

УДК 004.891.3

М.Г. Ткаченко**ПРИМЕНЕНИЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ,
ОПТИМИЗИРОВАННОЙ ГЕНЕТИЧЕСКИМ АЛГОРИТМОМ, В ЗАДАЧЕ
АНАЛИЗА СОСТОЯНИЯ ТЕХНОЛОГИЧЕСКОГО ОБОРУДОВАНИЯ
НЕФТЕГАЗОДОБЫВАЮЩЕЙ ПРОМЫШЛЕННОСТИ**

Одной из актуальных проблем нефтегазодобывающих предприятий является повышение эффективности работы технологического оборудования за счет внедрения инновационных технологий оперативного анализа и диагностики. Наибольшую эффективность в данной области имеют системы, построенные с применением подходов DataMining и мягких вычислений. В работе представлена модель, основанная на применении искусственной нейронной сети (ИНС) обратного распространения, оптимизированной с помощью генетического алгоритма (ГА). Применение ГА позволило оптимизировать процесс вычисления параметров ИНС, сократить время обучения, улучшить результаты нейросетевого анализа технологических процессов. Анализ результатов моделирования предложенного метода в задаче оперативного анализа состояния технологических объектов нефтегазодобывающей отрасли свидетельствуют, что метод может эффективно решать такие проблемы нейросетевых подходов, как недостаточная точность получаемых оценок, затрудненный выбор параметров сети, и длительное время обучения. Практическое применение ИНС ГА позволило существенно улучшить точность прогнозных оценок состояния погружного оборудования для нефтедобывающего комплекса.

Нейронная сеть; генетические алгоритмы; мягкие вычисления.

M.G. Tkachenko**APPLICATION OF ARTIFICIAL NEURAL NETWORKS OPTIMIZED
BY GENETIC ALGORITHM FOR EQUIPMENT STATE ANALYSIS
IN OIL AND GAS INDUSTRY**

One of actual problems of oil and gas extraction enterprises is increase of equipment overall performance due to introduction of innovative technologies of the operational analysis and diagnostics. The systems constructed with application of approaches of Data mining and soft computing in the field have the greatest efficiency. The paper is devoted to model based on back-propagation artificial neural network, which is optimized by genetic algorithm. Application of genetic algorithm allows optimize network parameters calculation, decrease learning time and improve the results of the analysis process. The simulation results of the offered method in the operational analysis of technological objects condition in oil and gas extraction branch show that the proposed method can solve such problems of neural network approaches as lack of accuracy, network parameters choice difficulties, and training time. Practical application of genetic algorithm to artificial neural network has significantly improved the accuracy of predictive assessments of submersible equipment for oil industry.

Neural network; genetic algorithms; soft computing.

Введение. Основными задачами, решаемыми предприятиями нефтегазовой отрасли, являются снижение себестоимости и увеличение объемов извлекаемой продукции. Для решения этих задач важным фактором является снижение простоев, вызванных необходимостью оперативного ремонта высоконагруженного добывающего оборудования. Контроль, анализ состояния оборудования, и принятие решений по организации ремонтно-восстановительных работ возлагается на технологов нефтегазодобывающих управлений, отслеживающих состояние добывающих установок на основе многопараметрических замеров, поступающих от датчиков станций управления нефтедобычи.

Несмотря на наличие вспомогательных систем автоматического информирования, основанных на проверке по жестким правилам «если-то», значительная часть работ по оперативному анализу состояния оборудования возлагается на экспертов-технологов. Ошибочные решения технологов могут существенно снизить эффективность ремонтных работ и увеличить время, требуемое на восстановление штатных параметров работы добывающего оборудования. В работе поставлена задача разработки метода диагностики состояния погружного оборудования, обеспечивающего высокую скорость и точность получаемых оценок.

Решение поставленной задачи основано на применении технологии мягких вычислений. Мягкие вычисления – это современная концепция, основное направление развития которой сосредоточено в области управления технологическими процессами, анализа состояния производственных объектов, а также обнаружения аварийных и предаварийных состояний [1]. Основанные на анализе параметров процесса, используя нейросетевые подходы, нечеткую логику, эволюционное моделирование и сочетания этих подходов, мягкие вычисления позволяют получать оценочные характеристики технологических процессов при испытании и в условиях промышленного внедрения.

Для того чтобы уменьшить сложность и стоимость работ по восстановлению последствий аварий, в стране и за рубежом проводятся исследования применения интеллектуальных методов для оперативного анализа и прогнозирования состояния технологических объектов [2–7]. Однако практическое внедрение подобных систем по-прежнему не имеет широкого распространения из-за недостаточной точности получаемых оценок [8–10].

В данной работе, путем применения технологии мягких вычислений, а именно сочетания ИНС и ГА, разработан метод оперативного анализа состояния погружных установок электроцентробежных насосов нефтегазодобывающей отрасли на основе обработки телеметрических данных, поступающих со станций управления.

Применение метода ГА для выбора параметров модели ИНС обратного распространения позволило преодолеть проблемы длительного времени обучения и недостаточной точности получаемых оценок состояния погружного оборудования в задаче анализа технологических процессов нефтедобывающего предприятия [5–7].

Эффективность предложенного метода подтверждается результатами моделирования на телеметрических данных производственного процесса. Результаты моделирования свидетельствуют, что расчетные значения модели, основанной на НС ГА, соответствуют фактическим характеристикам процессов нефтедобычи.

Принцип мягких вычислений. Технология мягких вычисления является по существу подходом моделирования на основе оценки параметров технологических процессов, которые доступны для измерения комплексами оперативного мониторинга состояния оборудования [11–13]. Реализация моделей включает в себя выбор параметров, сбор и предварительную обработку данных, а также построение модели процесса.

При мягких вычислениях такие факторы, как размерности, число и точность измерений, а также начальные значения вспомогательных переменных модели и особенности предварительной обработки данных могут серьезно влиять на результат моделирования. Предварительная обработка и преобразование входных данных требуется для повышения точности моделирования. Это связано с тем, что незначительная ошибка замеров (в частности, сбой показаний датчиков или обрывы линий связи), пропущенная на этапе формирования мягкой модели процесса, может привести к значительным отклонениям значений выходных параметров модели. В работе данные, получаемые от установок телеметрии, преобразуются, а

после нормализации и других, связанных с обработкой данных процессов, передаются нейронной сети, реализующей вычисления оценки технического состояния добывающего оборудования. Ключевым моментом всей системы является точность построения нейросетевой модели, которая имеет непосредственное влияние на точность построения оперативной оценки и прогноза состояния технологического оборудования.

Основы теории искусственных нейронных сетей обратного распространения (ИНС ОР). ИНС ОР представляет собой многослойную нейронную сеть с прямой связью, характеризуемой прямым распространением сигнала и обратным направлением распространением ошибки [13, 14]. При прямом распространении, сигнал передается из входного слоя в скрытые до достижения выходного слоя. Если выходной слой не выдает ожидаемого результата, в обратном направлении распространяется сигнал ошибки, и настраиваются сетевые веса и пороги срабатывания в соответствии с ошибкой прогнозирования.

ИНС ОР может строить точные оценки после обучения сети. Процесс обучения сети включает следующие шаги:

Шаг 1: инициализация сети. В соответствии с входным и выходным последовательностями задаются числа узлов во входном слое n , число узлов в скрытом слое, число узлов в выходном слое m . Задаются первоначальные веса связей нейронов между входами скрытым слоем ω_{ij} , скрытым и выходным слоем ω_{jk} , инициализация порог активации скрытого слоя a , порог активации выходного слоя b . Задается скорость обучения τ и функция возбуждения нейронов.

Шаг 2: расчет выхода скрытого слоя H в соответствии с входным вектором x , матрицей связей ω , порогом срабатывания скрытого слоя a .

$$H_j = f\left(\sum_{i=1}^n \omega_{ij} x_i - a_i\right), \quad j = 1, 2, \dots, l. \quad (1)$$

В формуле (1) f – функция возбуждения; в работе использована сигмоидальная функция.

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2)$$

Шаг 3: расчет значений выходного вектора O в соответствии со значением выхода скрытого слоя H , весами ω и пороговым значением b .

$$O_k = \sum_{j=1}^l \omega_{jk} H_j - b_j, \quad k = 1, 2, \dots, m. \quad (3)$$

Шаг 4: расчет ошибки в соответствии с выходом O , и требуемым выходом Y .

$$e_k = Y_k - O_k, \quad k = 1, 2, \dots, m. \quad (4)$$

Шаг 5: обновление весов ω согласно ошибке прогнозирования e .

$$\omega_{ij} = \omega_{ij} + \tau H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, l \quad (5)$$

$$\omega_{jk} = \omega_{jk} + \tau H_j e_k, \quad j = 1, 2, \dots, l; \quad k = 1, 2, \dots, m \quad (6)$$

Шаг 6: обновление порогов срабатывания a, b в соответствии с ошибкой предсказания e .

$$a_j = a_j + \tau H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k, \quad j = 1, 2, \dots, l \quad (7)$$

$$b_k = b_k + e_k, \quad k = 1, 2, \dots, m \quad (8)$$

Шаг 7: производится оценка результатов обучения, определяется, завершено ли обучение, если нет, перейти к шагу 2.

Теория НС ГА. Генетические алгоритмы являются универсальным алгоритмом оптимизации на основе принципа биологической эволюции. В соответствии с функцией приспособленности (фитинга) производится генетический отбор, кроссовер и мутация единичных особей популяции; значение ценных экземпляров сохраняются, минимальные различия индивидуальных признаков устраняется, новое поколение не только наследует информацию о группе, но и становится лучше, чем предыдущие [11–13]. Этот цикл повторяется, пока условие оптимизации не будет выполнено.

Алгоритм применения ГА для оптимизации нейронной сети показан на рис. 1. Последовательность действия включает три этапа. На первом определяются структуры нейронной сети в соответствии с числом входных и выходных параметров, задается метод отображения особи для генетического алгоритма. Второй этап использует генетические алгоритмы для оптимизации нейронных весов и порогов сети, производится расчет индивидуального значения функции приспособленности, и поиск лучших особей, выполняются генетические операции скрещивания и мутации. Выходом алгоритма является нейронная сеть, построенная с использованием генетических алгоритмов для получения оптимальных весов сети и пороговых значений.



Рис. 1. Алгоритм обучения НС ГА

Функция приспособленности. В качестве значения индивидуальной функции приспособленности F принимается сумма абсолютных погрешностей между предсказанным выходом сети и ожидаемым результатом после обучения НС.

$$F = k \sum_{i=1}^n \text{abs}(y_i - o_i), \quad (9)$$

где n – число выходных узлов сети; y_i – требуемый выход узла; o_i – прогнозируемый НС выход узла; k – коэффициент.

Операция выбора. Для выбора используется метод рулетки; на основе стратегии пропорциональной приспособленности вероятность выбора p_i для каждой i -й особи определяется по формуле

$$f_i = \frac{k}{F_i} \quad (10)$$

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j}, \quad (11)$$

где F_i – значение приспособленности особи i ; k – коэффициент; N – число особей популяции.

Операция кроссовера. В работе для особей использовано кодирование действительными числами, поэтому операция кроссовера хромосом \mathbf{a}_k и \mathbf{a}_l в j -бите определяется следующим образом:

$$a_{kj} = a_{kj}(1 - b) + a_{lj}b \quad (12)$$

$$a_{lj} = a_{lj}(1 - b) + a_{kj}b. \quad (13)$$

В формулах (12)–(13) b – случайное число в интервале $[0,1]$.

Операция Мутации. Для выбранной особи i операция мутации гена j определяется следующим образом:

$$a_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{max}) * f(g), & r \geq 0.5 \\ a_{ij} + (a_{min} - a_{ij}) * f(g), & r < 0.5 \end{cases} \quad (14)$$

где a_{max} – верхняя граница a_{ij} ; a_{min} – нижняя граница a_{ij} ; r – случайное число в интервале $[0,1]$; $f(g) = r_2 (1 - g/G_{max})$; r_2 – случайное число; g – итерация; G_{max} – максимальное время шагов эволюции.

Моделирование. Данные, используемые для обучения, формируются собственной разработкой автора – шлюзом онлайн-системы оперативного анализа состояния установок электроцентробежных насосов для нефтегазодобывающей отрасли [5–7]. В этой системе телеметрические параметры, собираемые из территориально распределенных станций управления, попадают в централизованную базу данных телеметрии. В периодическом режиме программный шлюз выбирает блоки телеметрических замеров из базы, производит предварительную обработку и передает системам нейросетевого анализа для оценки и построения прогнозов развития аварийных ситуаций.

Результаты, полученные нейросетевыми системами, заносятся в централизованную базу для последующего анализа и принятия управляющих решений инженерно-техническим персоналом.

Выбор параметров модели. При нормальных обстоятельствах, в базу данных телеметрических выборок заносятся многопараметрические записи, соответствующие показателям всех датчиков, установленных на станциях управления. Общее число таких параметров для ряда станций превышает 150 показателей. Однако, в процессе сбора и передачи данных замеров часть значений в базу данных не поступает. Это может быть связано с различными неисправностями технологического и измерительного оборудования, временными задержками сбора и передачи данных, режимами работы технологических установок.

Для оптимизации обучения из всего множества данных экспериментальным путем было выделено подмножество из 100 параметров, которые вносятся в базу данных и передаются для анализа блоку НС ГА.

Отсутствующие в базе данных значения параметров и значения параметров, не соответствующие диапазонам измерения установленных датчиков, заменяются предыдущими или штатными значениями параметров в зависимости от вида ошибочно внесенного значения.

Значения параметров, которые не вносятся в базу данных из-за продолжительного отсутствия сигналов измерительного оборудования, заменяются нулевыми значениями как при построении и обучении нейросетевой модели, так и в процессе промышленного применения системы.

Среди используемых параметров можно выделить следующие классы: электротехнические параметры насосного оборудования, габаритные параметры скважины, установочные параметры погружного оборудования, замеры датчиков уровня жидкости, другие параметры установленных систем мониторинга станции управления.

Для повышения скорости обучения и работы системы [14] линейно зависящие параметры станции управления были исключены из выборки шлюзом подготовки данных.

Для обучения и сравнительного анализа, данные дополняются предварительно загруженными экспертными оценками оперативного состояния погружного момента на историческом интервале обучающей выборки.

Сбор и обработка данных. В работе для построения модели и контроля качества обучения используются в общей сложности 10000 замеров, включающих от 47 до 60 независимых зафиксированных моментальных значения параметров телеметрических комплексов, которые собирают станции управления ОАО «Сургут-нефтегаз».

После устранения части данных, включающих значительные ошибки и противоречия, обработки, фильтрации и сглаживанием, и нормализации, входные и выходные данные в каждом замере отображаются на интервал [0,1]. На рис. 2 приведены диаграммы замеров одного из электротехнических параметров двигателя до и после фильтрации.

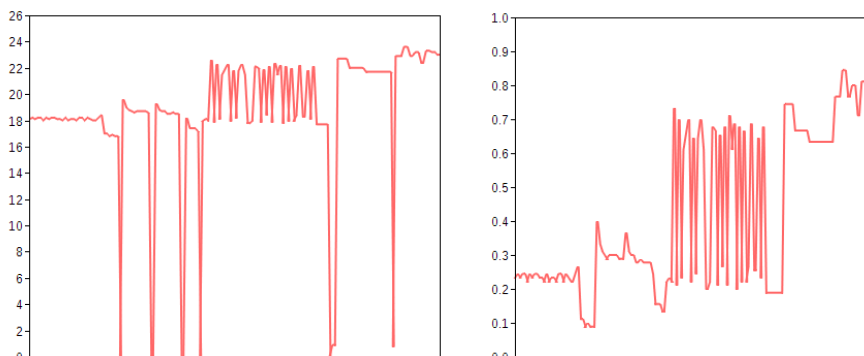


Рис. 2. Сигнал до (слева) и после (справа) фильтрации

Создание модели измерений. В соответствии с тестовым набором данных, искусственная нейронная сеть имеет 60 входных параметров, и по одному выходному параметру на каждый тип определяемой нештатной ситуации (6 типов неисправностей + 1 сигнал нормальной работы). Экспериментальным путем была задана структура нейронной сети 60-100-7, т.е. входной слой имеет 60 узлов, скрытый – 100, а выходной – 7 узлов. Были определены $60 \times 100 + 100 \times 7 = 6700$ весов, и $100 + 7 = 107$ порогов, таким образом, индивидуальная длина кодирующей генетического алгоритма равна $6700 + 107 = 6807$. Параметры генетического алгоритма заданы как: численность популяции составляет 10000 особей, количество шагов эволюции 750, вероятность кроссовера 0,4 и вероятность мутации составляет 0,2. Обучение и моделирование работы модели реализуются в созданном автором программном обеспечении системы анализа состояния нефтегазодобывающего оборудования.

Моделирование состояния добывающего оборудования. После обучения нейронной сети на подготовленных тестовых данных, была проведена проверка работы обученной сети на производственных данных. Аналогично обучающей выборке, данные телеметрии проходили предварительный этап фильтрации и нормализации, определенный в программном обеспечении шлюза данных модели. Подготовленные данные подавались на вход обученной сети, а выходы модели собирались и оценивались экспертами с целью формирования статистики распознавания аварийных ситуаций. Результаты тестирования приведены в табл. 1.

Таблица 1

Статистика работы блока нейросетевого анализа

Выход сети	Число замеров N	Число верных решений T	Число ошибок	Точность измерения ($\frac{T}{N}$)
Нормальная работа	57883	5780	103	0,998
Неисправность 1	1741	1644	97	0,994
Неисправность 2	231	205	26	0,887
Неисправность 3	30	29	1	0,967
Неисправность 4	14	14	0	1
Неисправность 5	78	73	5	0,936
Неисправность 6	23	21	2	0,913
Всего по неисправностям	2117	1986	131	0,938
Всего	60000	59766	234	0,996

Результаты проведенного эксперимента свидетельствуют о высокой точности работы нейросетевой модели. Точность определения ситуации для всей тестовой выборки превысила 99 %, точность определения неисправностей составила примерно 94 %. Для работы системы в условиях высокочастотных входных данных и возможных ошибок в обучающих выборках такие показатели свидетельствуют о высокой точности работы и перспективности технологии ИНС ГА.

Заключение. В статье представлен метод построения ИНС ГА для оперативного анализа состояния погружного оборудования нефтегазодобывающей отрасли. Сравнение результатов моделирования и экспериментальных результатов показало высокую точность получаемых оценок, что свидетельствует о достижении поставленной цели. По сравнению с неоптимизированной нейронной сетью, модель ИНС ГА может получать более точные результаты на данных производственного процесса нефтегазодобывающей отрасли.

Представленная модель ИНС ГА позволяет решить ряд проблем, связанных с использованием ИНС для анализа данных, повысить скорость обучения и точность работы интеллектуальных систем оперативного анализа состояния технологического оборудования. Внедрение данного метода в производственные процессы может повысить эффективность работы цехов нефтегазодобычи благодаря автоматизации и оптимизации части решаемых ими задач.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Ульянов С., Литвинцева Л., Добрынин В, Мишин А. Интеллектуальное робастное управление: технологии мягких вычислений. – 1-е изд. – М.: Pronetlabs, 2011. – 406 с.
2. Манжула В.Г., Федяшов Д.С. Нейронные сети кохонена и нечеткие нейронные сети в интеллектуальном анализе данных // Фундаментальные исследования. – 2011. – № 4. – С. 108-114.
3. Hoskins J.C., Himmelblau D.M. Process control via artificial neural networks and reinforcement learning // Computers & Chemical Engineering. – 1992. – № 16. – P. 241–251.

4. *Рутковский Л.* Методы и технологии искусственного интеллекта. – М.: Горячая линия-телеком, 2010. – 520 с.
5. *Ткаченко М.Г., Коровин Я.С., Кононов С.В.* Оперативная диагностика состояния нефтепромышленного оборудования на основе технологий интеллектуальной обработки данных // Нефтяное хозяйство. – 2012. – № 9. – С. 116-118.
6. *Коровин Я.С., Ткаченко М.Г.* Применение нейросетевого анализа данных в нефтегазодобывающей промышленности // Известия ЮФУ. Технические науки. – 2010. – № 12. – С. 172-178.
7. *Коровин Я.С., Хисамутдинов М.Г., Ткаченко М.Г.* Прогнозирование состояний нефтепромышленных объектов с применением технологий эволюционных алгоритмов и искусственных нейронных сетей // Нефтяное хозяйство. – 2013. – № 10. – С. 128-132.
8. *Ji B.Y.* Overview of Oilfield Development Indicators Forecasting Methods // *Petroleum Geology and Oilfield. Development in Daqing.* – 1999. – Vol. 18, No 2. – P. 19-22.
9. *Yang B.* Applied Neural Network in Oil Well Logging// *Petroleum Industry Press*, -Beijing. – 2005. – P. 36-39.
10. *Floudas C.A., Pardalos P.M.* Encyclopedia of Optimization // *Springer.* – 2008. – Vol. 1. – P. 727-748.
11. *Мищенко В.А., Коробкин А.А.* Использование генетических алгоритмов в обучении нейронных сетей // Современные проблемы науки и образования. – 2011. – № 6. – С. 116-119.
12. *Тенев В.А.* Решение задачи многокритериальной оптимизации генетическими алгоритмами // Интеллектуальные системы в производстве. – 2006. – № 2. – С. 03-109.
13. UCI Machine learning repository. – URL: <http://archive.ics.uci.edu/ml/>.
14. *Каллан Р.* Основные концепции нейронных сетей: Пер. с англ. – М.: ИД «Вильямс», 2001. – 291 с.

REFERENCES

1. *Ulyanov S., Litvintseva L., Dobrynin V, Mishin A.* Intellektualnoe robastnoe upravlenie: tekhnologii myagkikh vychisleniy [Intellectual robust control: technology of soft computing]. – 1st ed. Moscow: Pronetlabs, 2011, 406 p.
2. *Manzhula V.G., Fedyashov D.S.* Neyronnye seti kokhonena i nechetkie neyronnye seti v intellektualnom analize dannykh [Neural network Kohonen and fuzzy neural networks in data mining] *Fundamentalnye issledovaniya* [Fundamental Research, 2011, No. 4, pp. 108-114.
3. *Hoskins J.C., Himmelblau D.M.* Process control via artificial neural networks and reinforcement learning *Computers & Chemical Engineering*, 1992, No. 16, pp. 241-251.
4. *Rutkovskiy L.* Metody i tekhnologii iskusstvennogo intellekta [Methods and technologies of artificial intelligence]. Moscow: Goryachaya liniya-telekom, 2010, 520 p.
5. *Tkachenko M.G., Korovin Ya.S., Kononov S.V.* Operativnaya diagnostika sostoyaniya neftepromysloвого oborudovaniya na osnove tekhnologiy intellektualnoy obrabotki dannykh [Operational diagnostics of oil-field equipment-based data mining technologies], *Neftyanoe khozyaystvo* [Oil industry], 2012, No. 9, pp. 116-118.
6. *Korovin Ya.S., Tkachenko M.G.* Primenenie neyrosetevogo analiza dannykh v neftegazodobivayushchey promyshlennosti [The use of neural network data analysis in the oil and gas industry], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences]. 2010. No. 12, pp. 172-178.
7. *Korovin Ya.S., Khisamutdinov M.G., Tkachenko M.G.* Prognozirovanie sostoyaniy neftepromyslovykh obhektov s primeneniem tekhnologiy evolyutsionnykh algoritmov i iskusstvennykh neyronnykh setey [Forecasting of conditions of oil-field objects with application of technologies of evolutionary algorithms and artificial neural networks], *Neftyanoe khozyaystvo* [Oil industry], 2013, No. 10, pp. 128-132.
8. *Ji B.Y.* Overview of Oilfield Development Indicators Forecasting Methods, *Petroleum Geology and Oilfield. Development in Daqing*, 1999, Vol. 18, No. 2, pp. 19-22.
9. *Yang B.* Applied Neural Network in Oil Well Logging *Petroleum Industry Press*. 2005, pp. 36-39.
10. *Floudas C.A., Pardalos P.M.* Encyclopedia of Optimization *Springer*. 2008. Vol. 1, pp. 727-748.
11. *Mithenko V.A., Korobkin A.A.* Ispolzovanie geneticheskikh algoritmov v obuchenii neyronnykh setey [The use of genetic algorithms in training of neural networks], *Sovremennye problemy nauki i obrazovaniya* [Modern Problems of Science and Education], 2011, No. 6, pp. 116-119.

12. *Tenenev V.A.* Reshenie zadachi mnogokriterialnoy optimizacii geneticheskimi algoritmami [The solution of multicriteria optimization, genetic algorithms], *Intellektualnye sistemy v proizvodstve* [Intelligent Systems in Production], 2006, No. 2, pp. 03-109.
13. UCI Machine learning repository. Available at: <http://archive.ics.uci.edu/ml/>.
14. *Kallan R.* Osnovnye kontseptsii neyronnykh setey [Basic concepts of neural networks]: Per. s angl. Moscow: ID «Viljams», 2001, 291 p.

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

Ткаченко Максим Геннадьевич – Научно-исследовательский институт многопроцессорных вычислительных систем имени академика А.В. Каляева федерального государственного автономного образовательного учреждения высшего профессионального образования "Южный федеральный университет"; e-mail: tkachenkomg@gmail.com; 347928, г. Таганрог, ул. Чехова, 2; тел.: +79281032233; отдел 22; младший научный сотрудник.

Tkachenko, Maxim Gennadievich – Academician A.V. Kalyayev Scientific research institute of multiprocessing computing systems of federal state autonomous educational institution of higher professional education "Southern federal university"; e-mail: tkachenkomg@gmail.com; 2, Chehova street, Taganrog, 347928, Russia; phone: +79281032233; department 22; junior researcher.