

Małgorzata PRZYBYŁA-KASPEREK  
Uniwersytet Śląski, Instytut Informatyki

## **OCENA EFEKTYWNOŚCI WNIOSKOWANIA WIELOAGENTOWEGO SYSTEMU DECYZYJNEGO DZIAŁAJĄCEGO NA PODSTAWIE REGUŁ DECYZYJNYCH, WYGENEROWANYCH Z WYKORZYSTANIEM LOKALNYCH BAZ WIEDZY**

**Streszczenie.** Artykuł zawiera zagadnienia dotyczące procesu podejmowania decyzji globalnych na podstawie wiedzy zgromadzonej w kilku lokalnych bazach wiedzy. Lokalne bazy wiedzy zawierają informacje dotyczące tej samej dziedziny, ale określone są na różnych zbiorach atrybutów warunkowych, które nie muszą być rozłączne. Artykuł zawiera opis wieloagentowego systemu decyzyjnego o strukturze hierarchicznej oraz propozycję metody eliminacji niespójności wiedzy, działającej na podstawie reguł decyzyjnych, wygenerowanych z użyciem lokalnych baz wiedzy. Głównym celem artykułu jest porównanie efektywności wnioskowania, uzyskanej przy zastosowaniu metody eliminacji niespójności wiedzy, działającej na podstawie reguł decyzyjnych z efektywnością wnioskowania, otrzymaną przy zastosowaniu znanych z literatury metod eliminacji niespójności wiedzy.

**Słowa kluczowe:** system decyzyjny, system wieloagentowy, decyzja globalna, zbiory przybliżone, reguły decyzyjne

## **EVALUATION OF EFFECTIVENESS OF INFERENCE OF MULTI-AGENT DECISION-MAKING SYSTEM, OPERATING ON THE BASIS OF DECISION RULES, GENERATED BASED ON LOCAL KNOWLEDGE BASES**

**Summary.** The paper includes issues related to process of global decision-making on the basis of knowledge which is stored in several local knowledge bases. The local knowledge bases, that are used, contain information on the same subject, but are defined on different sets of conditional attributes that are not necessarily disjoint. The paper contains a description of a multi-agent decision-making system with a hierarchical structure. In the paper a method of elimination inconsistencies in the knowledge operating on the basis of decision rules generated based on local

knowledge bases was proposed. The main aim of this paper is to compare the efficiency of inference obtained using the method of elimination inconsistencies in the knowledge operating on the basis of decision rules, with the efficiency of inference obtained using the methods of elimination inconsistencies in the knowledge, which are known from the literature.

**Keywords:** decision-making system, multi-agent system, global decision, rough sets, decision rules

## 1. Wprowadzenie

Problem klasyfikacji polega na podejmowaniu decyzji dla pewnego nowego obiektu przy wykorzystaniu wnioskowania i wiedzy zawartej w bazie wiedzy. Obecnie z powodu dużego nagromadzenia wiedzy coraz częściej wiedza jest gromadzona w postaci wielu lokalnych baz wiedzy. W tej sytuacji wykorzystanie tylko jednej lokalnej bazy wiedzy w procesie podejmowania decyzji nie jest wystarczające. Problem rozpatrywany w artykule dotyczy złożonych baz wiedzy, w których istotna jest możliwość współpracy baz lokalnych dla wypracowania wspólnej decyzji – decyzji globalnej.

W artykule omówiono system decyzyjny, który umożliwia podejmowanie decyzji globalnej na podstawie wiedzy rozproszonej. W systemie tym nie zakładamy, że zbiory atrybutów warunkowych różnych baz wiedzy muszą być rozłączne, dlatego też może wystąpić niespójność wiedzy zgromadzonej w różnych bazach wiedzy. Przez niespójność wiedzy rozumiemy sytuację, w której na podstawie dwóch różnych baz wiedzy o wspólnych atrybutach warunkowych, dla tych samych wartości na atrybutach wspólnych, korzystając z logicznych implikacji, podejmowane są sprzeczne decyzje. W omówionym w niniejszej pracy systemie decyzyjnym proces eliminacji niespójności wiedzy jest realizowany w dwóch etapach. W pierwszym etapie bazy wiedzy o wspólnych atrybutach warunkowych są łączone w grupy. W drugim etapie stosujemy metodę eliminacji niespójności wiedzy w stworzonych grupach baz wiedzy. Przy takiej strukturze systemu oraz przy tak prowadzonym wnioskowaniu w grupach baz wiedzy występuje problem analizy konfliktów. Przez konflikt rozumiemy sytuację, w której dla zadanego obiektu testowego, na podstawie wiedzy zgromadzonej w różnych grupach baz wiedzy, podejmowane są sprzeczne decyzje. W pracy stosowane są dwie metody analizy konfliktów, umożliwiające wnioskowanie mimo występowania konfliktów. Celem niniejszego artykułu jest porównanie efektywności wnioskowania, uzyskanej przy zastosowaniu metody eliminacji niespójności wiedzy, działającej na podstawie reguł decyzyjnych, z efektywnością wnioskowania, otrzymaną przy zastosowaniu metod eliminacji niespójności wiedzy, zaproponowanych w pracach [20, 21, 22, 23, 24, 25, 26, 27, 28, 29].

Zagadnienie podejmowania decyzji globalnej na podstawie wielu decyzji lokalnych jest również rozważane w podejściu wielomodelowym (ang. *multiple model approach*) [2, 5, 8,

9]. Zagadnienie, które jest przedmiotem niniejszego artykułu, jest z gruntu odmienne. Dotyczy ono zastosowania kilku już istniejących baz wiedzy. Zatem w artykule przyjęto założenie, że postaci baz wiedzy, na podstawie których podejmowana jest decyzja globalna, będą zadane z góry. W pracy [10] Ryszarda Michalskiego i Janusza Wojtusiaka przedstawiono odmienne podejście do problemu agregacji informacji. Autorzy rozważają sytuację, w której zbiór uczący jest podzielony na kilka podzbiorów, a dla każdego podzbioru są podane tylko zagregowane wartości atrybutów. W pracy [18] Andrzeja Skowrona, Hui Wanga, Arkadiusza Wojna i Jana Bazana przedstawiono metodę konstrukcji ciągu modeli, które tworzą strukturę hierarchiczną przez stopniowe osłabienie założeń spełnianych przez modele. Metoda ta została opracowana w celu poprawy dokładności klasyfikacji dokonywanej na podstawie wiedzy zgromadzonej w jednej bazie wiedzy. W pracy [6] Jerzego Grzymały-Busse, Lindy Goodwin i Xinqun Zhenga przedstawiono metodę analizy konfliktów, zaistniałych podczas klasyfikacji, dla zbioru danych z dwiema klasami decyzyjnymi o bardzo zróżnicowanej liczbie obiektów w poszczególnych klasach. W metodzie tej jest wybierany pewien zbiór reguł optymalnych, którego elementy są w zadany sposób wyróżnione (ang. *strength multiplier*). Analiza konfliktów ma swoje korzenie w teorii gier. Podstawowymi metodami oceny koalicji w teorii gier są indeks Shapleya-Shubika oraz indeks Banzhafa [19]. W literaturze można również znaleźć modele pozwalające na opisanie w prosty sposób skomplikowanej struktury konfliktu; są to między innymi: model Zdzisława Pawlaka [11, 12] oraz model Andrzeja Skowrona i Rafała Deji [3, 16].

## 2. Struktura systemu wieloagentowego

W artykule przyjmujemy, że każdą lokalną bazą wiedzy zarządza jeden agent. Wykorzystywane w artykule pojęcie agenta zostało wprowadzone przez Zdzisława Pawlaka w pracy [12]. Będziemy wykorzystywać dwa rodzaje agentów. Pierwszym z nich jest agent zasobów (ang. *resource agent*), który ma dostęp do własnej, lokalnej bazy wiedzy, na podstawie której może podjąć decyzję lokalną w drodze procesów wnioskowania.

**Definicja 2.1.** Niech  $\mathbf{Ag}$  będzie skończonym zbiorem agentów  $\mathbf{Ag} = \{ag_1, \dots, ag_n\}$ . Każdy agent  $ag_i \in \mathbf{Ag}$  jest nazywany agentem zasobów, gdyż ma on dostęp do pewnych zasobów w postaci tablicy decyzyjnej  $\mathbf{D}_{ag_i} = (\mathbf{U}_{ag_i}, \mathbf{A}_{ag_i}, \mathbf{d}_{ag_i})$ , gdzie:  $\mathbf{U}_{ag_i}$  jest zbiorem zwanym uniwersum, a elementy zbioru  $\mathbf{U}_{ag_i}$  nazywamy obiektami;  $\mathbf{A}_{ag_i}$  jest zbiorem atrybutów warunkowych;  $\mathbf{d}_{ag_i}$  nazywamy atrybutem decyzyjnym.

Agenci zasobów, którzy wnioskują na podstawie wspólnych atrybutów, są łączeni w grupy. *Klastrem* nazywamy najmniejszy, ze względu na relację inkluzji, podzbiór zbioru agen-

tów zasobów  $\{ag_{i_1}, \dots, ag_{i_k}\} \subseteq Ag$ ,  $i_1, \dots, i_k \in \{1, \dots, n\}$ , spełniający dwa następujące warunki:  $\forall j \in \{1, \dots, k\} \exists l \in \{1, \dots, k\}; l \neq j A_{ag_{i_j}} \cap A_{ag_{i_l}} \neq \emptyset$  oraz  $\forall l \in \{1, \dots, n\} \setminus \{i_1, \dots, i_k\} \forall j \in \{1, \dots, k\} A_{ag_l} \cap A_{ag_{i_j}} = \emptyset$ .

Do każdego klastra definiujemy agenta syntezy (ang. *synthesis agent*), oznaczonego  $as_j$ , gdzie  $j$  to numer klastra. Agent syntezy ma dostęp do wiedzy, będącej wynikiem procesu wnioskowania, przeprowadzonego przez agentów zasobów należących do grupy jemu pod rządnej.

**Definicja 2.2.** Przez wieloagentowy system decyzyjny będziemy rozumieli czwórkę  $WSD_{Ag} = \langle Ag, \{D_{ag}: ag \in Ag\}, As, \delta \rangle$ , gdzie:  $Ag$  jest skończonym zbiorem agentów zasobów;  $\{D_{ag}: ag \in Ag\}$  jest zbiorem tablic decyzyjnych agentów zasobów;  $As$  jest skończonym zbiorem agentów syntezy;  $\delta: As \rightarrow 2^{Ag}$  jest różnowartościową funkcją przyporządkowującą każdemu agentowi syntezy jeden klastr.

Definicja oraz struktura wieloagentowego systemu decyzyjnego zostały szczegółowo omówione w pracach [22, 26, 28].

### 3. Metoda agregacji reguł wspierających

W niniejszym artykule rozważamy metodę podejmowania decyzji globalnych, w której na podstawie każdej tablicy decyzyjnej agenta zasobów wyznaczany jest zbiór reguł decyzyjnych. W bieżącym rozdziale podamy, w jaki sposób, wykorzystując zagadnienia teorii zbiorów przybliżonych, generowane są zbiory reguł. Rozpocznijmy od podania definicji reguły. Niech  $D = (U, A, d)$  będzie tablicą decyzyjną oraz niech zbiór  $P = \{b_1, \dots, b_k\}$  będzie podzbiorem zbioru atrybutów  $A$ . Formułę  $\alpha$  w postaci  $\alpha = (b_1, v_1) \wedge \dots \wedge (b_k, v_k)$ , gdzie  $v_i \in V^{b_i}, i \in \{1, \dots, k\}$ , nazywamy *P-formułą*. Mówimy, że obiekt  $x \in U$  spełnia *P-formułę*  $\alpha$  w tablicy  $D$  wtedy i tylko wtedy, gdy  $\forall i \in \{1, \dots, k\} b_i(x) = v_i$ . *Regułą decyzyjną* nazywamy wyrażenie w postaci  $\alpha \Rightarrow (d, v)$ , gdzie  $\alpha$  jest formułą oraz  $v \in V^d$ .

Reguły definiowane są tak, aby opisywały pewne zależności występujące w tablicy decyzyjnej. Na podstawie reguły decyzyjnej może być przeprowadzona klasyfikacja nowego obiektu do klasy decyzyjnej wskazanej przez następnik reguły. Klasyfikacja ta zazwyczaj przebiega w następujący sposób: jeśli nowy obiekt spełnia poprzednik reguły, czyli formułę  $\alpha$ , to wartość tego obiektu na atrybucie decyzyjnym  $d$  jest równa wartości decyzji, która występuje w następniku reguły. Niestety wnioskowanie takie nie jest wnioskowaniem niezawodnym, czyli od prawdziwych przesłanek można przejść do fałszywego wniosku. Dlatego w licznych pracach [1, 15, 17] rozpatrywane są różne metody generowania zbioru reguł de-

czyjnych oraz różne metody wyboru reguły, za pomocą której będziemy klasyfikować nowy obiekt do klasy decyzyjnej.

W niniejszym artykule, w celu wygenerowania reguł decyzyjnych na podstawie tablic decyzyjnych agentów zasobów, wykorzystano program Rough Set Exploration System (RSES [31]), który został stworzony na Uniwersytecie Warszawskim pod kierunkiem Andrzeja Skowrona. Program ten umożliwia analizę danych w postaci tablicowej, z zastosowaniem teorii zbiorów przybliżonych, sformułowanej w 1982 roku przez Zdzisława Pawłaka. Program RSES wykorzystano również do przeprowadzenia eksperymentów wstępnych, które miały na celu wybranie metody generowania reguł decyzyjnych, która gwarantuje największą efektywność wnioskowania rozważanego systemu decyzyjnego. Rozpatrzono wszystkie dostępne w programie RSES metody generowania reduktów oraz metody generowania reguł decyzyjnych i stwierdzono, że największą efektywność wnioskowania zapewnia metoda generowania reguł decyzyjnych agentów zasobów, która składa się z dwóch etapów:

- 1) generowanie zbioru reduktów względem atrybutu decyzyjnego i obiektu,
- 2) generowanie, na podstawie zbioru reduktów, reguł decyzyjnych metodą lokalną.

W dalszej części przedstawiono definicje rozróżnialności obiektów oraz reduktu względem atrybutu decyzyjnego i obiektu.

**Definicja 3.1.** Niech  $D = (U, A, d)$  będzie tablicą decyzyjną oraz niech będą dane obiekty  $x, y \in U$  i podzbiór atrybutów warunkowych  $B \subseteq A$ . Mówimy, że obiekty  $x, y$  są rozróżnialne przez  $B$  wtedy i tylko wtedy, gdy istnieje  $a \in B$  taki, że  $a(x) \neq a(y)$ .

**Definicja 3.2.** Niech  $D = (U, A, d)$  będzie tablicą decyzyjną. Zbiór atrybutów  $B \subseteq A$  nazywamy reduktem względem atrybutu decyzyjnego i obiektu  $x \in U$  tablicy decyzyjnej  $D$  wtedy i tylko wtedy, gdy: dla dowolnego obiektu  $y \in U$ , jeśli  $d(x) \neq d(y)$  i  $x, y$  są rozróżnialne przez  $A$ , to są również rozróżnialne przez  $B$ ; żaden właściwy podzbiór zbioru  $B$  nie spełnia powyższego warunku.

Zatem w pierwszym etapie metody generowania reguł decyzyjnych definiowane są redukty zgodnie z definicją 3.2. W kolejnym etapie metody dla każdego reduktu definiowana jest podtablica tablicy decyzyjnej agenta zasobów. Podtablica taka zawiera atrybuty warunkowe występujące w redukcji, natomiast zbiór uniwersum oraz atrybut decyzyjny pozostają takie same w pierwotnej tablicy decyzyjnej. Dla takiej podtablicy liczone są reguły z minimalną liczbą deskryptorów. Reguły takie mają następującą własność: nie można z niej już usunąć żadnej formuły atomowej poprzednika, gdyż spowoduje to, że reguła będzie sprzeczna w tablicy decyzyjnej. Dokładny opis metody wyznaczania reguł z minimalną liczbą deskryptorów można znaleźć w pracach [15, 17]. Na koniec wszystkie otrzymane zbiory reguł dla poszczególnych reduktów tablicy decyzyjnej agenta zasobów są sumowane do jednego zbioru reguł.

Kiedy już dla każdej tablicy decyzyjnej agenta zasobów zostanie wygenerowany zbiór reguł decyzyjnych, realizowana jest metoda eliminacji niespójności wiedzy. W metodzie agregacji reguł wspierających każdy agent syntezy dysponuje zbiorem zagregowanych reguł decyzyjnych, które są konstruowane na podstawie reguł agentów zasobów, należących do klastra podrzędnego wobec danego agenta syntezy. Reguły zagregowane tworzymy w sposób następujący. Dla każdego maksymalnego, ze względu na relację inkluzji, zbioru niesprzecznych reguł decyzyjnych różnych agentów zasobów z jednego klastra definiujemy jedną nową regułę. Przy czym mówimy, że reguły  $\alpha \Rightarrow (d, v_1)$  i  $\beta \Rightarrow (d, v_2)$  są niesprzeczne wtedy i tylko wtedy, gdy:

- 1) jeśli w formułach  $\alpha$  i  $\beta$  istnieją formuły atomowe, w których występuje ten sam atrybut, to wartości atrybutu zadane w tych formułach atomowych są równe, tzn.  $(\alpha \equiv (a, v_1^a) \wedge \alpha' \text{ oraz } \beta \equiv a, v_2^a \wedge \beta' \Rightarrow (v_1^a = v_2^a))$ , gdzie  $\alpha'$  i  $\beta'$  są formułami,
- 2)  $v_1 = v_2$ .

Nowa reguła jest definiowana w następujący sposób: poprzednik reguły jest koniunkcją poprzedników rozważanych reguł decyzyjnych agentów zasobów, natomiast następnik jest taki sam jak następnik każdej z rozważanych reguł decyzyjnych agentów zasobów.

Klasyfikacja nowego obiektu polega na wybraniu ze zbiorów reguł agentów syntezy reguł, których poprzednik jest spełniany przez nowy obiekt. Zazwyczaj obiekt testowy jest rozpoznawany przez wiele reguł należących do zbioru reguł jednego agenta syntezy, które klasyfikują go do różnych klas decyzyjnych. Wówczas każda z reguł decyzyjnych rozpoznających obiekt testowy oddaje jeden głos na rzecz wartości decyzji, która występuje w następniku reguły. W ten sposób dla każdego agenta syntezy  $j \in \{1, \dots, \text{card}\{As\}\}$  wyliczany jest  $c$ -wymiarowy wektor  $[\mu_{j,1}(x), \dots, \mu_{j,c}(x)]$ , gdzie wartość  $\mu_{j,i}(x)$  oznacza liczbę głosów, jaką uzyskała  $i$ -ta klasa decyzyjna przy klasyfikacji obiektu testowego  $x$ , a  $c$  jest liczbą wszystkich klas decyzyjnych. Oczywiście opisana metoda rozstrzygnięcia konfliktów pomiędzy regułami rozpoznającymi obiekt testowy jest jedną z możliwych metod rozwiązania tego problemu. Podczas eksperymentów wstępnych zbadano, że ta metoda gwarantuje największą efektywność wnioskowania w sytuacji rozważanej w artykule.

#### 4. Metody eliminacji niespójności wiedzy i analizy konfliktów

Jak wspomniano wcześniej, celem niniejszego artykułu jest porównanie efektywności wnioskowania, uzyskanej przy zastosowaniu metody agregacji reguł wspierających, z efektywnością wnioskowania, otrzymaną przy zastosowaniu metod eliminacji niespójności wiedzy, zaproponowanych we wcześniejszych pracach, w których rozważano następujące metody eliminacji niespójności wiedzy: metodę boolowską analizy niespójności; metodę agregacji

tablic decyzyjnych; aproksymacyjną metodę agregacji tablic decyzyjnych; metodę agregacji tablic decyzyjnych poprzedzoną losową edycją i kondensacją Harta. Metody te zostały szczegółowo omówione w pracach [20, 21, 22, 23, 24, 25, 26, 27, 28, 29].

Analiza konfliktów jest realizowana po wykonaniu procesu eliminacji niespójności wiedzy, gdyż wówczas agenci syntezy mają dostęp do wiedzy, na podstawie której mogą podjąć decyzję lokalną o zasięgu jednego klastra. Zastosowane w artykule metody rozwiązania problemu analizy konfliktu to: głosowanie ważone oraz metoda algorytmu gęstościowego. Metody te umożliwiają analizowanie konfliktów oraz generowanie zbioru decyzji globalnych. W przypadku metody algorytmu gęstościowego zastosowano znany z literatury algorytm gęstościowy DBSCAN [4]. Zbiór decyzji globalnych, wygenerowanych z zastosowania tej metody, będzie zawierał nie tylko te wartości decyzji, które mają największe wsparcie wiedzy zgromadzonej w lokalnych bazach wiedzy, ale również takie, dla których wsparcie to jest relatywnie wysokie. Szczegółowe omówienie metod analizy konfliktów można znaleźć w pracach [23, 28].

## 5. Wyniki eksperymentów obliczeniowych

Do eksperymentów zostały użyte następujące zbiory danych, które są dostępne w repozytorium *UCI repository* [30]: Soybean Data Set, Dermatology Database, Landsat Satellite. W celu określenia efektywności wnioskowania wieloagentowego systemu decyzyjnego, w odniesieniu do analizowanych danych, dokonano podziału każdego zbioru danych na dwa rozłączne podzbiory: zbiór uczący oraz zbiór testowy. Wybrano tę metodę oceny efektywności wnioskowania, ponieważ w rozważanym podejściu podejmowania decyzji na podstawie wiedzy rozproszonej zastosowanie krosvalidacji byłoby dość kłopotliwe. Zakładamy, że wiedza jest zapisana w wielu różnych tablicach decyzyjnych (które są zadane z góry), przy czym nie przyjmujemy żadnych dodatkowych założeń o zbiorach atrybutów warunkowych i zbiorach obiektów tych tablic. Natomiast zbiór testowy jest zapisany w jednej tablicy decyzyjnej. Zatem w metodzie krosvalidacji należałoby z każdej tablicy decyzyjnej wylosować pewną próbkę testową, a następnie na podstawie wylosowanych próbek testowych wygenerować jeden zbiór testowy, zapisany w tablicy decyzyjnej. W rozważanym podejściu założono, że nie potrafimy identyfikować obiektów z różnych tablic decyzyjnych. Zatem wygenerowanie jednej tablicy decyzyjnej na podstawie wybranego zbioru próbek testowych jest bardzo kłopotliwe.

Zaproponowany wieloagentowy system decyzyjny umożliwia podejmowanie decyzji globalnych na podstawie wiedzy rozproszonej, zgromadzonej w kilku tablicach decyzyjnych. Z powodu braku dostępu do zbioru lokalnych baz wiedzy (wykorzystywanych w rzeczywi-

stości), które zawierałyby wiedzę z jednej dziedziny oraz miały wspólny atrybut decyzyjny, do eksperymentów wykorzystano zbiory z repozytorium *UCI repository*. W przyszłości planowane jest przeprowadzenie testów na rzeczywistych danych. Aby w pełni zbadać możliwości i ocenić efektywność wnioskowania wieloagentowego systemu decyzyjnego, każdy ze zbiorów uczących został podzielony na zbiór tablic decyzyjnych, przy czym rozpatrywano podziały na różną liczbę tablic decyzyjnych. Dla każdego z wykorzystywanych zbiorów danych rozważano wieloagentowe systemy decyzyjne o pięciu różnych strukturach, w wersji z 3, 5, 7, 9 oraz 11 agentami zasobów. Następnie na podstawie każdej tablicy decyzyjnej, za pomocą programu RSES, generowane były zbiory reguł w sposób omówiony wcześniej. W przypadku wieloagentowych systemów decyzyjnych z 3 agentami zasobów  $WSD_{Ag_1}$  zbioru danych Soybean i Dermatology oraz wieloagentowego systemu decyzyjnego z 5 agentami zasobów  $WSD_{Ag_2}$  zbioru danych Landsat Satellite algorytm realizujący metodę agregacji reguł wspierających, działający na podstawie pełnego zbioru reguł, nie zakończył analizy zbioru testowego w przeciągu 6 godzin. Zatem, aby skrócić czas potrzebny do analizy zbioru testowego, dla każdego z tych systemów decyzyjnych dokonano skrócenia reguł [31] (ze współczynnikiem 0,99) dla jednego agenta zasobów, który dysponował największą liczbą reguł. W przypadku wieloagentowego systemu decyzyjnego z 3 agentami zasobów  $WSD_{Ag_1}$  zbioru danych Landsat Satellite program RSES w przeciągu 12 godzin nie wygenerował zbioru reguł dla agentów zasobów. Dlatego też w dalszej części eksperymentów nie rozważano tego systemu decyzyjnego.

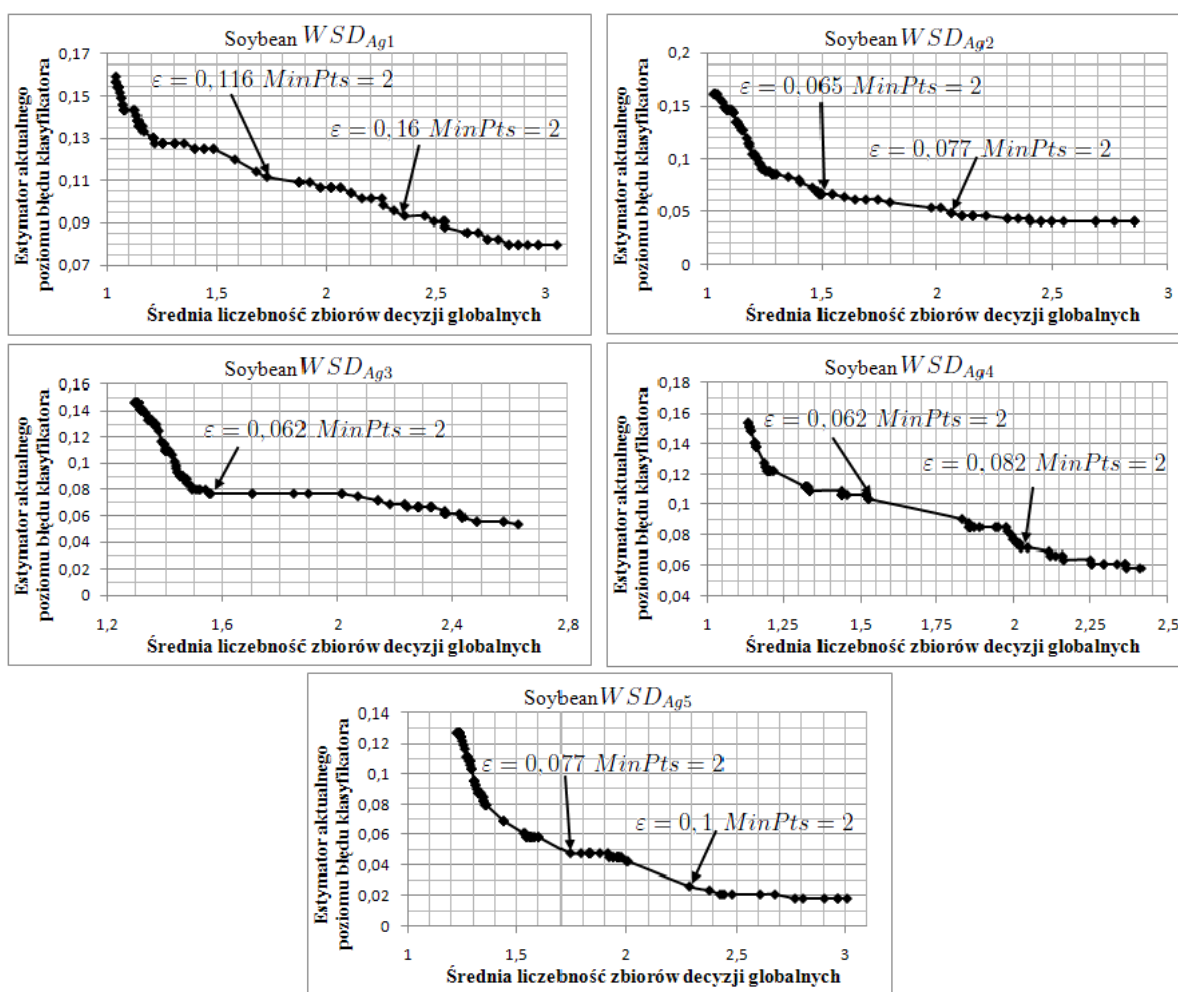
Miarami określającymi jakość klasyfikacji są: estymator aktualnego poziomu błędu klasyfikatora ( $e$ ), w którym za niepoprawnie sklasyfikowany przykład uważamy obiekt, którego klasa decyzyjna nie należy do zbioru decyzji globalnych wygenerowanych przez algorytm; estymator aktualnego poziomu błędu wieloznaczności klasyfikatora ( $e_{ONE}$ ), w którym obiekt uważamy za poprawnie sklasyfikowany, jeśli tylko jedna poprawna wartość decyzji została wygenerowana przez algorytm; średnia liczebność zbiorów decyzji globalnych wygenerowanych dla obiektów ze zbioru testowego ( $\bar{d}_{WSD_{Ag}}$ ).

### 5.1. Eksperymenty ze zbiorem danych Soybean

Testy na zbiorze danych Soybean rozpoczęto od optymalizacji parametrów  $\varepsilon$  oraz  $MinPts$  metody algorytmu gęstościowego. Na rysunku 1, dla wszystkich pięciu wieloagentowych systemów decyzyjnych rozważanych dla zbioru danych Soybean, zostały przedstawione wykresy, na których zaznaczone są punkty o współrzędnych  $(\bar{d}_{WSD_{Ag_i}}, e)$ ,  $i \in \{1,2,3,4,5\}$ , przy czym wartości te uzyskano, stosując algorytm realizujący agregację reguł wspierających oraz metodę algorytmu gęstościowego z różnymi wartościami parametru  $\varepsilon \in (0; 0,2)$ . Wartość parametru  $MinPts$  ustalono na podstawie eksperymentów wstępnych.



Na wykresach zaznaczono punkty, dla których stwierdzono największą poprawę efektywności wnioskowania. Punkty te spełniają następujący warunek: na lewo od danego punktu można zauważyć wyraźny spadek wartości estymatora aktualnego poziomu błędów klasyfikatora, natomiast na prawo od punktu następuje już nieznaczny spadek wartości tego estymatora wraz ze wzrostem wartości parametru  $\varepsilon$ . Dla każdego zaznaczonego na wykresie punktu podano odpowiadające mu wartości parametrów  $\varepsilon$  oraz  $MinPts$ . W drugim kroku eksperymentów zastosowano algorytm realizujący agregację reguł wspierających oraz głosowanie ważone.



Rys. 1. Optimalizacja parametrów metody algorytmu gęstościowego dla zbioru Soybean  
Fig. 1. Parameters optimization density algorithm method for Soybean set

W tabeli 1 zamieszczono wyniki eksperymentów. Podane są w niej następujące informacje: nazwa wieloagentowego systemu decyzyjnego (System); oznaczenie algorytmu (Algorytm), w którym pierwsza część symbolizuje metodę eliminacji niespójności wiedzy, a druga metodę analizy konfliktów. Przyjęto następujące oznaczenia: R – metoda agregacji reguł wspierających, W – metoda głosowania ważonego,  $G(\varepsilon, MinPts)$  – metoda algorytmu gęsto-

ściowego z parametrami  $\varepsilon$  oraz  $MinPts$ ; wartości trzech omówionych wcześniej miar  $e$ ,  $e_{ONE}$ ,  $\bar{d}_{WSD_{Ag}}$ ; wyrażony w minutach czas potrzebny do analizy zbioru testowego  $t$ .

W pracy [27] zamieszczono wyniki eksperymentów przeprowadzonych dla zbioru danych Soybean z zastosowaniem czterech metod eliminacji niespójności wiedzy, które wymieniono w rozdziale 4. Dla porównania w tabeli 2 przytoczono te wyniki. Oznaczenia występujące w tabeli 2 są takie same jak w tabeli 1, przy czym przyjęto następujące oznaczenia algorytmów (Algorytm): B – metoda boolowska analizy niespójności, T – metoda agregacji tablic decyzyjnych, A(m) – aproksymacyjna metoda agregacji tablic decyzyjnych z parametrem m, E(l;r) – metoda agregacji tablic decyzyjnych poprzedzona losową edycją i kondensacją Harta z parametrami l oraz r.

Tabela 1

Podsumowanie wyników eksperymentów ze zbiorem danych Soybean – metoda agregacji reguł wspierających

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	RG(0,16;2)	0,093	0,258	2,354	22,30
	RG(0,116;2)	0,112	0,242	1,731	22,30
	RW	0,159	0,199	1,040	22,30
$WSD_{Ag_2}$	RG(0,077;2)	0,048	0,309	2,066	2,49
	RG(0,065;2)	0,066	0,284	1,489	2,49
	RW	0,181	0,181	1,024	2,49
$WSD_{Ag_3}$	RG(0,062;2)	0,077	0,277	1,557	8,04
	RW	0,189	0,239	1,295	8,04
$WSD_{Ag_4}$	RG(0,082;2)	0,072	0,255	2,021	0,19
	RG(0,062;2)	0,104	0,221	1,524	0,19
	RW	0,178	0,242	1,069	0,19
$WSD_{Ag_5}$	RG(0,1;2)	0,027	0,303	2,290	0,08
	RG(0,077;2)	0,048	0,287	1,739	0,08
	RW	0,157	0,226	1,231	0,08

Na podstawie wyników eksperymentów, zamieszczonych w tabelach 1 oraz 2, można wyciągnąć następujące wnioski. Dla wszystkich rozważanych typów wieloagentowych systemów decyzyjnych algorytmy  $TG(\varepsilon, MinPts)$  oraz  $A(m)G(\varepsilon, MinPts)$  uzyskują lepsze wyniki niż algorytm  $RG(\varepsilon, MinPts)$ . Jedynie dla wieloagentowego systemu decyzyjnego z 11 agentami zasobów  $WSD_{Ag_5}$  algorytm  $RG(\varepsilon, MinPts)$  uzyskuje niższą wartość estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ), ale kosztem zwiększonej średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}}$ ). Algorytm  $RG(\varepsilon, MinPts)$  uzyskuje przeważnie znacznie lepsze wyniki niż algorytm  $E(l;r)G(\varepsilon, MinPts)$ . Wyjątek stanowi jedynie wieloagentowy system decyzyjny z 3 agentami zasobów  $WSD_{Ag_1}$ , w którym dokonano skracania reguł dla jednego agenta zasobów z największą liczbą reguł. W przypadku tego systemu algorytm  $E(l;r)G(\varepsilon, MinPts)$  uzyskał lepsze wyniki niż algorytm  $RG(\varepsilon, MinPts)$ . W przypadku

wieloagentowego systemu decyzyjnego z 7 agentami zasobów  $WSD_{Ag_3}$  algorytm  $RG(\varepsilon, MinPts)$  uzyskał wyniki zbliżone do wyników otrzymanych dla algorytmu  $E(l; r)G(\varepsilon, MinPts)$ . Algorytmy  $BW$  oraz  $TW$  uzyskują lepsze wyniki niż algorytm  $RW$ .

Tabela 2

Podsumowanie wyników eksperymentów ze zbiorem danych Soybean – metody niewymagające generowania zbioru reguł

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	TG(0,0025;2)	0,027	0,282	1,699	7,43
	A(1)G(0,0025;2)	0,027	0,295	2,005	0,03
	E(200;119)G(0,00275;2)	0,086	0,396	2,019	0,03
	BW	0,146	0,223	1,146	0,01
	TW	0,112	0,186	1,114	7,43
$WSD_{Ag_2}$	TG(0,006;2)	0,024	0,266	1,705	3,51
	A(1)G(0,00575;2)	0,035	0,327	1,968	0,02
	E(200;119)G(0,007;2)	0,110	0,412	2,008	0,03
	BW	0,144	0,215	1,141	0,02
	TW	0,122	0,178	1,096	3,51
$WSD_{Ag_3}$	TG(0,0065;2)	0,008	0,287	1,665	2,42
	A(1)G(0,00575;2)	0,008	0,306	1,968	0,03
	E(200;119)G(0,00675;2)	0,056	0,325	1,876	0,03
	BW	0,114	0,253	1,215	0,02
	TW	0,085	0,199	1,152	2,38
$WSD_{Ag_4}$	TG(0,012;2)	0,029	0,324	1,843	2,37
	A(1)G(0,0108;2)	0,058	0,319	1,755	0,03
	E(200;119)G(0,0124;2)	0,118	0,391	1,973	0,03
	BW	0,090	0,194	1,176	0,02
	TW	0,082	0,181	1,122	2,37
$WSD_{Ag_5}$	TG(0,0148;2)	0,032	0,316	2,008	1,54
	A(1)G(0,0128;2)	0,029	0,309	1,755	0,03
	E(200;119)G(0,0148;2)	0,126	0,425	1,960	0,03
	BW	0,109	0,242	1,274	0,02
	TW	0,098	0,207	1,141	1,52

## 5.2. Eksperymenty ze zbiorem danych Dermatology

W pierwszym kroku eksperymentów ze zbiorem danych Dermatology wartości parametrów  $\varepsilon$  oraz  $MinPts$  metody algorytmu gęstościowego optymalizowane były przy zastosowaniu algorytmu realizującego agregację reguł wspierających. Optymalizacja wartości tych parametrów była realizowana w taki sam sposób jak dla zbioru danych Soybean. W drugim kroku eksperymentów zastosowano algorytm realizujący agregację reguł wspierających oraz głosowanie ważone. W tabeli 3 zamieszczono wyniki eksperymentów. Oznaczenia występujące w tej tabeli są takie same jak w tabeli 1.

Dla porównania w tabeli 4 przytoczono wyniki eksperymentów (zamieszczone w pracy [27]) przeprowadzonych dla zbioru danych Dermatology z zastosowaniem metod eliminacji niespójności wiedzy, które wymieniono w rozdziale 4. Oznaczenia występujące w tabeli 4 są takie same jak w tabeli 2.

Tabela 3

Podsumowanie wyników eksperymentów ze zbiorem danych Dermatology – metoda agregacji reguł wspierających

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	RG(0,028;2)	0,045	0,127	1,155	12,20
	RW	0,091	0,091	1	12,20
$WSD_{Ag_2}$	RG(0,117;2)	0,009	0,264	1,564	8,40
	RG(0,084;2)	0,018	0,200	1,245	8,40
	RW	0,145	0,145	1	8,40
$WSD_{Ag_3}$	RG(0,09;2)	0	0,118	1,136	0,10
	RG(0,033;2)	0,009	0,073	1,064	0,10
	RW	0,100	0,100	1	0,10
$WSD_{Ag_4}$	RG(0,197;2)	0,009	0,200	1,400	0,08
	RG(0,051;2)	0,018	0,064	1,055	0,08
	RW	0,127	0,127	1	0,08
$WSD_{Ag_5}$	RG(0,143;2)	0	0,127	1,245	0,05
	RG(0,128;2)	0,009	0,118	1,173	0,05
	RW	0,136	0,136	1	0,05

Na podstawie wyników eksperymentów, zamieszczonych w tabelach 4 oraz 5, można wyciągnąć następujące wnioski. W przypadku wieloagentowych systemów decyzyjnych z 3 i 5 agentami zasobów  $WSD_{Ag_1}$ ,  $WSD_{Ag_2}$  algorytmy  $TG(\epsilon, MinPts)$  oraz  $A(m)G(\epsilon, MinPts)$  uzyskują lepsze wyniki niż algorytm  $RG(\epsilon, MinPts)$ . W przypadku wieloagentowego systemu decyzyjnego z 7 agentami zasobów  $WSD_{Ag_3}$  algorytm  $RG(\epsilon, MinPts)$  uzyskuje znacznie lepsze wyniki niż algorytm  $A(m)G(\epsilon, MinPts)$  oraz trochę lepsze wyniki niż algorytm  $TG(\epsilon, MinPts)$ . W przypadku wieloagentowego systemu decyzyjnego z 9 agentami zasobów  $WSD_{Ag_4}$  algorytm  $RG(\epsilon, MinPts)$  uzyskuje niską wartość estymatora aktualnego poziomu błędu klasyfikatora ( $e = 0,018$ ) przy bardzo małej średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}} = 1,055$ ), która jest znacznie mniejsza niż w przypadku algorytmów  $TG(\epsilon, MinPts)$  oraz  $A(m)G(\epsilon, MinPts)$ . Jednak jeszcze niższe wartości estymatora aktualnego poziomu błędu klasyfikatora są uzyskiwane przez algorytm  $RG(\epsilon, MinPts)$  już przy znacznie większej średniej liczebności zbiorów decyzji globalnych. W przypadku wieloagentowego systemu decyzyjnego z 11 agentami zasobów  $WSD_{Ag_5}$  algorytm  $RG(\epsilon, MinPts)$  uzyskuje tę samą wartość estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ) co algorytmy  $TG(\epsilon, MinPts)$  oraz  $A(m)G(\epsilon, MinPts)$  przy nieznacznie większej średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}}$ ). Dla wszystkich rozważanych typów wieloagentowych

systemów decyzyjnych algorytm  $RG(\varepsilon, MinPts)$  uzyskuje lepsze wyniki niż algorytm  $E(l; r)G(\varepsilon, MinPts)$ . Algorytmy  $BW$  oraz  $TW$  uzyskują lepsze wyniki niż algorytm  $RW$ .

Tabela 4  
Podsumowanie wyników eksperymentów ze zbiorem danych Dermatology – metody niewymagające generowania zbioru reguł

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	TG(0,002;2)	0	0,091	1,100	11,24
	TG(0,001;2)	0,009	0,018	1,009	11,24
	A(1)G(0,0015;2)	0	0,091	1,100	0,01
	A(1)G(0,0005;2)	0,009	0,018	1,009	0,01
	E(200;80)G(0,00325;2)	0,029	0,325	1,607	0,02
	E(200;80)G(0,0025;2)	0,051	0,258	1,329	0,02
	BW	0,018	0,018	1	0,01
	TW	0,018	0,018	1	11,23
$WSD_{Ag_2}$	TG(0,00325;2)	0	0,073	1,073	0,40
	TG(0,00075;2)	0,009	0,027	1,018	0,40
	A(1)G(0,00575;2)	0	0,273	1,427	0,01
	A(1)G(0,0015;2)	0,055	0,155	1,100	0,01
	E(200;96)G(0,0095;2)	0,014	0,294	1,501	0,02
	E(200;96)G(0,006;2)	0,031	0,208	1,250	0,02
	BW	0,045	0,045	1	0,01
	TW	0,027	0,027	1	0,39
$WSD_{Ag_3}$	TG(0,0065;2)	0	0,118	1,136	3,42
	TG(0,0055;2)	0,009	0,100	1,100	3,42
	A(1)G(0,0095;2)	0,009	0,255	1,318	0,01
	A(1)G(0,006;2)	0,027	0,191	1,191	0,01
	E(200;96)G(0,01505;2)	0,011	0,318	1,518	0,02
	E(200;96)G(0,0084;2)	0,036	0,213	1,221	0,02
	BW	0,027	0,045	1,018	0,01
	TW	0,082	0,091	1,009	3,42
$WSD_{Ag_4}$	TG(0,00725;2)	0	0,136	1,145	6,09
	TG(0,00275;2)	0,027	0,091	1,073	6,09
	A(1)G(0,012;2)	0,009	0,200	1,291	0,01
	A(1)G(0,00725;2)	0,018	0,155	1,145	0,01
	E(200;112)G(0,0168;2)	0,009	0,283	1,523	0,03
	E(200;112)G(0,0104;2)	0,029	0,199	1,239	0,03
	BW	0,036	0,045	1,009	0,01
	TW	0,055	0,064	1,009	6,06
$WSD_{Ag_5}$	TG(0,0145;2)	0	0,155	1,236	1,52
	TG(0,00625;2)	0,009	0,100	1,100	1,52
	A(1)G(0,00925;2)	0	0,136	1,191	0,01
	A(1)G(0,00625;2)	0,009	0,118	1,118	0,01
	E(200;112)G(0,0207;2)	0,009	0,260	1,503	3,03
	E(200;112)G(0,0135;2)	0,021	0,181	1,226	0,03
	BW	0,027	0,036	1,009	0,01

Tabela 4

Podsumowanie wyników eksperymentów ze zbiorem danych Dermatology –  
metody niewymagające generowania zbioru reguł

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
	TW	0,036	0,036	1	1,52

### 5.3. Eksperymenty ze zbiorem danych Landsat Satellite

Jak już wspomniano wcześniej, w przypadku zbioru danych Landsat Satellite oraz wieloagentowego systemu decyzyjnego z 3 agentami zasobów  $WSD_{Ag_1}$ , program RSES w przeciągu 12 godzin nie wygenerował zbioru reguł dla agentów zasobów, dlatego w dalszej części nie rozpatrujemy tej wersji wieloagentowego systemu decyzyjnego. W pierwszym kroku eksperymentów ze zbiorem danych Landsat Satellite wartości parametrów  $\varepsilon$  oraz  $MinPts$  metody algorytmu gęstościowego były optymalizowane przy zastosowaniu algorytmu realizującego agregację reguł wspierających. Optymalizacja wartości tych parametrów była realizowana w taki sam sposób jak dla zbioru danych Soybean. W drugim kroku eksperymentów zastosowano algorytm realizujący agregację reguł wspierających oraz głosowanie ważone. W tabeli 5 zamieszczono wyniki eksperymentów. Oznaczenia występujące w tej tabeli są takie same jak w tabeli 1.

Tabela 5

Podsumowanie wyników eksperymentów ze zbiorem danych Landsat Satellite  
– metoda agregacji reguł wspierających

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_2}$	RG(0,55;2)	0,059	0,262	1,743	48,00
	RG(0,314;2)	0,100	0,212	1,249	48,00
	RW	0,164	0,164	1	48,00
$WSD_{Ag_3}$	RG(0,528;2)	0,035	0,278	1,737	19,23
	RG(0,272;2)	0,071	0,202	1,245	19,23
	RW	0,163	0,163	1	19,23
$WSD_{Ag_4}$	RG(0,576;2)	0,036	0,279	1,739	14,05
	RG(0,312;2)	0,072	0,216	1,251	14,05
	RW	0,166	0,166	1	14,05
$WSD_{Ag_5}$	RG(0,65;2)	0,031	0,300	1,749	3,27
	RG(0,284;2)	0,063	0,218	1,254	3,27
	RW	0,155	0,155	1	3,27

Dla porównania w tabeli 6 przytoczono wyniki eksperymentów (zamieszczone w pracy [27]) przeprowadzonych dla zbioru danych Landsat Satellite z zastosowaniem metod eliminacji niespójności wiedzy, które wymieniono w rozdziale 4. Oznaczenia występujące w tabeli 5 są takie same jak w tabeli 2.

Na podstawie wyników eksperymentów, zamieszczonych w tabelach 6 oraz 7, można wyciągnąć następujące wnioski. Dla wszystkich rozważanych typów wieloagentowych systemów decyzyjnych algorytm  $A(m)G(\varepsilon, MinPts)$  uzyskuje lepsze wyniki niż algorytm  $RG(\varepsilon, MinPts)$ . W przypadku wieloagentowych systemów decyzyjnych z 5 i 7 agentami zasobów  $WSD_{Ag_2}, WSD_{Ag_3}$  algorytm  $E(l; r)G(\varepsilon, MinPts)$  uzyskuje lepsze wyniki niż algorytm  $RG(\varepsilon, MinPts)$ . W przypadku wieloagentowych systemów decyzyjnych z 9 i 11 agentami zasobów  $WSD_{Ag_4}, WSD_{Ag_5}$  oraz średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}}$ ), w przybliżeniu równej 1,25, algorytm  $RG(\varepsilon, MinPts)$  uzyskuje niższe wartości estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ) niż algorytm  $E(l; r)G(\varepsilon, MinPts)$ . Natomiast w przypadku średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}}$ ), w przybliżeniu równej 1,75, algorytm  $RG(\varepsilon, MinPts)$  uzyskuje wyższe wartości estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ) niż algorytm  $E(l; r)G(\varepsilon, MinPts)$ . Algorytm  $BW$  uzyskuje lepsze wyniki niż algorytm  $RW$ .

Tabela 6

Podsumowanie wyników eksperymentów ze zbiorem danych Landsat Satellite – metody niewymagające generowania zbioru reguł

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_2}$	A(1)G(0,0031;2)	0,012	0,396	1,744	3,08
	A(1)G(0,0012;2)	0,047	0,221	1,230	3,08
	E(200;528)G(0,0049;2)	0,024	0,438	1,720	8,37
	E(200;528)G(0,0021;2)	0,073	0,262	1,250	8,37
	BW	0,096	0,096	1	3,05
$WSD_{Ag_3}$	A(7)G(0,0046;2)	0,012	0,381	1,716	4,55
	A(7)G(0,0022;2)	0,047	0,232	1,255	4,55
	E(200;660)G(0,0064;2)	0,021	0,450	1,709	9,51
	E(200;660)G(0,0027;2)	0,071	0,267	1,255	9,51
	BW	0,099	0,099	1	3,09
$WSD_{Ag_4}$	A(10)G(0,0057;2)	0,020	0,348	1,698	6,32
	A(10)G(0,00285;2)	0,052	0,216	1,229	6,32
	E(200;396)G(0,0102;2)	0,030	0,412	1,701	9,26
	E(200;396)G(0,0045;2)	0,077	0,265	1,256	9,26
	BW	0,093	0,093	1	3,18
$WSD_{Ag_5}$	A(1)G(0,00585;2)	0,010	0,400	1,733	3,25
	A(1)G(0,00285;2)	0,048	0,230	1,259	3,25
	E(200;396)G(0,0135;2)	0,024	0,415	1,728	9,59
	E(200;396)G(0,00555;2)	0,070	0,263	1,258	9,59
	BW	0,096	0,096	1	3,16

## 6. Podsumowanie

W podsumowaniu zauważmy, że w przypadku prawie wszystkich rozważanych typów wieloagentowych systemów decyzyjnych algorytmy  $TG(\varepsilon, MinPts)$  (algorytm realizujący metodę agregacji tablic decyzyjnych oraz algorytm gęstościowy) oraz  $A(m)G(\varepsilon, MinPts)$  (algorytm realizujący aproksymacyjną metodę agregacji tablic decyzyjnych oraz algorytm gęstościowy) uzyskały lepsze wyniki niż algorytm  $RG(\varepsilon, MinPts)$  (algorytm realizujący metodę agregacji reguł wspierających oraz algorytm gęstościowy). Wyjątek stanowi wieloagentowy system decyzyjny z 7 agentami zasobów  $WSD_{Ag_3}$  zbioru danych Dermatology, w którym algorytm  $RG(\varepsilon, MinPts)$  uzyskał lepsze wyniki. Ponadto algorytmy  $BW$  (algorytm realizujący metodę boolowską analizy niespójności oraz głosowanie ważone) oraz  $TW$  (algorytm realizujący metodę agregacji tablic decyzyjnych oraz głosowanie ważone) uzyskały lepsze wyniki niż algorytm  $RW$  (algorytm realizujący metodę agregacji reguł wspierających oraz głosowanie ważone) w przypadku wszystkich rozważanych typów wieloagentowych systemów decyzyjnych. Na podstawie tych wyników można stwierdzić, że większą efektywność wnioskowania gwarantuje agregacja tablic decyzyjnych agentów zasobów niż agregacja reguł wygenerowanych na podstawie tych tablic decyzyjnych.

W przypadku większości rozważanych typów wieloagentowych systemów decyzyjnych algorytm  $RG(\varepsilon, MinPts)$  (algorytm realizujący metodę agregacji reguł wspierających oraz algorytm gęstościowy) uzyskał lepsze wyniki niż algorytm  $E(l; r)G(\varepsilon, MinPts)$  (algorytm realizujący metodę agregacji tablic decyzyjnych poprzedzoną losową edycją i kondensacją Harta oraz algorytm gęstościowy). Wyjątek stanowią wieloagentowy system decyzyjny z 3 agentami zasobów  $WSD_{Ag_1}$  zbioru danych Soybean oraz wieloagentowe systemy decyzyjne z 5 i 7 agentami zasobów  $WSD_{Ag_2}, WSD_{Ag_3}$  zbioru danych Landsat Satellite. Na podstawie tych wyników można stwierdzić, że większą efektywność wnioskowania gwarantuje agregacja reguł wygenerowanych na podstawie tablic decyzyjnych agentów zasobów niż agregacja reprezentatywnych podzbiorów obiektów wybranych z tych tablic decyzyjnych.

## BIBLIOGRAFIA

1. Bazan J.: Metody wnioskowań aproksymacyjnych dla syntezy algorytmów decyzyjnych. Praca doktorska. Uniwersytet Warszawski, Wydział Matematyki, Informatyki i Mechaniki, Warszawa 1998.
2. Cichosz P.: Systemy uczące się. WNT, Warszawa 2000.
3. Deja R.: Conflict analysis, Rough Sets; New Developments, [in:] Polkowski L. (ed.): Studies in Fuzziness and Soft Computer Science. Physica-Verlag, 2000.



4. Ester M., Kriegel H., Sander J., Xu X.: A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining, Portland 1996, s. 226÷231.
5. Gatnar E.: Podejście wielomodelowe w zagadnieniach dyskryminacji i regresji. PWN, Warszawa 2008.
6. Grzymała-Busse J., Goodwin L., Zhang X.: Increasing sensitivity of preterm birth by changing rule strengths. Proceedings of the Eight Workshop on Intelligent Information Systems, Ustroń, Poland 1999, s. 127÷136.
7. Hart P.: The condensed nearest neighbor rule. IEEE Transactions on Information Theory, Vol. 16, 1968, s. 515÷516.
8. Koronacki J., Ćwik J.: Statystyczne systemy uczące się. EXIT, Warszawa 2008.
9. Kuncheva L.: Combining pattern classifiers methods and algorithms. John Wiley & Sons, 2004.
10. Michalski R., Wojtusiak J.: The Distribution Approximation Approach to Learning from Aggregated Data. Reports of the Machine Learning and Inference Laboratory, George Mason University, Fairfax, VA 2008.
11. Pawlak Z.: An Inquiry Anatomy of Conflicts. Journal of Information Sciences, Vol. 109, 1998, s. 65÷78.
12. Pawlak Z.: On conflicts. International Journal of Man-Machine Studies, Vol. 21, 1984, s. 127÷134.
13. Pawlak Z.: Rough sets. International Journal of Information & Computer Sciences, Vol. 11, 1982, s. 341÷356.
14. Pawlak Z.: Rough Sets: Theoretical aspects of reasoning about data. Kluwer Academic Publishers, Boston 1991.
15. Pawlak Z., Skowron A.: A rough set approach for decision rules generation. ICS Research Report 23/93, Warsaw University of Technology, Proceedings of the IJCAI'93 Workshop W12: The Management of Uncertainty in AI, France 1993.
16. Skowron A., Deja R.: On Some Conflict Models and Conflict Resolutions. Romanian Journal of Information Science and Technology, Vol. 3(1-2), 2002, s. 69÷82.
17. Skowron A.: Boolean reasoning for decision rules generation, [in:] Komorowski J., Ras Z. (eds.): Lecture Notes in Artificial Intelligence, Vol. 689, Proceeding of the 7th International Symposium ISMIS'93. Springer-Verlag, Trondheim, Norway 1993, s. 295÷305.
18. Skowron A., Wang H., Wojna A., Bazan J.: Multimodal Classification: Case Studies. Rough Sets, 2006, s. 224÷239.
19. Straffin P.: Teoria gier. Scholar, Warszawa 2004.

20. Wakulicz-Deja A., Przybyła-Kasperek M.: Hierarchiczny system wieloagentowy. *Studia Informatica*, Vol. 28, No. 4(74), Wydawnictwo Politechniki Śląskiej, Gliwice 2007, s. 63÷80.
21. Wakulicz-Deja A., Przybyła-Kasperek M.: Hierarchical Multi-Agent System, *Recent Advances in Intelligent Information Systems*. Academic Publishing House EXIT, 2009, s. 615÷628.
22. Wakulicz-Deja A., Przybyła-Kasperek M.: Podejmowanie decyzji globalnej z zastosowaniem hierarchicznego systemu wieloagentowego oraz algorytmu mrówkowego. *Studia Informatica*, Vol. 30, No. 2A(83), Wydawnictwo Politechniki Śląskiej, Gliwice 2009, s. 213÷227.
23. Wakulicz-Deja A., Przybyła-Kasperek M.: Global decisions Taking on the Basis of Multi-Agent System with a Hierarchical Structure and Density-Based Algorithm. *Concurrency, Specification and Programming*, Warsaw University, Warsaw 2009, s. 616÷627.
24. Wakulicz-Deja A., Przybyła-Kasperek M.: Podejmowanie decyzji globalnych z zastosowaniem wieloagentowego systemu decyzyjnego oraz rodziny klasyfikatorów, [w:] Wakulicz-Deja A. (red.): *Systemy wspomaganie decyzji*. Instytut Informatyki Uniwersytetu Śląskiego, Katowice 2010, s. 83÷92.
25. Wakulicz-Deja A., Przybyła-Kasperek M.: Multi-Agent Decision Taking System. *Fundamenta Informaticae*, Vol. 101(1-2), 2010, s. 125÷141.
26. Wakulicz-Deja A., Przybyła-Kasperek M.: Wieloagentowy system decyzyjny – porównanie metod. *Studia Informatica*, Vol. 31, No. 2A(89), Wydawnictwo Politechniki Śląskiej, Gliwice 2010, s. 173÷188.
27. Przybyła-Kasperek M.: Wieloagentowy system decyzyjny – analiza konfliktów. Praca doktorska. Uniwersytet Śląski, Instytut Informatyki, Sosnowiec 2010.
28. Wakulicz-Deja A., Przybyła-Kasperek M.: Application of the method of editing and condensing in the process of global decision-making. *Fundamenta Informaticae*, Vol. 106 (1), 2011, s. 93÷117.
29. Wakulicz-Deja A., Przybyła-Kasperek M.: Wieloagentowy system decyzyjny – analiza porównawcza metod, [w:] Wakulicz-Deja A. (red.): *Systemy wspomaganie decyzji*. Instytut Informatyki Uniwersytetu Śląskiego, Katowice 2011.
30. <http://www.ics.uci.edu/~mlearn/MLRepository.html>.
31. <http://logic.mimuw.edu.pl/~rses/>.

Wpłynęło do Redakcji 19 grudnia 2011 r.

**Abstract**

The paper discusses the decision-making system that allows to make a global decision on the basis of distributed knowledge. In this system the sets of conditional attributes of different knowledge bases are not necessarily disjoint, and therefore inconsistencies of knowledge stored in different knowledge bases may occur. We understand inconsistency of knowledge to be situations in which, on the basis of two different knowledge bases that have common attributes and for the same values for common attributes using logical implications, conflicting decisions are made. In the decision-making system, which is discussed in this paper, the process of elimination inconsistencies in the knowledge is realized in two stages. In the first stage the knowledge base that have common conditional attributes are combined into groups. In the second stage we use one of the methods of elimination inconsistencies in the knowledge in created groups of knowledge bases. Because of such structure of the system and inference being conducted in groups of knowledge bases there is a problem of conflict analysis. By conflict we mean a situation in which for the specified set of conditions on the basis of knowledge stored in different groups of knowledge bases conflicting decisions are taken. In this paper two methods of conflict analysis, that allow inference despite the presence of conflicts, were used.

The purpose of this paper is to compare the efficiency of inference obtained using a method of elimination inconsistencies in the knowledge that operates on the basis of decision rules with the efficiency of inference obtained using other existing methods of elimination inconsistencies in the knowledge.

The second chapter of the paper presents the structure of multi-agent decision-making system. The third chapter describes new method of elimination inconsistencies in the knowledge. The fourth chapter describes methods of elimination inconsistencies in the knowledge and methods for the analysis of conflicts proposed in the earlier work. The fifth chapter shows description and the results of the experiments carried out with the use of data from the UCI repository.

**Adres**

Małgorzata PRZYBYŁA-KASPEREK: Uniwersytet Śląski, Instytut Informatyki,  
ul. Będzińska 29, 41-200 Sosnowiec, Polska, malgorzata.przybyla-kasperek@us.edu.pl.