

Раздел I. Эволюционное моделирование, генетические и бионические алгоритмы

УДК 004.891

Н.А. Полковникова, В.М. Курейчик

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ, НЕЧЁТКАЯ КЛАСТЕРИЗАЦИЯ И ГЕНЕТИЧЕСКИЕ АЛГОРИТМЫ В ЭКСПЕРТНОЙ СИСТЕМЕ*

Показана разработка модели нечёткой экспертной системы для идентификации неисправностей сложных технических объектов с применением технологий интеллектуального анализа данных, основанных на поиске в базах данных скрытых закономерностей. Применение нейросетевых технологий позволяет обнаруживать нелинейные зависимости входных и выходных данных, повысить качество процесса диагностики объекта, что в конечном итоге позволит снизить количество аварийных ситуаций в условиях эксплуатации. Предложен способ выделения оптимального числа нечетких кластеров в пространстве обучающих примеров и определения на их основе параметров функций принадлежности для входных переменных и результатов вывода. Рассмотрен нейро-нечёткий алгоритм кластеризации многомерных объектов в условиях неполноты и нечеткости исходной информации. Внедрение нейросетевых технологий в экспертную систему при решении задач диагностики позволит не только фиксировать показания датчиков и сравнивать их с эталонными значениями, но и производить комплексный анализ получаемых параметров объекта, прогнозируя возможность наступления сбоев в работе, как отдельных элементов, так и системы в целом. Архитектура такой экспертной системы позволяет перейти от обычного мониторинга к «информационному мониторингу» в специализированных человеко-машинных интеллектуальных системах.

Экспертная система; база знаний; нечёткая логика; лингвистическая переменная; кластеризация; генетические алгоритмы; нейронные сети.

N.A. Polkovnikova, V.M. Kureichik

NEURAL NETWORK TECHNOLOGIES, FUZZY CLUSTERING AND GENETIC ALGORITHMS IN EXPERT SYSTEM

The paper shows the development of fuzzy expert system model for fault identification of complex technical objects using data mining technology based on searching hidden patterns in database. Data mining technology allows optimizing database processing queries that retrieve the required information from the actual data in order to detect important patterns. Application of neural network technology allows to detect nonlinear dependencies of input and output data, to improve quality of object diagnostic process, which ultimately will reduce the number of accidents in operation. A method for allocating the optimal number of fuzzy clusters in the space of training examples and deducing the parameters of membership functions for input variables and output results is proposed. Considered a neuro-fuzzy clustering algorithm for multidimensional objects with incomplete and fuzzy initial information. Implementation of neural network technologies in an expert system for solving diagnosis problems will allow not only fixing the sensor readings and compare them with the reference values, but also produce a comprehensive analysis of the obtained parameters of object, predicting the possibility of failure occurrence as in separate elements, and in system overall. The architecture of such expert system allows moving from normal monitoring to «information monitoring» in the specialized intelligent human-machine systems.

Expert system; knowledge base; fuzzy logic; linguistic variable; clustering; genetic algorithms; neural networks.

* Работа выполнена при частичной поддержке РФФИ (проект № 12–07–00062).

Введение. В процессе эксплуатации сложных технических объектов, как при управлении, так и при поиске причин нарушения работоспособности обслуживающий персонал вырабатывает решения на основе поступающей информации. В связи с постоянным увеличением в ходе комплексной автоматизации объёма контролируемых параметров, обеспечению надёжной работы, оператор испытывает всё большие трудности при анализе поступающей информации. Это особенно проявляется при необходимости оперативного принятия решений в нестандартных ситуациях. Как следствие, более 70 % аварийных ситуаций возникает из-за ошибок операторов. Поэтому важность и актуальность приобретает разработка и внедрение интеллектуальных экспертных систем (ЭС), которые позволяют эффективно использовать результаты мониторинга и автоматизировать процедуры решения эксплуатационных задач с выдачей рекомендаций обслуживающему персоналу.

Как правило, объекты автоматизации характеризуются слабоформализуемыми зависимостями входных и выходных данных, поэтому построить четкую математическую модель таких объектов не всегда возможно. Для решения задачи описания свойств объекта управления необходима разработка интеллектуальных моделей, воспроизводящих логику рассуждения лица, принимающего решение (ЛПР), основой которых является база знаний (БЗ). Основной трудностью при применении нечёткой логики в ЭС является необходимость явно сформулировать правила проблемной области в форме продукций. Решением этой проблемы является применение нейронных сетей, преимущество которых заключается в возможности автоматического переноса знаний ЛПР в базу знаний ЭС. Недостатком современных систем мониторинга является невозможность определить начальную стадию возникновения неисправности объекта. Внедрение нейросетевых технологий в ЭС при решении задач диагностики позволит не только сравнивать контролируемые параметры с их эталонными значениями, но и прогнозировать возможность наступления сбоев, как отдельных элементов, так и объекта в целом [1, 2].

Гибридные технологии сочетают преимущества нечётких систем и нейронных сетей. Примером гибридной технологии служит реализация системы нечётких правил на основе нейросети [3]. Нечёткие ЭС используют представление знаний в форме нечётких продукций и лингвистических переменных. Основу лингвистической переменной составляет терм с функцией принадлежности. Способ обработки знаний в нечётких ЭС – это логический вывод по нечётким продукциям. Использование аппарата нечёткой логики при разработке БЗ и механизмов вывода ЭС позволяет формализовать процедуру оценки технического состояния на базе фрагментарной, ненадёжной и возможно неточной информации и обоснованно принимать решения по идентификации неисправностей. База знаний гибридной ЭС содержит следующие компоненты: функции принадлежности, нечёткие продукции, обученные нечёткие нейронные сети, процедуры интерпретации хромосом генетических алгоритмов, функции оптимальности. Ретроспективная информация, хранящаяся в базах данных, служит основой для прогнозирования с помощью нейронных сетей. При нахождении шаблонов, адекватно отражающих динамику поведения входных параметров, есть вероятность, что с их помощью можно успешно прогнозировать поведение объекта.

В настоящей работе использование нечёткой логики и нейросетевых технологий показано на примере разработки ЭС при решении задач диагностики главного судового дизельного двигателя. На рис. 1 представлена разработанная структурная схема гибридной ЭС. На этапе фаззификации значения входных параметров в виде N-мерного входного вектора $x = [x_1, x_2, \dots, x_n]^T$ приводятся в нечёткое множество \tilde{A} в соответствии с их лингвистической оценкой и последующим выбором закона изменения функции принадлежности $\mu_A(x)$.

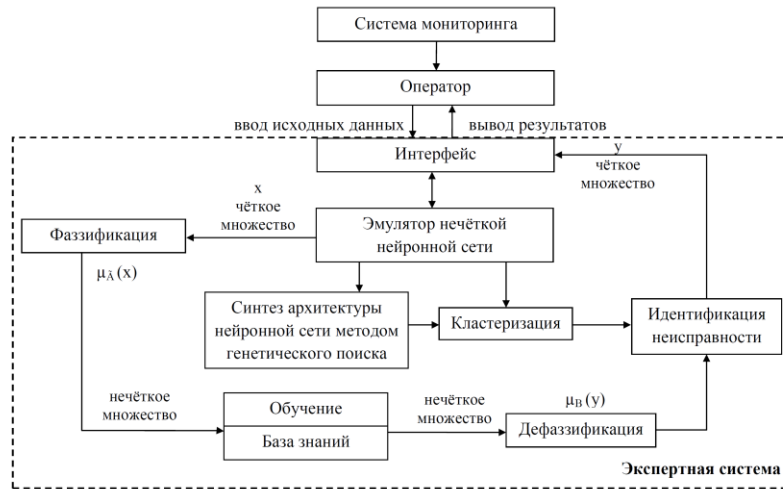


Рис. 1. Структурная схема экспертной системы

Фаззификация входных параметров. Процесс задания нечёткого множества на основе известного значения признака называется фаззификацией или приведением к нечёткости. Фаззификация позволяет представить объективно присутствующую неточность результатов физических измерений. При разработке базы знаний ЭС для главного судового двигателя были использованы результаты индцирования, которые преобразованы в три диапазона изменения входных значений параметров соответственно для трёх лингвистических переменных: низкое, нормальное, высокое.

Дефаззификация. Дефаззификатор трансформирует нечёткое множество в полностью детерминированное точечное решение y . Нечёткое множество представляет зависимость $\mu(y) = \mu_{A \rightarrow B}(y)$ как функцию от выходной переменной y . Результат $\mu(y)$ состоит из суммы нечётких функций для импликации всех M правил, образующих систему нечёткого вывода.

Разработка структуры нейронной сети по нечёткой адаптивной системе логического вывода Такаги-Сугено-Канга (TSK) для идентификации неисправностей была произведена с помощью ANFIS (ANFIS – Adaptive Network Based Fuzzy Inference System – адаптивная сеть нечеткого вывода) сети. Количество входных и выходных переменных определяется так же, как и при построении системы нечёткого вывода типа Мамдани-Заде. В этой системе функция заключения определяется нечётким точечным образом. Благодаря этому дефаззификатор на выходе системы не требуется, а система логического вывода значительно упрощается [4, 5]. Обобщённую схему вывода TSK нулевого порядка при использовании M правил и N переменных x_N представим в виде:

ЕСЛИ $(x_1 \text{ ЭТО } A_1) \text{ И } (x_2 \text{ ЭТО } A_2) \text{ И } \dots \text{ И } (x_N \text{ ЭТО } A_N) \text{ ТОГДА } y_M = k_M, (1)$
 где A_1, A_2, \dots, A_N – нечёткие множества антецедента; k – заданная константа.

Условие $(x_N \text{ IS } A_N)$ реализуется функцией фаззификации, которая представляется обобщённой трапецидальной функцией отдельно для каждой переменной x_N .

Вторая система – нечёткий логический вывод TSK первого порядка. Принципиальное отличие касается заключения, которое представляется в виде формы функциональной зависимости. Классическое представление этой функции, чаще всего используемое на практике – это полином первого порядка. Обобщённую схему вывода в модели TSK первого порядка при использовании M правил и N переменных x_N можно представить в виде:

ЕСЛИ $(x_1$ ЭТО $A_1)$ И $(x_2$ ЭТО $A_2)$ И ... И $(x_N$ ЭТО $A_N)$ ТОГДА

$$y_M = p_{M0} + \sum_{j=1}^N p_{Mj} x_j, \quad (2)$$

где p_{MN} – это цифровые веса, подбираемые в процессе адаптации (обучения).

Формализация базы знаний. Принципиально БЗ можно построить, используя либо нечеткий логический вывод Мамдани-Заде, либо вывод TSK. Отличие базы знаний TSK от Мамдани-Заде заключается в том, что заключения правил задаются не нечеткими термами, а функцией от входов. Однако, БЗ Мамдани-Заде можно построить, прибегнув к знаниям ЛПР, а БЗ TSK целесообразно использовать в случае отсутствия у оператора (ЛПР) необходимых знаний об объекте.

Построение нечеткой системы TSK выполняется в два этапа. На первом этапе синтезируются нечеткие правила из экспериментальных данных с использованием кластеризации. С помощью кластеризации нейронная сеть самостоятельно выделяет различные однородные неисправности в группы (кластеры) на основе схожести признаков.

Кластеризация. Кластеризация необходима для сокращения объема информации и области поиска, что позволяет сократить время для идентификации неисправности, а так же учёта динамики изменения результатов индицирования двигателя во времени. Для нейронной сети был выбран FCM-алгоритм (Fuzzy Classifier Means, Fuzzy C-Means) нечеткой кластеризации. Кластеры представляют собой нечеткие множества с нечеткими границами между ними. Исходной информацией для кластеризации является матрица значений параметров полученных по результатам индицирования главного двигателя. Каждая строка матрицы представляет собой значения N диагностируемых неисправностей одного индицирования из M параметров кластеризации. В общем случае, описание нечетких кластеров может быть представлено следующей матрицей нечеткого разбиения:

$$F = \{\mu_{ij}\}_{M \times N}, (i = \overline{1, M}, j = \overline{1, N}), \quad (3)$$

$$F = \begin{bmatrix} \mu_{11} & \mu_{12} & \dots & \mu_{1n} \\ \mu_{21} & \mu_{22} & \dots & \mu_{2n} \\ \dots & \dots & \dots & \dots \\ \mu_{m1} & \mu_{m2} & \dots & \mu_{mn} \end{bmatrix}, \quad (4)$$

где $\mu_{ij} \in [0, 1]$ – степень принадлежности объекта $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$ к кластеру C_j . Матрица F должна обладать следующими свойствами:

- 1) каждый объект должен быть распределён между всеми кластерами

$$\forall i = \overline{1, M} \left(\sum_{j=1, N} \mu_{ij} = 1 \right), \quad (5)$$

- 2) ни один кластер не должен быть пустым или содержать все элементы

$$\forall j = \overline{1, N} \left(0 < \sum_{i=1}^M \mu_{ij} < N \right). \quad (6)$$

Результат кластеризации представлен на рис. 2.

FCM-алгоритм нечетких состоит в итеративном изменении матриц F и вектора центров кластеров с целью минимизации критерия разброса:

$$\lambda = \sum_{i=1}^C \sum_{j=1}^N (\mu_{ij})^m \cdot \|v_j - x_i\|^2 \rightarrow \min, \quad (7)$$

где v_j – центры нечётких кластеров; $m \in [1, \infty)$ – экспоненциальный вес, определяющий нечёткость (размытость) кластеров. В качестве нормы $\|\cdot\|$ применяется матричная норма Евклида, $\|v_j - x_i\|^2$ – Евклидово расстояние между j -м центром кластера v_j и i -м объектом x_i .

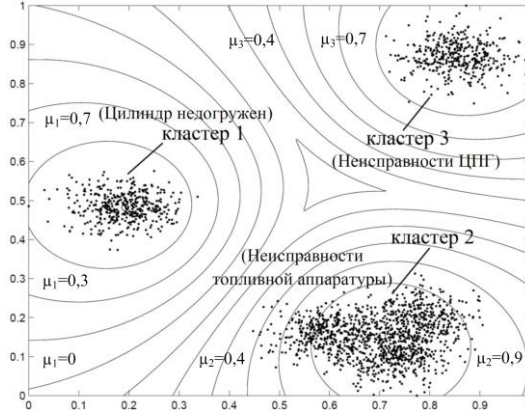


Рис. 2. Результат кластеризации с помощью FCM-алгоритма для идентификации неисправностей цилиндра с указанием областей со степенями принадлежности

Главным недостатком данного алгоритма кластеризации является тот факт, что все кластеры имеют форму гиперсферы, которая может не соответствовать действительности и даже приводить к некорректному разбиению исходных данных на кластеры [6, 7]. Одним из методов решения задачи кластеризации могут служить генетические алгоритмы (ГА).

Генетические алгоритмы. Применение ГА позволяет учесть особенности пространства поиска за счёт настройки параметров и определить более точное положение центров кластеров и, следовательно, улучшить результаты работы алгоритма нечёткой кластеризации [8]. При реализации ГА в алгоритме кластеризации для заданного количества кластеров c хромосома может быть закодирована координатами центров всех кластеров (рис. 3). При кодировании хромосомы центрами кластеров длина хромосомы равна $c \cdot q$, где c – количество кластеров, q – количество критериев: первые q координат соответствуют центру первого кластера, вторые q координат – центру второго кластера и т.п.



Рис. 3. Кодирование хромосом координатами центров кластеров

Каждая хромосома оценивается мерой её «приспособленности» (fitness function). «Приспособленность» для каждой хромосомы определяется суммой евклидовых расстояний от каждого результата индицирования до центра соответствующего кластера:

$$f = \sum_{j=1}^m \sqrt{\sum_{i=1}^c (v_q^c - v_j^i)^2}, \quad (8)$$

где j – количество результатов индицирования; c – количество кластеров; v_q^c – координата центра c -го кластера; v_j^i – координата j -го результата индицирования.

Реализация ГА без использования FCM-алгоритма оказывается менее эффективной, так как результаты кластеризации будут существенно зависеть от того, насколько хорошо выполнена инициализация центров кластеров [9–12].

Нейронная сеть. На втором этапе построения нечеткой модели TSK настраиваются параметры нечеткой модели с помощью ANFIS-алгоритма. ANFIS является гибридной нейро-нечеткой системой нечеткого вывода TSK нулевого или первого порядка в виде пятислойной нейронной сети прямого распространения сигнала. Архитектура ANFIS-сети изоморфна нечеткой БЗ и имеет единственный выход с несколькими входами, термы которых представляют собой нечёткие лингвистические переменные [13, 14]. Входы сети в отдельный слой не выделяются. На рис. 4 представлена разработанная нейронная ANFIS-сеть для идентификации 5 состояний (кластеров): неисправность ЦПГ, цилиндр перегружен, цилиндр недогружен, неисправность топливной аппаратуры и норма. Задача нейронной сети состоит в определении по входному вектору $P_{mi}, P_{max}, P_{exp}, t_{\Gamma}, FP_{max}$ принадлежности значений к кластеру через выходную функцию сети y .

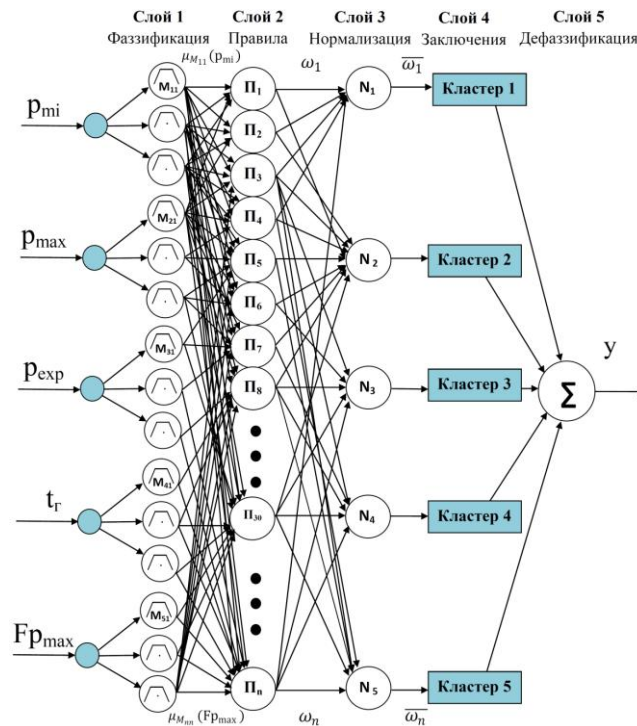


Рис. 4. Структура адаптивной нейро-нечёткой ANFIS-сети для идентификации пяти видов кластеров (неисправностей)

Назначение слоев следующее:

1) первый слой – термы входных переменных. Каждый узел первого слоя представляет один терм с трапециевидной функцией принадлежности. На данном слое происходит вычисление значений функций принадлежности

$$\mu_{M_{nn}}^{(k)}(P_{mi}, P_{max}, P_{exp}, t_{\tau}, FP_{max}), \quad (9)$$

определяя для каждого k-го правила вывода значение коэффициента принадлежности в соответствии с применяемой функцией фаззификации.

2) второй слой – antecedentes (посылки) нечетких правил. Выходом узла является степень выполнения правила, которая рассчитывается как произведение входных сигналов;

3) третий слой – нормализация степеней выполнения правил;

4) четвертый слой – заключения правил, формирует значения взвешенных компонент выхода n-го кластера (Φ_n):

$$\bar{\omega}_n \Phi_n = \bar{\omega}_n (c_{i1} P_{mi} + c_{i2} P_{max} + c_{i3} P_{exp} + c_{i4} t_{\tau} + c_{i5} FP_{max}); \quad (10)$$

5) пятый слой – агрегирование результата, полученного по различным правилам. Единственный нейрон этого слоя реализует операцию дефаззификации. Разработанная нейронная сеть позволяет идентифицировать неисправности с различными степенями принадлежности.

Заключение. В работе показана реализация гибридной ЭС для идентификации неисправностей главного судового дизельного двигателя. Для описания неопределенности использован аппарат нечетких множеств как сочетание нечеткой логики, нейронных сетей и ГА, что наделяет ЭС следующими преимуществами: управление неопределенностью, обучаемость, самоадаптация. Разработанные методы, модели и алгоритмы для ЭС позволяют обеспечить высокую обоснованность и адекватность принятия решения в условиях неопределенности и неточности исходной информации, а так же минимизировать временные и финансовые затраты, связанные с необходимостью сбора точных и полных исходных данных.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Полковникова Н.А., Курейчик В.М. Разработка модели экспертной системы на основе нечеткой логики // Известия ЮФУ. Технические науки. – 2014. – № 1 (150). – С. 83-92.
2. Полковникова Н.А., Курейчик В.М. Об интеллектуальном анализе баз данных для экспертной системы // Информатика, вычислительная техника и инженерное образование. – 2013. – № 2 (13). – С. 39-50.
3. Ярушкина Н.Г. Основы теории нечетких и гибридных систем: Учеб. пособие. – М.: Финансы и статистика, 2004. – 320 с.
4. Силич В.А., Силич М.П., Аксёнов С.В. Алгоритм построения нечеткой системы логического вывода Мамдани, основанный на анализе плотности обучающих примеров // Управление, вычислительная техника и информатика. Доклады Томского государственного университета систем управления и радиоэлектроники. – 2013. – № 3 (29). – С. 76-82.
5. Алтухов А.В. Формирование нечетких правил типа Takagi-Sugeno по результатам нечеткой кластеризации // Вестник ВГУ: Системный анализ и информационные технологии. – 2008. – № 1. – С. 44-50.
6. Ярушкина Н.Г., Чекина А.В. Кластеризация информационных ресурсов на основе генетического алгоритма // Автоматизация процессов управления. – 2010. – № 4. – С. 66-71.
7. Демидова Л.А., Коняева Е.И. Кластеризация объектов с использованием FCM-алгоритма на основе нечетких множеств второго типа и генетического алгоритма // Вестник РГРТУ. – 2008. – № 4 (26). – С. 46-54.
8. Демидова Л. А., Титов С.Б. Подход к проблеме нечеткой кластеризации в условиях неопределенности выбора целевой функции // Вестник РГРТУ. – 2009. – № 3 (29). – С. 54-60.
9. Гладков Л.А., Курейчик В.В., Курейчик В.М., Сороколетов П.В. Биоинспирированные методы в оптимизации. – М.: Издательская фирма "Физико-математическая литература", 2009. – 381 с.

10. Wang Y. Fuzzy clustering analysis by using genetic algorithm // *ICIC Express letters*. – 2008. – Vol. 2, № 4. – P. 331-337.
11. Maulik U., Bandyopadhyay S. Genetic algorithm-based clustering technique // *Pattern recognition*. – 2000. – № 33. – P. 1455-1465.
12. Mukhopadhyay A., Maulik U., Bandyopadhyay S. Multiobjective genetic algorithm-based fuzzy clustering of categorical attributes // *IEEE transactions on evolutionary computation*. – 2009. – Vol. 13, № 5. – P. 991-1005.
13. Shi Y., Mizumoto M. An improvement of neuro-fuzzy learning algorithm for tuning fuzzy rules // *Fuzzy sets and systems*. – 2001. – Vol. 118, № 2. – P. 339-350.
14. Zou K., Hu J., Kong X. The structure optimized fuzzy clustering neural network model and its application // *International journal of innovative computing: information and control*. – 2008. – Vol. 4, № 7. – P. 1627-1634.

REFERENCES

1. Polkovnikova N.A., Kureichik V.M. Razrabotka modeli ekspertnoy sistemy na osnove nechetkoy logiki [Development of an expert system model based on fuzzy logic], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2014, No. 1 (150), pp. 83-92.
2. Polkovnikova N.A., Kureichik V.M. Ob intellektualnom analize baz dannykh dlya ekspertnoy sistemy [Intellectual analysis of the data bases for expert systems], *Informatika, vychislitel'naya tekhnika i inzhenernoe obrazovanie* [Computer science and engineering education], 2013, No. 2 (13), pp. 39-50.
3. Yarushkina N.G. Osnovy teorii nechetkikh i gibridnykh sistem: Ucheb. posobie [Fundamentals of the theory of fuzzy and hybrid systems: textbook]. Moscow: Finansy i statistika, 2004, 320 p.
4. Silich V.A., Silich M.P., Aksenov S.V. Algoritm postroeniya nechetkoy sistemy logicheskogo vyvoda Mamdani, osnovanny na analize plotnosti obuchayushchikh primerov [The algorithm of construction of fuzzy system logical conclusion Mamdani, based on the analysis of the density of training examples], *Upravlenie, vychislitel'naya tekhnika i informatika. Doklady Tomskogo gosudarstvennogo universiteta sistem upravleniya i radioelektroniki* [Management, computer engineering and Informatics. The presentations of Tomsk state University of control systems and Radioelectronics], 2013, No. 3 (29), pp. 76-82.
5. Altukhov A.V. Formirovanie nechetkikh pravil tipa Takagi-Sugeno po rezultatam nechetkoi klasterizatsii [The formation of fuzzy rules of the type Takagi-Sugeno on the results of fuzzy clustering], *Vestnik VGU: Sistemnyy analiz i informatsionnye tekhnologii* [Herald of the Voronezh state University: System analysis and information technologies], 2008, No. 1, pp. 44-50.
6. Yarushkina N.G., Chekina A.V. Klasterizatsiya informatsionnykh resursov na osnove geneticheskogo algoritma [Clustering of information resources based on genetic algorithm], *Avtomatizatsiya processov upravleniya* [Automation of Management Processes], 2010, No. 4, pp. 66-71.
7. Demidova L.A., Konyaeva E.I. Klasterizatsiya obektov s ispolzovaniem FCM-algoritma na osnove nechetkikh mnozhestv vtorogo tipa i geneticheskogo algoritma [Clustering of objects using FCM algorithm based on fuzzy sets of the second type and genetic algorithm], *Vestnik RGRU* [Herald Ryazan State Radio University], 2008, No. 4 (26), pp. 46-54.
8. Demidova L.A., Titov S.B. Podkhod k probleme nechetkoy klasterizatsii v usloviyakh neopredelennosti vybora tselevoy funktsii [Approach to the problem of fuzzy clustering in conditions of uncertainty of the choice of target functions], *Vestnik RGRU* [Herald Ryazan State Radio University], 2009, No. 3 (29), pp. 54-60.
9. Gladkov L.A., Kureychik V.V., Kureychik V.M., Sorokoletov P.V. Bioinspirirovannye metody v optimizatsii [Bioinspiration methods in optimization]. Moscow: Izdatelskaya firma "Fiziko-matematicheskaya literatura", 2009, 381 p.
10. Wang Y. Fuzzy clustering analysis by using genetic algorithm, *ICIC Express letters*, 2008. Vol. 2, No. 4, pp. 331-337.
11. Maulik U., Bandyopadhyay S. Genetic algorithm-based clustering technique, *Pattern recognition*, 2000, No. 33, pp. 1455-1465.
12. Mukhopadhyay A., Maulik U., Bandyopadhyay S. Multiobjective genetic algorithm-based fuzzy clustering of categorical attributes, 2009, Vol. 13, No. 5, pp. 991-1005.

13. Shi Y., Mizumoto M. An improvement of neuro-fuzzy learning algorithm for tuning fuzzy rules, *Fuzzy sets and systems*, 2001, Vol. 118, No. 2, pp. 339-350.
14. Zou K., Hu J., Kong X. The structure optimized fuzzy clustering neural network model and its application, *International journal of innovative computing: information and control*, 2008, Vol. 4, No. 7, pp. 1627-1634.

Статью рекомендовал к опубликованию д.т.н., профессор Я.Е. Ромм.

Полковникова Наталья Анатольевна – Южный федеральный университет; e-mail: natalia-polkovnikova@mail.ru; 347928, г. Таганрог, пер. Некрасовский, 44; тел.: +79525617317; кафедра дискретной математики и методов оптимизации; аспирантка.

Курейчик Виктор Михайлович – e-mail: kur@tgn.sfedu.ru; тел.: +78634311487; кафедра дискретной математики и методов оптимизации; зав. кафедрой; д.т.н.; профессор.

Polkovnikova Natalia Anatolievna – Southern Federal University; e-mail: natalia-polkovnikova@mail.ru; 44, Nekrasovskiy, Taganrog, 347928, Russia; phone: +79525617317; the department of discrete mathematics and optimization methods; postgraduate student.

Kureichik Victor Mikhailovich – e-mail: kur@tgn.sfedu.ru; phone: +78634393260; the department of discrete mathematics and optimization methods; head of department; dr. of eng. sc.; professor.

УДК 004.82

Э.В. Кулиев, А.А. Лежебоков, А.Н. Дуккардт

ПОДХОД К ИССЛЕДОВАНИЮ ОКРЕСТНОСТЕЙ В РОЕВЫХ АЛГОРИТМАХ ДЛЯ РЕШЕНИЯ ОПТИМИЗАЦИОННЫХ ЗАДАЧ*

Рассмотрена ключевая проблема роевых алгоритмов и биоинспирированного подхода, которая заключается в определении функции близости решений и исследовании возникающих окрестностей для решения задач оптимизации. Подробно рассмотрена одна из важнейших задач этапа конструкторского проектирования, а именно задача размещения компонентов сверхбольших интегральных схем, качество решения которой напрямую влияет на качество трассировки схем и их тепловых, временных, энергетических характеристик. Решение поставленной проблемы окрестностей и близости решений внутри них продемонстрировано на примере их исследования гибридными методами поиска решений. Представлена методика поиска окрестностей в роевом алгоритме, на основе принципов самоорганизации и жадного подхода. Важным механизмом в работе алгоритма колонии пчел является исследование перспективных решений и позиций их окрестностей в пространстве решений. Авторами предлагается новый принцип формирования окрестности позиций в пространстве решений, для этого используется понятие окрестности в круговом пространстве поиска. Рассмотрен биоинспирированный подход к исследованию окрестности поиска решений. Основная идея данного подхода заключается в последовательной работе генетического и эволюционного алгоритмов. В методе биоинспирированного поиска оптимальных решений авторами предложен адаптивный фильтр, отсекающий решения с низким значением целевой функции. Проведены экспериментальные исследования, подтверждающие, что вычислительная и временная сложность разработанного подхода не выходит за пределы полиномиальной зависимости. Результаты исследований позволили авторам отметить, что в генетическом алгоритме в большей степени имеет место фактор случайности, а в эволюционном алгоритме фактор направленности.

Роевой алгоритм; генетический алгоритм; эволюционный алгоритм; «жадный» оператор; адаптация; окрестность; популяция.

* Работа выполнена при частичной поддержке РФФИ (проект № 14-07-00829).