

Janina Anna Jakubczyc

ALGORYTMY MRÓWKOWE W POZYSKIWANIU WIEDZY Z BAZ DANYCH

1. Wstęp

Niedoskonałości istniejących algorytmów pozyskiwania wiedzy są motywacją do ciągłych poszukiwań lepszych rozwiązań. Jednym z interesujących kierunków badań jest implementacja algorytmów mrówkowych, których możliwości rozwiązywania złożonych problemów obliczeniowych zostały potwierdzone wieloma badaniami w różnych dziedzinach np. [Monmarché, Slimane, Venturini 1999; Melhuish, Holland, Hoddell 1998; Kuntz, Layzell, Snyers 1994; Gałęa 2002; Kube, Bonabeau 2000].

Przedmiotem rozważań jest problem, czy wspomagane mechanizmami samoorganizacji i współdziałania społeczności owadów dwie główne grupy technik dotyczących grupowania (uczenia bez nadzoru) oraz zadania klasyfikacji (uczenia z nadzorem) działają efektywniej. Krótkie omówienie mechanizmów owadzych zawiera pkt. 2. Rozwój i implementacje wybranych mechanizmów do problemu taksonomii przedstawione są w pkt 3. Z kolei zastosowania algorytmów mrówkowych w zadaniu klasyfikacyjnym (indukcji reguł), ich analiza oraz propozycja nowego algorytmu indukacji reguł zawarte są w pkt 4 opracowania. W punkcie 5 przedstawiono podsumowanie przeprowadzonych rozważań.

2. Charakterystyka wybranych mechanizmów owadzych

Intensyfikację prób przeniesienia pewnych biologiczno-fizjologicznych mechanizmów organizujących i sterujących funkcjonowaniem kolonii różnych owadów, takich jak osy, pszczoły, mrówki, obserwuje się od drugiej połowy lat dziewięćdziesiątych ubiegłego wieku. Samoorganizacja społecznych insektów sterowana jest poprzez kontakty bezpośrednie (żuchwy, czułki, kontakt chemiczny lub wizualny itp.) lub pośrednie między owadami (por. [Camazine 2001; Wilson; Ramos 2002]). Pośrednie interakcje nazywane są synergią środowiskową. Przykładem może być dwóch osobników, którzy pośrednio na siebie oddziałują: gdy jeden z nich modyfikuje środowisko, wówczas drugi z pewnym opóźnieniem czasowym reaguje na nowe środowisko.

Przykładem synergii środowiskowej jest ślad feromonowy (por. [Wilson 1971; Edelstein-Keshet, Watmough, Ermentrout 1995]), po którym podążają mrówki. Forma ‘zostaw wiadomość’ jest środkiem tworzenia swoistej mapy feromonowej środowiska, która umożliwia korzystanie ze zdobytych doświadczeń wszystkim osobnikom kolonii (zob. pkt 3.5 i 4)

Z kolei dla problemu grupowania oczywistą umiejętnością mrówek jest budowanie stosów różnych rzeczy, takich np. jak ciała nieżywych osobników, sortowanie larw czy pożywienia (zob. pkt 3.1, 3.2, 3.3). Mechanizmem leżącym u podstaw tego rodzaju zjawiska agregacji jest przyciąganie między nieżywymi mrówkami a mrówkami robotnicami: mało liczne grupy rozrastają się poprzez przyciąganie mrówek robotnic, by deponowały więcej obiektów. Jest to autokatalityczne sprzężenie zwrotne, prowadzące do tworzenia coraz liczniejszych stosów (por. [Krieger, Billeter, Keller 2000]). Rozkład grup w środowisku odgrywa rolę synergii środowiskowej.

Mechanizm komunikacji mrówek może przyjąć również, jak wspomniano, bezpośrednią formę. Jednym z przykładów jest system ochrony własnego mrowiska przed intruzami, a więc system rozpoznawania swoich ziomeków (por. [Page, Mitchell 1990; Hölldobler, Wilson 1990]), w tym przypadku po zapachu. Każda mrówka uczy się odróżniania zapachu kolonii od swoich współziomeków poprzez fizyczne jego absorbowanie, np. podczas karmienia. Mrówka ciągle aktualizuje swój wzorzec oraz rozprzestrzenia swój zapach, by potwierdzić swój identyfikator. Zjawisko to polega na chemicznej wymianie zapachów, co prowadzi do ustalenia zapachu kolonii, który jest wspólny dla wszystkich mrówek w kolonii.

3. Implementacje wybranych mechanizmów mrówkowych

3.1. Model sortowania

Implementacją algorytmów mrówkowych do problemów grupowania zajmował się m.in. Deneubourg i in. [1991]. Populacja mrówek losowo wędruje po szachownicy, przemieszczając i grupując obiekty, wykorzystując heurystyki podobne do mrówkowych, bez globalnego sterowania.

Autorzy ci zaproponowali dwa modele związane ze zjawiskiem grupowania ciał mrówek oraz sortowania larw [1991]. Oba modele bazują na tych samych zasadach. Obszarem działania jest dwuwymiarowa pierścieniowa siatka. Ogólna idea polega na tym, że obiekty można podnosić i przenosić je w miejsca, gdzie jest więcej tego samego rodzaju obiektów. Jeśli dany jest jeden rodzaj obiektów, to prawdopodobieństwo P_p podniesienia jakiegoś obiektu przez losowo poruszającą się mrówkę, nie niosącą żadnego obiektu, dane jest formułą, $P_p = (k_1 / (k_1 + f))^2$ gdzie f jest postrzeganą frakcją obiektów w sąsiedztwie mrówki, natomiast k_1 jest ustalonym progiem. Gdy $f \leq k_1$, wówczas P_p jest bliskie 1, tzn. że prawdopodobieństwo wzięcia obiektu jest wysokie, gdy w pobliżu nie ma zbyt wielu

obiektów. P_p jest bliskie 0, gdy $f \geq k_1$, tzn. że prawdopodobieństwo przesunięcia obiektu z licznej grupy podobnych mu obiektów jest niewielkie.

Prawdopodobieństwo pozostawienia niesionego obiektu dane jest formułą,

$P_d = (f / (k_2 + f))^2$, gdzie k_2 jest ustalonym progiem, dla $f \leq k_2$, P_d jest bliskie 0, a bliskie 1, gdy $f \geq k_2$. Zastosowano tu binarną miarę podobieństwa dwóch obiektów.

Wyniki eksperymentów pokazują, że we względnie krótkim czasie powstaje stosunkowo niewiele dobrze rozłożonych grup, których łączenie w większe zbiorowości przebiega znacznie wolniej. Ale w efekcie można osiągnąć przestrzenny rozkład obiektów bardzo podobny do obserwowanego w naturze.

Przedstawiony mechanizm jest modelem podstawowym, w literaturze oznaczanym jako BM, i jako taki poddawany jest różnym modyfikacjom. Wprowadzane zmiany zmierzają w dwóch kierunkach, zmiany funkcji f , a więc ustalenia zasady przeniesienia obiektu, oraz zasady poruszania się mrówek po płaszczyźnie.

3.2. Modyfikacje algorytmu sortowania Lumera i Faieta

Model Denerbourga i in. został zmodyfikowany przez Lumera i Faieta [1994]. Ich pomysł polegał na zdefiniowaniu odległości lub niepodobieństwa d między obiektami w przestrzeni atrybutów obiektów. Wykorzystali oni średnie podobieństwo między obiektami, włączając progową funkcję reakcji.

Każda mrówka bezpośrednio postrzega otaczające ją obiekty na obszarze s^2 ($\text{Neigh}_{(sxs)}$). Średnie podobieństwa obiektów znajdujących się w sąsiedztwie dane jest formułą, $f(o_i) = \max\{0, 1 / s^2 \sum [1 - d(o_i, o_j) / \alpha]\}$.

Miara $f(o_i)$ zastępuje frakcję f z modelu BM obiektów podobnych. Natomiast α jest czynnikiem definiującym skalę niepodobieństwa.

Lumer i Faieta zaproponowali następujące formuły na podniesienie i pozostawienie obiektu, $P_p(o_i) = \{k_1 / (k_1 + f(o_i))\}^2$, $P_d(o_i) = 2f(o_i)$, jeśli $f(o_i) < k_2$ oraz $P_d(o_i) = 1$, jeśli $f(o_i) \geq k_2$, gdzie k_2 i k_1 są ustalonymi progami.

Ponieważ algorytm przejawiał tendencje do tworzenia większej liczby grup niż w danych wejściowych, wprowadzono kilka dodatkowych parametrów (szczegóły w pracy [Lumer, Faieta 1994]. Były nimi, różne prędkości poruszania, krótka pamięć i przełączniki behawioralne.

Wprowadzone modyfikacje zapewniają większą sterowalność procesem grupowania. Znakomicie zwiększają także koszty obliczeniowe, a ponadto dokładają trudny problem dostrajania złożonego zestawu parametrów. Można odnieść wrażenie, że zagubiona została zasada prostoty działania owadów społecznych, w efekcie czego powstał nowy skomplikowany insekt.

3.3. Modyfikacje algorytmu sortowania Handla, Knowlesa i Dorigo

Modyfikacja podstawowego algorytmu Denebourga dotyczy, podobnie jak w poprzedniej propozycji, elementu f , który jest zmodyfikowaną wersją funkcji sąsiedztwa Lumera i Faieta (por. [Handl, Knowles, Dorigo 2003]) postaci,

$$F^*(i) = 1/\sigma^2 \sum_j (1-d(i,j)/\alpha) \text{ jeśli } f^*(i) > 0 \cap \forall j (1-d(i,j)/\alpha) > 0 \text{ lub } 0.$$

Definicja $f^*(i)$ łączy dwie ważne własności. Pierwsza, jak w oryginalnej funkcji sąsiedztwa $f(i)$, jest wyrażona przez ułamek $1/\sigma^2$ oznaczający karę za puste komórki danej przestrzeni. Druga własność to dodatkowy element postaci,

$$\forall j (1-d(i,j)/\sigma) > 0, \text{ który służy karaniu wysokiego niepodobieństwa.}$$

Poniższe formuły zawierają rozszerzenie zakresu wartości funkcji $f^*(i)$, które wynika ze zwiększenia promienia postrzegania, a ich postać jest następująca,

$$p_{pick}^*(i) = 1, \text{ jeśli } f^*(i) \leq 1 \text{ lub } p_{pick}^*(i) = 1/(f^*(i))^2 \text{ w pozostałych przypadkach,}$$

$$p_{drop}^*(i) = 1, \text{ jeśli } f^*(i) \geq 1 \text{ lub } (f^*(i))^4 \text{ w pozostałych przypadkach,}$$

gdzie $f^*(i)$ jest zmodyfikowaną wersją funkcji sąsiedztwa Lumera i Faieta.

Szukanie obiektu do podniesienia realizowane jest poprzez indeks, który przechowuje pozycje wszystkich obiektów do wzięcia, mrówka losowo wybiera jeden obiekt i z listy; przemieszcza się do jego pozycji na siatce; oblicza wartość funkcji sąsiedztwa $f^*(i)$ i probabilistycznie podejmuje decyzję, czy podnieść dany obiekt. Poszukiwanie jest kontynuowane aż do skutku.

Kolejna zmiana dotyczy zastąpienia losowej wędrówki skokiem mrówki do najbardziej odpowiedniego miejsca. Skok jest realizowany z pewnym wyliczanym prawdopodobieństwem, zależnym od jakości dopasowania. Podobnie wyznaczone jest prawdopodobieństwo pozostawiania obiektu $p_{drop}^*(i)$.

Inna zmiana dotyczy rozmiaru lokalnego sąsiedztwa postrzeganego przez mrówki, które ogranicza informacje, jakie mogą być wykorzystane w procesie sortowania. Zastosowano stopniowe zwiększanie promienia percepcji, co oszczędza obliczeń we wstępnej fazie procesu grupowania oraz zabezpiecza przed trudnościami z kształtowaniem wstępnych formacji grup.

Autorzy zaproponowali także adaptacyjny parametr skalujący niepodobieństwo wewnątrz funkcji sąsiedztwa $f^*(i)$, od którego zależy zasadniczo funkcjonowanie algorytmu. Niestety odpowiedni dobór parametru α zależy od rozkładu niepodobieństwa par obiektów w zbiorze, a więc nie może być ustalony bez analizy danych. Obserwujemy wzrost liczby parametrów, sprawiających, że z założenia proste mechanizmy gubią właśnie tę ważną cechę. Niestety wysiłki te nie mają przełożenia na lepszą jakość otrzymanych rozwiązań w porównaniu z klasycznymi metodami grupowania.

3.4. Algorytmy hybrydowe

Tendencja do tworzenia zbyt wielu grup przewija się przez wszystkie wyżej opisane algorytmy. To jej starały się zapobiec kolejne modyfikacje, które przejawiały się zwiększaniem liczby parametrów sterujących. Zbyt duża liczba grup powstałych w wyniku zastosowania algorytmu mrówkowego znalazła również swoje odzwierciedlenie w pracach N. Monmarchégo, M. Slimane'a, G. Venturiniiego i D. Steinberga (por. m.in. [1999]) oraz P.M. Kande i L.O. Halla [2003]. Tworzą oni hybrydowe systemy grupowania, w których algorytm mrówkowy bazujący na algorytmie Denebourg'a, rzadziej Lumera i Faieta, służy do zgrubnego pogrupowania obiektów, do których następnie stosują jeden z klasycznych algorytmów grupowania, k -średnich i ISODATA (AntClass) zastosowanych przez pierwszą grupę badaczy oraz algorytm FCM (Fuzzy C Means) wykorzystany przez drugą grupę. Pożądana poprawa nie zawsze ma miejsce, dlatego na przemian stosuje się algorytm mrówkowy i jeden z klasycznych, gwarantujący pożądaną zbieżność. Te podejścia wprowadzają dodatkowo możliwość działania na grupach obiektów w kolejnych iteracjach tworząc formę grupowania hierarchicznego. Otrzymane wyniki wskazują, że zastosowane algorytmy dają lepsze wyniki od porównawczych algorytmów.

3.5. Mapy feromonowe

Powrót do prostych zasad rządzących zachowaniem mrówek w mrowiskach zaproponowali Ramos i in. w algorytmie ACLUSTER (por. [Ramos, Abraham 2004; Ramos 2002]). ACLUSTER jest modelem, w którym mrówka jest opisana przez dwie wielkości, pozycję r oraz orientację θ . Przejście z jednej komórki (r, θ) do następnej (r^*, θ') definiowane jest przez wagową funkcję feromonową postaci,

$$W(\sigma) = (1 + (\sigma / \gamma \sigma)^\beta).$$

Wyrażenie to mierzy względne prawdopodobieństwo przejścia do komórki r z gęstością feromonu $\sigma(r)$. Parametr β steruje poziomem losowości, na podstawie którego mrówka podąża za gradientem feromonu. Natomiast $1/\gamma$ jest pojemnością sensoryczną. Ważony czynnik orientacji $w(\Delta\theta)$, gdzie $\Delta\theta$ jest zmianą kierunku. Ponadto każda mrówka pozostawia stałą ilość feromonu η . Tempo wietrzenia feromonu wynosi k . Stąd znormalizowane prawdopodobieństwa przejścia z komórki k do komórki i na siatce dane jest wzorem

$$P_{ki}, P_{ik} = W(\sigma_i)w(\Delta_i) / \sum_{j/k} W(\sigma_j)w(\Delta_j),$$

gdzie zapis j/k oznacza wszystkie komórki j , które znajdują się w sąsiedztwie k .

Δ_i mierzy rozmiar różnicy orientacji względem poprzedniego kierunku w czasie $t - 1$. Wybór każdej mrówki zależy od pola feromonowego kolonii i środowiska.

Każda mrówka angażuje się w wykonanie jakiegoś zadania, gdy poziom bodźca dla danego zadania przekracza jej próg. Intensywność bodźca s może być wyrażona np. przez liczbę spotkań, koncentrację chemiczną lub inny odbierany sygnał. Proóg reakcji θ jest wyrażany w jednostce intensywności bodźca, jest zmienną determinującą tendencję pojedynczej reakcji na bodziec s i wykonanie przypisanego zadania. Zastosowano funkcję intensywności bodźca s zaproponowaną przez Bonabeau i in. w pracy [1996].

Algorytm ACLUSTER ze względu zarówno na osiągnięte wyniki w grupowaniu dokumentów i pozyskiwaniu informacji tekstowych, jak i na powrót do znacznych uroszczeń należy uznać za krok w dobrym kierunku.

3.6. Algorytm rozpoznawania

N. Labroche, N. Monmarché i G. Venturi m.in. w pracy [2002] przedstawili ciekawy i odmienny od innych algorytm ANTCLUST bazujący na mechanizmie identyfikacji osobniczej (zob. pkt 1). Podstawowym pojęciem w tym algorytmie jest wzorzec identyfikacji (zapach), który posiada każda mrówka. Jest on miarą przynależności do mrowiska. Reprezentowany jest przez dwa elementy. Pierwszym jest genom, którym jest obiekt, jaki należy zgrupować (nie ulega on zmianom w procesie grupowania). Drugim jest poziom akceptacji, który jest funkcją zaobserwowanego maksymalnego i średniego podobieństwa w fazie uczenia.

U podstaw algorytmu ANTCLUST leżą dwa mechanizmy: ontogeneza mrówek – ustalenie wzorca identyfikacji oraz przebieg spotkania mrówek. Celem algorytmu jest organizacja spotkań między wszystkimi mrówkami, by zbliżyć ich zapachy bardziej, jeśli akceptują się wzajemnie, lub je oddalić, gdy się nie akceptują (ma tu zastosowanie dynamiczna miara oceny efektów spotkania M). Po jakimś czasie mrówki reprezentujące obiekty tego samego typu gromadzone są w tym samym obszarze. Zapach ulega zmianom zgodnie z wynikami odbytych spotkań z innymi mrówkami. Jeśli są podobne, równocześnie wymieniają swoje zapachy, w przeciwnym wypadku mniej podobna absorbuje zapach drugiej. Takie założenia zapewniają zbieżność algorytmu, dzięki zabezpieczaniu dobrze zakwalifikowanych mrówek przed przenoszeniem ich do innych mrowisk. Zasady działania algorytmu opisane zostały za pomocą zbioru reguł.

Przedstawione wyniki są odrobinę lepsze od tych uzyskanych za pomocą algorytmu k -means ($k = 10$). Algorytm zdecydowanie gorzej sobie radzi, gdy klasy zachodzą na siebie oraz gdy obiekty są zaburzane jednolitym zakłóceniem.

4. Algorytmy mrówkowe w zadaniu klasyfikacji

4.1. Mrówkowy algorytm indukcji reguł

Niedoskonałość algorytmów indukcji reguł dotyczy charakteru przeszukiwania, który zwany jest zachłannym lub krótkowzrocznym. Jest on determinowany przy-

rostową zasadą konstrukcji reguły. Podejście to polega na analizie jednego atrybutu w danym momencie i wyborze w każdym kroku najlepszego warunku, jaki będzie dodany do przesłanki reguły (por. [Berry, Linoff 1997; Cichosz 2000; Eibe 2000; Freitas 2001]). Poszukuje się mechanizmu, który dałby możliwość globalnej oceny dokonywanych wyborów i tworzonej reguły oraz możliwości skorzystania z doświadczeń nabytych w procesie tworzenia reguł, które miałyby możliwość sterowania kolejnymi wyborami przesłanek. Jedną z propozycji jest zastosowanie mechanizmu 'zostaw wiadomość' algorytmów mrówkowych.

Algorytmy mrówkowe w indukcji reguł łączą w sobie indukcyjny mechanizm generowania zbioru reguł klasyfikacyjnych oraz mechanizm dzielenia się wiedzą o jakości znalezionych rozwiązań oraz zaawansowaniu w pracach poszukiwawczych. Modyfikacji poddany został algorytm CN2 (por. [Cichosz 2000]). Celem jest wypośrodkowanie pomiędzy lokalnym (zachłannym) przeszukiwaniem, jakie prezentowane jest przez CN2, a globalnym sterowaniem, jakie mogą wnieść algorytmy mrówkowe.

Mrówkowy algorytm indukcji reguł obejmuje dwa rodzaje procedur,

- a) budowy/modyfikacji rozwiązań problemu tworzenia zbioru reguł;
- b) modyfikacji śladu feromonowego.

Podstawowa zmiana dotyczy charakteru procesu budowy (modyfikacji) zbioru reguł z deterministycznego na stochastyczny. Wyrażony jest on przez prawdopodobieństwo (P_{ij} opisane wzorem (1)) dodania nowego warunku do aktualnie budowanej reguły, które określane jest przez dziedzinowo zależną heurystykę (η opisaną wzorem (2)) oraz ilość feromonu (τ opisanego wzorem (4)) zdeponowanego przez mrówki na tej ścieżce w poprzednich działaniach. Modyfikacja śladu feromonowego wyznaczana jest przez funkcję, której wartość zależy od wskaźnika wietrzenia oraz jakości tworzonego rozwiązania.

Tworzenie zbioru reguł klasyfikacyjnych polega na przyrostowym tworzeniu zbioru reguł i samych reguł. Wybór kolejnych przesłanek do reguły określane jest przez prawdopodobieństwo wyboru termu $_{ij}$, które dane jest wzorem,

$$P_{ij} = \frac{\tau_{ij}(t)\eta_{ij}}{\sum_i^a \sum_j^{b_i} \tau_{ij}(t)\eta_{ij}} \forall i \in I, \quad (1)$$

gdzie, η_{ij} – wartość funkcji heurystycznej dla termu $_{ij}$, miara siły predykcji termu $_{ij}$,

$\tau_{ij}(t)$ – ilość feromonu przypisana termowi $_{ij}$ w iteracji t ,

a – liczba atrybutów,

b_i – liczba wartości atrybutu i ,

I – zbiór atrybutów jeszcze nie użytych przez mrówkę.

W przeciwieństwie do klasycznego algorytmu wybór kolejnego warunku do przesłanki nie jest deterministyczny, jest zaś określony przez prawdopodobieństwo. Drugą zmianą jest dodanie wzmocnienia jakości termów przez zdobyte doświadczenie w tworzeniu zbioru reguł klasyfikacyjnych, które jest mierzone ilością

feromonu $\tau_{ij}(t)$. Miara siły predykcji termu jest znana definicja bazująca na entropii wyrażona wzorem,

$$\eta_{ij} = \frac{\log_2 k - H(W | A_i = V_{ij})}{\sum_{i=1}^a x_i \sum_{j=1}^{b_j} (\log_2 k - H(W | A_i = V_{ij}))}, \quad (2)$$

gdzie: k – liczba klas; W – atrybut klasy;

$H(W | A_i = V_{ij})$ – entropia termu wyrażona następującym wzorem,

$$H(W | A_i = V_{ij}) = - \sum_{w=1}^k (P(w | A_i = V_{ij}) \cdot \log_2 P(w | A_i = V_{ij})),$$

x_i – przyjmuje wartość 1, gdy atrybut jest dostępny i 0 w przeciwnym razie,

a – liczba atrybutów; b_j – liczba wartości atrybutu i ;

V_{ij} – j -ta wartość i -tego atrybutu; A_i – i -ty atrybut.

Kolejnym krokiem jest ocena jakości reguły, która jest potrzebna do modyfikacji poziomu feromonu – zdobytej wiedzy. Oznaczana jest symbolem Q i opisywana następującym wzorem,

$$Q = \text{wrażliwość} \cdot \text{ściśłość} = \frac{TP}{TP + FN} \cdot \frac{TN}{FP + TN}, \quad (3)$$

gdzie: TP – liczba poprawnie sklasyfikowanych przypadków,

FP – liczba przypadków pokrytych przez regułę, należących do innej kategorii,

FN – liczba przypadków nie objętych przez regułę, należących do tej samej kategorii,

TN – liczba przypadków nie objętych przez regułę, należących do innej kategorii niż reguła.

Zdefiniowane zostały już wszystkie potrzebne elementy niezbędne do wyznaczenia strategii modyfikacji feromonu, która wyrażona jest następującym wzorem,

$$\tau_{ij}(t+1) = \tau_{ij}(t) + \tau_{ij}(t)Q, \quad \forall i, j \in R. \quad (4)$$

Poziom feromonu wszystkich termów może być znormalizowany przez podzielenie przez łączną sumę feromonu. Ilość feromonu wzrasta dla termów, które wystąpiły w regule R i zmniejsza się dla pozostałych.

Schematyczny mrówkowy algorytm indukcji reguł przedstawia się następująco,

1. Każda mrówka startuje z pustą regułą, następnie

a) dodaje jeden warunek w czasie bieżącej cząstkowej reguły¹;

kryterium wyboru warunku P_{ij} (por. równanie (1)) determinowane jest przez problemowo-zależną funkcję heurystyczną η_{ij} (por. równanie (2)) oraz ilość feromonu τ_{ij} (por. równanie (4)), jaka jest przypisana danemu warunkowi (termowi);

b) zakończenia budowy reguły następuje, gdy:

¹ Aktualna postać reguły wyznacza przebyta przez mrówkę ścieżkę po zbiorze warunków.

- dodanie jakiegokolwiek warunku zmniejsza liczbę przypadków pokrywanych przez tę regułę;
 - gdy zbiór warunków jest pusty;
- c) weryfikowana jest odkryta reguła.

2. Aktualizacja feromonu i ; startuje (pkt 1) kolejna mrówka korzystająca z doświadczeń poprzedniczek.

Rozpatrywane są dwa mrówkowe algorytmy indukcji reguł klasyfikacyjnych AntMiner autorów, R.S. Parpinelliego, H.S. Lopesa i Freitas, przedstawione m.in. w pracy [2002] oraz nazwane przez nas Thesis, których autorem jest M. Galea [2002]). W wypadku obu algorytmów mają zastosowanie powyższe ustalenia; różnice między AntMinerem i Thesis przedstawiono w tab. 1.

Tabela 1. Charakterystyka algorytmów AntMiner i Thesis

Element	AntMiner	Thesis
Struktura	przebieg, przebieg mrówek, mrówka	przebieg, przebieg mrówek, iteracja, mrówka
Próg jakości reguły	określony na 10	nieokreślony
Kryterium stopu	maksymalna liczba niepokrytych przypadków – 10	nieokreślony
Przycinanie reguł	gdy jakość po redukcji jest większa od aktualnej	gdy jakość po redukcji jest większa od obecnej lub jej równa, a nawet mniejsza
Modyfikacja feromonu	po każdej regule zbudowanej przez mrówkę	po każdej iteracji, według najlepszej reguły z ostatniej iteracji

Źródło: opracowanie własne na podstawie [Parpinelli, Lopes, Freitas 2001; 2002a; 2002b; Wilson].

4.2. Analiza wyników

Poniżej przedstawione zostało zestawienie efektów zastosowania czterech różnych technik do zadania klasyfikacyjnego na podstawie standardowych eksperymentalnych baz danych². Tabela 2 zawiera ocenę trafności klasyfikacji w procentach z zaokrągleniem do całości i błąd systematyczny w zaokrągleniu do całości, by zwiększyć przejrzystość danych.

Tabela 2. Zestawienie trafność klasyfikacyjnej algorytmów indukcji reguł

Baza Danych	AntMiner		Thesis		C4.5		CN2	
	T	O	T	O	T	O	T	O
Ljubijana Breast Cancer	75	11	73	8	73	3	68	4
Wisconsin Breast Cancer	96	3	92	3	95	0	95	1
Tic-Tac-Toe	73	8	74	4	83	2	97	0
Dermatology	87	6	90	6	89	1	90	2
Hepatitis	90	9	84	11	86	1	90	2
Cleveland Hart Disease	60	8	56	8	58	1	57	2

T – trafność klasyfikacji w %, O – błąd systematyczny (w %).

Źródło: opracowanie na podstawie [Parpinelli, Lopes, Freitas 2001; 2002a; 2002b; Galea 2002].

² Można je znaleźć pod adresem: <http://www.ics.uci.edu/~mllearn/MLRepository.html>.

Tabela 3. Zestawienie maksymalnych różnic w ramach poszczególnych baz danych

Baza	Algorytm		Maksymalna różnica
	Najlepszy	Najgorszy	
Ljubijana Breast Cancer	AntMiner	CN2	7 (75)*
Wisconsin Breast Cancer	AntMiner	Thesis	4 (96)
Tic-Tac-Toe	CN2	AntMiner	26 (97)
Dermatology	CN2	AntMiner	3 (90)
Hepatitis	CN2	Thesis	6 (90)
Cleveland Hart Disease	AntMiner	Thesis	4 (60)

* W nawiasach podana jest wartość maksymalna trafności klasyfikacyjnej.

Źródło: opracowanie na podstawie [Parpinelli, Lopes, Freitas 2001; 2002a; 2002b; Galea 2002].

Porównanie trafności klasyfikacyjnej czterech algorytmów indukcji reguł skłania do wyciągnięcia następującej konkluzji,

- najbardziej odpornym i uniwersalnym algorytmem jest C4.5; poziom trafności klasyfikacyjnej dla każdej bazy danych plasował się pomiędzy najlepszym i najgorszym wynikiem;
- najbardziej nieprzewidywalnym algorytmem jest AntMiner; można powiedzieć, że ma charakter ‘spekulacyjny’;
- najczęściej dającym najgorszy poziom trafności klasyfikacyjnej jest algorytm Thesis³.

Ogólnie można pokusić się o stwierdzenie, że próby wzmocnienia algorytmów indukcji reguł o mechanizm dzielenia się zdobytą w trakcie uczenia wiedzą nie odniosły zamierzonego skutku. Stawiamy tezę, że przyczyną tego może być sama konstrukcja tego mechanizmu. Odnosi się ona do lokalnych wyborów sterowanych globalnym ukierunkowaniem. Naszym zdaniem, globalne wytyczanie kierunków faktycznie globalne nie jest, gdyż dokonywane jest po odkryciu pojedynczej reguły a więc cząstkowego rozwiązania problemu klasyfikacji, może prowadzić zarówno do najlepszego jak i najgorszego rozwiązania. Raczej będzie to przypadek niż zamierzone działanie. Inaczej jest np. niż w algorytmach genetycznych, gdzie ocena globalna wyrażana za pomocą funkcji dopasowania dotyczy pełnego rozwiązania. Globalne sterowanie powinno odnosić się do pełnego rozwiązania. Jednak ze względu na sekwencyjny charakter prezentowanych algorytmów indukcji reguł nie jest możliwe do zastosowania.

Przy analizie wyników trafności klasyfikacji nasuwa się jeszcze jedno spostrzeżenie, a mianowicie, że możliwe jest poprawienie jakości klasyfikacji. Niewątpliwie wynika to z niedoskonałości miernika, jakim są entropia i inne mierniki, np. statystyczne. Natomiast włączenie globalnego sterowania poszukiwaniem najlepszego rozwiązania spowodowało otrzymywanie skrajnie różnych wyników. Jeśli pominąć globalne sterowanie, które naszym zdaniem globalne nie jest, to pozostaje tylko różnica w sposobie dokonywania wyborów, a mianowicie rozróżnienie czy są one deterministyczne czy stochastyczne.

³ Najgorsze wyniki mogą być spowodowane mniej restrykcyjnym kryterium przycinania reguł niż w wypadku algorytmu AntMiner (por. [Galea 2002, s. 59]).

Stawiamy zatem tezę, że zastąpienie deterministycznych wyborów wyborami stochastycznymi nie da istotnie gorszych wskaźników trafności klasyfikacji, bez konieczności uciekania się do włączenia mechanizmu algorytmów mrówkowych.

Interesującym wynikiem jest wpływ rozmiaru populacji mrówek na poziom trafności klasyfikacji, z którego wynika, że 10 mrówek to wystarczająca liczba dająca wzrost zauważalnej jakości (powyżej 1% trafności (zob. [Galea 2002, s. 64, tab. 7.3 (a) i (b)]). Zwiększenie liczby populacji nie przekłada się na monotoniczną poprawę jakości predykcji. Jej wartości są porozrzucane między różne liczebnie populacje. Ponieważ cztery spośród sześciu baz danych osiągnęły lepsze wyniki przy zwiększonej populacji, autor Thesis stawia hipotezę, że przemawia to na korzyść zastosowanych zasad algorytmu mrówkowego, z sugestią większego udziału lokalnej różnorodności wyborów kosztem globalnego sterowania. Naszym zdaniem niekoniecznie, raczej skłaniamy się ku niedoskonałości miar i stochastycznego procesu wyboru kolejnego warunku przesłanki reguły.

Kryterium trafności klasyfikacji jest wspomagane przez kryterium zrozumiałości otrzymanego rozwiązania, które determinowane jest przez liczbę i złożoność reguł odkrytego zbioru (listy) reguł. Wyniki poszczególnych algorytmów wykonanych na różnych bazach danych prezentuje tab. 4.

Tabela 4. Złożoność odkrytych zbiorów reguł klasyfikacyjnych

Baza danych	AntMiner		Thesis		C4.5		CN2	
	R	T	R	T	R	T	R	T
Ljubijana Breast Cancer	7	10	8	1	6	13	55	2
Wisconsin Breast Cancer	6	12	12	1	11	44	19	2
Tic-Tac-Toe	9	10	8	1	83	384	40	3
Dermatology	7	81	7	3	23	92	18	2
Hepatitis	3	8	4	2	4	9	7	2
Cleveland Hart Disease	10	16	15	2	49	183	42	3

R – liczba reguł, T – liczba warunków (termów).

Źródło: opracowanie na podstawie [Parpinelli, Lopes, Freitas 2001; 2002a; 2002b; Galea 2002].

Przyczyną jednoznacznej przewagi AntMinera (mniejszej liczby reguł i warunków w przesłankach reguł) może być nieokreślenie progu, jaki reguła powinna spełniać odnośnie do minimalnej liczby pokrytych przypadków w algorytmie Thesis. Takie twierdzenie jest zasadne, gdyż różnice między tymi algorytmami są nie-wielkie. Natomiast może zaskakiwać tak znaczne uproszczenie zbioru reguł i samych reguł. Można postawić hipotezę, że jedną z przyczyn może być stochastyczność wyboru kolejnych warunków do przesłanki. Drugą przyczyną znacznego uproszczenia zbioru reguł może być moment weryfikacji (przycinania) reguł, którym w C4.5 i CN2 jest zakończenie tworzenia zbioru reguł, w algorytmach AntMiner i Thesis zaś przeprowadzany jest po wygenerowaniu każdej reguły. Warto również prześledzić relacje między trafnością klasyfikacyjną odkrytych zbiorów reguł a ich złożonością na większej liczbie baz danych.

4.3. Eksperyment

Założenia eksperymentu wynikają z postawionej w poprzednim punkcie tezy, że zastąpienie deterministycznych wyborów wyborami stochastycznymi da nie gorsze wskaźniki trafności klasyfikacji od prezentowanych w tab. 2 w pkt 4.2, bez konieczności uciekania się do włączenia mechanizmu algorytmów mrówkowych. W proponowanym eksperymencie zastosowano iteracyjnie algorytm C4.5, stosując miarę jakości kolejnego elementu jako prawdopodobieństwo obliczane według wzoru (1) z pominięciem ilości feromonu, a więc w postaci:

$$P_{ij} = \frac{\eta_{ij}}{\sum_i \sum_j \eta_{ij} \forall i \in I} \quad (5)$$

Za liczbę iteracji dla każdej reguły przyjęto 10, zatem, by utworzyć jedną regułę, wykonywanych jest 10 przebiegów. Uzasadnieniem takiego założenia są wnioski z przeprowadzonej analizy wpływu rozmiaru populacji na poziom trafności klasyfikacyjnej, z której wynika, że 10 mrówek to wystarczająca liczba dająca zauważalny wzrost jakości. Następnie wybierana jest najlepsza reguła. Najlepsze reguły tworzą ostateczny zbiór reguł klasyfikujących. Pozostałe parametry są zgodne z parametrami AntMinera – kryterium stopu (albo brak w zbiorze warunków do dodania, albo liczba niepokrytych przypadków jest mniejsza od 10); poziom jakości reguły – pokrycie minimum 10 przykładów; przycinanie po każdej utworzonej regule. Wyniki tego eksperymentu przedstawiono w tab. 5.

Tabela 5. Zestawienie trafności klasyfikacyjnej algorytmów indukcji reguł

Baza Danych	AntMiner		Thesis		C4.5		CN2		EKS	
	T	O	T	O	T	O	T	O	T	O
Ljubijana Breast Cancer	75	11	73	8	73	3	68	4	74	7
Wisconsin Breast Cancer	96	3	92	3	95	0	95	1	94	1
Tic-Tac-Toe	73	8	74	4	83	2	97	0.5	90	3
Dermatology	87	6	90	6	89	1	90	2	89	2
Hepatitis	90	9	84	11	86	1	90	2.5	90	3
Cleveland Hart Disease	60	8	56	8	58	1	57	2	57	4

EKS – iteracyjny C4.5, T – trafność klasyfikacji (w %), O – błąd systematyczny (w %).

Źródło: opracowanie na podstawie [Parpinelli, Lopes, Freitas 2001; 2002a; 2002b; Galea 2002].

Eksperyment wykonany na sześciu bazach danych potwierdza postawioną hipotezę, że nie ma potrzeby uciekania się do obliczeniowo bardziej złożonych algorytmów. Otrzymane wyniki są czasami lepsze od C4.5, tylko w dwóch przypadkach są nieznacznie gorsze. Podobnie, a nawet bardziej korzystnie, przedstawia się porównanie z algorytmami AntMiner i Thesis. Nie stawia się wniosku, że

algorytmy mrówkowe nie powinny być wykorzystywane do indukcji reguł, zwraca się zaś uwagę na trudności zdefiniowania globalnego kryterium sterującego przeszukiwaniem przestrzeni potencjalnych rozwiązań w zadaniu klasyfikacyjnym.

Drugie kryterium oceniające jakość utworzonego zbioru reguł w tym eksperymencie przedstawiono w tab. 6.

Tabela 6. Złożoność odkrytych zbiorów reguł klasyfikacyjnych

Baza Danych	AntMiner		Thesis		C4.5		CN2		EKS	
	R	T	R	T	R	T	R	T	R	T
Ljubijana Breast Cancer	7	10	8	1	6	13	55	2	7	8
Wisconsin Breast Cancer	6	12	12	1	11	44	19	2	10	3
Tic-Tac-Toe	9	10	8	1	83	384	40	3	70	365
Dermatology	7	81	7	3	23	92	18	2	24	89
Hepatitis	3	8	4	2	4	9	7	2	4	3
Cleveland Hart Disease	10	16	15	2	49	183	42	3	47	184

EKS – iteracyjny C4.5, R – liczba reguł, T – liczba warunków.

Źródło: opracowanie na podstawie [Parpinelli, Lopes, Freitas 2001; 2002a; 2002b; Galea 2002].

Stopień złożoności zbioru reguł i przesłanek reguł nieznacznie się poprawił względem algorytmu C4.5. Jednak prezentowana poprawa w odniesieniu do algorytmów mrówkowych indukcji reguł jest zdecydowanie nieistotna. Proponuje się pogłębienie badań weryfikujących postawione hipotezy w poprzednim punkcie.

5. Podsumowanie

Wyróżniającą właściwością przedstawionych algorytmów jest ich stochastyczność. Jej przejawem jest losowa wędrówka mrówek w poszukiwaniu obiektu do podniesienia lub miejsca do jego pozostawienia. Użyteczność takiej eksploracji przestrzeni przeszukiwań raczej się nie sprawdziła. Kolejne propozycje próbują ograniczyć bezproduktywne spacerowanie po pustych obszarach działania algorytmu, gdyż mogą one sprawiać, że wprowadzony obszar postrzegania obiektów (lub pamięć krótka) będzie bezużyteczny, ponieważ okaże się pusty. Ponadto stają się one czasochłonne. Sięgają po parametry znalezienia miejsca, gdzie powinna znaleźć się mrówka, bez konieczności losowych wędrówek, np. wykorzystanie pamięci pkt 3.2, indeks obiektów do wzięcia pkt 3.3, wyznaczanie kolejnej pozycji mrówki na podstawie wagowej funkcji feromonowej pkt 3.5.

Stochastyczność związana jest także z wyborem podniesienia lub pozostawienia obiektu, a więc z procesem grupowania. Można stwierdzić, że w tym przypadku należy liczyć się z niedopracowanym rozwiązaniem, a nie z możliwością otrzymania lepszego rozwiązania, gdyż zasady grupowania (stopień podobieństwa, próg akceptowalności dodania nowego obiektu, usunięcia obiektu już zakwalifiko-

wanego do grupy, akceptowanego poziomu niepodobieństwa itp.) są ściśle określone bez względu na algorytm. Jeśli nie ma rozróżnienia między zasadami tworzenia a zasadami oceny grup obiektów, stochastyczność wyborów nie wpłynie na jakość otrzymanych rozwiązań, po prostu nie ma takiej możliwości. Przełoży się to tylko na czas potrzebny do znalezienia rozwiązania.

Przykładem najbardziej wyraźnym niedokładności otrzymywanych rozwiązań za pomocą algorytmów mrówkowych są algorytmy hybrydowe, w których klasyczne algorytmy grupowania odgrywają rolę dopracowującą rozwiązanie wygenerowane przez mrówki. Działania takie wykonywane są nawet w kilku iteracjach, w których na przemian pracuje algorytm mrówkowy z algorytmem klasycznym.

Wspólną cechą przedstawionych algorytmów jest specyficzna fizyczna reprezentacja obiektów w przestrzeni dwuwymiarowej pierścieniowej siatki. Niedogodność takiej reprezentacji wynika z liczności obiektów do grupowania, którą można opisać. Zatem ważny problem skali pozostaje otwarty. Z tą reprezentacją wiąże się też ograniczenie dostępności informacji o grupowanych obiektach determinowane pojemnością pamięci, promieniem czy obszarem postrzegania.

Niewątpliwą zaletą algorytmów mrówkowych jest brak wymagań odnośnie do dostarczenia dodatkowych informacji o grupowanej populacji obiektów, np. o liczbie klas, rodzaju grup, wstępnej partycji populacji itp.

Pozostałe charakterystyki algorytmów mrówkowych, chociaż wymagają dużo uwagi, są właściwe algorytmom grupowania w ogóle, a ich rola nie zależy od tego, w jakich algorytmach zostały zastosowane, dlatego zostały pominięte.

Podkreślając, że badania są ciągle w fazie wstępnej, algorytmy mrówkowe, jak na razie, nie zaskoczyły osiągniętymi wynikami rozwiązań zadania grupowania.

Algorytm mrówkowy jest obiecującym narzędziem, które może wspomóc zachłanne algorytmy indukcji reguł. Jednak trudności w zdefiniowaniu globalnego kryterium oceny rozwiązania powodują, że nie mogą one konkurować z klasycznymi podejściami. Odniesienie się do oceny cząstkowego rozwiązania w definicji globalnego kryterium, którego wpływ na pełne rozwiązanie nie jest znany, jest trudny do zaakceptowania. Opinię tę potwierdza wykonana analiza. Przeprowadzony eksperyment miał na celu zwrócenie uwagi na to, iż poprawę jakości klasyfikacyjnej można zwiększyć, nie uciekając się do tworzenia bardziej złożonych algorytmów.

Przeprowadzone badanie jest badaniem wstępnym. Dalsze prace będą poświęcone analizie możliwości zdefiniowania globalnego kryterium oceny rozwiązań w sekwencyjnych algorytmach indukcji reguł. Planowane jest również rozszerzenie przeprowadzonego eksperymentu, mające na celu odpowiedź na pytanie o głębsze przyczyny tak dużych różnic w złożoności zbiorów reguł między algorytmami wspomaganyymi mechanizmem 'zostaw wiadomość' a algorytmami C4.5, CN2 i AQ.

Literatura

- Berry M.J.A., Linoff G., *Data Mining Techniques for Marketing Sales and Customer Support*, John Wiley & Sons, 1997.
- Bonabeau E., Théraulaz G., Deneubourg J.L., *Quantitative Study of the Fixed Response Threshold Model for the Regulation of Division of Labour in Insect Societies*, Soc. B, 263, 1996.
- Camazine S., *Self-Organization in Biological Systems*, Princeton University Press, 2001.
- Cichosz P., *Systemy uczące się*, Wydawnictwo Naukowo-Techniczne, Warszawa 2000.
- Deneubourg J.L., Goss S., Franks N., Sendova-Franks A., Detrain C., Chretien L., *The Dynamic of Collecting Sorting Robot-like Ants and Ant-like Robots*, In Proc. of the first Conf. SAB'90, J.A. Meyer, S.W. Wilson (red.), MIT Press/Bradford Books.
- Eibe F., *Pruning Decision Trees and Lists*, PhD Thesis, University of Waikato, 2000.
- Edelstein-Keshet L., Watmough J., Ermentrout G.B., *Trial Following in Ants, Individual Properties Determine Population Behaviour*, Behav. Ecol. Sociobiology 1995, no 36, s. 119-133.
- Freitas A.A., *Understanding the Crucial Role of Attribute Interaction in Data Mining*, Artificial Intelligence Review 16(3), Nov. 2001, pp. 177-199.
- Galea M., *Applying Swarm Intelligence to Rule Induction*, MSc Artificial Intelligence, Division of Informatics, University of Edinburgh, 2002.
- Handl J., Knowles J., Dorigo M., *Ant-based Clustering, a Comparative Study of its Performance with Respect to k-means, Average Link and 1D-SOM*, Technical report TR-IRIDIA-2003-24. IRIDIA, Universite Libre de Bruxelles, Brussels, 2003.
- Hölldobler B., Wilson E.O., *The Ants, Chapter Colony Odor and Kin Recognition*, 197-208, Springer Verlag, Berlin, Germany, 1990.
- Kande P.M., Hall L.O., *Fuzzy Ants as a Clustering Concept*, NAFIPS'03 Conference 2003, s. 227-232.
- Krieger M., Billeter J.B., Keller L., *Ant-like Task Allocation and Recruitment in Cooperative Robots*, Nature 406 (6799) 2000.
- Kube C., Bonabeau E., *Cooperative Transport by Ants and Robots*, „Robotics and Autonomous Systems” 30 (2000), 85-101.
- Kuntz P., Layzell P., Snyers D., *A Colony of Ant-like Agents for Partitioning in VLSI Technology*. In *Proceedings of the Fourth European Conference on Artificial Life 1994*, P. Husbands, I. Harvey (red.), MIT Press, 417-424.
- Labroche N., Monmarché N., Venturini G., *Visual Clustering Based on the Chemical Recognition System of Ants*, Internal Report E3i, Laboratoire d'Informatique, University of Tours, 2002.
- Lumer E., Faieta B., *Diversity and Adaptation in Populations of Clustering Ants*, [w:] D. Cliff, P. Husbands, J. Meyer, S. Wilson (red.), *From Animals to Animates 3*, Proc. of the 3th Int. Conf. SAB Cambridge, MA, The MIT Press/Bradford Books, 1994.
- Melhuish C., Holland O., Hoddell S., *Collective Sorting and Segregation in Robots with Minimal Sensing*, In *Proceedings of the International Conference on Simulation of Adaptive Behavior*, 1998.
- Monmarché N., Slimane M., Venturini G., *AntClass, Discovery of Clusters in Numeric Data by an Hybridization of an Ant Colony with the Kmeans Algorithm*, Technical Report No. 213, Laboratoire d'Informatique, E3i, University of Tours, 1999.
- Monmarché N., Venturini G., Slimane M., *On how the Ants Pachycondyla Apicalis are Suggesting a New Search Algorithm*, Internal Report No.214, E3i, University of Tours, January 1999.
- Page R.E., Mitchell S.D., *Self-organization and Adaptation in Insect Societies*. In, Ph.Sc. Assoc. A. Fine, M. Forbes, L. Wessels (red.), 1990 no 2, p. 289-298.
- Parpinelli R.S., Lopes H.S., Freitas A.A., *An Ant Colony Based System for Data Mining, Application to Medical Data*, Proc. Of the Genetic and Evolutionary Computation, GECCO-2001.
- Parpinelli R.S., Lopes H.S., Freitas A.A., *An Ant Colony Algorithm for Classification Rule Discovery*, [w:] H.A. Abbas, R.A. Sarker, C.S. Newton (red.), *Data Mining, A Heuristic Approach*, s. 190-208, Idea Group Publishing, London 2002a.

- Parpinelli R.S., Lopes H.S., Freitas A.A., *Data Mining with an Ant Colony Optimization Algorithm*, *IEEE Transactions on Evolutionary Computation*, Special issue on Ant Colony Algorithms, 2002b.
- Ramos V., Abraham A., *Evolving a Stigmergic Self-organized Data-Mining*, Intelligent Systems, Design and Applications, 2004.
- Ramos V., *On the Implicit and on the Artificial. Morphogenesis and Emergent Aesthetics in Autonomous Collective Systems*, in *ARCHITOPIA – Art, Architecture and Science*, J.L. Maubant, L. Moura (red.), Ministério da Ciência e Tecnologia, Feb. 2002.
- Wilson E.O., *The Sociogenesis of Insects' Colonies*, *Science* 228, 1489-1495.
- Wilson E.O., *The Insect Societies*, Belknap Press Cambridge, 1971.

THE ANT COLONY ALGORITHMS FOR KNOWLEDGE DISCOVERY FROM DATABASES

Summary

The knowledge discovery is still an open problem with many unsolved tasks. One of them is greediness of existing rule induction algorithms. Therefore there appear attempts enriching them with some global criterion that would control the search. One of such attempt is applying the mechanism of ant colony algorithms. The achievements of the study of ant colonies behaviour and of their self-organization capability is of interest to discover more universal unsupervised clustering algorithms. The analysis of the implementations of different swarm intelligent mechanism is also the subject of this paper.

Janina Anna Jakubczyc – dr, adiunkt w Katedrze Systemów Sztucznej Inteligencji Akademii Ekonomicznej we Wrocławiu.