

Alicja WAKULICZ-DEJA
Uniwersytet Śląski, Instytut Informatyki
Małgorzata PRZYBYŁA-KASPEREK
Uniwersytet Śląski, Instytut Matematyki

WIELOAGENTOWY SYSTEM DECYZYJNY – PORÓWNANIE METOD

Streszczenie. Praca 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. System decyzyjny działający w oparciu o kilka baz wiedzy podejmuje decyzje globalne na podstawie zbioru przesłanek określonych dla atrybutów wszystkich wykorzystywanych baz wiedzy.

Praca zawiera opis wieloagentowego systemu decyzyjnego o strukturze hierarchicznej oraz omówienie i porównanie proponowanych metod wnioskowania umożliwiających podejmowanie decyzji globalnych w tym systemie.

Słowa kluczowe: system decyzyjny, system wieloagentowy, decyzja globalna

MULTI-AGENT DECISION SYSTEM – COMPARISON OF METHODS

Summary. The paper includes issues related to the process of taking global decisions on the basis of knowledge included in a few local knowledge bases. The knowledge bases contain information regarding the same subject, but are defined on different sets of conditional attributes, which are not necessarily disjoint. Decision system, which operates based on knowledge from a few knowledge bases, take global decisions on the basis on a set of conditions inflicted on the attributes of used knowledge bases.

The paper contains a description of multi-agent decision system with a hierarchical structure. The paper also contains a discussion and comparison of the proposed methods of inference enabling global decisions taking in this system.

Keywords: decision system, multi-agent system, global decision

1. Wprowadzenie

W systemach decyzyjnych (systemach wspomaganie decyzji) stosowana jest wiedza zapisana w postaci reguł oraz metody wnioskowania w celu rozwiązywania problemów, które wymagają doświadczenia ludzkiego. Stworzono liczne systemy decyzyjne, których zadaniem jest wspomaganie podejmowania decyzji w wyspecjalizowanym, wąskim zakresie w oparciu o bazę wiedzy określoną na zadanym zbiorze atrybutów. Istotnym zagadnieniem jest możliwość jednoczesnego wykorzystania kilku lokalnych baz wiedzy, zawierających informacje dotyczące tej samej dziedziny, w celu podjęcia decyzji globalnej. Przez decyzję globalną rozumiemy decyzję podjętą na podstawie wiedzy zgromadzonej we wszystkich rozważanych bazach wiedzy. Decyzja lokalna jest to decyzja podjęta w oparciu o wiedzę znajdującą się w jednej bazie wiedzy lub w pewnym właściwym podzbiorze rozważanych baz wiedzy.

Ważnym problemem pojawiającym się podczas podejmowania decyzji globalnej jest wyeliminowanie niespójności wiedzy zgromadzonej w różnych bazach wiedzy. Przez niespójność wiedzy rozumiemy sytuację, w której w oparciu o dwie różne bazy wiedzy o wspólnych atrybutach, dla tych samych wartości na atrybutach wspólnych, korzystając z logicznych implikacji, podejmowane są sprzeczne decyzje. Aby rozwiązać ten problem proponujemy organizację lokalnych systemów decyzyjnych (podejmujących decyzje w oparciu o jedną bazę wiedzy) w system wieloagentowy o strukturze hierarchicznej. W systemie tym lokalne systemy decyzyjne, działające w oparciu o bazy wiedzy o wspólnych atrybutach warunkowych, są łączone w grupy. Kolejnym etapem procesu podejmowania decyzji globalnej jest rozwiązywanie konfliktów. Przez konflikt rozumiemy sytuację, w której dla zadanego zbioru przesłanek różne grupy lokalnych systemów decyzyjnych podejmują sprzeczne decyzje. W pracy omówione zostaną metody wnioskowania umożliwiające analizowanie konfliktów oraz generowanie zbioru decyzji globalnych. Zbiór taki 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. Omówione w pracy metody wnioskowania zaproponowane zostały przez autorów niniejszego artykułu w pracach [12, 13, 14, 15]. W publikacjach tych rozważano zastosowanie różnych metod do rozwiązania problemu analizy konfliktu, takich jak: głosowanie proste lub ważne, algorytm mrówkowy oraz algorytm gęstościowy. W niniejszej pracy porównano poprawność klasyfikacji dokonanej przez zaproponowane metody podejmowania decyzji globalnych. Eksperymenty przeprowadzono na rzeczywistych zbiorach danych. Miernikiem oceny poprawności wnioskowania jest współczynnik błędu klasyfikacji, którego definicja podana jest w dalszej części pracy.

W literaturze analiza konfliktów szeroko rozważana jest w zakresie teorii gier, gdzie podstawowymi metodami oceny siły koalicji jest indeks Shapleya-Shubika oraz indeks Banzhafa [11]. Znane są również inne sposoby rozwiązania sytuacji konfliktowych agentów. Jeden

z nich omówiony jest w pracy Zdzisława Pawlaka [8], gdzie rozważana jest metoda analizy konfliktów oparta na teorii zbiorów przybliżonych. Również inni autorzy zajmowali się tym tematem [1, 7, 10]. W pracach tych założono rozłączność zbiorów atrybutów warunkowych, na podstawie których agenci podejmują decyzję lokalną.

2. Struktura systemu wieloagentowego

W pracy przyjmujemy pojęcie agenta wprowadzone przez Zdzisława Pawlaka w pracy [8] i uwzględnione w pracy Stana Franklina [5]. Zgodnie z tą definicją agent ma następujące właściwości. Pierwszą jest zdolność agenta do autonomicznej pracy, drugą jest zdolność agenta do przeprowadzania wnioskowania w określonej dziedzinie. W pracy będziemy wykorzystywać dwa rodzaje agentów. Pierwszym z nich jest agent zasobów (ang. *resource agent*). Agent taki ma dostęp do własnej, lokalnej bazy wiedzy, na podstawie której może podjąć decyzję lokalną w wyniku procesów wnioskowania.

Niech A będzie skończonym zbiorem agentów $A = \{a_1, \dots, a_n\}$. Każdy agent $a_i \in A$ nazywany jest agentem zasobów, gdyż ma on dostęp do pewnych zasobów w postaci tablicy decyzyjnej $D_{a_i} = (U_{a_i}, A_{a_i}, d)$, gdzie U_{a_i} jest skończonym niepustym zbiorem, zwanym uniwersum, zaś elementy zbioru U_{a_i} nazywamy obiektami; A_{a_i} jest skończonym niepustym zbiorem atrybutów warunkowych, gdzie każdy atrybut $b \in A_{a_i}$ jest funkcją $b: U_{a_i} \rightarrow V_{a_i}^b$, przy czym $V_{a_i}^b$ jest zbiorem wartości atrybutu b , do którego należą znaki specjalne $*$ oraz $?$. Równość $b(x) = *$ dla pewnego $x \in U_{a_i}$ oznacza, że dla obiektu x wartość na atrybucie b nie wpływa na wartość atrybutu decyzyjnego, natomiast równość $b(x) = ?$ oznacza, że wartość atrybutu b dla obiektu x jest nieznaną; d nazywamy atrybutem decyzyjnym, jest to funkcja $d: \bigcup_{i=1}^n U_{a_i} \rightarrow V^d$, przy czym V^d jest zbiorem wartości atrybutu d .

Tablica decyzyjna D_{a_i} jest podtablicą uniwersalnej tablicy decyzyjnej $T_{a_i} = (W_{a_i}, A_{a_i}^*, d^*)$, gdzie W_{a_i} jest zbiorem wszystkich możliwych obiektów; $A_{a_i}^*$ jest skończonym niepustym zbiorem atrybutów warunkowych, gdzie każdy atrybut $b^* \in A_{a_i}^*$ jest funkcją $b^*: W_{a_i} \rightarrow V_{a_i}^{b^*}$; d^* nazywamy atrybutem decyzyjnym, jest to funkcja $d^*: \bigcup_{i=1}^n W_{a_i} \rightarrow V^{d^*}$. Oznacza to, że $U_{a_i} \subseteq W_{a_i}$ oraz spełnione są następujące warunki:

$$\forall b \in A_{a_i} \exists b^* \in A_{a_i}^* b^*/_{U_{a_i}} = b,$$

$$d^*/_{\bigcup_{i=1}^n U_{a_i}} = d,$$

gdzie $b^*/_{U_{a_i}}$ oraz $d^*/_{\bigcup_{i=1}^n U_{a_i}}$ oznacza obcięcie funkcji b^* , d^* do zbioru U_{a_i} lub odpowiednio zbioru $\bigcup_{i=1}^n U_{a_i}$.

Każdy agent zasobów $a_i \in A$ na podstawie wiedzy zawartej w tablicy decyzyjnej D_{a_i} potrafi samodzielnie wyznaczyć wartość decyzji dla zestawu przesłanek określonych na zbiorze atrybutów A_{a_i} . Nie zakładamy rozłączności zbiorów atrybutów warunkowych różnych agentów zasobów. Rozsądne wydaje się łączenie w grupy agentów, którzy wnioskujeją na podstawie wspólnych atrybutów warunkowych.

Definicja 2.1. Niech $A = \{a_1, \dots, a_n\}$ będzie zbiorem agentów zasobów. *Klastrem* nazywamy najmniejszy, ze względu na relację inkluzji, podzbiór zbioru agentów zasobów $\{a_{i_1}, \dots, a_{i_k}\} \subseteq A$, $i_1, \dots, i_k \in \{1, \dots, n\}$ spełniający następujące dwa warunki:

$$\begin{aligned} \forall_{j \in \{1, \dots, k\}} \exists_{l \in \{1, \dots, k\}; l \neq j} A_{a_{i_j}} \cap A_{a_{i_l}} &\neq \emptyset, \\ \forall_{l \in \{1, \dots, n\} \setminus \{i_1, \dots, i_k\}} \forall_{j \in \{1, \dots, k\}} A_{a_l} \cap A_{a_{i_j}} &= \emptyset. \end{aligned}$$

Warunek pierwszy powyższej definicji gwarantuje, że agenci, którzy wnioskujeją na podstawie wspólnych atrybutów warunkowych będą zaliczeni do jednego klastra. Natomiast warunek drugi definicji zapewnia rozłączność zbiorów atrybutów warunkowych agentów zasobów znajdujących się w różnych klastrach.

Do każdego klastra definiujemy agenta syntezy (ang. *synthesis agent*), ozn. S_j , gdzie j -numer klastra. Agent syntezy ma dostęp do wiedzy będącej wynikiem procesu wnioskowania przeprowadzonego przez agentów zasobów, należących do grupy jemu podrzędnej. Zadaniem agenta syntezy jest wyeliminowanie niespójności wiedzy, do której mają dostęp agenci zasobów.

3. Metody eliminacji niespójności wiedzy

W niniejszej pracy rozważać będziemy algorytmy realizujące dwie zaproponowane metody eliminacji niespójności wiedzy:

- metoda boolowska analizy niespójności,
- aproksymacyjna metoda agregacji tablic decyzyjnych.

Metoda boolowska analizy niespójności wiedzy rozpatruje niekoherencje obiektów, należących do tablic decyzyjnych agentów zasobów, relewantnych do zbioru przesłanek, dla którego chcemy podjąć decyzje globalne. Aproksymacyjna metoda agregacji tablic decyzyjnych polega na stworzeniu zbioru nowych tablic decyzyjnych. Tablice te konstruowane są poprzez agregację obiektów relewantnych, należących do tablic decyzyjnych agentów zasobów z jednego klastra.

Podamy teraz definicje formuły oraz P-formuły (można je również znaleźć w literaturze [9]), które będziemy wykorzystywać do formalnego zapisu zbioru przesłanek, dla którego chcemy dokonać predykcji wartości atrybutu decyzyjnego.

Definicja 3.1 Niech $S = (U, A)$ będzie systemem informacyjnym oraz niech zbiór $P = \{b_1, \dots, b_k\}$ będzie podzbiorem zbioru atrybutów A . Wówczas formułą atomową nazywamy wyrażenie postaci (b, v) , gdzie $b \in A$ oraz $v \in V^b$. Mówimy, że obiekt $x \in U$ spełnia formułę atomową (b, v) w systemie S , ozn. $x \models_S (b, v)$, wtedy i tylko wtedy, gdy $b(x) = v$. Formułę α 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. Jeśli $P = A$, to wyrażenie α nazywamy formułą. Mówimy, że obiekt $x \in U$ spełnia P -formułę α w systemie S , ozn. $x \models_S \alpha$ wtedy i tylko wtedy, gdy

$$\forall_{i \in \{1, \dots, k\}} x \models_S (b_i, v_i).$$

Założmy zatem, że zbiór przesłanek, dla którego chcemy dokonać predykcji wartości atrybutu decyzyjnego, opisany jest przez $\bigcup_{i=1}^n A_{a_i}$ -formułę α . Z tej formuły konstruujemy zbiór n formuł $\{\beta_1, \dots, \beta_n\}$, które są koniunkcją formuł atomowych zadanych dla wartości atrybutów warunkowych każdego z n agentów zasobów. Zatem formuła β_i jest A_{a_i} -formułą utworzona z formuły α .

Podzbiory obiektów relewantnych do zbioru przesłanek ozn. $U_{a_i}^{rel}$, $i = 1, \dots, n$, dla którego chcemy podjąć decyzje globalne, wyznaczane są w następujący sposób. Z tablicy decyzyjnej D_{a_i} dla każdej wartości decyzji $v \in V^d$ wybieramy najmniejszy zbiór liczący co najmniej m obiektów, których wartości na atrybutach warunkowych realizują największe podobieństwo do zbioru przesłanek oraz wartość na atrybucie decyzyjnym jest równa v . Parametr m , który należy określić przy zastosowaniu tej metody, będziemy dobierać eksperymentalnie. Aby wyznaczyć zbiór obiektów relewantnych, należy obliczyć wartość współczynnika podobieństwa każdego z obiektów należących do tablicy decyzyjnej agenta zasobów do zbioru przesłanek. Opierać będziemy się na miarach podobieństwa obiektów Sneatha oraz Gowera [6].

Współczynnik podobieństwa Sneatha jest to miara stosowana dla obiektów o cechach jakościowych. Przy założeniu, że obiekty x oraz y opisywane są przez p -wymiarowy zestaw cech jakościowych $\{a_1, \dots, a_p\}$, miarę tę definiujemy następująco:

$$s(x, y) = \frac{\text{card}\{a_i: a_i(x) = a_i(y), i = 1, \dots, p\}}{p}.$$

Miary Gowera używamy, gdy obiekty są opisywane przez atrybuty o wartościach mieszanych (ilościowych, jakościowych oraz binarnych). Dla każdego atrybutu dokonujemy obliczenia cząstkowego współczynnika podobieństwa. Jeśli i -ty atrybut jest atrybutem ilościowym, to $s_i(x, y) = 1 - \frac{|a_i(x) - a_i(y)|}{\text{zakres } i\text{-tego atrybutu}}$, jeśli jest atrybutem jakościowym, to

$$s_i(x, y) = \begin{cases} 1, & a_i(x) = a_i(y) \\ 0, & \text{w przeciwnym przypadku} \end{cases}$$

jeśli jest atrybutem binarnym, to

$$s_i(x, y) = \begin{cases} 1, & a_i(x) = 1 \wedge a_i(y) = 1 \\ 0, & (a_i(x) = 1 \wedge a_i(y) = 0) \vee (a_i(x) = 0 \wedge a_i(y) = 1) \end{cases}$$

Miara Gowera uwzględnia również przypadek, w którym wartości danego atrybutu są nieporównywalne (na przykład w sytuacji, gdy wartości tej brakuje lub gdy atrybut binarny nie występuje dla jednego z obiektów). Wówczas $s_i(x, y) = 0$ oraz $\delta_i = 0$. Jeśli istnieje możliwość porównania i -tego atrybutu, to $\delta_i = 1$. Miarę podobieństwa Gowera dla obiektów x oraz y , opisywanych przez p atrybutów, definiujemy następująco:

$$s(x, y) = \frac{\sum_{i=1}^p s_i(x, y)}{\sum_{i=1}^p \delta_i}.$$

Stosując miarę podobieństwa Sneatha lub Gowera, dla każdego obiektu z tablicy decyzyjnej agenta zasobów D_{a_i} , wyznaczamy współczynnik podobieństwa wartości na atrybutach warunkowych obiektu do zbioru przesłanek β_i . Następnie z każdej klasy decyzyjnej $v \in V^d$ wybieramy m obiektów, które są najbardziej podobne do zbioru przesłanek. Przy czym, jeżeli więcej niż jeden obiekt z tablicy decyzyjnej agenta zasobów jest tak samo podobny do zbioru przesłanek jak m -ty obiekt, to pod uwagę bierzemy obiekty bliższe zbiorowi przesłanek niż m -ty obiekt oraz wszystkie obiekty tak samo podobne do zbioru przesłanek jak m -ty obiekt. Podzbiór obiektów relewantnych jest sumą zbiorów obiektów wybranych ze wszystkich klas decyzyjnych.

Po wygenerowaniu podzbiorów obiektów relewantnych w metodzie boolowskiej analizy niespójności wiedzy kolejnym krokiem jest sprawdzenie, czy dla każdych dwóch różnych agentów zasobów znajdziemy obiekty relewantne, które mają równe wartości na wszystkich wspólnych atrybutach warunkowych oraz tę samą wartość na atrybucie decyzyjnym. Oczywiście analizy tej dokonujemy tylko w obrębie jednego klastra, gdyż agenci, którzy należą do różnych klastrów, mają rozłączne zbiory atrybutów warunkowych. Jeśli dla danej wartości decyzji oraz dla wszystkich par agentów z jednego klastra istnieją obiekty relewantne, które są zgodne na wspólnych atrybutach warunkowych i atrybucie decyzyjnym, to uznajemy, że nie występuje niespójność wiedzy dotyczącej danej wartości decyzji w obrębie klastra. W kolejnym etapie podejmowania decyzji globalnych preferowane będą te decyzje, dla których nie odnotowano niespójności wiedzy w żadnym z klastrów.

W aproksymacyjnej metodzie agregacji tablic decyzyjnych każdy agent syntezy dysponuje zasobami podanymi w formie tablicy decyzyjnej, która skonstruowana jest z podzbiorów obiektów relewantnych należących do tablic decyzyjnych agentów zasobów podrzędnych wobec agenta syntezy. Tablice zagregowane będziemy definiować następująco.

Definicja 3.2 Niech $\{a_{i_1}, \dots, a_{i_k}\}$ będzie klastrem, natomiast S agentem syntezy nadrzędnym w stosunku do tego klastra. Wówczas zasoby agenta S można zapisać w postaci tablicy

decyzyjnej $D_S = (U_S, A_S, \bar{d})$. Ponadto dla każdego maksymalnego ze względu na relację inkluzji zbioru $G = \{a_{i_{j_1}}, \dots, a_{i_{j_k}}\} \subseteq \{a_{i_1}, \dots, a_{i_k}\}$ oraz każdego zbioru obiektów $\{x_{i_{j_1}}, \dots, x_{i_{j_k}}\}$, $x_{i_m} \in U_{a_{i_m}}^{rel}$, $j_1 \leq m \leq j_k$, dla którego spełnione są warunki:

$$\forall_{b \in W_{SpG}} \exists_{v_b \in V^b} \forall_{j_1 \leq m \leq j_k} [b \in A_{a_{i_m}} \rightarrow b(x_{i_m}) = v_b],$$

$$d(x_{i_{j_1}}) = \dots = d(x_{i_{j_k}}),$$

gdzie $W_{SpG} = \{b: b \in A_{a_i} \cap A_{a_j} \text{ oraz } a_i, a_j \in G\}$, definiujemy obiekt $x \in U_S$ następująco:

$$\forall_{a_j \in G} \forall_{b \in A_{a_j}} [\bar{b}(x) := b(x_j) \text{ oraz } \bar{d}(x) := d(x_j)],$$

$$\forall_{b \in \bigcup_{j=1}^k A_{a_{i_j}} \setminus \bigcup_{m=j_1}^{j_k} A_{a_{i_m}}} \bar{b}(x) = ?,$$

gdzie \bar{b} oraz \bar{d} są funkcjami $\bar{b}: U_S \rightarrow V^b$, $\bar{d}: U_S \rightarrow V^d$; $A_S = \{\bar{b}: U_S \rightarrow V^b, b \in \bigcup_{j=1}^k A_{a_{i_j}}\}$.

Przy czym tablica D_S jest podtablicą uniwersalnej tablicy decyzyjnej $T_S = (W_S, A_S^*, \bar{d}^*)$, gdzie $A_S^* = \bigcup_{j=1}^k A_{a_{i_j}}^*$; $\bar{d}^*: W_S \rightarrow V^d$.

Powyższą definicję można zinterpretować następująco: każdy obiekt, należący do tablicy decyzyjnej agenta syntezy, jest odwzorowaniem wspólnych przesłanek, które skłoniły agentów zasobów, należących do pewnego maksymalnego podzbioru jednego klastra, do podjęcia zgodnej decyzji. Równanie $\bar{b}(x) = ?$ dla pewnego atrybutu warunkowego $\bar{b} \in A_S$ oraz obiektu $x \in U_S$ oznacza, że agenci zasobów, podejmujący decyzje na podstawie atrybutu \bar{b} , nie wykazywali zgodności z agentami, których przesłanki przy podejmowaniu określonej decyzji zapisane zostały w obiekcie x .

4. Analiza konfliktów

Po wykonaniu eliminacji niespójności wiedzy agenci syntezy mają wiedzę wystarczającą do podjęcia lokalnej decyzji o zasięgu jednego klastra. Jak już wspomniano wcześniej, sytuację, w której agenci syntezy głosując niezależnie wybraliby różne wartości decyzji dla zadanego zbioru przesłanek, nazywamy konfliktem. Do rozwiązywania problemu analizy konfliktu stosujemy:

- głosowanie proste lub ważone,
- algorytm mrówkowy,
- algorytm gęstościowy.

Podejmowanie decyzji globalnych przez głosowanie zastosowano w połączeniu z metodą boolowską analizy niespójności wiedzy. Jak już wspomniano wcześniej, w metodzie boolowskiej analizy niespójności każdy agent zasobów a_i wyznacza podzbiór $U_{a_i}^{rel}$ obiektów rele-

wantnych do zbioru przesłanek z parametrem m równym 1. Następnie każdy agent syntezy, dla każdej wartości decyzji $v \in V^d$ wyznacza średnią z wartości podobieństwa obiektów, które należą do podzbiorów obiektów relewantnych agentów zasobów podrzędnych wobec agenta syntezy i mają wartość na atrybucie decyzyjnym równą v . W głosowaniu prostym zbiorem decyzji preferowanych przez danego agenta syntezy są decyzje, dla których wyznaczona wartość średnia jest maksymalna oraz nie odnotowano niespójności wiedzy dla tej decyzji w obrębie klastra. W głosowaniu ważonym wielkości wag określające siłę głosu agentów syntezy zadajemy jako wartość wyznaczonej wcześniej średniej.

Zastosowanie podstawowych metod rozwiązywania konfliktów takich jak głosowanie proste lub ważne powoduje wybranie wartości decyzji, które są preferowane przez ponad połowę agentów lub otrzymały maksymalne poparcie agentów syntezy. Zauważmy, że w zbiorze wartości decyzji mogą znajdować się takie decyzje, które wprawdzie nie otrzymały maksymalnego poparcia agentów syntezy, ale pewność, z jaką agenci syntezy podjęliby tę decyzję, jest relatywnie wysoka. Aby znaleźć takie wartości i uwzględnić je w zbiorze decyzyjnym zaproponowano dwie kolejne metody analizy konfliktów wykorzystujące algorytm mrówkowy i algorytm gęstościowy. Metody te zastosowano w połączeniu z aproksymacyjną metodą agregacji tablic decyzyjnych. W obu przypadkach pierwszym etapem procesu podejmowania decyzji globalnych jest wyznaczenie poziomu pewności, z jakim wszyscy agenci syntezy podejmują daną decyzję.

$$TD_v = \sum_{j=1}^m \frac{\mu_{S_j}(v)}{\sum_{z \in V^d} \mu_{S_j}(z)}, \quad v \in V^d,$$

gdzie $\mu_{S_j}(v) = \max\{s(x, \alpha_j) : x \in U_{S_j} \text{ oraz } d(x) = v\}$ jest największą wartością podobieństwa obiektów ze zbioru U_{S_j} do formuły α_j . Przy czym formuła α_j jest koniunkcją formuł atomowych zadanych dla wartości atrybutów warunkowych j -tego agenta syntezy, utworzoną z formuły α , $j = 1, \dots, m$. W dalszej części pracy będziemy zakładać, że każda wartość decyzji $v \in V^d$ reprezentowana jest za pomocą zdefiniowanego powyżej poziomu pewności, z jakim wszyscy agenci syntezy podejmują tę decyzję.

Metoda algorytmu mrówkowego wykorzystuje inteligencję sztucznych mrówek. Opiera się ona na założeniu, że każda sztuczna mrówka potrafi wykonać proste działania, natomiast kolonia mrówek współpracujących jest w stanie rozwiązać złożony problem. Agenci mrówki po wykonaniu zadania pozostawiają ślad feromonowy, którego ilość jest uzależniona od jakości otrzymanego przez nich rozwiązania. Ślad feromonowy po pewnym czasie zanika. Kolejna sztuczna mrówka podąża śladem feromonowym pozostawionym przez poprzednie mrówki. W pierwszym kroku metody inicjujemy wartości feromonu dla każdej decyzji

$$TD_v(t = 0) = TD_v, \quad v \in V^d.$$

Następnie wyznaczany jest początkowy zbiór rozwiązań

$$D_{max} = \left\{ v \in V^d : TD_v = \max_{z \in V^d} TD_z \right\},$$

zawierający wartości decyzji, które otrzymały maksymalne poparcie wszystkich agentów syntezy. Miarą, za pomocą której będziemy oceniać jakość rozwiązania, otrzymanego przez mrówkę, jest współczynnik zmienności zbioru decyzyjnego. Definiujemy go następująco.

Definicja 4.1 Niech D będzie niepustym podzbiorem zbioru wartości atrybutu decyzyjnego V^d , $D \subseteq V^d$ oraz niech $TD_v(t), v \in V^d$ będzie zbiorem wartości feromonu dla decyzji. Wówczas współczynnik zmienności zbioru decyzyjnego definiujemy następująco:

$$DSV := \frac{\sum_{v \in D} \sum_{z \notin D} |TD_v(t) - TD_z(t)| - \frac{1}{2} \sum_{v \in D} \sum_{z \in D} |TD_v(t) - TD_z(t)|}{\frac{1}{2} \sum_{v \in V^d} \sum_{z \in V^d} |TD_v(t) - TD_z(t)|} - \frac{|D| - 1}{|V^d|} \varepsilon,$$

gdzie ε jest stałą z przedziału $(0,1)$.

Pierwsze wyrażenie z licznika współczynnika DSV informuje o zmienności pomiędzy wartościami decyzji należącymi do zbioru decyzyjnego a wartościami decyzji spoza tego zbioru. Drugie wyrażenie licznika informuje o zmienności wewnątrz zbioru decyzyjnego. Wyrażenie $\frac{|D|-1}{|V^d|}$ jest współczynnikiem kary dużego zbioru. Przemnożenie tego współczynnika przez stałą $\varepsilon \in (0,1)$ pozwala kontrolować wpływ wartości wyrażenia na wartość współczynnika zmienności zbioru decyzyjnego. Algorytm realizujący tę metodę analizy konfliktów generuje niewielkie zbiory decyzji globalnych dla wartości współczynnika ε bliskich 1, natomiast dla wartości współczynnika ε bliskich 0 algorytm generuje zbiory decyzji globalnych, które zawierają średnio więcej wartości decyzji. Wartość współczynnika ε dobieramy eksperymentalnie.

Każdy agent-mrówka wykonuje ciąg poniższych operacji. Pierwszą czynnością i -tego agenta, należącego do populacji t , jest ustalenie zbioru $D_i(t) = \emptyset$. Następnie:

- 1) Z prawdopodobieństwem proporcjonalnym do wartości współczynników feromonu $TD_v(t), v \in V^d$ agent-mrówka losuje jedną wartość decyzji ze zbioru $V^d \setminus D_{max}$.
- 2) Jeśli wylosowana wartość decyzji nie należy do zbioru $D_i(t)$, to agent dodaje ją do tego zbioru.

Operacje 1 i 2 są powtarzane, dopóki współczynnik zmienności zbioru decyzyjnego $D_{max} \cup D_i(t)$ wyznaczony dla wartości feromonu $TD_k(t=0)$ jest większy niż współczynnik zmienności zbioru decyzyjnego otrzymanego w poprzedniej iteracji. Zatem, jak długo dodawanie do zbioru decyzyjnego wylosowanej wartości decyzji zwiększa jego współczynnik zmienności, tak długo agent-mrówka wykonuje operacje 1 i 2. Zbiór decyzyjny $D_{max} \cup D_i(t)$, który wyznaczony został przez agenta w ostatniej iteracji powtarzanych kroków, interpretujemy jako rozwiązanie otrzymane przez i -tą mrówkę.

Jeśli wszystkie mrówki należące do populacji t wyznaczą rozwiązanie, to aktualizowane są współczynniki feromonu w sposób następujący:

$$TD_v(t+1) = \sum_{i=1}^p [(1-\rho)TD_v(t) + DSV_i \cdot TD_v(t) \cdot x_{iv}], \quad v \in V^d$$

gdzie p jest liczbą mrówek należących do populacji t ; DSV_i jest współczynnikiem zmienności zbioru decyzyjnego, który jest rozwiązaniem wyznaczonym przez i -tą mrówkę; $x_{iv} = 0$, jeśli $v \notin D_i(t)$, $x_{iv} = 1$, jeśli $v \in D_i(t)$; ρ jest współczynnikiem wyparowania feromonu, stałą należącą do przedziału $(0,1)$. Kolejna populacja mrówek $t+1$ wykonuje ciąg operacji opisanych powyżej, przy czym mrówki z tej populacji losują wartości decyzji z prawdopodobieństwem proporcjonalnym do wartości współczynników feromonu $TD_v(t+1)$, $v \in V^d$.

Kiedy już ustalona liczba populacji wyznaczy rozwiązania w sposób opisany powyżej, spośród wszystkich rozwiązań wybieramy zbiór decyzyjny o największym współczynniku zmienności i interpretujemy go jako zbiór decyzji globalnych podjętych dla zadanego zbioru przesłanek.

Kolejną metodą umożliwiającą uwzględnienie w zbiorze decyzji globalnych wartości, które otrzymały relatywnie wysokie poparcie agentów syntezy, jest metoda wykorzystująca popularny algorytm wyszukiwania gęstości DBSCAN [4]. Algorytm ten polega na wyszukiwaniu punktów gęsto ułożonych, dzięki temu dobrze wykrywa punkty oddalone. Podstawową ideą zastosowanej metody jest założenie, iż dla każdego punktu należącego do skupienia punktów gęsto ułożonych musi być spełniony warunek, że w ε -otoczeniu znajduje się minimalna, z góry zadana, liczba punktów. Przy czym ε -otoczenie definiujemy jako zbiór wszystkich punktów, których odległość od zadanego punktu względem wybranej miary jest nie większa niż ε . Definicja skupienia oparta jest na obiektach wzajemnie osiągalnych lub połączonych z pewną zadaną gęstością.

Punkt y jest bezpośrednio osiągalny z zadaną gęstością z innego punktu x , jeśli spełnione są warunki:

$$y \in \{z \in X: d(x, z) \leq \varepsilon\},$$

$$|\{z \in X: d(x, z) \leq \varepsilon\}| \geq MinPts,$$

gdzie $d(x, z)$ oznacza odległość punktów względem miary, $MinPts$ to ustalony parametr określający minimalną liczebność zbioru.

Punkt osiągalny z zadaną gęstością z innego punktu, to punkt, dla którego istnieje ścieżka punktów bezpośrednio osiągalnych z punktu startowego do końcowego. Dwa punkty x, y są połączone z pewną zadaną gęstością, jeśli istnieje punkt z , dla którego punkty x i y są osiągalne z zadaną gęstością.

Niech X będzie zbiorem punktów. Skupieniem C nazywamy niepusty podzbiór zbioru X spełniający warunki:

$$\forall_{x, y \in X} [(x \in C \text{ oraz } y \text{ jest osiągalny z zadaną gęstością z punktu } x) \Rightarrow y \in C],$$

$\forall_{x,y \in C}$ x i y są połączone z pewną zadaną gęstością.

Stosując algorytm DBSCAN z odległością Euklidesową, wyznaczamy grupy decyzji (zdefiniowane powyżej skupienia), które mają podobne poparcie wśród agentów syntezy. Zbiorem podjętych decyzji globalnych będzie skupienie, do którego należy wartość decyzji z największym poparciem wszystkich agentów syntezy.

5. Wyniki eksperymentów obliczeniowych

Algorytmy realizujące omówione metody podejmowania decyzji globalnej zaimplementowano w języku C#. Na podstawie wczytanego pliku tekstowego, zawierającego dane o liczbie agentów zasobów oraz tablice decyzyjne agentów, algorytm realizuje jedną z metod eliminacji niespójności wiedzy oraz analizy konfliktów i generuje zbiór decyzji globalnych dla danego zbioru przesłanek, zapisanego w odrębnym pliku tekstowym.

Dokonyjemy analizy poprawności klasyfikacji dokonywanej przez trzy algorytmy:

- Algorytm 1: realizuje boolowską analizę niespójności oraz głosowanie ważne.
- Algorytm 2: realizuje aproksymacyjną agregację tablic decyzyjnych oraz algorytm mrówkowy.
- Algorytm 3: realizuje aproksymacyjną agregację tablic decyzyjnych oraz algorytm gęstościowy.

Miarami określającymi jakość klasyfikacji są:

- estymator aktualnego poziomu błędu klasyfikatora oparty na n -elementowej próbie testowej $((\alpha_1, Y_1), \dots, (\alpha_n, Y_n))$ niezależnej od zbioru treningowego

$$e = \frac{1}{n} \sum_{i=1}^n I(Y_i \notin Al(\alpha_i)),$$

gdzie $I(Y_i \notin Al(\alpha_i)) = 1$ gdy $Y_i \notin Al(\alpha_i)$ oraz $I(Y_i \notin Al(\alpha_i)) = 0$ gdy $Y_i \in Al(\alpha_i)$; $Al(\alpha_i)$ jest zbiorem decyzji globalnych wygenerowanych przez algorytm Al dla α_i ,

- estymator aktualnego poziomu błędu wieloznaczności klasyfikatora oparty na n -elementowej próbie testowej $((\alpha_1, Y_1), \dots, (\alpha_n, Y_n))$ niezależnej od zbioru treningowego

$$e_{ONE} = \frac{1}{n} \sum_{i=1}^n I(Y_i \neq Al(\alpha_i)),$$

gdzie $I(Y_i \neq Al(\alpha_i)) = 1$ gdy $\{Y_i\} \neq Al(\alpha_i)$ oraz $I(Y_i \neq Al(\alpha_i)) = 0$ gdy $\{Y_i\} = Al(\alpha_i)$,

- średnia liczebność zbiorów decyzji globalnych wygenerowanych dla próby testowej (\bar{D}).

Z powodu braku dostępu do zbioru lokalnych baz wiedzy, które zawierałyby wiedzę z jednej dziedziny oraz miały wspólny atrybut decyzyjny, w celu wykonania eksperymentów

dokonano podziału jednego zbioru danych na moduły. Testy zostały przeprowadzone na zbiorach danych dostępnych w repozytorium UCI repository [16]:

- Soybean Data Set,
- Primate splice-junction gene sequences (DNA),
- Dermatology Data Set,
- Vehicle Silhouettes.

Charakterystyki liczbowe zbiorów danych podano w tabeli 1.

Każdy ze zbiorów został podzielony na moduły, tablice decyzyjne o losowo wybranych, wspólnych atrybutach warunkowych tak, aby możliwe było przetestowanie pracy algorytmu podejmowania decyzji globalnej. Rozważano systemy wieloagentowe o dwóch różnych strukturach, w wersji z pięcioma oraz siedmioma agentami zasobów.

Tabela 1

Charakterystyki zbiorów danych

Zbiór danych	# Obiekty	# Atrybuty warunkowe	# Decyzje
Soybean	307	35	19
DNA	3190	60	3
Dermatology	366	34	6
Vehicle	846	18	4

Pierwszy i drugi zbiór danych zawierają tylko atrybuty jakościowe. W trzecim zbiorze danych występują atrybuty jakościowe, ilościowe ciągłe oraz skokowe. W czwartym zbiorze danych znajdują się tylko atrybuty ilościowe. W przypadku pierwszego zbioru próba testowa, zawierająca 376 obiektów, została pobrana z repozytorium UCI. Drugi, trzeci oraz czwarty zbiór danych zostały podzielone w sposób losowy na zbiór treningowy oraz próbę testową.

Miary określające jakość klasyfikacji zostały zamieszczone w tabeli 2 oraz 3. Podane wyniki otrzymano dla najlepszego znalezionej wartości parametrów definiowanych przez użytkownika. W tabeli 4 zamieszczono miary otrzymane w poszczególnych przypadkach testowych dla algorytmu 3 oraz zbioru danych DNA. Wartości te pokazują wpływ parametru m na wartość współczynnika błędu klasyfikacji. Testy, których wyniki zaprezentowano w tabeli 4, były przeprowadzone w następujący sposób: do zadanej wartości parametru m dobierano wartości parametrów ε oraz $MinPts$ tak, aby średnia liczebność zbiorów decyzji globalnych była na zadanym poziomie. Na podstawie eksperymentów wnioskujemy, że dla wieloagentowego systemu decyzyjnego składającego się z pięciu agentów zasobów optymalną wartością parametru m jest 4 lub 5. Natomiast dla wieloagentowego systemu decyzyjnego składającego się z siedmiu agentów zasobów optymalną wartością parametru m jest 3. Podobną analizę przeprowadzono dla pozostałych zbiorów danych oraz algorytmu 2 i algorytmu 3.

Tabela 2

Wyniki eksperymentów

Dane	#A	Algorytm 1				Algorytm 2					
		e	e_{ONE}	\bar{D}	t	e	e_{ONE}	\bar{D}	t	#x	#U
Soybean	5	0,269	0,412	1,19	0.01	0,066	1	3,20	3.10	57	307
	7	0,189	0,423	1,28	0.02	0,075	1	3,32	3.12	88	307
DNA	5	0,185	0,299	1,14	0.08	0,235	0,320	1,09	0.37	129	1595
	7	0,177	0,289	1,13	0.09	0,201	0,287	1,09	1.24	180	1595
Dermatology	5	0,045	0,155	1,12	0.01	0,082	0,527	1,58	0.13	16	256
	7	0,082	0,127	1,05	0.01	0,027	0,536	1,56	0.13	16	256
Vehicle	5	0,298	0,520	1,33	0.01	0,192	0,640	1,62	0.41	25	423
	7	0,298	0,482	1,26	0.01	0,194	0,602	1,51	0.41	17	423

Tabela 3

Wyniki eksperymentów

Dane	#A	Algorytm 3					
		e	e_{ONE}	\bar{D}	t	#x	#U
Soybean	5	0,141	0,779	2,93	0.03	57	307
	7	0,072	0,915	4,27	0.05	88	307
DNA	5	0,088	0,529	1,70	0.50	129	1595
	7	0,061	0,485	1,67	0.59	115	1595
Dermatology	5	0,018	0,164	1,18	0.02	16	256
	7	0	0,273	1,46	0.02	16	256
Vehicle	5	0,128	0,522	1,60	0.11	41	423
	7	0,128	0,508	1,59	0.13	37	423

Tabela 4

Wpływ parametru m na jakość klasyfikacji

m	Algorytm 3, DNA, 5 agentów			Algorytm 3, DNA, 7 agentów		
	e	e_{ONE}	\bar{D}	e	e_{ONE}	\bar{D}
1	0,194	0,633	1,70	0,115	0,539	1,66
2	0,109	0,565	1,70	0,062	0,494	1,67
3	0,087	0,538	1,70	0,061	0,485	1,67
4	0,085	0,532	1,70	0,066	0,486	1,67
5	0,088	0,529	1,70	0,069	0,494	1,67
6	0,089	0,530	1,71	0,065	0,487	1,67
7	0,095	0,526	1,70	0,069	0,487	1,67
8	0,095	0,524	1,69	0,071	0,493	1,66

W tabelach 2 oraz 3 znajduje się również wyrażony w minutach czas potrzebny do analizy próby testowej (t). W przypadku algorytmów realizujących aproksymacyjną metodę agregacji tablic decyzyjnych podano maksymalną liczbę obiektów, należących do tablicy decyzyjnej agenta zasobów, wykorzystaną do budowy tablicy decyzyjnej agenta syntezy (#x).

W tabeli podano również liczbę obiektów, należących do tablicy decyzyjnej agenta zasobów (#U).

6. Podsumowanie

Proponowane metody podejmowania decyzji globalnych na podstawie wiedzy zgromadzonej w różnych bazach wiedzy, dotyczących tej samej dziedziny, pozwalają na podejmowanie decyzji w oparciu o większy zbiór przesłanek. Tym samym poprawność dokonanej klasyfikacji jest większa niż poprawność klasyfikacji przeprowadzonej na podstawie tylko jednej bazy wiedzy. Zaproponowana metoda organizacji lokalnych systemów decyzyjnych w system wieloagentowy o strukturze hierarchicznej pozwala wyeliminować niespójność wiedzy na niższym poziomie hierarchii, co wymaga mniejszego nakładu pracy. Natomiast na wyższym poziomie rozwiązywany jest konflikt decyzji podjętych przez agentów, wynikający z różnic w decyzjach już częściowo zagregowanych. Zaproponowane w pracy metody wnioskowania umożliwiają generowanie zbioru decyzji globalnych. Zbiór taki zawiera 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.

W pracy omówiono dwie metody eliminacji niespójności wiedzy oraz trzy metody analizy konfliktów. Przedstawiono również wyniki eksperymentów przeprowadzonych dla algorytmów realizujących omówione metody z zastosowaniem danych rzeczywistych. Wyniki testów pokazują, że algorytm 3, który realizuje aproksymacyjną metodę agregacji tablic decyzyjnych oraz algorytm gęstościowy, dokonuje klasyfikacji o najmniejszym współczynniku błędu. W jednym z przypadków otrzymaliśmy nawet współczynnik błędu klasyfikacji e równy 0, a dla wszystkich testowanych baz jest on bliski zeru. Algorytm 1, który realizuje bołowską analizę niespójności oraz głosowanie ważone w większości przypadków dokonuje klasyfikacji z największym współczynnikiem błędu.

Najmniejszą złożoność czasową wykazuje algorytm 1, natomiast algorytm 2 charakteryzuje się największą złożonością czasową.

Zbiory decyzji globalnych podjęte przez zaproponowane algorytmy zawierają średnio więcej niż jedną wartość. Jednak na przykład wiedza, która pozwala na stwierdzenie z tak dużą pewnością, że ze zbioru dziewiętnastu chorób możemy wykluczyć szesnaście, jest bardzo przydatna. Ostatecznie naszym celem jest znalezienie jak najmniejszego zbioru decyzji globalnych podjętych przy wypracowanej zgodzie agentów, które są najbardziej odpowiednie dla zestawu otrzymanych przesłanek, a nie znalezienie jednej decyzji.

BIBLIOGRAFIA

1. Deja R., Conflict analysis, Rough Sets; New Developments. In: Polkowski L. (eds.), Studies in Fuzziness and Soft Computer Science, Physica-Verlag, 2000.
2. Dorigo M., DiCaro G., Gambardella L.M., Ant Algorithms for Discrete Optimisation, *Artificial Life* 5, 1999, s. 137÷172.
3. Dorigo M., Blum C., Ant colony optimization theory: A survey, *Theoretical Computer Science* 344, 2005, s. 243÷278.
4. Ester M., Kriegel H.P., Sander J., Xu X., A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. In: Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining, 1996, s. 226÷231.
5. 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, Berlin: Springer-Verlag, 1996, s. 21÷35.
6. Koronacki J., Ćwik J., Statystyczne systemy uczące się, EXIT, Warszawa, 2008.
7. Pawlak Z., An Inquiry Anatomy of Conflicts, *Journal of Information Sciences* 109, 1998, s. 65÷78.
8. Pawlak Z., On conflicts. *Int. J. of Man-Machine Studies*, 1984, nr 21, s. 127÷134.
9. Pawlak Z., *Rough Sets: Theoretical aspects of reasoning about data*. Kluwer Academic Publishers, Boston, 1991.
10. 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.
11. Straffin P., *Teoria gier*, Scholar, Warszawa, 2004.
12. Wakulicz-Deja A., Przybyła-Kasperek M.: Hierarchiczny system Wieloagentowy, *Studia Informatica*, 2007, nr 4 (74), s. 63÷80.
13. Wakulicz-Deja A., Przybyła-Kasperek M., Hierarchical Multi-Agent System, *Recent Advances in Intelligent Information Systems*, Academic Publishing House EXIT, 2009, s. 615÷628.
14. Wakulicz-Deja A., Przybyła-Kasperek M., Podejmowanie decyzji globalnej z zastosowaniem hierarchicznego systemu wieloagentowego oraz algorytmu mrówkowego, *ZN Pol. Śl. Studia Informatica Vol. 30, No. 2A (83)*, 2009, s. 213÷227.
15. 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, 2009, s. 616÷627.
16. <http://www.ics.uci.edu/~mllearn/MLRepository.html>.

Recenzenci: Dr inż. Marcin Gorawski
Dr inż. Tomasz Traczyk

Wpłynęło do Redakcji 19 stycznia 2010 r.

Abstract

The paper presents the process of taking global decisions on the basis of the knowledge of local decision systems. The authors suggest organization of local decision systems into a multi-agent system with a hierarchical structure. The paper discusses various methods of eliminate the inconsistencies of knowledge collected in different knowledge bases and methods of analysis of conflicts. This paper shows the results of experiments conducted the use of realistic data. These experiments were conducted to compare the efficiency of algorithms which implement the presented methods.

The first part of the paper presents the structure of multi-agent system and theoretical aspects of the organization of the system whereas the second part deals with the practical aspect of the suggested solution on the basis of the discussed the results of experiments carried out with the data.

The first chapter establishes the main purpose of the paper. The second chapter describes the structure of multi-agent structure. The notions of resource agent and synthesis agent have been defined. The chapter also defines the agents' purposes and resources which are available to the agents. The third chapter describes two methods of eliminate the inconsistencies of knowledge. The fourth chapter describes three methods for the analysis of conflicts, which implement the simple or weighted voting, the ant algorithm and the density-based algorithm. The last chapter shows description and the results of the experiments carried out with the use of realistic data.

Adresy

Alicja WAKULICZ-DEJA: Uniwersytet Śląski, Instytut Informatyki, ul. Będzińska 29,
41-200 Sosnowiec, Polska, alicja.wakulicz-deja@us.edu.pl;

Małgorzata PRZYBYŁA-KASPEREK: Uniwersytet Śląski, Instytut Matematyki,
ul. Bankowa 14, 40-007 Katowice, Polska, malgorzataprzybyla@poczta.fm.