раздел ХИМИЯ

УДК 004.8

DOI: 10.33184/bulletin-bsu-2019.3.2

СОЗДАНИЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ОПРЕДЕЛЕНИЯ
ОПТИМАЛЬНОГО ТЕМПЕРАТУРНОГО РЕЖИМА
ВЕДЕНИЯ ХИМИЧЕСКОГО ПРОЦЕССА© Д. Р. Шаймухаметов^{1*}, С. А. Мустафина², Д. В. Шаймухаметова²¹Институт нефтехимии и катализа УФИЦ РАН

Россия, Республика Башкортостан, 450075 г. Уфа, пр. Октября, 141.

²Башкирский государственный университет

Россия, Республика Башкортостан, 453103 г. Уфа, ул. Заки Валиди, 32.

Тел: +7 (917) 386 07 52.

*Email: shaimukhametov@yandex.ru

В работе представлен алгоритм поиска оптимального температурного режима химического процесса, основанный на замене математической модели процесса в форме дифференциальных уравнений моделью на основе искусственной нейронной сети. Апробация созданного алгоритма проводится на примере процесса дегидрирования метилбутонов в изопрен. Для решения задачи оптимального управления построена модель искусственной нейронной сети, позволяющая решать прямую задачу химической кинетики. Далее на основе разработанного алгоритма решена задача теоретической оптимизации по поиску оптимального температурного режима процесса с учетом максимального выхода продукта.

Ключевые слова: искусственные нейронные сети, оптимальное управление, прямая задача химической кинетики.

Введение

При исследовании каталитических реакций и процессов чаще всего используются методы математического моделирования, которые позволяют описывать изменения состояний изучаемой системы. Однако для некоторых процессов построение полных математических моделей, учитывающих все особенности химико-технологического процесса, является весьма трудоемкой задачей. В этом случае при создании моделей вводят ряд упрощений и ограничений, которые в свою очередь вносят погрешности в численные расчеты и могут существенно исказить получаемые результаты.

Альтернативным подходом при моделировании химико-технологических процессов может быть применение искусственных нейронных сетей (ИНС), позволяющих максимально учесть особенности изучаемых процессов [12–14; 16]. Модель ИНС представляет собой сеть элементов (искусственных нейронов), связанных между собой и накапливающих экспериментальные знания, которые используются для последующей обработки [2]. Для накопления знаний по конкретной модели используются связи между нейронами, так называемые синаптические веса. Сеть обрабатывает входную информацию, и в процессе изменения своего состояния по времени формирует совокупность выходных сигналов [1; 17].

От вида модели процесса будет зависеть выбор метода решения задачи по поиску оптимальных режимов ведения процесса. На сегодняшний день имеется широкий спектр методов, позволяющих решать задачу оптимального управления, такие как метод множителей Лагранжа, метод динамического программирования, принцип максимума Л. С. Понт

рягина и др. Однако каждый из этих методов применим для конкретного класса задач. В то же время преимущество ИНС при моделировании химических процессов определяется возможностью строить гибкие модели процессов, которые описываются сложными математическими многомерными функциями [15; 18–20]. Следует также отметить, что нейронные сети являются наиболее эффективным инструментом при решении задач прогнозирования и управления в условиях, когда имеется связь между переменными-предикторами (входами) и прогнозируемыми переменными (выходами), даже если эта связь имеет очень сложную природу и ее трудно выразить в обычных терминах корреляций или различий между группами. Поэтому создание алгоритмов решения задачи оптимального управления на основе модели искусственной нейронной сети является актуальной задачей.

В представленной работе апробация разработанного алгоритма проводилась на примере процесса дегидрирования метилбутена в изопрен. Для химической промышленности данный процесс интересен тем, что синтетические полиизопреновые каучуки являются полноценной альтернативой натурального каучука. Ранее в [3] была описана четырехстадийная схема превращения процесса дегидрирования метилбутонов в изопрен:

где $i-C_5H_{12}$ – изомеры пентана, $i-C_5H_{10}$ – изомеры метилбутена, $i-C_5H_8$ – изомеры изопрена. На основе представленной схемы в работе [8] построена ма-

тематическая модель процесса дегидрирования метилбутенов в изопрен в виде системы обыкновенных дифференциальных уравнений без учета технологических параметров:

$$\begin{aligned} \frac{dC_1}{dt} &= \frac{k_{+1}C_1 - k_{-1}C_2C_4}{(1+b_{11}C_1+b_{12}C_2+b_{13}C_3)^2} \\ \frac{dC_2}{dt} &= \frac{k_{+2}C_2 - k_{-2}C_3C_4}{(1+b_{21}C_2+b_{22}C_3+b_{23}C_4)^2} \\ \frac{dC_3}{dt} &= \frac{k_3C_3}{1+b_3C_4} \\ \frac{dC_4}{dt} &= \frac{k_4}{1+b_4C_4} \end{aligned} \quad (2)$$

где C_i – концентрации компонентов (моль/л), индексация компонентов по i : 1 – изопентан, 2 – метилбутены, 3 – изопрен, 4 – водород, 5 – продукты скелетных превращений (или продукты крекинга – ПК), 6 – диоксид углерода, W_j – скорости химических реакций (кмоль/(м³·ч)), k_i – константы скоростей реакций, b_i – коэффициенты адсорбции (м³/кмоль).

Далее в работе покажем этапы разработки архитектуры искусственной нейронной сети моделирования кинетики дегидрирования метилбутена в изопрен, оценим эффективность ИНС, а также на ее основе решим задачу прогнозирования оптимального температурного режима для вышеназванного химического процесса.

Методика эксперимента

Для построения алгоритма поиска оптимального температурного режима процесса используем нейронную сеть, которая позволяет решить прямую задачу химической кинетики. Алгоритм представим в виде последовательности шагов:

Шаг 1. Вводим исходные параметры процесса: исходный состав смеси, диапазон допустимых температур протекания процесса.

Шаг 2. Проведем варьирование температуры процесса в заданном диапазоне. При каждом значении T_i находим решение прямой задачи химической кинетики на момент времени $t_i + dt$ с использованием ИНС. В результате определим множество допустимых значений вектора варьируемых параметров $V[T_i, C_{1i}^i, C_{2i}^i]$.

Шаг 3. Построим целевую вектор-функцию $F(V) = \beta(V)$, где β – выход продукта. Вычислим значения вектора для всего множества допустимых значений варьируемых параметров.

Шаг 4. Из полученных значений найдем максимальное значение целевой функции и соответствующее ему значение оптимального вектора $V^*[T_i^*, C_{1i}^{i*}, C_{2i}^{i*}]$.

Шаг 5. Полученные значения используем в качестве входных параметров в ИНС на следующей итерации. Перейдем к шагу 1. Итерационный процесс продолжим до тех пор, пока не достигнем конечного времени ведения процесса.

На основе разработанного алгоритма создана программа с моделью ИНС на языке C# в среде разработки Visual Studio Community 2017 компании Microsoft.

Результаты и их обсуждение

По модели (2) в виде системы обыкновенных дифференциальных уравнений ранее в работах [5; 9–11] представлены результаты вычислительных экспериментов, которые нами были использованы для обучения искусственной нейронной сети. Создание ИНС выполнялось в программном пакете Statistica компании Statsoft с применением модуля Neural Networks. В данном программном продукте имеется возможность загрузки обученных нейронных сетей в виде программного кода на языке программирования C#. В дальнейшем модель искусственной нейронной сети была подключена к основной авторской программе. Обученная нейронная сеть имеет структуру многослойного персептрона и позволяет решать регрессионные задачи. Создаваемые на основе экспериментальных и расчетных данных нейронные сети имеют разную комбинацию применяемых функций активации. Это дает возможность выявить наиболее подходящий набор активационных функций в скрытом и выходном слоях. В качестве таких функций были выбраны следующие типы: тождественная, логистическая, функция тангенса, функция экспоненты.

В качестве входных параметров для построения нейронной сети были выбраны следующие режимные параметры процесса: температура ведения процесса, °C (обозначим X_1) в диапазоне от 580 до 630°C; момент времени реакции, сек (обозначим X_2); концентрация i -C₅H₁₀ на текущий момент времени, доля масс (обозначим X_3); концентрация i -C₅H₈ на текущий момент времени, доля масс (обозначим X_4).

Выходными параметрами искусственной нейронной сети были: концентрация i -C₅H₁₀ в следующий момент времени, доля масс (обозначим Y_1); концентрация i -C₅H₈ в следующий момент времени, доля масс (обозначим Y_2).

Для обучения использовалась выборка данных по концентрациям метилбутена и изопрена при режиме работы реактора с постоянной температурой. Сеть была обучена на четырех режимах работы реактора с температурами: 570, 590, 610, 630°C.

Выборка данных для обучения и проверки нейронной сети составила 500 наборов значений $[X_1, X_2, X_3, X_4, Y_1, Y_2]$. Данная выборка разбивалась на три подвыборки: обучающая, тестовая и контрольная в соотношении 30%, 30%, 40% от общего количества наборов в выборке. Распределение наборов по подвыборкам производилось случайным образом.

При анализе полученных нейронных сетей были отобраны пять наиболее адекватных моделей (табл. 1).

Таблица 1

Модели нейронных сетей

№	Архитектура	Алгоритм обучения	Функция активации скрытых нейронов	Функция активации выходных нейронов
1	MLP 4-28-2	BFGS 84	Логистический	Логистический
2	MLP 4-80-2	BFGS 79	Тангенс	Логистический
3	MLP 4-24-2	BFGS 107	Логистический	Тожественный
4	MLP 4-37-2	BFGS 112	Логистический	Логистический
5	MLP 4-64-2	BFGS 145	Тангенс	Тангенс

Рис. 1. Архитектура используемой искусственной нейронной сети прямого распространения (многослойный персептрон).

Отобранные нейронные сети имеют архитектуру многослойного персептрона с одним скрытым слоем (рис. 1). Для определения завершения обучения нейронных сетей применялся метод минимизации ошибок по выходным параметрам нейронной сети. Метод минимизации ошибок реализован по алгоритму второго порядка точности Бройдена–Флетчера–Гольдфарба–Шанно (BFGS). Данный метод позволяет определить глобальный экстремум, игнорируя локальные экстремумы функции ошибок по целевым параметрам [21–22].

Модели нейронных сетей, указанные в табл. 1, показали хорошую предсказательную способность на всех подвыборках. Оценка адекватности полу-

ченных моделей производилась, исходя из параметров, указанных в табл. 2. Предсказательная способность выражена коэффициентом детерминации модели, который является параметром качества модели. Также качество модели определяется по средней абсолютной погрешности по выходным параметрам нейронной сети. По табл. 2 погрешность вычислений целевых параметров составила не более 12%, что говорит о хорошей согласованности с данными вычислительного эксперимента.

На рис. 2 и 3 представлены отклонения на контрольных подвыборках по исходному веществу и целевому продукту.

Таблица 2

Параметры качества модели нейронных сетей

№	Коэффициент детерминации на обучающей подвыборке ($R^2_{\text{обуч}}$)	Коэффициент детерминации на тестовой подвыборке ($R^2_{\text{тест}}$)	Коэффициент детерминации на контрольной подвыборке ($R^2_{\text{контр}}$)	Средняя абсолютная погрешность по выходному параметру Y_1 (MAE_{Y1})	Средняя абсолютная погрешность по выходному параметру Y_2 (MAE_{Y2})
1	0.9923	0.9981	0.9767	0.1200	0.1110
2	0.9928	0.9982	0.9756	0.1100	0.1200
3	0.9929	0.9979	0.9771	0.0840	0.1130
4	0.9930	0.9974	0.9803	0.0860	0.0980
5	0.9928	0.9979	0.9773	0.0830	0.1100

Рис. 2. Диаграмма рассеивания предсказанных значений по исходному веществу (Y_1 – значения из контрольной подвыборки, Y_1^* – значения полученные в ИНС).

По диаграммам рассеивания предсказанных значений видно, насколько точно нейронная сеть определила данные из контрольной подвыборки по исходному веществу – метилбутену (рис. 2) и целевому продукту – изопрену (рис. 3). Каждому значе-

нию контрольной подвыборки ставится в соответствие значение, полученное в искусственной нейронной сети. Чем ближе полученная точка на диаграмме к линии контрольных значений, тем лучше нейронная сеть предсказала данное значение [23–25].

Рис. 3. Диаграмма рассеивания предсказанных значений по целевому продукту (Y_2 – значения из контрольной подвыборки, Y_2^* – значения полученные в ИНС).

Рис. 4. График зависимости оптимальной температуры процесса от времени.

Наиболее адекватная нейронная сеть прямого моделирования процесса должна иметь хорошую предсказательную способность на всех трех подвыборках. Соответственно оптимальной является модель нейронной сети №4 (табл. 2). Отметим, что нейронная сеть имеет наименьшую ошибку на контрольной подвыборке. Для нее регрессионная модель имеет следующий вид:

$$\begin{aligned} Y_i &= \sigma\left(\sum_{j=1}^{37} \omega_{ij} y_j\right), \\ y_j &= \sigma\left(\sum_{k=1}^4 \omega_{jk} x_k\right), \\ \sigma(y) &= \frac{1}{1+e^{-y}}, \end{aligned} \quad (3)$$

где x_k – входные параметры нейронной сети, $\omega_{j,k}$ и $\omega_{i,j}$ – синаптические веса связей j – го нейрона входного и скрытого слоя соответственно, y_j – выходной сигнал от j – го нейрона скрытого слоя, Y_i – выходные параметры нейронной сети, $\sigma(y)$ – функция активации нейронов скрытого и выходного слоев.

Программный модуль обученной нейронной сети был подключен к авторской программе, с применением которого решили задачу поиска оптимального температурного режима исследуемого процесса (рис. 4). В качестве критерия оптимальности был выбран максимальный выход продукта изопрена.

Из рис. 4 следует, что максимальный выход продукта изопрена достигается при поддержке следующего температурного режима: на начальный момент времени оптимальная температура достигает максимального значения (ограниченного регламентом производства) и удерживается на заданном значении до определенного момента времени. Далее в силу влияния побочных реакций температурный режим следует снизить до минимальной температуры из допустимого диапазона. Найденный температурный режим возможен, поскольку обучение нейронной сети осуществлялось на модели

теоретического уровня, не учитывающей тепловой и материальные балансы. Полученные значения хорошо согласуются с результатами из работ [3–7], что подтверждает адекватность разработанного алгоритма.

Для нахождения оптимального температурного режима на технологическом уровне нет необходимости изменять разработанный алгоритм. Достаточно лишь построить новую нейронную сеть, обученную на значениях технологического уровня либо экспериментальных данных, полученных в лабораторных условиях. Причем нейронная сеть, обученная на экспериментальных данных, будет более полно и адекватно описывать химический процесс. Преимуществом созданного алгоритма является возможность его применения без построения математической модели на сложных неизученных химических процессах.

Исследование выполнено при финансовой поддержке РФФИ и Правительства Республики Башкортостан в рамках научного проекта №17-47-020068.

ЛИТЕРАТУРА

1. Горбань А. Н., Дунин-Барковский В. Л., Кирдин А. Н. Нейроинформатика. Новосибирск: Наука. Сибирское предприятие РАН, 1998. 296 с.
2. Хайкин С. Нейронные сети: полный курс. М.: Издательский дом «Вильямс», 2006. 1104 с.
3. Бокин А. И. Дегидрирование метилбутиенов в изопрен с использованием оксидных железокалиевых катализаторов: дис. ... канд. хим. наук. Уфа, 2004. 105 с.
4. Бокин А. И., Балаев А. В., Баженов Ю. П., Касьянова Л. З., Кутепов Б. И. Моделирование процесса дегидрирования метилбутиенов в адиабатическом реакторе с неподвижным слоем железокалиевых катализаторов // Катализ в промышленности. 2004. №6. С. 25–29.
5. Берзина Д. В., Смирнов Д. Ю., Мустафина С. А. Моделирование процесса дегидрирования метилбутиенов в присутствии оксидных железокалиевых катализаторов // Катализ в промышленности. 2014. №4. С. 22–26.
6. Шаймухаметова Д. В. Оптимизация процесса дегидрирования метилбутиенов в изопрен с учетом изменения активности катализатора // Фундаментальная математика и ее приложения в естествознании. Доклады VIII Междунар.

- школы-конф. для студентов, аспирантов и молодых ученых. Уфа: БашГУ, 2015. С. 354–356.
7. Шаймухаметов Д. В. Поиск оптимального температурного режима реакции дегидрирования метилбутенов с изменяющейся активностью катализатора в условиях квазистационарности // Математическое моделирование процессов и систем: мат-лы IV Всероссийской научно-практ. конф. Уфа: БашГУ, 2015. С. 125–128.
8. Ильин В. М., Сайфуллина А. А., Баженов Ю. П., Касьянова А. З., Балаев А. В., Кутепов Б. И. Разработка кинетической модели дегидрирования бутенов на железокатализованных катализаторах // Химическая промышленность сегодня. 2006. №4. С. 19–22.
9. Мустафина С. А., Смирнов Д. Ю., Балаев А. В., Спивак С. И. Моделирование каталитического процесса дегидрирования метилбутенов // Системы управления и информационные технологии. 2006. №1. С. 10–14.
10. Shaimukhametov D. R., Mustafina S. I., Shaimukhametova D. V., Mustafina S. A. Neural network modelling of the process of methylbutene dehydranation into isoprene // ARPN Journal of Engineering and Applied Sciences. 2018. Т. 13. №21. С. 8499–8504.
11. Шаймухаметов Д. Р., Мустафина С. А., Шаймухаметова Д. В. Прямое моделирование процесса дегидрирования метилбутенов в изопрен на основе искусственных нейронных сетей // Вестник Казанского технол. ун-та. 2017. Т. 20. №24. С. 123–127.
12. Горбань А. Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей // Сибирский журнал вычислительной математики. 1998. Т. 1. №1. С. 12–24.
13. Оборнев И. Е., Родионов Е. А. Численные методы решения многомерных обратных задач геоэлектрики с применением нейросетевых технологий // Теория и численные методы решения обратных и некорректных задач. Тезисы IV Междунар. молодежной науч. школы-конф. Новосибирск: Институт математики им. С. Л. Соболева СО РАН, 2012. С. 91.
14. Спичак В. В., Попова И. В. Методология нейросетевой инверсии геофизических данных // Физика Земли. 2005. №3. С. 71–85.
15. Шимелевич М. И., Оборнев Е. А. Применение метода нейронных сетей для аппроксимации обратных операторов в задачах электромагнитных зондирований // Известия ВУЗов. Геология и разведка. 1999. №2. С. 63–73.
16. Poulton M. Neural networks as an intelligence amplification tool: a review of applications // Geophysics. 2002. V. 67. P. 979–993.
17. Сараев П. В. Многошаговое оптимальное нейросетевое управление // Проблемы управления. 2008. №5. С. 14–18.
18. Аведьян Э. Д. Алгоритмы настройки многослойных нейронных сетей // Автоматика и телемеханика. 1995. №4. С. 106–118.
19. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2002. 344 с.
20. Сараев П. В. Обучение искусственных нейронных сетей: учет линейно нелинейной структуры // Вестник молодых ученых. Сер. Прикладная математика и механика. 2003. №2. Вып. 1. С. 92–100.
21. Blyumin S. L., Saraev P. V. Reduction of Adjusting Weights Space Dimension in Feedforward Artificial Neural Networks Training // Proc. of IEEE Int. Conf. on Artificial Intelligence Systems. 2002. P. 242–247.
22. Пупков К. А., Егупов Н. Д. Методы робастного, нейронечеткого и адаптивного управления. М.: МГТУ им. Н. Э. Баумана, 2002. 744 с.
23. Пашенко Г. Н. Построение нейросетевой модели для технологического процесса варки стекла // Проблемы информатики. 2013. №4. С. 56–59.
24. Терехов В. А., Ефимов Д. В., Тюкин И. Ю. Нейросетевые системы управления. М.: Высшая школа, 2002. 183 с.
25. Сараев П. В. Нейросетевое моделирование и управление ценовой политикой // Системы управления и информационные технологии. 2004. №1(13). С. 37–41.

Поступила в редакцию 09.04.2019 г.

После доработки – 16.06.2019 г.

DOI: 10.33184/bulletin-bsu-2019.3.2

CREATING ARTIFICIAL NEURAL NETWORK TO DETERMINE THE OPTIMAL TEMPERATURE REGIME OF THE CHEMICAL PROCESS

© D. R. Shaimukhametov^{1*}, S. A. Mustafina², D. V. Shaimukhametova²

¹*Institute of Petrochemistry and Catalysis, Ufa Federal Research Center of RAS
141 Oktyabrya Avenue, 450075 Ufa, Republic of Bashkortostan, Russia.*

²*Bashkir State University
32 Zaki Validi Street, 450076 Ufa, Republic of Bashkortostan, Russia.*

Phone: +7 (917) 386 07 52.

**Email: shaimukhametov@yandex.ru*

The choice of the method for solving the problem of finding the optimal modes of the process depends on the type of process model. Today there is a wide range of methods to solve the problem of optimal control. However, each of these methods has a narrow scope. The authors of this paper developed an algorithm for finding the optimal temperature regime of the chemical process, based on the replacement of a mathematical model of the process in the form of differential equations by a model based on an artificial neural network. The advantage of the neural network in relation to the modeling of chemical processes is the ability to build flexible models of processes described by complex mathematical multidimensional functions. Testing of the created algorithm was carried out on the example of the process of dehydrogenation of methylbutenes into isoprene. To solve the problem of optimal control, a model of an artificial neural network was constructed, which enables solving the direct problem of chemical kinetics. Then, on the basis of the developed algorithm, the problem of theoretical optimization for determining the optimal temperature regime of the process, taking into account the maximum yield of the product, was solved. The advantage of this algorithm is that it can be applied to unexplored complex chemical processes without building a mathematical model. There is no need to modify the algorithm; it is enough to build a new neural network trained on the experimental data. Moreover, a neural network trained on experimental data will provide more adequate and complete description of the chemical process.

Keywords: artificial neural networks, optimal control, direct problem of chemical kinetics.

Published in Russian. Do not hesitate to contact us at bulletin_bsu@mail.ru if you need translation of the article.

REFERENCES

1. Gorban' A. N., Dunin-Barkovskii V. L., Kirdin A. N. *Neiroinformatika [Neuroinformatics]*. Novosibirsk: Nauka. Sibirskoe predpriyatie RAN, 1998.
2. Khaikin S. *Neironnye seti: polnyi kurs [Neural networks: complete course]*. Moscow: Izdatel'skii dom «Vil'yams», 2006.
3. Bokin A. I. *Degidrirovaniye metilbutenov v izopren s ispol'zovaniem oksidnykh zhelezokalievykh katalizatorov: dis. ... kand. khim. nauk*. Ufa, 2004.
4. Bokin A. I., Balaev A. V., Bazhenov Yu. P., Kas'yanova L. Z., Kutepov B. I. *Kataliz v promyshlennosti*. 2004. No. 6. Pp. 25–29.
5. Berzina D. V., Smirnov D. Yu., Mustafina S. A. *Kataliz v promyshlennosti*. 2014. No. 4. Pp. 22–26.
6. Shaimukhametova D. V. *Fundamental'naya matematika i ee prilozheniya v estestvoznaniy. Doklady VIII Mezhdunar. shkoly-konf. dlya studentov, aspirantov i molodykh uchenykh*. Ufa: BashGU, 2015. Pp. 354–356.
7. Shaimukhametova D. V. *Matematicheskoe modelirovaniye protsessov i sistem: mat-ly IV Vserossiiskoi nauchno-prakt. konf. Ufa: BashGU*, 2015. Pp. 125–128.
8. Il'in V. M., Saifullina A. A., Bazhenov Yu. P., Kas'yanova A. Z., Balaev A. V., Kutepov B. I. *Khimicheskaya promyshlennost' segodnya*. 2006. No. 4. Pp. 19–22.
9. Mustafina S. A., Smirnov D. Yu., Balaev A. V., Spivak S. I. *Sistemy upravleniya i informatsionnye tekhnologii*. 2006. No. 1. Pp. 10–14.
10. Shaimukhametov D. R., Mustafina S. I. *ARP Journal of Engineering and Applied Sciences*. 2018. Vol. 13. No. 21. Pp. 8499–8504.
11. Shaimukhametov D. R., Mustafina S. A. *Vestnik Kazanskogo tekhnol. un-ta*. 2017. Vol. 20. No. 24. Pp. 123–127.
12. Gorban' A. N. *Sibirskii zhurnal vychislitel'noi matematiki*. 1998. Vol. 1. No. 1. Pp. 12–24.
13. Osborne I. E., Rodionov E. A. *Teoriya i chislennyye metody resheniya obratnykh i nekorrektnykh zadach. Tezisy IV Mezhdunar. molodezhnoi nauch. shkoly-konf.*. Novosibirsk: Institut matematiki im. S. L. Soboleva SO RAN, 2012. Pp. 91.
14. Spichak V. V., Popova I. V. *Fizika Zemli*. 2005. No. 3. Pp. 71–85.
15. Shimelevich M. I., Osborne E. A. *Izvestiya VUZov. Geologiya i razvedka*. 1999. No. 2. Pp. 63–73.
16. Poulton M. *Geophysics*. 2002. Vol. 67. Pp. 979–993.

17. Saraev P. V. Problemy upravleniya. 2008. No. 5. Pp. 14–18.
18. Aved'yan E. D. Avtomatika i telemekhanika. 1995. No. 4. Pp. 106–118.
19. Osovskii S. Neironnye seti dlya obrabotki informatsii [Neural networks for information processing]. Moscow: Finansy i statistika, 2002.
20. Saraev P. V. Vestnik molodykh uchenykh. Ser. Prikladnaya matematika i mekhanika. 2003. No. 2. No. 1. Pp. 92–100.
21. Blyumin S. L., Saraev P. V. Proc. of IEEE Int. Conf. on Artificial Intelligence Systems. 2002. Pp. 242–247.
22. Pupkov K. A., Egupov N. D. Metody robastnogo, neiro-nechetkogo i adaptivnogo upravleniya [Robust, neuro-fuzzy, and adaptive control methods]. Moscow: MGTU im. N. E. Baumana, 2002.
23. Pashchenko G. N. Problemy informatiki. 2013. No. 4. Pp. 56–59.
24. Terekhov V. A., Efimov D. V., Tyukin I. Yu. Neirosetevye sistemy upravleniya [Neural network control systems]. Moscow: Vysshaya shkola, 2002.
25. Saraev P. V. Sistemy upravleniya i informatsionnye tekhnologii. 2004. No. 1(13). Pp. 37–41.

Received 09.04.2019.

Revised 16.06.2019.