

УДК 004.93

А.А. ОЛЕЙНИК, аспирант ЗНТУ (г. Запорожье),
С.А СУББОТИН, канд. техн. наук, ЗНТУ (г. Запорожье)

РЕДУКЦИЯ БАЗ НЕЧЁТКИХ ПРАВИЛ НА ОСНОВЕ МУЛЬТИАГЕНТНОГО ПОДХОДА

В статье рассмотрена актуальная задача отбора и преобразования баз нечётких правил, которые используются в экспертных системах. Для решения данной задачи предложен мультиагентный метод с непрямой связью между агентами, учитывающий взаимовлияние правил при прогнозировании. Проведены эксперименты по решению тестовых задач. Полученные результаты показали эффективность разработанного метода. Ил.: 1. Библиогр.: 21 назв.

Ключевые слова: база нечётких правил, экспертная система, мультиагентный метод.

Постановка проблемы и анализ литературы. В настоящее время экспертные системы, основанные на нечётких правилах [1 – 3], успешно применяются в различных прикладных областях, таких как: медицинская и техническая диагностика, финансовый менеджмент, распознавание образов, управление технологическими процессами и др. Широкое применение таких систем объясняется, в первую очередь, тем, что данные системы являются логически прозрачными и относительно дешёвыми в реализации.

Поскольку базы нечётких правил в экспертных системах часто характеризуются большим объёмом, то актуальной является задача объединения и преобразования нечётких правил, суть которой заключается в том, чтобы на основе начального набора нечётких правил сформировать новую базу правил меньшего объёма, которая в достаточной мере представляла бы начальную базу и была бы менее избыточной.

Пусть задана база нечётких правил $\Omega = \{R^1, R^2, \dots, R^{RN}\}$, описывающая объекты обучающей выборки $O = \{O^1, O^2, \dots, O^N\}$. Тогда на основе обучающей выборки объектов O и лингвистических термов, использующихся в исходной базе нечётких правил Ω , требуется сформировать такую базу нечётких правил $\Omega^* = \{R^1, R^2, \dots, R^{RN^*}\}$, $RN^* \ll RN$, которая обеспечивала бы качество прогнозирования нечёткой системы, построенной на основе полученной базы нечётких правил Ω^* , в допустимом пределе:

$$Q(\Omega^*) \geq Q_{threshold} \cdot \quad (1)$$

Существуют различные методы преобразования и объединения нечётких правил [4, 5], однако эти методы при обработке правил анализируют их качество по отдельности, не рассматривая и не учитывая качество всей базы в целом, что приводит к получению неоптимальных баз нечётких правил. Поэтому актуальной является разработка новых методов преобразования и

объединения нечётких правил, которые учитывали бы качество всей базы знаний, а не только отдельных правил. Задача преобразования и объединения нечётких правил может быть рассмотрена как задача дискретной оптимизации, в которой поиск производится в пространстве дискретных состояний, которые описываются наличием в правиле различных термов.

Одним из новых направлений искусственного интеллекта является роевой интеллект (Swarm Intelligence) [6]. Среди методов роевого интеллекта [7 – 14] наиболее приспособленным для решения задач дискретной оптимизации является метод муравьиных колоний [7, 8]. Поскольку задача преобразования и объединения нечётких правил может быть отнесена к задачам дискретной оптимизации, в данной работе исследуется применение мультиагентного подхода с непрямой связью между агентами для преобразования и объединения нечётких правил.

Цель статьи – разработка мультиагентного метода с непрямой связью между агентами для преобразования и объединения нечётких правил.

Принципы нечёткого вывода и оценка покрытия нечётких правил. Нечёткий вывод осуществляют на основе нечёткой базы знаний. Нечёткая база знаний о влиянии факторов на значение выходного параметра представляет собой совокупность логических выражений типа "ЕСЛИ <антецедент>, ТО <консеквент>", в которых антецеденты описывают значения входов, являющихся условием срабатывания правила, а консеквентом является класс экземпляра с заданными значениями входных параметров [15, 16].

Существуют различные методы нечёткого вывода [15, 17]. Однако в контексте рассматриваемой задачи объединения и преобразования нечётких правил традиционно применяется метод нечёткого вывода, основанный на выборе для классифицируемого экземпляра правила с наибольшим соответствием (single winner based-method) [18].

Пусть для объекта o , характеризующегося значениями факторов $\{o^1, o^2, \dots, o^P\}$, необходимо определить его класс по заданной базе правил. Тогда, в соответствии с рассматриваемым подходом нечёткого вывода, необходимо определить степень соответствия между каждым j -м правилом R_j и экземпляром o :

$$\text{match}(R_j, o) = \min(\text{matchAttr}(R_j^1, o^1), \dots, \text{matchAttr}(R_j^p, o^p), \dots, \text{matchAttr}(R_j^P, o^P)),$$

где $\text{match}(R_j, o)$ – степень соответствия между правилом R_j и экземпляром o ; $\text{matchAttr}(R_j^p, o^p)$ – мера соответствия между p -ым атрибутом в правиле R_j и соответствующим атрибутом экземпляра o , которая рассчитывается в соответствии с формулой:

$$matchAttr(R_j^p, o^p) = \begin{cases} 1, R_j^p = \emptyset; \\ \max_q (\min(m_q(R_j^p), m_q(o^p))), \forall q = \overline{1, Q^p}, R_j^p \neq \emptyset, \end{cases}$$

где q – отдельный терм, относящийся к области описания атрибута p ; Q^p – количество термов, относящихся к области описания атрибута p .

Таким образом, в соответствии с данным подходом, после оценки всех $match(R_j, o)$ выбирается то правило, которому экземпляр соответствует в наибольшей степени. После определения правила с наибольшей степенью соответствия, данное правило используется для классификации экземпляра o .

Такой подход определения степени соответствия между правилом и отдельным экземпляром может быть использован не только в процессе классификации, но и в процессе решения задачи объединения и преобразования правил, поскольку позволяет оценить степень соответствия между отдельным правилом и объектом, а также позволяет определить, сколько экземпляров отдельного класса заданное правило может оценить в пределах заданной степени соответствия.

Метод муравьиных колоний. Метод муравьиных колоний является мультиагентным эвристическим итеративным методом случайного поиска с непрямой связью между агентами [8, 19, 20]. Поведение агентов моделируется как процесс перемещения и исследования пространства поиска. Особенностью моделируемого перемещения является моделирование выделения феромонов, которые агенты оставляют на пути в процессе своего перемещения. Феромоны в процессе работы испаряются. Таким образом, на наилучшем пути остаётся большее количество феромонов, поскольку добавление феромонов происходит чаще, чем испарение. А поскольку выбор пути для перемещения агентов основывается на информации о количестве феромонов, то агенты выбирают лучший путь. Обобщённая схема работы метода муравьиных колоний представлена на рис.

На этапе инициализации задаются параметры метода, влияющие на его работу. Далее происходит передвижение агентов между узлами графа, в результате чего, после окончания передвижения каждого агента формируются решения, из которых выбирается лучшее на данной итерации. Далее выполняется проверка на окончание работы метода (критерием окончания работы может быть заданное количество итераций или некоторый критерий для выбранного решения). После чего, если проверка закончилась успешно, то происходит окончание поиска, в процессе которого выбирается самое лучшее решение из всех, которые встречались на пройденных итерациях. Если же проверка была неуспешной, то производится обновление граней, которое заключается в имитации испарения реальных феромонов в природе, и перезапуск агентов.




Рис. Обобщённая схема работы метода муравьиных колоний

Основываясь на основных принципах метода муравьиных колоний, его разновидностях и областях применения [7, 8, 18, 19], можно выделить следующие преимущества и недостатки.

К преимуществам метода муравьиных колоний можно отнести то, что:

- он может использоваться в динамических приложениях (агенты адаптируются к изменениям окружающей среды);
- в процессе поиска метод использует память всей колонии, что достигается за счёт моделирования выделения феромонов;
- сходимость метода к оптимальному решению гарантируется;
- стохастичность оптимизационного процесса, то есть случайность поиска, за счёт чего исключается возможность зацикливания в локальном оптимуме;
- мультиагентность метода;
- скорость нахождения оптимального решения у метода муравьиных колоний выше, чем у традиционных методов;
- применяется к множеству различных задач оптимизации.

Можно выделить следующие недостатки метода муравьиных колоний:

- теоретический анализ затруднён, поскольку итоговое решение формируется в результате последовательности случайных решений; распределение вероятностей меняется при итерациях; исследования являются больше экспериментальными, чем теоретическими;
- сходимость гарантируется, но время сходимости не определено;
- высокая итеративность метода;

– результат работы метода достаточно сильно зависит от начальных параметров поиска, которые подбираются экспериментально.

Таким образом, можно отметить, что рассматриваемый мультиагентный метод с непрямой связью может эффективно решать задачи преимущественно дискретной оптимизации, которые должны удовлетворять следующим требованиям:

– задача должна быть описана в виде графа с набором узлов и граней между узлами;

– задача должна допускать применение эвристических мер адекватности отдельных элементов в графе поиска;

– допускать составление альтернативных решений, посредством чего можно рационально определять допустимые решения;

– иметь правило обновления феромонов – правило, которое определяет вероятность перемещения агента из одного узла графа к другому.

Мультиагентный метод с непрямой связью между агентами для преобразования и объединения нечётких правил. Для решения задачи преобразования и объединения нечётких правил на основе мультиагентного подхода с непрямой связью между агентами необходимо привести основные этапы метода муравьиных колоний в соответствии с особенностями решаемой задачи.

1. *Инициализация.* Создаётся граф поиска, задаются параметры работы, а также эвристические меры важности отдельных узлов. В контексте решения задачи преобразования и объединения нечётких правил граф поиска будет состоять из узлов, которые представляют собой отдельные лингвистические термы, которые могут быть включены в antecedentes правил. В качестве эвристической меры значимости узла предлагается использовать меру важности данного лингвистического термина для описания соответствующего класса выходного значения.

2. *Перемещение агентов.* В процессе перемещения агенты должны принимать решение, какой терм добавить в создаваемое правило. Для такого решения применяется правило случайного выбора, основанное на эвристических мерах важности и мере приоритетности, которая базируется на моделировании выделения феромонов агентами в процессе перемещения. Таким образом, на данном этапе должен осуществляться выбор и добавление нового лингвистического термина в формируемое правило. Решение о прекращении перемещения отдельного агента необходимо принимать, основываясь на том, насколько хорошо сформированное правило описывает соответствующий класс экземпляров.

3. *Моделирование выделения феромонов.* Выделение феромонов влияет на изменение меры приоритетности узла. В традиционном методе муравьиных колоний изменение меры приоритетности зависит от длины пройденного агентом пути. В данном случае в качестве меры изменения меры приоритетности необходимо использовать качество покрытия отдельной базой

правил входного множества экземпляров. При этом предлагается добавление феромонов выполнять в соответствии с элитной стратегией, что позволит обеспечить более быструю сходимость к итоговому решению.

4. *Обновление феромонов.* Для исключения решений, которые характеризуются плохим качеством покрытия исходных классов, необходимо осуществлять испарение феромонов, что понижает меру приоритетности тех термов, включение которых в правила является нежелательным. Процедура обновления феромонов не имеет каких-либо существенных особенностей для решаемой задачи, поэтому её можно применять для преобразования и объединения нечётких правил.

Важной особенностью разрабатываемого мультиагентного метода с непрямой связью между агентами для преобразования и объединения нечётких правил является то, что для каждого отдельного класса экземпляров требуется создавать отдельное пространство поиска, а, соответственно, и отдельные матрицы эвристических мер важности и феромонов, а также в каждом отдельном пространстве поиска будет выполняться поиск отдельным множеством агентов. Это объясняется тем, что важность и приоритетность отдельно взятого лингвистического термина различна для различных классов экземпляров.

В соответствии с указанными особенностями этапов выполнения мультиагентного метода с непрямой связью между агентами в контексте решения задачи преобразования и объединения нечётких правил, а также с описанными ранее подходами оценки покрытия нечётких правил, был разработан мультиагентный метод, который представлен в виде последовательности шагов 1 – 17.

Шаг 1. Инициализация. Задаются статические параметры работы метода: коэффициенты α, β, ρ . Для каждого из возможных классов выходных значений создаётся своё пространство поиска, и, соответственно, своё отдельное множество агентов, отдельный граф поиска, представляющий собой лингвистические термины, которые могут быть включены в правила, а также для каждого пространства поиска рассчитываются эвристические значения значимости отдельного термина для соответствующего класса

$$\eta_p^q = \frac{\sum_{o=1}^N \min(\mu_p(o), \mu_q(o))}{\sum_{o=1}^N \mu_q(o)}, \quad p = \overline{1, T}, \quad q = \overline{1, K},$$

где η_p^q – значение эвристической значимости лингвистического термина p для описания класса q ; o – экземпляр входной выборки, содержащей N экземпляров; $\mu_p(o), \mu_q(o)$ – значение функции принадлежности объекта o

терму p и классу q , соответственно; T – количество лингвистических термов; K – количество классов.

В каждом пространстве поиска каждому узлу графа поиска ставится в соответствие начальное значение количества феромонов τ_{init}

$$\tau_p^q(1) = \tau_{init}, \quad p = \overline{1, T}, \quad q = \overline{1, K}, \quad (2)$$

где $\tau_p^q(1)$ – значение количества феромонов для p -го термина в пространстве поиска для q -го класса на первой итерации поиска.

Шаг 2. Установить: $t = 1$.

Шаг 3. Установить: $i = 1$.

Шаг 4. Установить: $j = 1$.

Шаг 5. Установить: $k = 1$.

Шаг 6. Выбор термина для добавления в правило j -го агента в пространстве поиска i -го класса.

Шаг 6.1. Для j -го агента на основе правила случайного выбора рассчитывается вероятность включения k -го лингвистического термина в правило, описывающего i -й класс выходного значения

$$P_k^{i,j} = \frac{\eta_k^i \cdot \tau_k^i(t)}{\sum_{p \in R^j} \eta_p^i \cdot \tau_p^i(t)}, \quad (3)$$

где $P_k^{i,j}$ – вероятность добавления k -го термина в правило j -го агента в пространстве поиска для i -го класса; R^j – множество термов, которые могут быть добавлены в правило j -го агента. Формирование данного множества определяет вид правил, которые могут составляться в процессе поиска, то есть предполагается, что правило может включать выражения типа ИЛИ. После добавления термина из данного множества исключается только данный терм, если же предполагается, что правило не может включать выражения типа ИЛИ, то кроме выбранного термина, исключаются и все термы, описывающие данный атрибут.

Шаг 6.2. Проверить условие

$$P_k^{i,j} > rand(1), \quad (4)$$

где $rand(1)$ – случайное число из интервала $[0; 1]$. Если условие выполняется, тогда лингвистический терм k добавляется в правило j -го агента, удаляется из множества возможных термов для данного агента и выполняется переход к шагу 7. В противном случае – переход к шагу 6.3.

Шаг 6.3. Установить $k = k + 1$.

Шаг 6.4. Если были рассмотрены все термы, то установить: $k = 1$.
Переход к шагу 6.1.

Шаг 7. Проверка завершения перемещения j -го агента.

Шаг 7.1. Если множество термов, которые j -й агент может добавить в формируемое правило, пусто, то выполняется переход к шагу 8.

Шаг 7.2. Определяется, сколько экземпляров i -го класса покрывает правило j -го агента.

Шаг 7.2.1. Для экземпляра o , относящегося к классу i , рассчитывается степень соответствия сформированного правила R_j и экземпляра o

$$match(R_j, o) = \min(matchAttr(R_j^1, o^1), \dots, matchAttr(R_j^p, o^p), \dots, matchAttr(R_j^q, o^q)),$$

где $match(R_j, o)$ – степень соответствия между правилом j -го агента R_j и экземпляром o ; $matchAttr(R_j^p, o^p)$ – мера соответствия между p -м атрибутом в правиле R_j и соответствующим атрибутом экземпляра o . Данная мера рассчитывается следующим образом:

$$matchAttr(R_j^p, o^p) = \begin{cases} 1, R_j^p = \emptyset; \\ \max_q (\min(m_q(R_j^p), m_q(o^p))), \forall q = \overline{1, Q^p}, R_j^p \neq \emptyset, \end{cases} \quad (5)$$

где q – отдельный терм, относящийся к области описания атрибута p ; Q^p – количество термов, относящихся к области описания атрибута p .

Шаг 7.2.2. Проверить условие

$$match(R_j, o) \geq inMatchMin, \quad (6)$$

где $inMatchMin$ – заданный параметр, который определяет, какое минимальное значения соответствия является достаточным, чтобы считать, что правило R_j в достаточной степени описывает объект o .

Если условие выполняется, то считается, что данный объект o покрывается правилом R_j .

Шаги 7.2.1 и 7.2.2 выполняются для всех экземпляров, относящихся к классу i , и на основании получаемых данных увеличивается счётчик $cntMatch$, в котором хранится количество экземпляров, покрываемых правилом R_j .

Шаг 7.3. Проверить условие

$$cntMatch \geq inCntMatchMin_i, \quad (7)$$

где $inCntMatchMin_i$ – предельное минимальное количество экземпляров i -го класса, которое должно покрываться правилом.

Если указанное условие выполняется, то считается, что правило покрывает необходимое количество экземпляров, и j -й агент завершил своё перемещение, выполняется переход к шагу 8. В противном случае – выполняется переход к шагу 5.

Шаг 8. Если $j < cntAgents$, то установить: $j = j + 1$ и выполнить переход к шагу 5. В противном случае – переход к шагу 9.

Шаг 9. Если $i < k$, то установить: $i = i + 1$ и выполнить переход к шагу 4. В противном случае – переход к шагу 10.

Шаг 10. Случайным образом формируются базы правил. Создаётся n баз правил, при этом для описания каждого класса выходного значения выбирается одно правило из соответствующего пространства поиска.

Шаг 11. Оценка качества сформированных баз правил. Для оценки качества баз правил используется входная обучающая выборка, для каждого экземпляра которой выбирается правило с самой высокой степенью совпадения, на основании которого определяется расчётный класс, к которому относится данный экземпляр, основываясь на соответствующей базе правил. Основываясь на данных о классе экземпляров, полученных при помощи базы знаний, и классе экземпляров, исходя из заданной обучающей выборки, рассчитывают оценку качества базы правил:

$$Q = \frac{cntNotMatch}{N}, \quad (8)$$

где $cntNotMatch$ – количество экземпляров, для которых класс был определён неверно с помощью заданной базы правил; Q – качество прогнозирования класса экземпляров на основе соответствующей базы правил.

Шаг 12. Проверить условие

$$Q_{high} \geq Q_{threshold}, \quad (9)$$

где Q_{high} – качество прогнозирования базы знаний, которая характеризуется наилучшей точностью прогнозирования; $Q_{threshold}$ – приемлемое качество прогнозирования.

Если указанное условие выполняется, то производится переход к шагу 17, в противном случае – переход к шагу 13.

Шаг 13. Добавление феромонов. Добавление феромонов выполняется с целью повышения приоритетности тех термов, включение которых в правила способствует повышению качеству прогнозирования результирующих баз правил. В связи с этим количество добавляемого коэффициента приоритетности прямо пропорционально качеству прогнозирования базы правила, в которое входит заданное нечёткое правило. При этом добавление феромонов предлагается выполнять только для тех термов, входящих в правила баз нечётких правил, для которых выполняется условие

$$Q_{\Omega} \geq \delta \cdot Q_{high}, \quad (10)$$

где δ – коэффициент, определяющий, насколько близко качество прогнозирования базы правил Q_{Ω} должно приближаться к лучшему качеству прогнозирования Q_{high} , чтобы можно было применять процедуру добавления феромонов для правил, входящих в данную базу правил Ω .

Таким образом, добавление феромонов выполняется для каждого терма, входящего в правило, которое, в свою очередь, входит в базу правил Ω

$$\tau_p^q(t) = \tau_p^q(t) + Q_{\Omega} \cdot \tau_p^q(t), \quad \forall p \in R, \quad \forall R \subset \Omega,$$

где $\tau_p^q(t)$ – количество феромонов для терма p в пространстве поиска для класса q , который определяется с помощью соответствующего правила.

Шаг 14. Испарение феромонов. Для исключения худших термов, то есть таких, которые при включении их в правила, понижают качество прогнозирования с помощью соответствующего правила, применяют процедуру испарения феромонов, которая выполняется в конце каждой итерации и применяется для всех узлов во всех графах поиска.

Испарение феромонов выполняется в соответствии с формулой

$$\tau_p^q(t+1) = \rho \cdot \tau_p^q(t), \quad p = \overline{1, T}, \quad q = \overline{1, K},$$

где ρ – коэффициент испарения, который задаётся при инициализации.

Шаг 15. Если $t < t_{\max}$, тогда установить: $t = t + 1$ и выполнить переход к шагу 16, в противном случае – считается, что выполнено максимально допустимое количество итераций, и выполняется переход к шагу 17.

Шаг 16. Перезапуск агентов. Все данные о перемещениях агентов обновляются, агенты размещаются в случайные точки пространств поиска. Переход к шагу 3.

Шаг 17. Останов.

Таким образом, можно отметить, что основной особенностью предложенного метода является учёт качества базы правил в целом, а не отдельных правил, за счёт чего, в частности, учитывается взаимное влияние правил при прогнозировании на основе соответствующей базы правил. Также существенной особенностью предложенного метода, по сравнению с традиционным методом, является то, что поиск производится одновременно на нескольких графах поиска, что вызвано необходимостью рассмотрения влияния термов на качество прогнозирования разных классов экземпляров.

Предложенный мультиагентный метод программно реализован в среде пакета Matlab 7.0. Для экспериментов использовались тестовые данные, взятые из общедоступных репозиториях [21]. Рассматривалась выборка, содержащая данные об эхокардиограммах пациентов, у которых когда-либо были сердечные приступы. Выборка содержала данные о 132 пациентах, каждое измерение характеризовалось 12 признаками, а также для каждого пациента указано его состояние (жив он или умер).

Разработанный метод сравнивался с каноническим методом эволюционного поиска [4] и методом, основанном на нечётком дереве принятия решений [5]. На основе проведенных экспериментов были получены базы нечётких правил, которые характеризовались следующей точностью классификации пациентов: 83,2%, 78,6% и 85,6% для метода эволюционного поиска, метода с использованием нечёткого дерева принятия решений и предложенного метода с непрямой связью между агентами, соответственно.

Таким образом, можно сделать вывод, что предложенный метод обеспечивает формирование редуцированной базы нечётких правил, которая характеризуется достаточно точными результатами прогнозирования, сокращая при этом временные затраты на прогнозирование.

Выводы. В статье решена актуальная задача объединения и преобразования нечётких правил. Научная новизна работы заключается в том, что предложен мультиагентный метод с непрямой связью между агентами для объединения и преобразования нечётких правил, позволяющий выполнять объединение нечётких правил во входной выборке, сокращая таким образом размер базы правил. Это ускоряет процесс прогнозирования в экспертных системах, использующих преобразованные нечёткие правила, что достигается за счёт моделирования агентов с использованием непряой связи между ними в разных пространствах поиска для отдельных классов экземпляров. В отличие от известных методов объединения и преобразования нечётких правил, предложенный метод в процессе своей работы ориентирован на оценку качества прогнозирования базы правил в целом, а не отдельных нечётких правил, что позволяет учесть взаимовлияния между правилами, за счёт чего достигается более высокая точность прогнозирования редуцированной базы правил.

Практическая ценность работы заключается в разработке программного обеспечения, позволяющего на основе предложенного мультиагентного метода с непряой связью между агентами выполнять преобразование и объединение нечётких правил входной выборки. Получаемая таким образом сокращённая база нечётких правил может быть использована в экспертных системах нечёткого вывода.

Список литературы: 1. *Zadeh L.* Fuzzy sets / *L. Zadeh* // Information and Control. – 1965. – № 8. – P. 338–353. 2. *Mamdani E.H.* An Experiment in Linguistic Synthesis with Fuzzy Logic Controller / *E.H. Mamdani, S. Assilian* // Int. J. Man-Machine Studies. – 1975. – Vol. 7. – № 1. – P. 1–13. 3. *Bellman R.E.* Decision-Making in Fuzzy Environment / *R.E. Bellman, L.A. Zadeh* // Management Science. – 1970. – № 4. – P. 141–160. 4. *Yuan Y.* Induction of fuzzy decision trees / *Y. Yuan, M. Shaw* // Fuzzy Sets and Systems. – 1995. – № 69. – P. 125–139. 5. *Yuan Y.* A genetic algorithm for generating fuzzy classification rules / *Y. Yuan, H. Zhuang* // Fuzzy Sets and Systems. – 1996. – № 84. – P. 4–19. 6. *Beni G.* Swarm Intelligence / *G. Beni, J. Wang* // Annual Meeting of the Robotics Society: Proceedings of Seventh International Conference. – Tokyo: RSJ Press, 1989. – P. 425–428. 7. *Dorigo M.* Optimization, Learning and Natural Algorithms / *M. Dorigo*. – Milano: Politecnico di Milano, 1992. – 140 p. 8. *Олейник А.А.* Сравнительный анализ методов оптимизации на основе метода муравьиных колоний / *А.А. Олейник* // Комп'ютерне моделювання та інтелектуальні системи: Збірник наукових праць / За ред. Д.М. Пізи, С.О. Субботіна. – Запоріжжя: ЗНТУ, 2007. – С. 147–159. 9. *Sumpter D.J.T.* Formalising the Link between Worker and Society in Honey Bee Colonies / *D.J. Sumpter, D.S. Broomhead* // Lecture Notes In Computer Science: Proceedings of the First International Workshop on Multi-Agent Systems and Agent-Based Simulation // MABS '98 LNAI, 1998. – P. 95–110. 10. *De Castro L.N.* Artificial Immune Systems. Part I. Basic Theory And Applications / *L.N. De Castro, F.J. Von Zuben*. – Technical Report No. Rt Dca 01/99. – Brazil: Feec/Unicamp, 1999. – 95 p. 11. *Subbotin S.A.* PSO with Control of Velocity Change for Feature Selection / *S.A. Subbotin, A.A. Oleynik* // Inductive Modeling: Proceedings of 2nd International Conference ICIM'2008, 15–19 May 2008. – Kyiv, 2008. – P. 81–83. 12. *Lučić P.* Bee System: Modeling Combinatorial Optimization