunkowych są przydzielone do różnych klas decyzyjnych. (przez klasę decyzyjną rozumie się zbiór obiektów posiadających tę samą wartość atrybutu decyzyjnego w tablicy decyzyjnej). Wiąże się to z ograniczoną rozróżnialnością obiektów dla danego zbioru atrybutów, np. wynikającą z użycia języka naturalnego w opisie przykładów.

Istnienie sprzecznych przykładów jest utrudnieniem w procesie uczenia się. Niektóre ze znanych algorytmów są przeznaczone do analizy wyłącznie niesprzecznych przykładów. W innych systemach uczących w celu uwzględnienia sprzecznych przykładów stosuje się specjalne techniki, np. redukcji drzew (por. metoda CART [1], rozwinięcia klasycznej wersji algorytmu ID3 [13], a także system C4.5 [14]). W systemie AQ15 [9] odrzuca się z wygenerowanych reguł składniki odnoszące się do zbyt małej liczby przykładów. Inne rozwiązanie przyjęto w systemie CN2 [4], gdzie w trakcie budowy reguł wykorzystuje się specjalne kryteria oceniające błędy klasyfikowania.

W proponowanym systemie wspomagania klasyfikowania obiektów, do analizy zbioru przykładów uczących zastosowano podejście oparte na *teorii zbiorów przybliżonych*. Teoria ta zaproponowana przez Pawlaka [10,11] jest szczególnie dogodna do analizy zbioru przykładów, który może zawierać sprzeczności.

W teorii zbiorów przybliżonych obiekty nierozróżnialne za pomocą zbioru dostępnych atrybutów warunkowych tworzą, tzw. zbiory elementarne. W ogólności, nie zawsze jest możliwe precyzyjne zdefiniowanie danego zbioru obiektów, np. należących do wybranej klasy decyzyjnej, za pomocą elementarnych zbiorów nierozróżnialnych obiektów. Wprowadzono więc pojęcie zbioru przybliżonego. Zbiór przybliżony jest parą *dolnego* i *górnego przybliżenia* danego zbioru obiektów. Dolne przybliżenie jest maksymalną sumą zbiorów elementarnych zawartych w danym zbiorze obiektów, podczas gdy górne przybliżenie jest minimalną sumą zbiorów elementarnych mających elementy wspólne z danym zbiorem obiektów. Różnica pomiędzy górnym a dolnym przybliżeniem tworzy tzw. *brzeg* danego zbioru obiektów. Posługując się pojęciami przybliżeń definiuje się wiele operacji przydatnych zwłaszcza przy tworzeniu tzw. opisu sytuacji decyzyjnej [12,17]. Na szczególną uwagę zasługuje możliwość redukcji atrybutów nieznaczących dla przybliżenia klasyfikacji obiektów.

Wykorzystanie podejścia opartego na teorii zbiorów przybliżonych w procesie uczenia się pozwala na uzyskanie dwóch typów reguł: *dokładnych* i *przybliżonych*. Reguły dokładne są generowane z obiektów należących do dolnych przybliżeń klas decyzyjnych, podczas gdy reguły przybliżone są tworzone w oparciu o obiekty należące do brzegów klas decyzyjnych. Reguły dokładne wiążą z danym opisem warunków (a_i, v_i)

dokładnie jedną decyzję klasyfikacyjną (d, v_j), natomiast reguły przybliżone wskazują wiele decyzji możliwych do podjęcia dla danych warunków. Do tworzenia reguł decyzyjnych wykorzystano implementację algorytmu LEM opartego na idei, tzw. *lokalnego pokrycia* zbioru przykładów uczących zaproponowanej przez Grzymałę w [5].

Podstawowe operacje teorii zbiorów przybliżonych umożliwiające analizę zbioru przykładów decyzji klasyfikacyjnych oraz algorytm generowania reguł zostały zaimplementowane w programie *RoughDAS* [19,22].

Zbiór reguł decyzyjnych pozyskanych z przykładów uczących może być użyty do *wspomagania klasyfikowania nowych obiektów*, tj. obiektów, które nie wystąpiły w fazie uczenia. Wspomaganie to realizowane jest w oparciu o dopasowanie opisu nowego obiektu do części warunkowych pozyskanych reguł decyzyjnych.

Należy jednak zauważyć, że zastosowanie reguł decyzyjnych do wypracowywania zaleceń decyzji klasyfikacyjnych może prowadzić do trudności w dopasowaniu opisu nowego obiektu do reguł. Trudności związane są z możliwością dopasowania nowego obiektu do reguły przybliżonej lub wielu reguł równocześnie. Możliwa jest także sytuacja, w której zbiór reguł nie zawiera reguły uzasadniającej decyzję dla nowego obiektu.

Wspomaganie decydenta przy klasyfikowaniu nowych obiektów, zwłaszcza przy rozstrzyganiu powyżej opisanych sytuacji jest głównym zadaniem systemu omawianego w niniejszej pracy.

W proponowanej koncepcji wspomagania szczególną uwagę poświęcono sytuacji braku dopasowania nowego obiektu do istniejących reguł decyzyjnych. Dla jej rozwiązania proponuje się wspomaganie decydenta poprzez zaprezentowanie mu zbioru reguł "*bliskich*" względem klasyfikowanego obiektu. Definicja reguł "*bliskich*" wiąże się z użyciem pewnej miary bliskości. Do tego celu używa się tzw. *wartościowanej relacji bliskości* konstruowanej w oparciu o pewne informacje preferencyjne pochodzące od decydenta [18,20].

Uwzględnianie współdziałania decydenta w wypracowywaniu zaleceń klasyfikacyjnych jest ważną cechą omawianego systemu. Innymi istotnymi cechami są: prezentacja zaleceń w formie łatwo zrozumiałej dla decydenta, a także możliwość uzasadniania tych zaleceń. Powyższe cechy odróżniają proponowany system od systemów automatycznego klasyfikowania (np. sieci neuronowe lub metody statystyczne), które są dla decydenta rodzajem "czarnych skrzynek" prezentującymi mu potencjalnie poprawne rozwiązanie bez wyjaśnienia zasad, na których jest ono oparte.

Proponowana koncepcja systemu wspomagania decyzji odnośnie do klasyfikowania nowych obiektów została zaimplementowana w postaci interakcyjnego oprogramowania dla mikrokomputera IBM PC.

W celu oceny tego systemu przeprowadzono serię eksperymentów obliczeniowych, które miały na celu zbadanie poprawności proponowanych przez system sugestii klasyfikacyjnych. Eksperymenty polegały na wykonaniu testów klasyfikowania dla 12 zbiorów przykładów o różnej charakterystyce, pochodzących zarówno ze znanych zastosowań teorii zbiorów przybliżonych jak i metod uczenia się maszynowego.

W następnych rozdziałach przedstawia się ideę wspomaganie decydenta z wykorzystaniem wartościowanej relacji bliskości oraz omawia się wyniki przeprowadzonych eksperymentów obliczeniowych.

2. Wykorzystanie wartościowanej relacji bliskości we wspomaganie klasyfikowania nowych obiektów

Proces dopasowywania opisu nowego obiektu do części warunkowych wygenerowanych reguł decyzyjnych może doprowadzić do jednej z następujących sytuacji:

- (a) nowy obiekt dopasowany jest do jednej reguły dokładnej,
- (b) nowy obiekt dopasowany jest do jednej reguły przybliżonej,
- (c) nowy obiekt dopasowany jest do więcej niż jednej reguły,
- (d) nowy obiekt nie jest dopasowany do żadnej z istniejących reguł.

Sytuacja (a) jest jednoznaczna w interpretacji. Zalecenie decyzji formułowane jest na podstawie dopasowanej reguły. Natomiast każda z pozostałych sytuacji powoduje niejednoznaczności w interpretacji.

Należy zauważyć, że w niektórych systemach regułowych nie wszystkie powyższe sytuacje zachodzą. W systemach CN2 [4] oraz C4.5 [14] reguły decyzyjne uporządkowane są w postaci *listy decyzyjnej*. Dopasowania obiektu dokonuje się do kolejnych reguł na liście. Pierwsza napotkana dopasowana reguła służy do określenia klasyfikacji. Nie przegląda się wtedy dalszych reguł. Ostatnią regułą na liście jest tzw. *default rule* (ang.). Nie zawiera ona żadnych warunków i jest wykorzystywana, gdy opis klasyfikowanego obiektu nie spełnia żadnej z poprzednich reguł.

W omawianym systemie przyjęto inne mniej arbitralne dla decydenta rozwiązanie. Podczas klasyfikowania przeglądany jest cały zbiór reguł decyzyjnych (podobne jak np. w systemach AQ [9]). Rozstrzygnięcie sytuacji niejednoznacznego dopasowania dokonywane jest z użyciem informacji o konkretnych przykładach uczących wspierających reguły decyzyjne.

Z każdą regułą decyzyjną wiąże się parametr nazywany *siłą reguły*. Jest to liczba przykładów spełniających część warunkową tej reguły. W przypadku reguły przybliżonej siłę oblicza się oddzielnie dla każdej decyzji wskazywanej przez regułę.

Stąd w sytuacji (b) decydent informowany jest o sile związanej z każdą z możliwych decyzji. Przyjmuje się sugestię wskazującą na najsilniejszą decyzję. Decydent jest ponadto informowany o konkretnych przykładach wspierających każdą z możliwych decyzji.

Sytuacja (c) jest rozstrzygana podobnie jak (b). Tzn. wszystkie dopasowane reguły wraz z informacjami o ich siłach prezentowane są decydentowi. Jeśli wszystkie reguły wskazują tę samą decyzję, to nie występuje niejednoznaczność w sugestii klasyfikacyjnej. W przeciwnym razie decydent może traktować tę sugestię podobnie jak w przypadku (b) przyjmując najsilniejszą z możliwych decyzji.

Sytuacja (d) jest najtrudniejsza w interpretacji. W tym przypadku proponuje się przedstawienie decydentowi skończonego zbioru reguł bliskich względem nowego

przypadku. Przez reguły bliskie rozumie się reguły, których część warunkowa jak najmniej różni się od opisu klasyfikowanego obiektu w sensie pewnej miary bliskości.

Motywacją do szukania tego typu reguł jest przekonanie, że udostępnienie decydentowi więcej informacji o "sąsiedztwie" klasyfikowanego obiektu może być dla niego bardziej przydatne niż pozostawienie go w sytuacji braku jakichkolwiek wskazań. Należy zauważyć, że podobne podejście do rozstrzygnięcia sytuacji braku dopasowania prezentowane było przez Michalskiego w systemie AQ15 [9] (tzw. częściowe dopasowanie), oraz w zmodyfikowanym systemie LERS [6] (tzw. "bucket brigade algorithm") a także w poprzedniej wersji systemu *RoughClass* [19,21] (tzw. miary odległościowe). Podejścia te były jednak ukierunkowane na automatyczne rozstrzygnięcie tej sytuacji i nie wykorzystują informacji, które można pozyskać od decydenta.

W proponowanym w pracy systemie miara bliskości definiowana jest z wykorzystaniem *wartościowanej relacji bliskości* wprowadzonej w [18,20]. Poniżej przedstawimy krótko podstawowe zasady konstruowania tej relacji. Pełniejsze informacje dostępne są w pracy [20].

Przy definiowaniu miary zakłada się, że bliskość jest badana tylko dla atrybutów warunkowych występujących w części warunkowej danej reguły. Należy ponadto zauważyć, że w ogólności w opisie obiektów występują dwa typy atrybutów: *porządkowe* i *nieporządkowe*. Za atrybuty porządkowe uważa się te, dla których dziedziny wartości można uporządkować zgodnie z pewną skalą, podczas gdy dziedziny atrybutów nieporządkowych nie mogą być uporządkowane.

Konstrukcja wartościowanej relacji bliskości R oparta jest na podobnych zasadach jak relacji przewyższania wprowadzonej przez Roy w [15]. Zgodnie z tymi zasadami nowy obiekt x porównywany jest z każdą regułą rd w celu oszacowania prawdziwości twierdzenia: " x jest bliskie rd ". Oszacowanie wiarygodności $r(x,rd)$ relacji bliskości jest tworzone z uwzględnieniem pewnych jakościowych zasad, w szczególności z odrzuceniem niepożądanego kompensacji. Wiarygodność $r(x,rd)$ zmienia się od 1, gdy bliskość jest dobrze uzasadniona do 0, gdy nie ma podstaw do zakładania bliskości x względem rd .

Formuła obliczania $r(x,rd)$ jest oparta na dwóch testach *zgodności* i *niezgodności* [16]. Celem testu zgodności jest scharakteryzowanie grupy atrybutów (warunków) będących w zgodności z rozważanym twierdzeniem o bliskości i oszacowanie ich względnej ważności w porównaniu z pozostałymi atrybutami, Celem testu niezgodności jest scharakteryzowanie tych atrybutów (warunków), których opozycja wobec twierdzenia o bliskości jest na tyle silna, aby móc zredukować wiarygodność $r(x,rd)$ wynikającą z wzięcia pod uwagę tylko atrybutów zgodnych.

W celu obliczenia $r(x,rd)$ decydent może najpierw określić względną ważność dla każdego z atrybutów. Globalny współczynnik zgodności $C(x,rd)$ definiowany jest jako suma ważona cząstkowych współczynników zgodności dla każdego z atrybutów. Dla atrybutów porządkowych, obliczanie współczynników zgodności wiąże się ze zdefiniowaniem przez decydenta dwóch progów: $0 \leq q \leq p$, nazywanych odpowiednio *progami nierozróżnialności* i *silnej różnicy*. Progi te mają czysto intuicyjne znaczenie. Jeżeli różnica pomiędzy obiektem x a regułą rd dla danego atrybutu porządkowego jest nie większa niż q to oznacza, że decydent nie dostrzega różnicy pomiędzy x a rd

względem odpowiedniego atrybutu. Jeżeli różnica pomiędzy x a rd jest większa niż q a mniejsza niż p to decydent dostrzega słabą różnicę wynikającą z niedopasowania x i rd . Dla różnicy większej niż p decydent dostrzega dużą różnicę. Dla atrybutów nieporządkowych, zamiast definiowania progów decydent może wyszczególnić pary wartości dla danego atrybutu, które uznaje za równoważne, będące w słabej różnicy, oraz w silnej różnicy.

Dla każdego atrybutu, który jest w opozycji do twierdzenia o bliskości definowany jest wskaźnik niezgodności $d_i(x, rd)$. W przypadku atrybutów porządkowych jest on obliczany na podstawie tzw. *progu weta* v (gdzie $v \geq p$). Dla atrybutów nieporządkowych decydent wyszczególnia odpowiednie pary wartości, które jego zdaniem nie stwarzają podstaw dla przyjęcia twierdzenia o bliskości obiektu x względem reguły rd .

Stożek wiarygodności $r(x, rd)$ jest ostatecznie obliczany z globalnego współczynnika zgodności $C(x, rd)$ osłabionego przez współczynniki niezgodności $d_i(x, rd)$. Szczegółowe formuły obliczeń przedstawione są w pracy [20].

We wspomaganiu decydenta przy klasyfikacji nowego obiektu przegląda się wszystkie reguły i oblicza dla każdej z nich wartość współczynnika $r(x, rd)$. Następnie prezentuje się decydentowi listę reguł o największej wartości $r(x, rd)$ wraz z informacjami o ich sile, liczbie różnic, konkretnych przykładach wspierających regułę, itp. Interpretacja tych informacji oraz ostateczna decyzja pozostawiona jest decydentowi.

3. Eksperyment obliczeniowy

Koncepcja systemu wspomaganie decyzji o klasyfikowaniu nowych obiektów przedstawiona w poprzednich rozdziałach została zaimplementowana jako interakcyjne oprogramowanie dla mikrokomputera IBM PC. System wykorzystuje zbiór reguł decyzyjnych wygenerowanych ze zbioru przykładów za pomocą programu RoughDAS.

W celu oceny tego oprogramowania, a zwłaszcza praktycznej przydatności zaproponowanej koncepcji wykorzystywania wartościowanej relacji bliskości, przeprowadzono serie eksperymentów obliczeniowych. W eksperymencie oceniano poprawność wypracowywanych przez system sugestii klasyfikacyjnych dla zbiorów rzeczywistych przykładów.

Ocena poprawności klasyfikowania dokonywana była za pomocą parametru *trafności klasyfikowania*. Jeżeli n_k jest liczbą klasyfikowanych obiektów, a n_p liczbą tych obiektów, które zostały zaklasyfikowane przez system w sposób poprawny, to trafność klasyfikowania jest zdefiniowana jako stosunek n_p/n_k (wyrażany w procentach).

Eksperyment wykonano w teście automatycznego klasyfikowania posługując się technikami podziału: "*10-fold-cross-validation*" (gdy liczba przykładów w danym zbiorze była większa niż 100) oraz "*leaving-one-out*" (gdy liczba przykładów była mniejsza niż 100).

W trakcie eksperymentu symulowano możliwe preferencje decydenta dobierając dla danego zbioru przykładów różne wartości parametrów takich jak

względne ważności atrybutów występujących w warunkach reguł, wartości odpowiednich progów w definicji relacji bliskości, liczby rozpatrywanych reguł bliskich itp. Dla każdego zbioru przykładów test wykonywano w trzech kolejnych etapach. W pierwszym etapie dla określenia wskazania systemu wykorzystywano wyłącznie jednoznaczne dopasowanie nowego obiektu do reguł decyzyjnych; inne sytuacje traktowano jako błąd. W etapie drugim wykorzystywano także strategię rozstrzygnięcia sytuacji niejednoznacznego dopasowania na podstawie siły reguł. W trzecim etapie prócz dwóch powyższych strategii wykorzystywano dodatkowo strategię poszukiwania reguł bliskich.

Pierwszym celem eksperymentu było sprawdzenie przydatności proponowanych strategii w klasyfikowaniu nowych obiektów. Oceną przydatności była zmiana wartości współczynnika trafności klasyfikowania. Ponadto chciano sprawdzić czy trafność klasyfikowania osiągnana przez zaimplementowany system jest porównywalna z wynikami zastosowania innych znanych metod indukcyjnych. Zdecydowano się więc przeprowadzić dla tych samych zbiorów przykładów testy także za pomocą stworzonych przez autorów implementacji: innych metod indukcyjnego uczenia się na przykładach. Użyto następujących implementacji: algorytmu PRISM [2]; klasycznego algorytmu ID3 oraz systemu PT, tj. modyfikacji algorytmu ID3 pozwalającej na otrzymywanie zredukowanego drzewa z liśćmi o charakterze probabilistycznym (idea pre-pruningu z [3]); i metody ELYSEE [23].

Użyte w eksperymencie zbiory przykładów odnoszą się do realnych sytuacji decyzyjnych z dziedzin takich jak: medycyna, farmacja, diagnostyka techniczna, diagnostyka chorób roślin czy badania socjologiczne. Podstawowe informacje o tych zbiorach przykładów przedstawione są w tabeli 1.

zbiór przykładów	liczba obiektów	liczba atrybutów	liczba klas dec.	sprzeczne przykłady
large soybean*	265	35	15	N
election	444	30	2	N
iris	150	4	3	N
hsv_4	122	11	4	T
hsv_2	122	11	2	T
pustaki	216	10	2	T
breast cancer*	285	8	2	T
imidazolium	201	8	5	N
lymphography	148	18	4	N
buses	76	8	2	N
vdiag	55	10	2	N
small soybean	46	35	4	N

Tabela 1. Zbiory przykładów użyte w eksperymencie obliczeniowym, (*- oznacza że oryginalny zbiór został zmodyfikowany)

Autorzy składają podziękowania wszystkim osobom, które udostępniły do eksperymentu zbiory przykładów. W przypadku zbiorów pochodzących z zastosowań teorii zbiorów przybliżonych dotyczy to: K.Słowińskiego (*hsv*), J.Krysińskiego (*imidazolium*), R.Nowickiego (*vdiag*), A.Wasilewskiej i M.Hadjimicheall (*election*), Z.Piąście (*pustaki*), J.Żakowi (*buses*). Zbiory *large* i *small soybean disease, iris, breast cancer, lymphography* są znanymi zbiorami z literatury dotyczącej indukcyjnego uczenia się na przykładach. Skorzystanie z nich okazało się możliwe dzięki bazie danych dostępnej na University of California at Irvine [7].

Zwróćmy uwagę, że w eksperymencie analizowano przykłady w pełni zdefiniowane, tj. takie w opisie których nie występują nieznanne lub nieprecyzyjne wartości atrybutów. W związku z tym konieczne okazało się zmodyfikowanie dwóch zbiorów zawierających nieznanne wartości atrybutów. Polegało to na usunięciu niektórych obiektów lub atrybutów.

W analizowanych zbiorach atrybuty opisujące obiekty miały ponadto charakter jakościowy, tzn. ich dziedziną były zbiory określeń jakościowych. Stąd, dla niektórych zbiorów przykładów dokonano dyskretyzacji dziedzin atrybutów ilościowych (szegółowe informacje w [22]). Z uwagi na powyższe modyfikacje należy zachować ostrożność przy ewentualnych prównaniach z wynikami znanymi z literatury.

Reguły decyzyjne były każdorazowo generowane za pomocą implementacji algorytmu LEM dostępnej w systemie RoughDAS. W tabeli 2 przedstawiono zbiorcze wyniki eksperymentu obliczeniowego oraz porównanie działania implementacji proponowanego systemu, oznaczonej jako *RS_SWD*, z innymi metodami. W przypadku systemu *RS_SWD* zamieszcza się wyniki klasyfikowania w poszczególnych etapach. Stosuje się zapis Etap3 (Etap2 / Etap1).

Zbiór przykładów	ID3	PT	PRISM	ELYSEE	RS_SWD
large soybean	81.2	76.6	62.5	86.8	87.9 (85.7 / 79.2)
election	84.4	88.8	76.7	84.0	89.4 (79.5 / 71.8)
iris	90.7	90.7	90	94.7	95.3 (89.3 / 88)
hsv_4	50	60.7	----	52.5	58.2 (49.2 / 41.9)
hsv_2	68	71.3	----	68	77.1 (70.5 / 59.8)
pustaki	86.6	92	----	89.4	88.9 (82.8 / 81)
breast cancer	62.5	68.1	----	63.5	67.1 (59.3 / 51.2)
imidazolium.	35.3	35.3	35.8	59.7	53.3 (44.8 / 34.4)
lymphograp..	75	82.4	66.9	79.7	85.2 (73.6 / 67.6)
buses	94.7	96.9	?	?	98 (93.5 / 90.8)
vdiag	83.6	85.4	?	?	96.4 (90.9 / 87.3)
small soybean	97.8	97.8	?	?	97.8 (97.8 / 97.8)

Tabela 2. Porównanie trafności klasyfikowania (w %) dla implementacji wybranych metod.. ---- oznacza niemożność wykonania testu dla PRISM-u z powodu występowania sprzecznych przykładów, ? oznacza brak możliwości wykonania testu "leaving-one-out" w posiadanej implementacji danej metody.

4. Wnioski

W pracy przedstawiono koncepcję regułowego systemu wspomaganie decyzji o klasyfikowaniu nowych obiektów. Reguły decyzyjne są pozyskiwane z przykładów uczących z wykorzystaniem elementów teorii zbiorów przybliżonych. W systemie, w celu rozstrzygnięcia niejednoznaczności wynikających z braku dopasowywania opisu nowego obiektu do części warunkowych istniejących reguł zastosowano oryginalną koncepcję wartościowanej relacji bliskości. W proponowanym systemie możliwe jest uwzględnianie współdziałania decydenta w wypracowywaniu zaleceń klasyfikacyjnych.

Wyniki przeprowadzonego eksperymentu obliczeniowego wskazują, że proponowane koncepcje rozstrzygnięcia sytuacji konfliktowych związanych z niejednoznacznym dopasowaniem oraz poszukiwaniem reguł bliskich okazały się efektywne z punktu widzenia poprawy trafności klasyfikowania (Por. tabela 2).

Trafność klasyfikowania nowych obiektów otrzymana za pomocą implementacji proponowanego systemu jest także porównywalna z wynikami osiągniętymi przez implementacje innych metod. Analizując osiągnięte wyniki należy zauważyć, że posługiwanie się tylko prostą strategią jednoznacznego dopasowania (PRISM i Etap1 RS_SWD w tabeli 2) nie daje zadowalających rezultatów.

LITERATURA

1. Breiman L, Friedman J.H., Olshen R., Stone C.J.: *Classification and Regression Trees*, Wadsworth & Brooks (1984).
2. Cendrowska J.: PRISM, an algorithm for inducing modular rules. *Int. J. Man-Machine Studies*, 27 (1987), 349-370.
3. Cestnik B., Kononenko I., Bratko I.: Assistant 86, a knowledge elicitation tool for sophisticated users. W Bratko I., Lavrac N. (red.) *Progress in Machine Learning*, Sigma Press, Wilmslow (1987), 31-45.
4. Clark P., Niblett T.: The CN2 induction algorithm. *Machine Learning* 3 (1989), 261-283.
5. Grzymala-Busse J.W.: LERS - A system for learning from examples based on rough sets. W *Intelligent Decision Support. Handbook of Applications and Advances of the Rough Sets Theory*. Słowiński R. (red.) Kluwer Academic Publishers (1992), 3-18.
6. Grzymala-Busse J.W.: Managing uncertainty in machine learning from examples. Proceedings of 3rd Int. Symp. on Intelligent Systems, Wigry 1994, Springer Verlag (w druku).
7. Murphy P.M., Aha, D.W.: UCI Repository of machine learning databases. [Machine-readable data repository]. Irvine, CA., University of California, Department of Information and Computer Science. (1991)
8. Michalski R.S.: A theory and methodology of inductive learning. W Michalski R.S., Carbonell J.G., Mitchell T.M. (red.) *Machine learning: An Artificial Intelligence Approach*, Morgan Kaufmann Publishers, Los Altos (1983), .

9. Michalski R.S., Mozetic I., Hong J., Lavrac N.: The multi-purpose incremental learning system AQ15 and its testing application to three medical domains. *Proc. of the 5th Nat. Conf. on AI* (1986), 1041-1045.
10. Pawlak Z.: Rough sets. *Int. J. Computer and Information Sci.* **11** (1982), 341-356.
11. Pawlak Z.: *Rough Sets. Theoretical Aspects of Reasoning about Data*. Kluwer Academic Publishers (1991).
12. Pawlak Z. Słowiński: Rough set approach to multi-attribute decision analysis. *European Journal of Operational Research*, **72**, 443-459.
13. Quinlan J.R.: Probabilistic decision trees. W *Machine Learning: An Artificial Intelligence Approach*, vol. III, Kodratoff Y., Michalski R.S. (red.) Morgan Kaufmann Publishers (1990), 140-152.
14. Quinlan J.R.: *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers (1993).
15. Roy B.: *Méthodologie Multicritère d'Aide a la Décision*. Economica, Paris (1995).
16. Roy B., Bouyssou D.: *Aide Multicritere a la Decision: Méthodes et Cas*, Economica, Paris 1993.
17. Słowiński R. (red): *Intelligent Decision Support. Handbook of Applications and Advances of the Rough Sets Theory*. Kluwer Academic Publishers (1992)
18. Słowiński R.: Rough sets learning of preferential attitude in multi-criteria decision making. W: Komorowski J., Raś Z.W. (red.): *Proc. of Int. Symp. on Methodologies for Intelligent Systems*, LNAI 689, Springer Verlag, Berlin (1993), 642-651.
19. Słowiński R., Stefanowski J.: 'RoughDAS' and 'RoughClass' software implementations of the rough set approach. W *Intelligent Decision Support. Handbook of Applications and Advances of the Rough Sets Theory*. Słowiński R. (red.) Kluwer Academic Publishers (1992), 445-456.
20. Słowiński R., Stefanowski J.: Rough Classification with Valued Closeness Relation. W Diday E. (red.) *Post-Proceedings of the 4th Conference of the Int. Federations of Classification Societies. Paris 1993* Springer-Verlag w druku/ także jako ICS Warsaw University of Technology Research Report 25/94.
21. Stefanowski J.: Classification and Decision Supporting Based on the Rough Set Theory. *Foundations of Decision and Computing Sciences*, **18** (1993), 371-380.
22. Stefanowski J.: Dialogowe wspomaganie decyzji na podstawie wiedzy pozyskanej metodą zbiorów przybliżonych. Rozprawa doktorska. Politechnika Poznańska, Wydz. Elektryczny (1994).
23. Teghem J., Benjelloun M.: Some experiments to compare rough sets theory and ordinal statistical methods. W *Intelligent Decision Support. Handbook of Applications and Advances of the Rough Sets Theory*. Słowiński R. (red.) Kluwer Academic Publishers (1992), 165-180.
24. Weiss S. M. , Kulikowski C.A. *Computer Systems That Learn: Classification and Prediction Methods from Statistics, Neural Nets, Machine Learning, and Expert Systems*. Morgan Kaufmann Publishers (1991).

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**