

Małgorzata PRZYBYŁA-KASPEREK  
Uniwersytet Śląski, Instytut Informatyki

## WIELOAGENTOWY SYSTEM DECYZYJNY Z DYNAMICZNIE GENEROWANYMI ROZŁĄCZNYMI KLASTRAMI

**Streszczenie.** Artykuł zawiera zagadnienia związane z procesem podejmowania decyzji globalnych na podstawie wiedzy rozproszonej, przechowywanej w kilku lokalnych bazach wiedzy.

W artykule zaproponowano nowe podejście do organizacji struktury systemu umożliwiającego podejmowanie decyzji na podstawie wiedzy rozproszonej. W prezentowanym podejściu rozpatrywany jest system o dynamicznej strukturze. Będziemy dążyć do wyznaczenia grup lokalnych baz wiedzy, na podstawie których wyznaczane są zgodne decyzje dla obiektu testowego. Następnie w utworzonych grupach realizowany będzie proces eliminacji niespójności wiedzy. Decyzje globalne podejmowane są z wykorzystaniem jednej z metod analizy konfliktu.

Artykuł zawiera definicję wieloagentowego systemu decyzyjnego o strukturze dynamicznej oraz definicję dynamicznie generowanych klastrów. Przedstawiono opis procesu wyznaczania decyzji globalnych oraz wyniki eksperymentów przeprowadzonych na danych z repozytorium UCI.

**Słowa kluczowe:** system decyzyjny, decyzja globalna, koalicja, konflikt

## DECISION-MAKING SYSTEM WITH DYNAMICALLY GENERATED DISJOINT CLUSTERS

**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 paper proposes a new approach to organization of structure of multi-agent decision-making system, operating on the basis of dispersed knowledge. In the presented system, the local knowledge bases will be combined into groups in a dynamic way. We will seek to designate groups of local bases on which the test object is classified to the decision classes in a similar manner. Then in the created groups a process of elimination inconsistencies in the knowledge will be implemented. Global decisions will be made by using one of the methods of analysis of conflict.

The paper includes the definition of multi-agent decision-making system with dynamically generated clusters and a description of global decision-making process. In

addition, the paper presents results of experiments carried out on data from the UCI repository.

**Keywords:** decision-making system, global decision, coalition, conflict

## 1. Wprowadzenie

W niniejszym artykule rozpatrywany jest problem podejmowania decyzji na podstawie wiedzy rozproszonej, przechowywanej w wielu lokalnych bazach wiedzy. W badanym podejściu zostały przyjęte bardzo ogólne założenia. Przyjęto, że danych jest kilka baz wiedzy zawierających informacje na ten sam temat, ale o różnych zbiorach atrybutów. Zbiory atrybutów warunkowych i zbiory obiektów lokalnych baz wiedzy nie muszą być równe ani rozłączne. Jedynym przyjętym założeniem jest występowanie tych samych atrybutów decyzyjnych we wszystkich rozważanych bazach wiedzy.

W niniejszym artykule zostało zaproponowane nowe podejście do organizacji struktury systemu, który wykorzystuje wiedzę rozproszoną. We wcześniejszych pracach [20, 24, 25, 26, 27, 28] rozważany był system, w którym lokalne bazy wiedzy o wspólnych atrybutach warunkowych były łączone w grupę. Nowe podejście opiera się na założeniu, że jedna grupa powinna zawierać bazy wiedzy, na podstawie których dokonywana jest zgodna klasyfikacja dla obiektu testowego. W procesie podejmowania decyzji globalnych bazy wiedzy znajdujące się w jednej grupie podlegają agregacji. W celu agregacji wiedzy wykorzystywana jest jedna z metod eliminacji niespójności wiedzy, która została zaproponowana w pracach [25, 26]. Na podstawie zagregowanej wiedzy podejmowane są decyzje lokalne, w obrębie jednej grupy. Ponieważ wnioskowanie prowadzone jest w grupach baz wiedzy, istnieje problem analizy konfliktów. W artykule wykorzystywane są dwie metody analizy konfliktów, które zaproponowane zostały w pracach [24, 25, 28].

Głównym celem niniejszego artykułu jest zaproponowanie systemu, w którym bazy wiedzy są łączone w koalicje w sposób dynamiczny. Negocjacje oraz sposób tworzenia koalicji są ważną formą interakcji społecznej i przedmiotem badań różnych dziedzin nauk społecznych oraz informatyki. Krótki przegląd różnych modeli negocjacji zaproponowanych w literaturze można znaleźć w pracy [12]. Zeng i Sycara [29] zaproponowali model sekwencyjnego podejmowania decyzji o nazwie Bazar. Faratin i in. [6] opisali model dwustronnych negocjacji, który definiuje zbiór strategii oraz trzy grupy taktyk. Lopes i in. [11] omówili model negocjacji formalizujący różne strategie rozwiązywania problemów. Nguyen i Jennings [14] zaproponowali model, w którym kupujący angażuje się w wiele równoległych negocjacji dwustronnych ze zbiorem sprzedawców.

W pracach Pawlaka [15, 16, 18] opisane zostało podejście do tworzenia koalicji. Opracowany model opisuje sytuację konfliktową, w której agenci postanowili rozwiązać konflikt

drogą pokojową. Zdefiniowane zostały relacje konfliktu, przyjaźni i neutralności. Ponadto opisany został sposób formułowania koalicji oraz przedstawiona została metoda obliczania natężenia konfliktu. W niniejszym artykule wykorzystano niektóre zagadnienia analizy konfliktów i tworzenia koalicji, które zostały zaprezentowane w modelu Zdzisława Pawlaka.

Analiza konfliktów ma swoje korzenie w teorii gier, w której jedną z podstawowych metod stosowanych do pomiaru siły uczestników głosowania jest indeks Shapleya-Shubika oraz indeks Banzhafa. W pracy Polkowskiego i Araszkiwicz [19] indeks Shapleya-Shubika został zastosowany do analizy gry z niepełną informacją. Jak wspomniano wcześniej, jeden z modeli analizy konfliktów został zaproponowany przez Pawlaka [15, 18]. Inni autorzy również rozpatrywali zagadnienie analizy konfliktów [4, 21].

Podjęcie globalnej decyzji na podstawie decyzji lokalnych jest też rozważane w zagadnieniach dotyczących podejścia wielomodelowego [10]. Przykłady zastosowania tego podejścia można znaleźć w literaturze [1, 23]. W niniejszym artykule opisano odmienne podejście do podejmowania decyzji globalnych. Główna różnica wynika z przyjętego założenia, że zbiór lokalnych baz wiedzy jest zadany z góry. Natomiast jedynym warunkiem, jaki muszą spełniać bazy lokalne, jest występowanie wspólnych atrybutów decyzyjnych.

W pracy Michalskiego i Wojtusiaka [13] przedstawiono zagadnienie syntezy informacji. Autorzy rozważają sytuację, w której dla obiektów testowych dostępne są tylko wartości atrybutów zagregowane w ramach pewnej grupy obiektów. W pracy Skowrona i in. [22] zaproponowana została metoda konstrukcji szeregu modeli, które tworzą strukturę hierarchiczną. Powyższe metody zostały opracowane w celu poprawy dokładności klasyfikacji dokonywanej na podstawie wiedzy zapisywanej w jednej bazie wiedzy. Dlatego podejścia te różnią się od podejścia przedstawionego w tym artykule, w którym decyzje globalne podejmowane są na podstawie rozproszonej wiedzy, przechowywanej w zadanych z góry lokalnych bazach wiedzy.

W pracach [2, 3, 8, 9] można znaleźć inne (różne od tego, które jest rozważane w niniejszym artykule) podejście do problemu klasyfikacji na podstawie kilku tablic decyzyjnych. W metodach Distributed Data Mining (DDM) zakłada się, że dane są gromadzone i przechowywane w kilku tablicach decyzyjnych, reprezentujących podział horyzontalny lub wertykalny. Podejście rozważane w niniejszym artykule jest szersze niż podejście rozważane w DDM, ponieważ zakłada się, że zarówno zbiory atrybutów, jak i zbiory obiektów mogą być różne w różnych tablicach decyzyjnych.

W drugiej części artykułu opisano nowe, dynamiczne podejście do tworzenia struktury wieloagentowego systemu decyzyjnego. Podana została definicja wieloagentowego systemu decyzyjnego z dynamicznie generowanymi klastrami. W rozdziale trzecim wspomniano krótko o metodzie eliminacji niespójności wiedzy oraz o metodach analizy konfliktów, które za-

proponowano we wcześniejszych pracach. Kolejny rozdział zawiera opis i wyniki eksperymentów przeprowadzonych na zbiorach danych z repozytorium UCI.

## 2. Dynamiczna struktura systemu wieloagentowego

Tak jak wspomniano wcześniej, zakładamy, że dostępny jest zbiór baz wiedzy, na podstawie których chcemy wyznaczyć decyzje globalne. Przyjmujemy, że każdą lokalną bazą wiedzy zarządza jeden agent. Dokładniej wiedza posiadana przez agenta ogranicza się do jednej lokalnej bazy wiedzy. Wykorzystywane w artykule pojęcie agenta zostało wprowadzone przez Pawlaka w pracach [15, 16]. Zgodnie z tą definicją agent jest stroną biorącą udział w konflikcie. Każdy agent wyraża swoje zdanie na temat sprawy, czyli potrafi samodzielnie podjąć decyzję dla zadanego zbioru przesłanek. W przypadku rozważanym w artykule agent podejmuje decyzje na podstawie wiedzy zawartej w jednej lokalnej bazie wiedzy. Pojęcie to jest odmienne od klasycznego rozumienia pojęcia agenta w systemie wieloagentowym. Istnieją tu jednak pewne cechy wspólne. W pracy Franklina i Graessera [7] uwzględniono pojęcie agenta, które jest zgodne z tym wprowadzonym przez Pawlaka. Zgodnie z tą definicją agent ma następujące własności. Pierwszą jest jego zdolność do autonomicznej pracy. Drugą własnością jest zdolność agenta do przeprowadzania wnioskowania w określonej dziedzinie. W artykule 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  $Ag$  będzie skończonym zbiorem agentów  $Ag = \{ag_1, \dots, ag_n\}$ . Każdy agent  $ag_i \in Ag$  nazywany jest agentem zasobów, gdyż ma on dostęp do pewnych zasobów w postaci tablicy decyzyjnej  $D_{ag_i} = (U_{ag_i}, A_{ag_i}, d_{ag_i})$ , gdzie  $U_{ag_i}$  jest zbiorem zwanym uniwersum, elementy zbioru  $U_{ag_i}$  nazywamy zaś obiektami;  $A_{ag_i}$  jest zbiorem atrybutów warunkowych;  $d_{ag_i}$  nazywamy atrybutem decyzyjnym. W tablicy decyzyjnej  $D_{ag_i}$  jest zapisana wiedza posiadana przez agenta  $ag_i$ .

Każdy agent zasobów  $ag_i \in Ag$  na podstawie wiedzy zawartej w tablicy decyzyjnej  $D_{ag_i}$  potrafi samodzielnie wyznaczyć wartość decyzji dla pewnego obiektu testowego, dla którego określone są wartości na zbiorze atrybutów  $A_{ag_i}$ . W zaproponowanym systemie będziemy dążyć do wyznaczenia jednorodnych, w pewnym sensie, grup agentów zasobów. W grupy będziemy łączyli tych agentów, którzy są zgodni co do klasyfikacji danego obiektu testowego do klas decyzyjnych. W dalszej części zdefiniujemy relację przyjaźni oraz konfliktu agentów, a następnie opiszemy proces łączenia agentów zasobów w klastry, czyli grupy agentów pozo-

stających w relacji przyjaźni. Definicje relacji przyjaźni oraz konfliktu, a także sposób określania natężenia konfliktu zostały zaczerpnięte z pracy Zdzisława Pawłaka [15, 16].

Niech  $x$  będzie obiektem testowym, dla którego chcemy wyznaczyć decyzję globalną. Niech dla obiektu  $x$  określone będą wartości na zbiorze atrybutów  $U_{i=1}^n A_{ag_i}$ . Z tablicy decyzyjnej agenta zasobów  $D_{ag_i}, i \in \{1, \dots, n\}$  oraz z każdej klasy decyzyjnej  $X_v, v \in V^d$  wybieramy najmniejszy zbiór liczący co najmniej  $m_1$  obiektów, których wartości na atrybutach warunkowych realizują największe podobieństwo do obiektu testowego  $x$ . Parametr  $m_1$  będziemy dobierać eksperymentalnie. W celu wyznaczenia zbioru obiektów relewantnych obliczana jest miara podobieństwa Gowera obiektów, której definicję można znaleźć w pracy [28]. Zatem dla każdego obiektu z tablicy decyzyjnej agenta zasobów  $D_{ag_i}$  obliczamy miarę podobieństwa Gowera do obiektu  $x$ . Następnie z każdej klasy decyzyjnej  $X_v$  wybieramy  $m_1$  obiektów, które realizują największe podobieństwo, przy czym jeżeli więcej niż jeden obiekt z tablicy decyzyjnej agenta zasobów i klasy decyzyjnej  $X_v$  jest tak samo podobny do obiektu  $x$  jak  $m_1$ -ty obiekt, to pod uwagę bierzemy obiekty bliższe obiektowi  $x$  niż  $m_1$ -ty obiekt oraz wszystkie obiekty tak samo podobne do obiektu  $x$  jak  $m_1$ -ty obiekt. Przez  $m_1$ -ty rozumiemy taki obiekt, który w ciągu obiektów należących do klasy decyzyjnej  $X_v$ , uporządkowanych malejąco według wartości miary podobieństwa do obiektu  $x$  znajduje się na  $m_1$  miejscu. W przypadku gdy  $card\{x \in U_{ag_i} : d(x) = v\} \leq m_1$ , to do zbioru obiektów relewantnych zaliczamy wszystkie obiekty z klasy decyzyjnej  $X_v$ . Następnie dla każdego agenta zasobów generowany jest wektor wartości określający poziom pewności, z jakim podejmuje on daną decyzję dla obiektu testowego. Każdy z poziomów pewności określany jest na podstawie obiektów wybranych wcześniej z tablicy decyzyjnej agenta zasobów. Zatem dla każdego agenta zasobów  $i \in \{1, \dots, n\}$  generowany jest  $c$ -wymiarowy wektor  $[\bar{\mu}_{i,1}(x), \dots, \bar{\mu}_{i,c}(x)]$  gdzie wartość  $\bar{\mu}_{i,j}(x)$  oznacza pewność, z jaką obiekt  $x$  klasyfikowany jest do klasy decyzyjnej  $v_j \in V^d, j \in \{1, \dots, c\}, c = card\{V^d\}$  przez agenta zasobów  $ag_i$ . Wartość wyrażenia  $\bar{\mu}_{i,j}(x)$

definiujemy następująco: 
$$\bar{\mu}_{i,j}(x) = \frac{\sum_{y \in U_{ag_i}^{rel} \cap X_{v_j}^{ag_i}} s(x, y)}{card\{U_{ag_i}^{rel} \cap X_{v_j}^{ag_i}\}}, i \in \{1, \dots, n\}, j \in \{1, \dots, c\},$$
 gdzie

$c = card\{V^d\}$ ,  $U_{ag_i}^{rel}$  jest zbiorem obiektów relewantnych wybranych z tablicy decyzyjnej agenta zasobów  $ag_i$ ,  $X_{v_j}^{ag_i}$  jest klasą decyzyjną tablicy decyzyjnej agenta zasobów  $ag_i$ ,  $s(x, y)$  jest miarą podobieństwa obiektów  $x$  oraz  $y$ .

Na podstawie powyższego wektora wartości określającego poziom pewności, z jakim agent zasobów podejmuje daną decyzję dla obiektu testowego, określany jest wektor rang przyporządkowanych poszczególnym wartościom atrybutu decyzyjnego. Wartości decyzyji,

które podejmowane są z maksymalnym poziomem pewności, otrzymują rangę 1. Wartościom decyzji podejmowanym z maksymalnym poziomem pewności w zbiorze decyzji, które nie otrzymały rangi 1, przyporządkowana jest ranga 2. Przy takim postępowaniu dla każdego agenta zasobów  $ag_i, i \in \{1, \dots, n\}$  wyznaczony zostanie wektor rang  $[r_{i,1}(x), \dots, r_{i,c}(x)]$

**Przykład 2.1.** Niech dla  $i$ -tego agenta zasobów dany będzie wektor wartości określający poziom pewności, z jakim podejmuje on daną decyzję dla obiektu testowego  $[\bar{\mu}_{i,1}(x), \dots, \bar{\mu}_{i,4}(x)] = [0,24; 0,45; 0,21; 0,09]$ . Wówczas wektor rang przyporządkowanych poszczególnym wartościom atrybutu decyzyjnego będzie miał następującą postać:  $[r_{i,1}(x), \dots, r_{i,4}(x)] = [2; 1; 3; 4]$

Przejdziemy teraz do podania definicji relacji przyjaźni oraz konfliktu. Relacje między agentami są zdefiniowane przez ich pogląd na klasyfikację obiektu testowego  $x$  do klas decyzyjnych. Dla obiektu testowego  $x$  oraz każdej wartości decyzji  $v_j \in V^d$  definiujemy funkcję  $\phi_{v_j}^x : Ag \times Ag \rightarrow \{0,1\}$ , określoną następująco:

$$\phi_{v_j}^x(ag_i, ag_k) = \begin{cases} 0 & \text{gdy } r_{i,j}(x) = r_{k,j}(x) \\ 1 & \text{gdy } r_{i,j}(x) \neq r_{k,j}(x) \end{cases}, \quad (1)$$

gdzie  $ag_i, ag_k \in Ag$ .

**Definicja 2.2.** Agenci  $ag_i, ag_k \in Ag$  są w relacji przyjaźni względem klasyfikacji obiektu  $x$  do klasy decyzyjnej  $v_j \in V^d$ , co zapisujemy  $R_{v_j}^+(ag_i, ag_k)$ , wtedy i tylko wtedy, gdy  $\phi_{v_j}^x(ag_i, ag_k) = 0$ . Agenci  $ag_i, ag_k \in Ag$  są w relacji konfliktu względem klasyfikacji obiektu  $x$  do klasy decyzyjnej  $v_j \in V^d$ , co zapisujemy  $R_{v_j}^-(ag_i, ag_k)$ , wtedy i tylko wtedy, gdy  $\phi_{v_j}^x(ag_i, ag_k) = 1$ .

Następnie określamy natężenie konfliktu pomiędzy agentami za pomocą funkcji odległości agentów. Dla obiektu testowego  $x$  definiujemy odległość agentów  $\rho^x : Ag \times Ag \rightarrow [0,1]$

w następujący sposób:  $\rho^x(ag_i, ag_k) = \frac{\sum_{v_j \in V^d} \phi_{v_j}^x(ag_i, ag_k)}{\text{card}\{V^d\}}$ , gdzie  $ag_i, ag_k \in Ag$ .

**Definicja 2.3.** Mówimy, że agenci  $ag_i, ag_k \in Ag$  są w relacji przyjaźni względem klasyfikacji obiektu  $x$ , co zapisujemy  $R^+(ag_i, ag_k)$ , wtedy i tylko wtedy, gdy  $\rho^x(ag_i, ag_k) < 0,5$ . Agenci  $ag_i, ag_k \in Ag$  są w relacji konfliktu względem klasyfikacji obiektu  $x$ , co zapisujemy  $R^-(ag_i, ag_k)$ , wtedy i tylko wtedy, gdy  $\rho^x(ag_i, ag_k) \geq 0,5$ .

Korzystając z powyższej definicji funkcji odległości agentów, wyznaczamy odległości pomiędzy każdą parą agentów zasobów. Następnie rozpoczynamy proces generowania kla-

strów w następujący sposób. Początkowo każdy agent jest traktowany jako oddzielny klastery. Poniższe dwa kroki wykonujemy dopóty, dopóki nie zostanie spełniony warunek stopu zadany w pierwszym kroku.

1. Wybieramy parę różnych klastrów (w pierwszym kroku parę różnych agentów zasobów), dla których funkcja odległości przyjmuje wartość minimalną. Jeśli wybrana wartość funkcji odległości jest mniejsza niż 0,5, to łączymy agentów z wybranej pary klastrów w jeden nowy klastery. W przeciwnym wypadku kończymy proces tworzenia klastrów.
2. Po zdefiniowaniu nowego klastrera przeliczamy ponownie wartość funkcji odległości pomiędzy klastrami. W tym celu rozszerzymy definicję funkcji odległości w następujący sposób:  $\rho^x : 2^{Ag} \times 2^{Ag} \rightarrow [0,1]$ . Niech  $D_i$  będzie klastrem powstałym z połączenia dwóch klastrów –  $D_i = D_{i,1} \cup D_{i,2}$  – oraz niech będzie dany klastery  $D_j$ , wówczas

$$\rho^x(D_i, D_j) = \begin{cases} \frac{\rho^x(D_{i,1}, D_j) + \rho^x(D_{i,2}, D_j)}{2} & \text{gdy } \rho^x(D_{i,1}, D_j) < 0,5 \text{ oraz } \rho^x(D_{i,2}, D_j) < 0,5 \\ \max\{\rho^x(D_{i,1}, D_j), \rho^x(D_{i,2}, D_j)\} & \text{gdy } \rho^x(D_{i,1}, D_j) \geq 0,5 \text{ lub } \rho^x(D_{i,2}, D_j) \geq 0,5 \end{cases}$$

Proces tworzenia klastrów jest bardzo podobny do hierarchicznej aglomeracyjnej metody grupowania. Jednak w powyższej metodzie występuje wyraźnie określony warunek stopu. Wynika on z założenia, że jeden klastery nie może zawierać dwóch agentów zasobów, którzy pozostają w relacji konfliktu ze względu na klasyfikację obiektu  $x$ .

Po zakończeniu procesu grupowania dla każdego klastrera zawierającego co najmniej dwóch agentów zasobów definiujemy agenta syntezy  $as$  (ang. *synthesis agent*). Agent syntezy ma dostęp do wiedzy będącej wynikiem procesu wnioskowania przeprowadzonego przez agentów zasobów należących do grupy jemu podrzędnej.

**Definicja 2.4.** Przez wieloagentowy system decyzyjny o strukturze dynamicznej będziemy rozumieli czwórkę  $WSD_{Ag}^{dyn} = \langle Ag, \{D_{ag} : ag \in Ag\}, \{As_x : x \text{ jest obiektem testowym}\}, \{\delta_x : x \text{ jest obiektem testowym}\} \rangle$ , gdzie  $Ag$  jest skończonym zbiorem agentów zasobów,  $\{D_{ag} : ag \in Ag\}$  jest zbiorem tablic decyzyjnych agentów zasobów,  $As_x$  jest skończonym zbiorem agentów syntezy zdefiniowanym dla klastrów dynamicznie generowanych względem obiektu testowego  $x$ ,  $\delta_x : As_x \rightarrow 2^{Ag}$  jest różnowartościową funkcją przyporządkowującą każdemu agentowi syntezy jeden klastery dynamicznie generowany względem obiektu testowego  $x$ .

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

Po zakończeniu procesu grupowania realizowany jest proces eliminacji niespójności wiedzy w obrębie klastrów. Do tego celu zastosowano zaproponowaną we wcześniejszych pracach aproksymacyjną metodę agregacji tablic decyzyjnych [20, 25, 27, 28]. Istotą tej metody jest stworzenie zbioru nowych tablic decyzyjnych na podstawie tablic decyzyjnych agentów zasobów. Liczba stworzonych tablic jest równa liczbie klastrów zawierających co najmniej dwóch agentów zasobów, wyodrębnionych w wieloagentowym systemie decyzyjnym. W metodzie tej każdy agent syntezy dysponuje zasobami podanymi w formie tablicy decyzyjnej, która powstała przez agregację obiektów relewantnych wybranych z tablic decyzyjnych agentów zasobów, należących do klastra podrzędnego wobec danego agenta syntezy. Tablice zagregowane agentów syntezy są konstruowane tak, aby nie zawierały wiedzy niespójnej. Obiekty tablicy zagregowanej tworzone są przez połączenie obiektów wybranych wcześniej z tablic agentów zasobów podrzędnych, przy czym łączymy te obiekty, dla których wartości na atrybucie decyzyjnym oraz wspólnych atrybutach warunkowych są równe.

Analiza konfliktów realizowana jest 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. Konfliktem nazywamy sytuację, w której agenci syntezy na podstawie dostępnej wiedzy podejmują sprzeczne decyzje dla zadanego obiektu testowego. W artykule zastosowano dwie metody rozwiązania problemu analizy konfliktu: głosowanie ważone oraz metodę algorytmu gęstościowego. Metody te zostały zaproponowane we wcześniejszych pracach [20, 25, 27, 28]; umożliwiają one analizowanie konfliktów oraz generowanie zbioru decyzji globalnych.

Po realizacji procesu eliminacji niespójności wiedzy dla każdego klastra generowany jest wektor wartości  $[\mu_{j,1}(x), \dots, \mu_{j,c}(x)]$  określający poziom pewności, z jaką podejmowana jest dana decyzja dla zadanego obiektu testowego  $x$ . W metodzie głosowania ważonego każdy agent syntezy głosuje na poszczególne wartości decyzji z siłą głosu równą wartości współrzędnej wektora odpowiadającej danej decyzji. Zbiór decyzji globalnych podjętych z zastosowaniem metody głosowania ważonego definiujemy przez wybranie decyzji, które są podejmowane z maksymalnym poziomem pewności.

W metodzie algorytmu gęstościowego zastosowano znany z literatury algorytm gęstościowy DBSCAN [5] w celu wygenerowania grup decyzji, które są przez agentów podejmowane z podobnym poziomem pewności. Algorytm ten polega na poszukiwaniu grup elementów gęsto ułożonych. Podstawą działania tego algorytmu jest definiowanie grupy w sytuacji, gdy w sąsiedztwie danego elementu (o zadanym promieniu  $\varepsilon$ ) znajduje się co najmniej  $z$  elementów z góry zadana liczba elementów (*MinPts*). W ten sposób wyszukiwane są elementy, które w zadanym sensie (określonym przez parametry) są gęsto ułożone. W sytuacji rozważanej w niniej-



szym artykule zbiorem elementów podlegających grupowaniu jest zbiór  $V^d$ , natomiast odległość dwóch wartości decyzji jest zależna od poziomu pewności, z jaką decyzja jest podejmowana. Stosując algorytm DBSCAN z odległością euklidesową, wyznaczamy grupy decyzji, które mają podobne poparcie wśród agentów syntezy. Zbiorem podjętych decyzji globalnych jest grupa decyzji, do której należy wartość decyzji z największym poparciem wszystkich agentów syntezy. W pracy [27] przedstawiono porównanie poprawności klasyfikacji dokonywanej przy zastosowaniu różnych metod analizy konfliktów, m.in. przy zastosowaniu algorytmu gęstościowego oraz algorytmu mrówkowego. Na podstawie otrzymanych wyników stwierdzono, że najlepsze wyniki są otrzymywane przy zastosowaniu algorytmu gęstościowego DBSCAN.

#### 4. Wyniki eksperymentów obliczeniowych

Przedstawimy teraz wyniki eksperymentów wykonanych na czterech różnych zbiorach danych, które dostępne są w repozytorium UCI repository [<http://www.ics.uci.edu/~mllearn/MLRepository.html>]. Wybrano następujące zbiory: Soybean Data Set, Dermatology Database, Vehicle Silhouettes oraz Landsat Satellite.

W celu określenia efektywności wnioskowania wieloagentowego systemu decyzyjnego w odniesieniu do analizowanych danych dokonujemy podziału zbiorów danych na dwa rozłączne podzbiory: zbiór uczący oraz zbiór testowy. Charakterystyki liczbowe wszystkich zbiorów danych zostały zebrane w tabeli 1.

Tabela 1

Charakterystyki zbiorów danych

Zbiór danych	# Zbiór uczący	# Zbiór testowy	# Atrybuty warunkowe	# Decyzje
Soybean	307	376	35	19
Dermatology	256	110	34	6
Vehicle	592	254	18	4
Satellite	4435	1000	36	6

Wieloagentowy system decyzyjny umożliwia podejmowanie decyzji globalnych na podstawie wiedzy rozproszonej. Aby w pełni zbadać możliwości i ocenić efektywność wnioskowania systemu, wymagane jest dostarczenie wiedzy zapisanej w formie zbioru tablic decyzyjnych. W celu wykonania eksperymentów dokonano podziału każdego zbioru uczącego na zbiór tablic decyzyjnych, przy czym rozpatrywano podziały na różną liczbę tablic decyzyjnych. Dla każdego z wykorzystywanych zbiorów danych rozważano wieloagentowe systemy decyzyjne w wersji z 3, 5, 7, 9 oraz 11 agentami zasobów.

Podział zbioru uczącego na tablice decyzyjne agentów zasobów był realizowany w następujący sposób. W pierwszym kroku określono liczbę atrybutów warunkowych w każdej

z tablic decyzyjnych agentów zasobów oraz wskazano liczbę wspólnych atrybutów warunkowych tablic. Następnie w sposób losowy definiowano zbiory atrybutów warunkowych tablic decyzyjnych, tak aby spełnione były zadane wcześniej warunki oraz aby każdy atrybut warunkowy występujący w zbiorze uczącym został uwzględniony przynajmniej w jednym z definiowanych zbiorów. Atrybut decyzyjny w tablicach decyzyjnych jest tożsamy z atrybutem decyzyjnym w zbiorze uczącym. W każdym zbiorze uniwersum tablic decyzyjnych agentów zasobów uwzględniono wszystkie obiekty ze zbioru uczącego.

Miarami określającymi jakość klasyfikacji są: estymator aktualnego poziomu błędu klasyfikatora ( $e$ ), gdzie 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 ( $\bar{d}_{WSD_{Ag}}$ ).

Eksperymenty przeprowadzono według następującego planu:

1. W pierwszym kroku wybierana była optymalna wartość parametru  $m_1$ , który wpływa na postać klastrów, oraz optymalna wartość parametru  $m_2$  aproksymacyjnej metody agregacji tablic decyzyjnych. Dla małych i średnich zbiorów danych stosowano wartości parametrów  $m_1$ ,  $m_2$  należące do zbioru  $\{1, \dots, 10\}$ , natomiast dla dużego zbioru danych Landsat Satellite badano wartości ze zbioru  $\{1, \dots, 5\}$ . Dla każdego systemu wybierano jedną, najmniejszą wartość parametru  $m_1$  oraz parametru  $m_2$  pozwalającą osiągnąć najniższą wartość estymatora aktualnego poziomu błędu klasyfikatora opartego na zbiorze testowym.
2. W drugim kroku optymalizowane były wartości parametrów  $\varepsilon$  oraz  $MinPts$  algorytmu gęstościowego przy zastosowaniu aproksymacyjnej metody agregacji tablic decyzyjnych, oznaczonej jako  $A(m_2)G(\varepsilon; MinPts)$ . Optymalna wartość parametru  $MinPts$  była ustalana na podstawie eksperymentów wstępnych. Następnie dla obranej wartości parametru  $MinPts$  optymalizowano wartość parametru  $\varepsilon$ . Proces ten był realizowany przez wykonanie wielu eksperymentów z zastosowaniem wartości parametru  $\varepsilon$ , które były zwiększane od 0 do wartości progowej o zadaną stałą. Później tworzono wykres, na którym zaznaczano punkty o współrzędnych  $(\bar{d}_{WSD_{Ag}}, e)$ , uporządkowane rosnąco względem wartości parametru  $\varepsilon$ . Dalej na wykresie wyznaczano 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 błędu klasyfikatora, natomiast na prawo od punktu następuje już nieznaczny spadek wartości tego estymatora wraz ze wzrostem wartości parametru  $\varepsilon$ .

### Ekspertymenty ze zbiorem danych Soybean

W tabeli 2 przedstawiono wyniki eksperymentów ze zbiorem danych Soybean, natomiast w tabeli 3 przytoczono wyniki dla tego zbioru danych zamieszczone w pracy [27], które otrzymano dla wieloagentowego systemu decyzyjnego z klastrami zdefiniowanymi statycznie. W podejściu statycznym w klastry łączeni są agenci zasobów, którzy wnioskujeją na podstawie wspólnych atrybutów warunkowych.

Tabela 2

Wyniki eksperymentów ze zbiorem danych Soybean dynamicznie generowane  
rozłączne klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$ $m_1 = 1$	A(1)G(0,0072;2)	0,026	0,319	2,401	0,03
	A(1)G(0,00645;2)	0,064	0,287	2,082	0,03
$WSD_{Ag_2}$ $m_1 = 4$	A(1)G(0,01575;2)	0,019	0,311	2,059	0,05
	A(1)G(0,013;2)	0,043	0,285	1,545	0,05
$WSD_{Ag_3}$ $m_1 = 6$	A(1)G(0,01875;2)	0,016	0,306	2,008	0,07
	A(1)G(0,0135;2)	0,019	0,279	1,598	0,07
$WSD_{Ag_4}$ $m_1 = 1$	A(1)G(0,006;2)	0,043	0,261	1,529	0,06
$WSD_{Ag_5}$ $m_1 = 1$	A(4)G(0,005;2)	0,037	0,327	1,838	4,22

Tabela 3

Wyniki eksperymentów ze zbiorem danych Soybean statycznie zdefiniowane klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	A(1)G(0,0025;2)	0,027	0,295	2,005	0,03
$WSD_{Ag_2}$	A(1)G(0,00575;2)	0,035	0,327	1,968	0,02
	A(1)G(0,0035;2)	0,093	0,242	1,335	0,02
$WSD_{Ag_3}$	A(1)G(0,00575;2)	0,008	0,306	1,968	0,03
	A(1)G(0,00375;2)	0,024	0,274	1,559	0,03
$WSD_{Ag_4}$	A(1)G(0,0108;2)	0,058	0,319	1,755	0,03
$WSD_{Ag_5}$	A(1)G(0,0128;2)	0,029	0,309	1,755	0,03
	A(1)G(0,0084;2)	0,090	0,253	1,298	0,03

W tabelach 2 oraz 3 podane są następujące informacje: nazwa wieloagentowego systemu decyzyjnego (System) oraz oznaczenie algorytmu (Algorytm), w którym pierwsza część symbolizuje metodę eliminacji niespójności wiedzy, a druga – metodę analizy konfliktów. Przyjęto następujące oznaczenia:  $A(m_2)$  – aproksymacyjna metoda agregacji tablic decyzyj-

nych z parametrem  $m_2$ ,  $W$  – metoda głosowania ważonego,  $G(\varepsilon, MinPts)$  – metoda algorytmu gęstościowego 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  $t$ .

Na podstawie wyników eksperymentów zamieszczonych w tabelach 2 oraz 3 można wyciągnąć następujące wnioski:

- dla wieloagentowych systemów decyzyjnych z 5 oraz 9 agentami zasobów  $WSD_{Ag_2}, WSD_{Ag_4}$  – w przypadku gdy klastry są generowane dynamicznie – otrzymujemy lepsze wyniki niż dla wieloagentowego systemu decyzyjnego ze statycznie zdefiniowanymi klastrami;
- dla wieloagentowego systemu decyzyjnego z 3 agentami zasobów  $WSD_{Ag_1}$  – w przypadku gdy klastry są generowane dynamicznie – uzyskujemy tę samą wartość estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ) co dla wieloagentowego systemu decyzyjnego ze statycznie zdefiniowanymi klastrami, ale przy większej średniej liczebności zbiorów decyzji globalnych  $\bar{d}_{WSD_{Ag}}$ ;
- dla wieloagentowego systemu decyzyjnego z 7 agentami zasobów  $WSD_{Ag_3}$  oraz dla średniej liczebności zbiorów decyzji globalnych  $\bar{d}_{WSD_{Ag}}$  w przybliżeniu równej 1,6 – w przypadku gdy klastry są generowane dynamicznie – uzyskujemy niższe wartości estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ), natomiast dla średniej liczebności zbiorów decyzji globalnych  $\bar{d}_{WSD_{Ag}}$  w przybliżeniu równej 2 – w przypadku gdy klastry są generowane dynamicznie – uzyskujemy wyższe wartości estymatora aktualnego poziomu błędu klasyfikatora ( $e$ );
- dla wieloagentowego systemu decyzyjnego z 11 agentami zasobów  $WSD_{Ag_5}$  – w przypadku gdy klastry są generowane dynamicznie – otrzymujemy gorsze wyniki niż dla wieloagentowego systemu decyzyjnego ze statycznie zdefiniowanymi klastrami.

### **Ekspertymenty ze zbiorem danych Dermatology**

W tabeli 4 przedstawiono wyniki eksperymentów ze zbiorem danych Dermatology, natomiast w tabeli 5 przytoczono wyniki zamieszczone w pracy [27], które otrzymano dla wieloagentowego systemu decyzyjnego z klastrami zdefiniowanymi statycznie. Oznaczenia występujące w tabelach 4 oraz 5 są takie same jak w tabelach 2 oraz 3.

Na podstawie wyników eksperymentów zamieszczonych w tabelach 4 oraz 5 można stwierdzić, że dla wszystkich rozważanych typów wieloagentowych systemów decyzyjnych zastosowanie dynamicznie generowanych klastrów wpłynęło na poprawę efektywności wnioskowania pod względem wartości estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ) lub średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}}$ ).

Tabela 4

Wyniki eksperymentów ze zbiorem danych Dermatology – dynamicznie generowane rozłączne klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	A(1)G(0,0048;2)	0	0,073	0,073	0,02
	$m_1 = 1$ A(1)G(0,0021;2)	0,009	0,018	1,009	0,02
$WSD_{Ag_2}$	A(7)G(0,00705;2)	0	0,082	1,091	0,03
	$m_1 = 2$ A(7)G(0,00165;2)	0,009	0,045	1,036	0,03
$WSD_{Ag_3}$	A(1)G(0,009;2)	0	0,073	1,082	0,02
	$m_1 = 5$ A(1)G(0,00375;2)	0,009	0,073	1,064	0,02
$WSD_{Ag_4}$	A(1)G(0,01185;2)	0	0,073	1,073	0,03
	$m_1 = 5$ A(1)G(0,01005;2)	0,009	0,073	1,064	0,03
$WSD_{Ag_5}$	A(1)G(0,02875;2)	0	0,173	1,236	0,03
	$m_1 = 5$ A(1)G(0,00465;2)	0,009	0,055	1,045	0,03

Tabela 5

Wyniki eksperymentów ze zbiorem danych Dermatology – statycznie zdefiniowane klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	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
$WSD_{Ag_2}$	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
$WSD_{Ag_3}$	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
$WSD_{Ag_4}$	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
$WSD_{Ag_5}$	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

### **Eksperymenty ze zbiorem danych Vehicle Silhouettes**

W tabeli 6 przedstawiono wyniki eksperymentów ze zbiorem danych Vehicle Silhouettes, natomiast w tabeli 7 przytoczono wyniki zamieszczone w pracy [27], które otrzymano dla wieloagentowego systemu decyzyjnego z klastrami zdefiniowanymi statycznie. Oznaczenia występujące w tych tabelach są takie same jak we wcześniejszych tabelach.

Tabela 6

Wyniki eksperymentów ze zbiorem danych Vehicle Silhouettes – dynamicznie generowane rozłączne klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$ $m_1 = 2$	A(2)G(0,0051;2)	0,138	0,476	1,528	0,06
	A(2)G(0,0018;2)	0,209	0,358	1,224	0,06
$WSD_{Ag_2}$ $m_1 = 1$	A(10)G(0,0069;2)	0,181	0,516	1,528	0,11
	A(10)G(0,003;2)	0,244	0,421	1,236	0,11
$WSD_{Ag_3}$ $m_1 = 6$	A(10)G(0,0087;2)	0,130	0,492	1,500	0,24
	A(10)G(0,00435;2)	0,205	0,398	1,260	0,24
$WSD_{Ag_4}$ $m_1 = 1$	A(4)G(0,00615;2)	0,177	0,528	1,516	0,10
	A(4)G(0,0033;2)	0,260	0,429	1,244	0,10
$WSD_{Ag_5}$ $m_1 = 4$	A(5)G(0,00615;2)	0,138	0,516	1,512	0,22
	A(5)G(0,003;2)	0,197	0,398	1,232	0,22

Tabela 7

Wyniki eksperymentów ze zbiorem danych Vehicle Silhouettes – statycznie zdefiniowane klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	A(20)G(0,00225;2)	0,106	0,492	1,524	0,32
	A(20)G(0,00125;2)	0,177	0,378	1,236	0,32
$WSD_{Ag_2}$	A(17)G(0,0035;2)	0,154	0,508	1,535	0,16
	A(17)G(0,0015;2)	0,244	0,406	1,224	0,16
$WSD_{Ag_3}$	A(1)G(0,00525;2)	0,161	0,543	1,520	0,04
	A(1)G(0,0025;2)	0,240	0,457	1,260	0,04
$WSD_{Ag_4}$	A(1)G(0,00375;2)	0,189	0,504	1,512	0,04
	A(1)G(0,002;2)	0,272	0,453	1,248	0,04
$WSD_{Ag_5}$	A(1)G(0,00475;2)	0,146	0,500	1,512	0,04
	A(1)G(0,0025;2)	0,213	0,406	1,256	0,04

Na podstawie wyników eksperymentów zamieszczonych w tabelach 6 oraz 7 można wyciągnąć następujące wnioski:

- dla wieloagentowych systemów decyzyjnych z 7, 9 oraz 11 agentami zasobów  $WSD_{Ag_3}$ ,  $WSD_{Ag_4}$ ,  $WSD_{Ag_5}$  – w przypadku gdy klastry są generowane dynamicznie – otrzymujemy znacznie lepsze wyniki niż dla wieloagentowego systemu decyzyjnego ze statycznie zdefiniowanymi klastrami;

- dla wieloagentowych systemów decyzyjnych z 3 oraz 5 agentami zasobów  $WSD_{Ag_1}, WSD_{Ag_2}$  – w przypadku gdy klastry są generowane dynamicznie – otrzymujemy gorsze wyniki niż dla wieloagentowego systemu decyzyjnego ze statycznie zdefiniowanymi klastrami.

### Eksperymenty ze zbiorem danych Landsat Satellite

Tabela 8

Wyniki eksperymentów ze zbiorem danych Landsat Satellite – dynamicznie generowane rozłączne klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$ $m_1 = 1$	A(5)G(0,00225;2)	0,033	0,330	1,736	6,00
$WSD_{Ag_2}$ $m_1 = 1$	A(3)G(0,0053;2)	0,012	0,402	1,724	6,30
	A(3)G(0,0022;2)	0,047	0,215	1,235	6,30
$WSD_{Ag_3}$ $m_1 = 2$	A(3)G(0,0057;2)	0,015	0,401	1,720	7,25
	A(3)G(0,0029;2)	0,046	0,245	1,263	7,25
$WSD_{Ag_4}$ $m_1 = 2$	A(4)G(0,0064;2)	0,013	0,378	1,644	8,30
	A(4)G(0,0032;2)	0,047	0,236	1,252	8,30
$WSD_{Ag_5}$ $m_1 = 1$	A(3)G(0,01;2)	0,011	0,425	1,764	7,50
	A(3)G(0,0042;2)	0,041	0,232	1,255	7,50

Tabela 9

Wyniki eksperymentów ze zbiorem danych Landsat Satellite – statycznie zdefiniowane klastry

System	Algorytm	$e$	$e_{ONE}$	$\bar{d}_{WSD_{Ag}}$	$t$
$WSD_{Ag_1}$	A(10)G(0,0014;2)	0,042	0,401	1,757	4,15
$WSD_{Ag_2}$	A(1)G(0,0031;2)	0,012	0,396	1,744	3,08
	A(1)G(0,0012;2)	0,047	0,221	1,23	3,08
$WSD_{Ag_3}$	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
$WSD_{Ag_4}$	A(10)G(0,0057;2)	0,02	0,348	1,698	6,32
	A(10)G(0,00285;2)	0,052	0,216	1,229	6,32
$WSD_{Ag_5}$	A(1)G(0,00585;2)	0,01	0,4	1,733	3,25
	A(1)G(0,00285;2)	0,048	0,23	1,259	3,25

W tabeli 8 przedstawiono wyniki eksperymentów ze zbiorem danych Landsat Satellite, natomiast w tabeli 9 przytoczono wyniki zamieszczone w pracy [27], które otrzymano dla

wieloagentowego systemu decyzyjnego z klastrami zdefiniowanymi statycznie. Oznaczenia występujące w tych tabelach są takie same jak we wcześniejszych tabelach.

Na podstawie wyników eksperymentów zamieszczonych w tabelach 8 oraz 9 można stwierdzić, że dla wszystkich rozważanych typów wieloagentowych systemów decyzyjnych zastosowanie dynamicznie generowanych klastrów wpłynęło na poprawę efektywności wnioskowania pod względem wartości estymatora aktualnego poziomu błędu klasyfikatora ( $e$ ) lub średniej liczebności zbiorów decyzji globalnych ( $\bar{d}_{WSD_{Ag}}$ ).

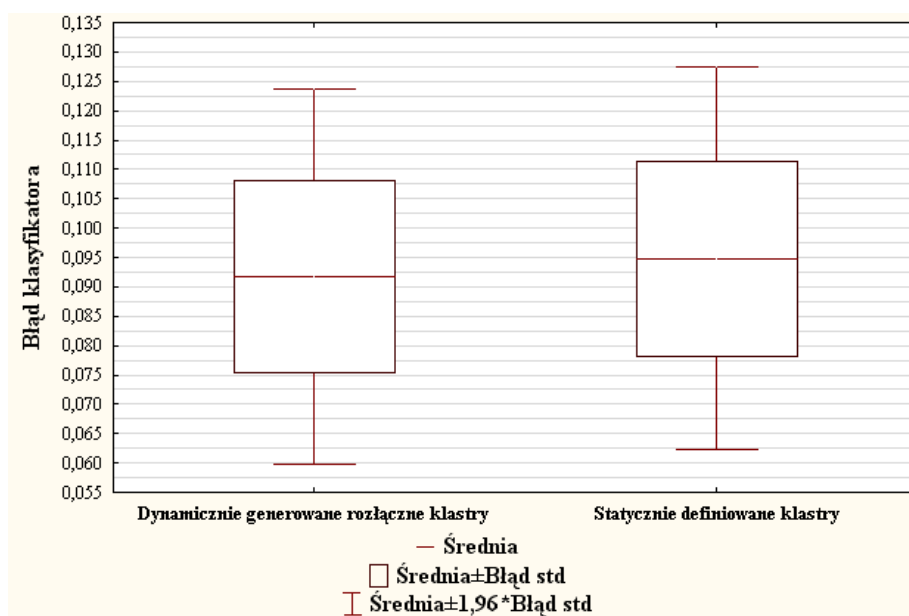
W niniejszym artykule pracy przeprowadzono wiele testów metodą *train and test* dla wieloagentowego systemu decyzyjnego o dynamicznej strukturze z wykorzystaniem rozproszonych zbiorów danych. Tak jak wspomniano wcześniej, w systemie rozpatrywanym w artykule przyjęto bardzo ogólne założenia; zbiory atrybutów warunkowych oraz zbiory obiektów różnych lokalnych baz wiedzy nie muszą być równe ani też rozłączne. Ponadto nie są przechowywane jakiegokolwiek identyfikatory obiektów znajdujących się w różnych lokalnych bazach wiedzy. Przyjęcie tak ogólnych założeń powoduje, że nie ma możliwości sprawdzenia, czy w różnych lokalnych bazach wiedzy przechowywane są te same obiekty, oraz ewentualnego zidentyfikowania, które obiekty są jednakowe, co z kolei powoduje, że zastosowanie metody k-krotnej walidacji krzyżowej staje się niemożliwe przy jednoczesnym zachowaniu ogólności. Dokładniej wynika to z założenia, że mamy wiedzę zapisaną w postaci wielu lokalnych baz wiedzy (które są zadane z góry), natomiast zbiór testowy jest zapisany w jednej tablicy, w której zbiór atrybutów warunkowych jest równy sumie zbiorów atrybutów warunkowych lokalnych baz wiedzy. Przy zastosowaniu metody kroswalidacji należałoby z każdej tablicy decyzyjnej wylosować pewną próbkę testową. Przy przyjętych założeniach nie ma możliwości zidentyfikowania, czy wylosowane zostały te same obiekty z poszczególnych lokalnych baz wiedzy. Zatem nie ma możliwości wygenerowania jednej tablicy decyzyjnej z wybranego zbioru próbek testowych.

Jednak z uwagi na kompletność testów podjęto próbę zastosowania metody k-krotnej walidacji krzyżowej. W tym celu konieczne było odstąpienie od ogólności założeń. Po pierwsze, we wszystkich lokalnych bazach wiedzy zostały uwzględnione te same obiekty, po drugie, przyjęto, że każdy obiekt ma przypisany identyfikator. Losowanie próby testowej przebiegało w następujący sposób. Wylosowano pewien zbiór identyfikatorów obiektów, a następnie z każdej lokalnej bazy wiedzy wybrano ten sam zbiór obiektów o wylosowanych identyfikatorach. Dzięki temu możliwe było wygenerowanie jednej tablicy decyzyjnej z wybranego zbioru próbek testowych. Pozostałe, niewylosowane obiekty lokalnej bazy wiedzy stanowiły w danym kroku k-krotnej walidacji krzyżowej zbiór treningowy. Wyniki otrzymane metodą 10-krotnej walidacji krzyżowej były bardzo zbliżone do wyników uzyskanych metodą *train and test*. W niniejszym artykule nie przytoczono wyników otrzymanych metodą 10-krotnej walidacji krzyżowej z uwagi na jego ograniczoną długość.



## 5. Podsumowanie

W artykule zaproponowano nowe podejście do tworzenia struktury wieloagentowego systemu decyzyjnego. W podejściu tym zastosowano dynamicznie generowane rozłączne klastry. W klastry łączeni są agenci, którzy są zgodni co do klasyfikacji danego obiektu testowego do klas decyzyjnych. Porównano wyniki eksperymentów uzyskanych dla systemu z dynamicznie generowanymi rozłącznymi klastrami z wynikami otrzymanymi przy zastosowaniu statycznie zdefiniowanych klastrów. Zauważono, że dla większości rozważanych typów wieloagentowych systemów decyzyjnych zastosowanie dynamicznie generowanych rozłącznych klastrów wpłynęło na poprawę efektywności wnioskowania w porównaniu ze statycznym podejściem do tworzenia klastrów.



Rys. 1. Porównanie systemu z dynamicznie generowanymi rozłącznymi klastrami oraz systemu ze statycznie zdefiniowanymi klastrami

Fig. 1. Comparison of system with dynamically generated disjoint clusters and system with statically defined clusters

Dla potwierdzenia tego stwierdzenia opracowano wykres porównawczy ramka-wąsy dla otrzymanych w czasie eksperymentów wartości błędu klasyfikatora (rysunek 1). Na wykresie wyraźnie widać, że średnia wartość błędu klasyfikatora odnotowana dla systemu z dynamicznie generowanymi rozłącznymi klastrami jest niższa niż średnia wartość błędu klasyfikatora dla systemu ze statycznie zdefiniowanymi klastrami.

**BIBLIOGRAFIA**

1. Bazan J., Peters J., Skowron A., Nguyen H., Szczuka M.: Rough set approach to pattern extraction from classifiers. *Electronic Notes in Theoretical Computer Science* 82, Elsevier Science Publishers, 2003.
2. Caragea D.: Learning Classifiers from Distributed, Semantically Heterogeneous, Autonomous Data Sources. PhD thesis, Iowa State University, USA 2004.
3. Chawla N., Eschrich S., Hall L.: Creating Ensembles of Classifiers. *IEEE International Conference on Data Mining*, 2001, s. 580÷581.
4. Deja R.: Conflict Analysis, Rough Sets; New Developments, [in:] Polkowski L. (ed.): *Studies in Fuzziness and Soft Computing*, Physical-Verlag, 2000.
5. 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, KDD*, 1996, s. 226÷231.
6. Faratin P., Sierra C., Jennings N.: Using Similarity Criteria to make issue trade-offs in automated negotiations. *Artificial Intelligence Journal*, Vol. 142, No. 2, 2002, s. 205÷237.
7. Franklin, S., Graesser, A.: Is it an Agent, or just a Program – A Taxonomy for Autonomous Agents. *Proceedings of the Third International Workshop on Agent Theories, Architectures, and Languages*, Springer-Verlag, Berlin 1996, s. 21÷35.
8. Jiang W., Zhang X., Cohen A., Ras Z.: Multiple Classifiers for Different Features in Timbre Estimation. *Advances in Intelligent Information Systems*, 2010, s. 335÷356.
9. Kargupta H., Park B., Johnson E., Sanseverino E., Silvestre L., Hershberger D.: Collective DataMining From Distributed Vertically Partitioned Feature Space. *Workshop on distributed data mining. International Conference on Knowledge Discovery and Data Mining*, 1998.
10. Kuncheva L.: *Combining Pattern Classifiers Methods and Algorithms*. John Wiley&Sons, 2004.
11. Lopes F., Mamede N., Novais A.Q., Coelho H.: Negotiation Strategies for Autonomous Computational Agents. *ECAI 2004*, IOS Press, Amsterdam 2004, s. 38÷42.
12. Lopes F., Wooldridge M., Novais A.Q.: Negotiation among autonomous computational agents: principles, analysis and challenges. *Artificial Intelligence Review*, Vol. 29, No. 1, 2008, s. 1÷44.
13. Michalski R., Wojtusiak J.: The Distribution Approximation Approach to Learning from Aggregated Data. *Reports of the Machine Learning and Inference Laboratory, MLI 08-2*, George Mason University, Fairfax, VA, USA 2008.

14. Nguyen T., Jennings N.: Coordinating multiple concurrent negotiations. Proceedings of 3rd International Joint Conference on Autonomous Agents and Multi Agent Systems, New York, USA 2004, s. 1064÷1071.
15. Pawlak Z.: On Conflicts. *Int. J. of Information and Computer Science*, Vol. 11, 1984, s. 344÷356.
16. Pawlak Z.: O konfliktach. Państwowe Wydawnictwo Naukowe, Warszawa 1987.
17. Pawlak Z.: *Rough Sets: Theoretical aspects of reasoning about data*. Kluwer Academic Publishers, Boston, USA 1991.
18. Pawlak Z.: An Inquiry Anatomy of Conflicts. *Journal of Information Sciences*, Vol. 109, 1998, s. 65÷78.
19. Polkowski L., Araszkiwicz B.: A rough set approach to estimating the game value and the Shapley value from data. *Fundamenta Informaticae* 53, 2003, s. 335÷343.
20. Przybyła-Kasperek M., Wakulicz-Deja A.: Application of decision rules, generated on the basis of local knowledge bases, in the process of global decision-making. 4th International Symposium on Intelligent Decision Technologies, IDT-2012, INVITED SESSION Rough Sets and Granular Computing, 2012.
21. Skowron, A., Deja, R.: On Some Conflict Models and Conflict Resolutions. *Romanian Journal of Information Science and Technology* 3(1-2), 2002, s. 69÷82.
22. Skowron A., Wang H., Wojna A., Bazan J.: Multimodal Classification: Case Studies. *T. Rough Sets*, 2006, s. 224÷239.
23. Ślęzak D., Wróblewski J., Szczuka M.: Neural network architecture for synthesis of the probabilistic rule based classifiers. [in:] *Electronic Notes in Theoretical Computer Science* 82, Elsevier Science Publishers, 2003.
24. Wakulicz-Deja A., Przybyła-Kasperek M.: Hierarchical Multi-Agent System. *Recent Advances in Intelligent Information Systems*, Academic Publishing House EXIT, 2009, s. 615÷628.
25. 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 CS&P*, Uniwersytet Warszawski, Warszawa 2009, s. 616÷627.
26. Wakulicz-Deja A., Przybyła-Kasperek M.: Multi-Agent Decision Taking System. *Fundamenta Informaticae* 101(1-2), 2010, s. 125÷141.
27. Wakulicz-Deja A., Przybyła-Kasperek M.: Wieloagentowy system decyzyjny – porównanie metod. *Studia Informatica*, Vol. 31, No. 2A (89), Gliwice 2010, s. 173÷188.
28. Wakulicz-Deja A., Przybyła-Kasperek M.: Application of the method of editing and condensing in the process of global decision-making. *Fundamenta Informaticae* 106 (1), 2011, s. 93÷117.

29. Zeng D., Sycara K.: Bayesian learning in negotiation. *Int. J. Hum. Comput. Stud.* 48, 1998, s. 125÷141.

Wpłynęło do Redakcji 27 grudnia 2012 r.

### **Abstract**

In this paper a new approach to organization of structure of multi-agent decision-making system, operating on the basis of dispersed knowledge, was proposed. In this approach dynamically generated disjoint clusters are used. The new approach is based on the assumption that one cluster should contain resource agents who agree on the classification of test object to the decision classes. This compatibility of agents is determined by certain relationships: a friendship relation and a conflict relation of agents. Definitions of friendship and conflict relations as well as method of determining the intensity of conflict between agents were taken from the paper of Zdzisław Pawlak [16].

In the process of global decision-making, the knowledge of resource agents remaining in such a coalition, is aggregated. On the basis of aggregated knowledge, local decisions, within clusters, are taken. In the last stage of global decision-making process a set of global decisions, using the method of conflict analysis, is generated.

In this paper, the efficiency of inference of the multi-agent decision-making system with dynamically generated disjoint clusters were compared with the efficiency of inference of the system with statically defined clusters. For the overwhelming majority of the considered types of multi-agent decision-making system application of dynamically generated clusters have improved the efficiency of inference. The best results were obtained for data sets: Dermatology, Vehicle Silhouettes and Landsat Satellite, slightly worse results were obtained for the Soybean Data Set. It should also be noted that the greater the number of resource agents in multi-agent decision-making system, the greater the expected improvement in the efficiency of inference, when applied dynamically generated clusters.

### **Adres**

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