

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

## **PODEJMOWANIE DECYZJI GLOBALNEJ Z ZASTOSOWANIEM HIERARCHICZNEGO SYSTEMU WIELOAGENTOWEGO ORAZ ALGORYTMU MRÓWKOWEGO**

**Streszczenie.** Praca przedstawia opis procesu podejmowania globalnych decyzji na podstawie reguł decyzyjnych lokalnych systemów ekspertowych zawierających wzajemnie uzupełniające się obserwacje stanu obiektów, które mogą być również wzajemnie sprzeczne. W pracy zaprezentowano także wyniki eksperymentów przeprowadzonych na danych rzeczywistych.

**Słowa kluczowe:** system ekspertowy, system wieloagentowy, decyzja globalna, algorytm mrówkowy

## **GLOBAL DECISIONS TAKING ON THE BASIS OF MULTI-AGENT SYSTEM WITH A HIERARCHICAL STRUCTURE AND ANT ALGORITHM**

**Summary.** The paper presents the process of taking global decisions on the basis of decision rules of local expert systems involving mutually complementary observations of objects which can be mutually contradictory. Furthermore the paper presents the results of experiments conducted with the use of realistic data.

**Keywords:** expert system, multi-agent system, global decision, ant algorithm

### **1. Wprowadzenie**

Metody odkrywania wiedzy z danych znajdują obecnie szerokie zastosowanie w wielu dziedzinach życia, takich jak: medycyna, biznes, polityka, operacje wojskowe oraz negocja-

cje. Przez odkrywanie reguł oraz wzorców ukrytych w zgromadzonych danych systemy ekspertowe wspomagają podejmowanie decyzji oraz pozwalają dokonać prognozy na przyszłość.

Stworzone liczne systemy ekspertowe i bazy wiedzy zazwyczaj wspomagają podejmowanie decyzji w wyspecjalizowanym, wąskim zakresie opierając się na, z góry zadanim, zbiorze atrybutów. Ważnym zagadnieniem staje się możliwość wykorzystania informacji zgromadzonych w kilku różnych bazach wiedzy jednocześnie, w celu podniesienia poprawności i efektywności podejmowanych decyzji.

Systemy wieloagentowe są wykorzystywane w celu analizowania i projektowania złożonych systemów komputerowych [5, 11]. Naturalną cechą tych systemów jest koordynacja i kooperacja działań agentów, eliminująca chaotyczne działanie jednostki. Agenci współpracują ze sobą, aby osiągnąć jeden cel, który jest poza zasięgiem każdego z nich.

W rozważanym zagadnieniu każdy lokalny system ekspertowy jest agentem posiadającym zdolność podejmowania decyzji w zakresie swojego środowiska, czyli zbioru dostępnych atrybutów warunkowych. Ponieważ agenci posiadają dane dotyczące obserwacji stanu obiektów, które się wzajemnie uzupełniają, ale są również wzajemnie sprzeczne, więc naturalne jest występowanie konfliktów pomiędzy agentami.

Analiza konfliktów ma swoje korzenie w teorii gier - nauce, która została stworzona w 1944 roku przez Johna von Neumanna i Oskara Morgensterna. Jedną z podstawowych metod oceny koalicji w teorii gier jest indeks Shapleya-Shubika, który został wprowadzony w 1954 roku w publikacji [13]. Miara ta wartościuje siłę każdego uczestnika gry przez przypisanie mu prawdopodobieństwa, że dany uczestnik przyłączając się do istniejącej koalicji, powoduje, iż ta koalicja staje się koalicją wygrywającą, przy założeniu że wszystkie możliwe porozumienia między uczestnikami są jednakowo prawdopodobne.

Kolejną metodą oceny siły głosów w sytuacji podejmowania decyzji przez głosowanie jest indeks Banzhafa. Po raz pierwszy definicja tej miary została podana przez Lionela Penrose'a w 1946 roku [10]. W 1965 roku ukazała się praca Johna Banzhafa [1], w której również wprowadzono definicję tej wartości. Indeks Banzhafa wyznacza prawdopodobieństwo, że uczestnik gry jest członkiem krytycznym koalicji wygrywającej, czyli jego odłączenie się od koalicji spowodowałoby, że straciłaby ona charakter koalicji wygrywającej.

Znane są również inne sposoby rozwiązania sytuacji konfliktowych agentów. Jedną z nich jest praca Zdzisława Pawlaka [8] dotycząca analizy konfliktów. Również inni autorzy zajmowali się tym tematem [2, 7, 14]. W większości prace te analizują problem konfliktu przez głosowanie agentów na zadane konfliktowe pytanie, wnioskowanie o istniejących koalicjach oraz możliwościach podziału zasobów w taki sposób, aby agenci mogli w jak największym stopniu zrealizować swoje cele.

Autorzy niniejszego artykułu zaproponowali odmienny sposób rozwiązywania powstałych konfliktów [15], który polega na organizacji lokalnych systemów ekspertowych w hie-

rarchiczny system wieloagentowy. W podanej metodzie każdy agent wyznacza wartość decyzji (lub zbiór wartości decyzji) dla danego obiektu, na podstawie podzbioru atrybutów warunkowych charakteryzujących jego właściwości. Kolejnym etapem jest wyznaczenie wartości decyzji o największym wsparciu agentów oraz takiej, aby agenci podejmujący decyzje na podstawie wspólnych atrybutów warunkowych wykazywali zgodność wartości na tych atrybutach. Jednak zgodność ta sprawdzana jest tylko dla każdej pary agentów. Oznacza to, że nie wymagamy pełnej syntezy agentów. Ta uwaga prowadzi zaś do wniosku, że podjęta przez system wieloagentowy decyzja może w dalszym ciągu zawierać niezgodność agentów.

W niniejszej pracy autorzy przedstawiają kolejny sposób rozwiązania konfliktu zaistniałego między agentami. Tym razem celem badań jest stworzenie algorytmu, który zapewniłby pełną syntezę agentów, czyli zgodność wszystkich agentów na wspólnych atrybutach warunkowych przy podejmowaniu decyzji.

Zaproponowana poniżej metoda wykorzystuje inteligencje sztucznych mrówek. Algorytmy mrówkowe opierają się na założeniu, że każda sztuczna mrówka traktowana jako agent 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. Szersze omówienie algorytmów mrówkowych można znaleźć w pracach [3, 4].

## 2. Struktura systemu wieloagentowego

Niech  $Ag$  będzie skończonym zbiorem nazw 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  $D_{ag_i} := (U_{ag_i}, A_{ag_i}, d)$ , gdzie  $U_{ag_i}$  jest skończonym niepustym zbiorem zwanym uniwersum, a elementy zbioru  $U_{ag_i}$  nazywamy obiektami;  $A_{ag_i}$  jest skończonym niepustym zbiorem atrybutów warunkowych, gdzie każdy atrybut  $b \in A_{ag_i}$  jest funkcją  $b: U_{ag_i} \rightarrow V_{ag_i}^b$ , przy czym  $V_{ag_i}^b$  jest zbiorem wartości atrybutu  $b$ , do którego należy znak specjalny  $*$  oraz nie należy znak zastrzeżony  $?$  Równość  $b(x) = *$  dla pewnego  $x \in U_{ag_i}$  oznacza, że dla obiektu  $x$  wartość na atrybucie  $b$  nie wpływa na wartość atrybutu decyzyjnego;  $d$  nazywamy atrybutem decyzyjnym, jest to funkcja  $d: U_{ag_i} \rightarrow V^d$ , przy czym  $V^d$  jest zbiorem wartości atrybutu  $d$ .

Tablica decyzyjna  $D_{ag_i}$  jest podtablicą uniwersalnej tablicy decyzyjnej  $\mathbf{W}_{ag_i} := (W_{ag_i}, A_{ag_i}^*, d^*)$ , gdzie  $W_{ag_i}$  jest zbiorem wszystkich możliwych obiektów;  $A_{ag_i}^*$  jest skończonym niepustym zbiorem atrybutów warunkowych, gdzie każdy atrybut  $b^* \in A_{ag_i}^*$  jest funkcją  $b^* : W_{ag_i} \rightarrow V_{ag_i}^{b^*}$ ;  $d^*$  nazywamy atrybutem decyzyjnym, jest to funkcja  $d^* : \bigcup_{i=1}^n W_{ag_i} \rightarrow V^{d^*}$

Oznacza to, że  $U_{ag_i} \subseteq W_{ag_i}$  oraz spełnione są następujące warunki:

$$\forall_{b \in A_{ag_i}} \exists_{b^* \in A_{ag_i}^*} b^* / U_{ag_i} = b,$$

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

gdzie  $b^* / U_{ag_i}$  oznacza obcięcie atrybutu  $b^*$  do zbioru uniwersum  $U_{ag_i}$ .

Każdy agent zasobów  $ag_i \in Ag$  na podstawie obserwacji stanu obiektu  $x \in U_{ag_i}$  na zbiorze atrybutów  $A_{ag_i}$  potrafi samodzielnie wyznaczyć wartość decyzji dla tego obiektu. Zbiory atrybutów warunkowych różnych agentów zasobów nie muszą być rozłączne. W większości przypadków część wspólna tych zbiorów będzie niepusta.

Zadaniem systemu wieloagentowego jest podjęcie decyzji globalnej dla pewnego obiektu o zdefiniowanych wartościach na zbiorze atrybutów warunkowych systemu wieloagentowego  $\bigcup_{i=1}^n A_{ag_i}$ . Różnym wydaje się założenie, że agenci zasobów, którzy wnioskujeją na podstawie wspólnych atrybutów warunkowych, powinni tworzyć grupę agentów tzw. klastr.

**Definicja 2.1.** Niech  $Ag = \{ag_1, \dots, ag_n\}$  będzie zbiorem agentów zasobów. *Klastrem* nazywamy najmniejszy, ze względu na relację inkluzji, podzbiór zbioru agentów zasobów  $\{ag_{i_1}, \dots, ag_{i_k}\} \subseteq Ag$ ,  $i_1, \dots, i_k \in \{1, \dots, n\}$  spełniający następujące dwa warunki

$$\forall_{j \in \{1, \dots, k\}} \exists_{l \in \{1, \dots, k\}; l \neq j} A_{ag_{i_j}} \cap A_{ag_{i_l}} \neq \emptyset,$$

$$\forall_{l \in \{1, \dots, n\} \setminus \{i_1, \dots, i_k\}} \forall_{j \in \{1, \dots, k\}} A_{ag_l} \cap A_{ag_{i_j}} = \emptyset,$$

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

Dla każdego klastra zdefiniowany jest agent nadrzędny, którego nazywamy agentem syntezy, ozn.  $AS_j$ , gdzie  $j$  – numer klastra. Agent syntezy ma dostęp do zasobów znajdujących się w tablicy decyzyjnej, powstałej przez agregację tablic decyzyjnych agentów zasobów, należących do grupy jemu podrzędnej.

**Definicja 2.2** Niech  $\{ag_{i_1}, \dots, ag_{i_k}\}$  będzie klastrem, natomiast  $AS$  agentem syntezy nadrzednym w stosunku do tego klastra. Wówczas zasoby agenta  $AS$  można zapisać w postaci tablicy decyzyjnej

$$D_{AS} := (U_{AS}, A_{AS}, \bar{d})$$

gdzie  $A_{AS} := \bigcup_{j=1}^k A_{ag_{i_j}}$

$x \in U_{AS} \leftrightarrow$  Gdy istnieje, maksymalny ze względu na relację inkluzji zbiór

$$G \subseteq \{ag_{i_1}, \dots, ag_{i_k}\}, G \neq \emptyset \quad \text{taki, że}$$

$$\forall_{ag_{i_j} \in G} \exists_{x_j \in U_{ag_{i_j}}} [ \forall_{b \in A_{ag_{i_j}}} \bar{b}(x) = b(x_j) \wedge \bar{d}(x) = d(x_j) ] \quad \text{oraz} \quad \forall_{b \in \bigcup_{i=1}^n A_{ag_n} \setminus \bigcup_{ag \in G} A_{ag}} \bar{b}(x) = ?$$

gdzie  $\bar{b}$  oraz  $\bar{d}$  są funkcjami  $\bar{b} : U_{AS} \rightarrow V^b \cup \{?\}$ ,  $\bar{d} : U_{AS} \rightarrow V^d$ ,

przy czym tablica  $D_{AS}$  jest podtablicą uniwersalnej tablicy decyzyjnej

$$W_{AS} := (W_{AS}, A_{AS}^*, \bar{d}^*),$$

gdzie  $A_{AS}^* := \bigcup_{j=1}^k A_{ag_{i_j}}^*$ ;  $\bar{d}^* : W_{AS} \rightarrow V^d$ .

Każda reguła, należąca 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  $\bar{b} \in A_{AS}$  oraz obiektu  $x \in U_{AS}$  oznacza, że wszyscy agenci zasobów, podejmujący decyzje na podstawie atrybutu  $\bar{b}$ , nie wykazywali zgodności z agentami, których przesłanki przy podejmowaniu określonej decyzji zapisane zostały w regule  $x$ .

### 3. Schemat decyzyjny

Wspólnym celem agentów, w opisanym systemie wieloagentowym, jest podjęcie decyzji dla pewnego obiektu na podstawie wiedzy o jego właściwościach. Wiedzę tę można zapisać w postaci formuły, która jest spełniana przez dany obiekt. Definicję formuły, P-formuły oraz pojęcie spełnialności formuły podajemy poniżej, można je również znaleźć w bibliografii [6, 9, 16].

**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 o 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  $\alpha$  o 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  $\alpha$  nazywamy *formułą*. Mówimy, że obiekt  $x \in U$  spełnia *P-formułę*  $\alpha$  w systemie  $S$ , ozn.  $x \models_S \alpha$ , wtedy i tylko wtedy, gdy  $\forall_{i \in \{1, \dots, k\}} x \models_S (b_i, v_i)$ .

Agenci otrzymują zadanie, polegające na wyznaczeniu wartości decyzji dla obiektu spełniającego formułę  $\alpha$ , która jest określona na zbiorze atrybutów warunkowych wszystkich agentów zasobów  $\bigcup_{i=1}^n A_{ag_i}$ .

Założmy, że agenci zasobów zostali pogrupowani w  $r$  klastrów. Oznacza to, że zdefiniowanych zostaje  $r$  agentów syntezy  $AS_1, \dots, AS_r$ . Dla każdego agenta syntezy wyznaczamy  $A_{AS_j}$  formułę, ozn.  $\alpha / A_{AS_j}, j = 1, \dots, r$ , będącą obcięciem formuły  $\alpha$  do zbioru atrybutów warunkowych  $A_{AS_j}$  tablicy decyzyjnej  $j$ -tego agenta syntezy. Dla każdego agenta syntezy definiujemy również funkcję podobieństwa oraz funkcję wyznaczającą największy stopień podobieństwa względem decyzji  $v \in V^d$ .

**Definicja 3.2.** Niech  $W_{AS} := (W_{AS}, A_{AS}^*, \bar{d}^*)$ , będzie uniwersalną tablicą decyzyjną oraz niech  $D_{AS} := (U_{AS}, A_{AS}, \bar{d})$ , będzie daną tablicą decyzyjną agenta syntezy  $AS$ . Wówczas funkcję  $f_{AS} : W_{AS} \times U_{AS} \rightarrow N \cup \{0\}$  określoną następującym wzorem:

$$f_{AS}(x, y) := |\{b \in A_{AS} : b(x) = b(y) \vee b(x) = * \vee b(y) = *\}|, \text{ dla } x \in W_{AS}, y \in U_{AS}$$

nazywamy *funkcją podobieństwa* agenta syntezy.

**Definicja 3.3.** Niech  $W_{AS} := (W_{AS}, A_{AS}^*, \bar{d}^*)$ , będzie uniwersalną tablicą decyzyjną,  $D_{AS} := (U_{AS}, A_{AS}, \bar{d})$ , będzie daną tablicą decyzyjną agenta syntezy  $AS$  oraz niech  $v \in V^d$  będzie pewną wartością atrybutu decyzyjnego. Wówczas funkcję  $f_{AS}^v : W_{AS} \rightarrow N \cup \{0\}$ , określoną następującym wzorem:

$$f_{AS}^v(x) := \max \{f_{AS}(x, y) : y \in U_{AS} \text{ oraz } \bar{d}(y) = v\}, \text{ dla } x \in W_{AS}$$

nazywamy *funkcją wyznaczającą największy stopień podobieństwa względem decyzji*  $v$ .

Agenci syntezy, dla każdej wartości decyzji  $v \in V^d$ , obliczają wartość funkcji wyznaczającej największy stopień podobieństwa względem decyzji na argumentach  $\alpha / A_{AS_j}, j = 1, \dots, r$ , Aby wyznaczenie zbioru wartości:

$$f_{AS_j}^v(\alpha / A_{AS_j}), j = 1, \dots, r, v \in V^d$$

było możliwe, konieczne jest, by zbiór  $v \in V^d$  miał skończoną ilość elementów.

Kolejnym etapem jest obliczenie, przez agentów syntezy, współczynnika dokładności względem decyzji dla każdej wartości decyzji, którego definicję podajemy poniżej.

**Definicja 3.4.** Niech  $W_{AS} := (W_{AS}, A_{AS}^*, \overline{d^*})$ , będzie uniwersalną tablicą decyzyjną, niech  $D_{AS} := (U_{AS}, A_{AS}, \overline{d})$ , będzie daną tablicą decyzyjną agenta syntezy  $AS$  oraz niech  $v \in V^d$  będzie pewną wartością atrybutu decyzyjnego. Wówczas wyrażenie o postaci:

$$\mu_{AS}^v := \frac{f_{AS}^v(\alpha / A_{AS})}{|A_{AS}|}$$

nazywamy *współczynnikiem dokładności względem decyzji  $v$* .

Jest to miara opisująca pewność, z jaką agent syntezy podejmuje określoną decyzję, na podstawie wiedzy zawartej w jego tablicy decyzyjnej. Konflikty między agentami rozumiemy jako sytuację, w której agenci syntezy głosując niezależnie wybraliby różne wartości decyzji dla zadanego obiektu. Aby wyznaczyć wspólną wartość decyzji (lub zbiór wartości), dokonamy normalizacji siły głosu każdego agenta syntezy, przez wyliczenie stosunku współczynnika dokładności dla danej decyzji do sumy współczynników dokładności wyznaczonych przez danego agenta syntezy dla wszystkich decyzji. Operacja ta pozwoli zmniejszyć wpływ tych agentów syntezy, którzy z podobną pewnością głosują na wiele różnych wartości decyzji na wartość podjętej decyzji. Zatem, dla każdej decyzji  $v_k$ ,  $k = 1, \dots, |V^d|$ , obliczana jest wartość:

$$\sum_{j=1}^r \frac{\mu_{AS_j}^{v_k}}{\sum_{l=1}^{|V^d|} \mu_{AS_j}^{v_l}},$$

którą interpretujemy jako poziom pewności, z jakim wszyscy agenci syntezy podejmują daną decyzję. Następnie wyznaczany jest, zgodnie z poniższą definicją, początkowy zbiór rozwiązań

$$D_{\max} := \left\{ v_i \in V^d : \sum_{j=1}^r \frac{\mu_{AS_j}^{v_k}}{\sum_{l=1}^{|V^d|} \mu_{AS_j}^{v_l}} = \max_{k=1, \dots, |V^d|} \sum_{j=1}^r \frac{\mu_{AS_j}^{v_k}}{\sum_{l=1}^{|V^d|} \mu_{AS_j}^{v_l}} \right\}.$$

Oczywiście, w zbiorze  $V^d$  mogą znajdować się takie wartości, które wprawdzie nie otrzymały maksymalnego poparcia agentów syntezy, ale pewność, z jaką agenci syntezy podjęliby tę decyzję, jest bardzo duża. Aby znaleźć takie wartości decyzji i uwzględnić je w zbiorze decyzyjnym, w dalszej części zastosujemy algorytm mrówkowy.

W pierwszym kroku inicjujemy wartości feromonu dla każdej decyzji

$$TD_k(t=0) := \sum_{j=1}^r \frac{\mu_{AS_j}^{v_k}}{\sum_{l=1}^{|V^d|} \mu_{AS_j}^{v_l}} \quad k = 1, \dots, |V^d|$$

gdzie  $TD_k$  nazywamy współczynnikiem feromonu dla decyzji  $v_k$ . Następnie wyliczany jest współczynnik zmienności zbioru decyzyjnego  $D_{max}$ , którego definicję podajemy poniżej.

**Definicja 3.5.** Niech  $D$  będzie niepustym podzbiorem zbioru wartości atrybutu decyzyjnego  $V^d$ ,  $D \subseteq V^d$  oraz niech  $TD_k, k = 1, \dots, |V^d|$  będzie zbiorem wartości feromonu dla decyzji. Wówczas *współczynnik zmienności zbioru decyzyjnego* definiujemy następująco

$$DSV := \frac{\sum_{v_i \in D} \sum_{v_j \notin D} |TD_i - TD_j| - \frac{1}{2} \sum_{v_i \in D} \sum_{v_j \in D} |TD_i - TD_j|}{\sum_{k=1}^{|V^d|} \sum_{l=k+1}^{|V^d|} |TD_k - TD_l|} - \frac{|D| - 1}{|V^d|} \varepsilon,$$

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

Składnik  $\sum_{v_i \in D} \sum_{v_j \notin D} |TD_i - TD_j|$  współczynnika DSV informuje o zmienności pomiędzy wartościami decyzji należącymi do zbioru decyzyjnego a wartościami decyzji spoza tego zbioru. Dążymy do sytuacji, w której wartość tego wyrażenia będzie największa.

Składnik  $\frac{1}{2} \sum_{v_i \in D} \sum_{v_j \in D} |TD_i - TD_j|$  informuje o zmienności wewnątrz zbioru decyzyjnego. Chcemy otrzymać możliwie najmniejszą wartość tego wyrażenia.

Ostatni składnik  $\frac{|D| - 1}{|V^d|}$  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.

Po wyznaczeniu współczynnika zmienności zbioru decyzyjnego  $D_{max}$ , każdy z agentów – mrówek, należący do pewnej skończonej populacji, 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 współczynnika feromonu, agent - mrówka losuje jedną wartość decyzji ze zbioru  $V^d \setminus D_{max}$ .
2. Do zbioru  $D_i(t)$  agent dodaje wcześniej wylosowaną wartość decyzji, o ile ta wartość nie należała do zbioru  $D_i(t)$ .

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 1 oraz 2, interpretujemy jako rozwiązanie otrzymane przez mrówkę.

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

$$TD_k(t+1) = \sum_{i=1}^p [(1-\rho)TD_k(t) + DSV_i \cdot TD_k(t) \cdot x_{ik}],$$

gdzie  $p$  jest liczbą mrówek, należących do populacji  $t$ ;  $DSV_i$  jest współczynnikiem zmienności zbioru decyzyjnego, który jest rozwiązaniem wyznaczonym przez  $i$ -tą mrówkę;  $x_{ik} = 0$ , jeśli  $v_k \notin D_i(t)$ ,  $x_{ik} = 1$ , jeśli  $v_k \in D_i(t)$ ;  $\rho$  jest współczynnikiem wyparowania feromonu, pewna stała należąca do przedziału  $(0,1)$ .

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 wartość podjętej decyzji dla obiektu spełniającego formułę  $\alpha$ .

Jedną z miar dobroci wyznaczonego rozwiązania jest współczynnik zmienności, drugą, równie istotną miarą, jest współczynnik dokładności, który pokazuje, jaka część atrybutów warunkowych systemu wieloagentowego jest zgodna z atrybutami obiektu, dla którego wyznaczana jest wartość decyzji.

**Definicja 3.6.** Niech  $\{AS_1, \dots, AS_r\}$  będzie zbiorem agentów syntezy oraz  $D$  będzie niepustym podzbiorem zbioru wartości atrybutu decyzyjnego  $V^d$ . Wówczas *współczynnikiem dokładności* nazywamy wyrażenie o postaci:

$$\mu^v := \frac{\sum_{j=1}^r f_{AS_j}^v(\alpha / A_{AS_j})}{\sum_{j=1}^r |A_{AS_j}|}$$

gdzie  $v$  jest wartością atrybutu decyzyjnego należąca do zbioru  $D$ .

Jeśli chcemy dokonać oceny zbioru decyzyjnego o mocy  $|D| \geq 2$  za pomocą współczynnika dokładności, to bierzemy pod uwagę największy ze współczynników dokładności wyznaczonych dla wartości decyzji, należących do zbioru  $D$ .

#### 4. Aproksymacyjny algorytm podejmowania decyzji globalnej

Algorytm realizujący metodę wyznaczania decyzji globalnej, która została przedstawiona w rozdziale poprzednim, ma wykładniczą złożoność obliczeniową, ponieważ aby wyznaczyć tablicę decyzyjną agenta syntezy, konieczne jest porównanie, każdy z każdym, wszystkich obiektów zapisanych w tablicach decyzyjnych agentów zasobów należących do klastra pod-

rzędnego wobec tego agenta syntezy. Zatem, jeśli zbiór agentów zasobów  $\{ag_1, \dots, ag_k\} \subseteq Ag$  tworzy jeden klaster, to wyznaczenie tablicy decyzyjnej agenta syntezy ma złożoność obliczeniową  $O(\prod_{i=1}^r U_{ag_i} \cdot \prod_{i=1}^r A_{ag_i})$ .

W celu zmniejszenia złożoności obliczeniowej algorytmu, przy jednoczesnym zachowaniu możliwie jak najlepszej jego dokładności, zaproponowano algorytm aproksymacyjny, w którym przed rozpoczęciem budowy tablic decyzyjnych agentów syntezy wyznaczane są te reguły, należące do tablic decyzyjnych agentów zasobów, które realizują najlepsze dopasowanie do formuły  $\alpha$ . W pierwszym kroku, wyznaczamy formuły dla agentów zasobów, będące obciążeniem formuły  $\alpha$  do zbioru jego atrybutów warunkowych, ozn.  $\alpha / A_{ag_i}$ ,  $i = 1, \dots, n$

Następnie, korzystając z definicji funkcji wyznaczającej największy stopień podobieństwa względem decyzji dla agenta zasobów, wyznaczane są te reguły, które realizują najlepsze dopasowanie do warunków zadania.

**Definicja 4.1.** Niech  $\mathbf{W}_{ag} := (W_{ag}, A_{ag}^*, d^*)$  będzie uniwersalną tablicą decyzyjną oraz niech  $D_{ag} := (U_{ag}, A_{ag}^*, d^*)$  będzie daną tablicą decyzyjną agenta zasobów  $ag \in Ag$ . Wówczas funkcję  $f_{ag} : W_{AS} \times U_{ag} \rightarrow N \cup \{0\}$  określoną następującym wzorem

$$f_{ag}(x, y) := |\{b \in A_{ag} : b(x) = b(y) \vee b(x) = * \vee b(y) = *\}|, \text{ dla } x \in W_{ag}, y \in U_{ag}$$

nazywamy *funkcją podobieństwa* agenta zasobów.

**Definicja 4.2.** Niech  $\mathbf{W}_{ag} := (W_{ag}, A_{ag}^*, d^*)$  będzie uniwersalną tablicą decyzyjną,  $D_{ag} := (U_{ag}, A_{ag}, d)$  będzie daną tablicą decyzyjną agenta zasobów  $ag \in Ag$  oraz niech  $v \in V^d$  będzie pewną wartością atrybutu decyzyjnego. Wówczas funkcję  $f_{ag}^v : W_{AS} \rightarrow N \cup \{0\}$  określoną następującym wzorem

$$f_{ag}^v(x, y) := \max \{f_{AS}(x, y) : y \in U_{AS} \text{ oraz } d(y) = v\}, \text{ dla } x \in W_{AS}$$

nazywamy *funkcją wyznaczającą największy stopień podobieństwa względem decyzji*  $v$ .

Ostatecznie, z reguł agentów zasobów, realizujących wartość funkcji wyznaczającej największy stopień podobieństwa względem decyzji  $f_{ag}^v(\alpha / A_{ag})$  tworzone są tablice decyzyjne agentów syntezy. Metoda konstrukcji tablic decyzyjnych agentów syntezy pozostaje niezmienną, jednak w większości przypadków znacznie zmniejszona została liczba reguł, z których budujemy tablice decyzyjne. Pozwala to obniżyć złożoność obliczeniową algorytmu.

Oczywiście, użycie algorytmu aproksymacyjnego, który przegląda tylko część reguł decyzyjnych, może nie zapewnić najlepszego możliwego do osiągnięcia współczynnika dokładności. Jednak testy na danych, przedstawione w następnym rozdziale, pokazują, że wartości podjętych decyzji przez oba algorytmy są identyczne.

## 5. Wyniki eksperymentów z danymi


Eksperymenty miały na celu zarówno zbadanie efektywności algorytmu wykorzystującego hierarchiczny system wieloagentowy oraz algorytm mrówkowy, jak również porównanie dokładności tegoż algorytmu z algorytmem aproksymacyjnym. Testy zaprezentowane w tym rozdziale zostały przeprowadzone na zbiorach danych dostępnych w repozytorium baz wiedzy UCI repository ([ics.uci.edu/pub/machine-learning-databases](http://ics.uci.edu/pub/machine-learning-databases)). Użyto następujących zbiorów danych:

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

Zbiory te zostały podzielone na moduły, tablice decyzyjne o losowo wybranych wspólnych atrybutach warunkowych, tak aby możliwe było przetestowanie pracy algorytmu podejmowania decyzji globalnej.

Pierwszy zbiór danych związany jest z analizą zewnętrznych właściwości fasoli sojowej w celu zdiagnozowania czynników chorobotwórczych wpływających na zaburzenia w procesach życiowych rośliny.

Dane zapisane były w formie pięciu tablic decyzyjnych. W każdej z nich atrybutem decyzyjnym był atrybut *klasa*, którego zbiór wartości zawierał dziewiętnaście elementów. W zbiorze atrybutów warunkowych systemu wieloagentowego znajdowało się trzydzieści pięć elementów. Struktura hierarchicznego systemu wieloagentowego była następująca:



Rys. 1. Struktura systemu wieloagentowego  
Fig. 1. Structure of the multi-agent system

Po wyeliminowaniu reguł powtarzających się w pierwszej tablicy decyzyjnej znajdowało się 296 obiektów, w drugiej – 39 obiektów, w trzeciej – 51 obiektów, w czwartej – 32 obiekty, w piątej – 36 obiektów.

Testy przeprowadzono na zbiorze trzystu siedemdziesięciu sześciu formuł pobranych z repozytorium baz wiedzy. W tabeli poniższej przedstawiono porównanie współczynników dokładności oraz współczynnika DSV zbiorów decyzyjnych, które zostały podane przez opisane algorytmy jako rozwiązanie dla pięciu losowo wybranych formuł. Przyjęto następujące wartości parametrów  $LiczbaPopulacji=10$ ,  $LiczbaMrowek=10$ ,  $\rho=0,5$  oraz  $\varepsilon=0,5$ . W ostatniej kolumnie tabeli zamieszczono również współczynniki dokładności zbiorów decyzyjnych wygenerowanych przez algorytm realizujący metodę podejmowania decyzji globalnej przedsta-

wioną w pracy [15]. We wszystkich przypadkach współczynniki dokładności wygenerowanych zbiorów były równe, natomiast korzyść czasowa, jaką otrzymano przy użyciu algorytmu aproksymacyjnego w porównaniu z algorytmem pierwotnym, była rzędu kilku minut.

Tabela 1

Wyniki eksperymentów na danych

Numer formuły	Algorytm pierwotny		Algorytm aproksymacyjny		Algorytm [15]
	Wsp. dokładności	DSV	Wsp. dokładności	DSV	Wsp. dokładności
1	0,971	0,288	0,971	0,313	0,971
2	0,914	0,214	0,914	0,181	0,914
3	0,914	0,206	0,914	0,232	0,914
4	0,971	0,293	0,971	0,240	0,971
5	0,943	0,364	0,943	0,454	0,943


Zestawienie współczynników błędu dla omówionych algorytmów, który jest ilorazem liczby obiektów błędnie sklasyfikowanych do liczby wszystkich obiektów znajdujących się w zbiorze testującym, zostało zaprezentowane w tabeli 2.

Tabela 2

Wyniki eksperymentów na danych

Algorytm pierwotny	Algorytm aproksymacyjny
0,293	0,293

Drugi zbiór danych dotyczył przyporządkowania genu do jednej z trzech klas: dawcy, biorcy, żadna z grup na podstawie 60 jakościowych atrybutów warunkowych o jednakowych zbiorach wartości równych {A, G, C, T}. Rozważana baza wiedzy zawierała 3190 obiektów, z których wylosowano zbiór testujący o mocy 2871 obiektów. Następnie zbiór uczący bazy DNA został podzielony na siedem modułów. Struktura hierarchicznego systemu wieloagentowego była następująca:



Rys. 2. Struktura systemu wieloagentowego

Fig. 2. Structure of the multi-agent system

Po wyeliminowaniu reguł powtarzających się, w pierwszej tablicy decyzyjnej znajdowało się 298 obiektów, w drugiej – 290 obiektów, w trzeciej – 290 obiektów, w czwartej – 29 obiektów, w piątej – 298 obiektów, w szóstej – 297 obiektów, w siódmej – 299 obiektów.

Testy przeprowadzono na wylosowanym wcześniej zbiorze testującym. Przyjęto następujące wartości parametrów  $LiczbaPopulacji=50$ ,  $LiczbaMrowek=10$ ,  $\rho=0,5$  oraz  $\varepsilon=0,5$ .

Poniżej podano współczynniki dokładności oraz współczynniki zmienności zbiorów decyzyjnych wygenerowanych przez algorytmy dla pięciu losowo wybranych formuł. Współczynniki dokładności zbiorów decyzyjnych podanych przez algorytm [15] dla części formuł były wyższe, jednak decyzje te nie były podjęte przy pełnej syntezie agentów. Sytuację tę prezentują dane zamieszczone w tabeli 3.

Tabela 3

Numer formuły	Algorytm pierwotny		Algorytm aproksymacyjny		Algorytm [15]
	Wsp. dokładności	DSV	Wsp. dokładności	DSV	Wsp. dokładności
1	0,667	0,820	0,6	0,515	0,667
2	0,8	0,840	0,733	0,697	0,8
3	0,65	0,918	0,6	0,841	0,667
4	0,917	0,877	0,917	0,968	0,917
5	1	0,895	1	0,928	1

Zestawienie współczynników błędu dla omówionych algorytmów zostało zaprezentowane w tabeli 4.

Tabela 4

Algorytm pierwotny	Algorytm aproksymacyjny
0,251	0,301

## 6. Podsumowanie

W niniejszej pracy została przedstawiona koncepcja podejmowania decyzji globalnej, na podstawie wiedzy lokalnych systemów ekspertowych, z wykorzystaniem hierarchicznego systemu wieloagentowego oraz algorytmu mrówkowego.

Zaletą przedstawionej w pracy metody podejmowania decyzji globalnej jest otrzymywanie wartości decyzji, które zostały podjęte przy pełnej syntezie agentów zasobów. Oznacza to, że przy zachowaniu zgodności wszystkich agentów, wyznaczone decyzje mają największe poparcie. Kolejną zaletą metody jest możliwość wyznaczenia zbioru wartości decyzji, do którego należą nie tylko te decyzje, które mają maksymalne poparcie wśród agentów, ale również te, dla których poparcie agentów jest stosunkowo bliskie maksymalnemu, w porównaniu z pozostałymi decyzjami.

Ponieważ algorytm, realizujący przedstawioną metodę, ma wykładniczą złożoność obliczeniową, zaproponowano algorytm aproksymacyjny, który przegląda tylko pewną część reguł z tablic decyzyjnych agentów zasobów. Wprowadzona heurystyka pozwala znacznie obniżyć złożoność obliczeniową algorytmu i przyspiesza jego pracę.

Testy zaprezentowane w przedostatnim rozdziale pokazują, że stosowanie algorytmu aproksymacyjnego dla niektórych danych może obniżać w niewielkim stopniu dokładność algorytmu, ale znacznie krótszy czas działania algorytmu aproksymacyjnego uzasadnia stosowanie tegoż algorytmu dla dużych zbiorów danych.

## BIBLIOGRAFIA

1. Banzhaf J. F.: Weighted voting doesn't work: A mathematical analysis, *Rutgers Law Review* 19, 1965, p. 317÷343.
2. Deja R., Conflict analysis, *Rough Sets; New Developments*. In: Polkowski L. (eds.), *Studies in Fuzziness and Soft Computer Science*, Physica-Verlag, 2000.
3. Dorigo M., DiCaro G., Gambardella L.M.: Ant Algorithms for Discrete Optimisation, *Artificial Life* 5, 1999, s. 137÷172.
4. Dorigo M., Maniezzo V., Colorni A.: The Ant System: Optimization by a colony of cooperating agents, *IEEE Transactions on Systems, Man and Cybernetics – Part B* 26 (1), 1991, s. 29÷41.
5. Maturana F. P., Norrie D. H., Distributed decision-making using the contract net within a mediator architecture, *Decision Support Systems* 20, 1997, s. 53÷64.
6. Mulawka J. J.: *Systemy ekspertowe*. WNT, Warszawa 1996.
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, no. 21, s. 127÷134.
9. Pawlak Z., *Rough Sets: Theoretical aspects of reasoning about data*. Kluwer Academic Publishers, Boston 1991.
10. Penrose L., The Elementary Statistics of Majority Voting, *Journal of the Royal Statistical Society* 109, 1946, s. 53÷57.
11. Po - Hsian Huang, An application of quantitative techniques to conflict resolution in a multi-agent system, *Computers and Electrical Engineering* 29, 2003, s. 757÷779.
12. Polkowski L., Skowron A.: Synthesis of complex objects: rough mereological approach, *Proceedings of The Multi-Agent Day, Warsaw, Poland, 1998*.
13. Shapley L.S., Shubik M.: A Method for Evaluating the Distribution of Power in a Committee System, *American Political Science Review* 48, 1954, s. 787÷792.
14. 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.
15. Wakulicz-Deja A., Przybyła-Kasperek M.: Hierarchiczny system wieloagentowy. *Studia Informatica*, 2008, nr 4 (74).

16. Wakulicz-Deja A.: Podstawowy systemów ekspertowych. Zagadnienia implementacji. *Studia Informatica*, 2005, nr 3 (64).

Recenzent: Dr hab. Tadeusz Pankowski, prof. UAM

Wpłynęło do Redakcji 19 stycznia 2009 r.

### **Abstract**

The paper presents the process of taking global decisions on the basis of the knowledge of local expert systems. The author suggests organization of local expert systems into a multi-agent system. This paper shows the results of experiments conducted the use of realistic data.

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. Also, the tools which are to be used by the agents while establishing decision value.

The third chapter describes the scheme of taking decisions through the multi-agent system. The way of exchanging information between agents is discussed as well as the ways of solving conflicts which arise between them. All the available kinds of decisions have been presented.

The fourth chapter describes the approximate algorithm fulfilling the presented theory.

The last chapter shows description and the results of two experiments carried out with the use of realistic data. Fig. 1 and Fig. 2 shows the structure of the multi-agent system which are used in the experiments.

### **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.