

УДК 666.94

**СРАВНИТЕЛЬНАЯ ОЦЕНКА КАЧЕСТВА ЦЕМЕНТНОГО СЫРЬЯ
НА КАРЬЕРАХ С ПОМОЩЬЮ ТРЕХМЕРНОЙ ИДЕНТИФИКАЦИИ**

А. Дж. Оздемыр¹, А. Даг¹, Т. Ибрыкджы²

¹*Факультет горного дела, Чукурова университет,*

E-mail: acozdemir@cu.edu.tr, 01330, Саричам, Адана, Турция

²*Кафедра электротехники и электронной инженерии, Чукурова университет,
01330, Саричам, Адана, Турция*

В цементной индустрии, помимо увеличения производственной мощности, важное значение имеет улучшение качества продукции. Процесс производства цемента требует знания химических свойств оксидных смесей для получения характеристик клинкера. Коэффициент насыщения, определяющий отношение алита к белиту в клинкере, также часто используется для оценки качества цемента. Исследование посвящено оценке распределения коэффициента насыщения в натуральных условиях. Для этой цели применялись вероятностный (геостатистический) и невероятностный (нейронно-сетевой) алгоритмы. Достоверность исследования, выраженная показателями эффективности, основывается на преимуществе использования невероятностных методов в статистическом прогнозе продуктивности. Показано, что адаптивные нейронные алгоритмы могут обеспечить получение данных о качестве при определенных геологических параметрах.

Цемент, карьер, коэффициент насыщения, геостатистика, нейронная сеть

DOI: 10.15372/FTPRPI20180411

Во всем мире цемент используется в различных областях производства, особенно в строительной промышленности. Преимущественно в его состав входят кальций, алюминий, кремний и оксиды железа, по которым определяют качество цемента [1]. Главная цель цементной промышленности — изготовление цемента однородного по сырьевому составу.

Качество продукта можно оценить по различным параметрам, таким как химический состав или прочность сжатия. Коэффициент насыщения, характеризующий клинкер, — один из наиболее важных параметров, влияющих на качество готового цемента, и может выступать для оценки качества месторождения [2, 3]. По этой причине входными данными модели выбраны координаты $х_{уз}$, а коэффициент насыщения LSF представляет собой выходную переменную, получаемую на основании скважинных измерений:

$$LSF = \frac{100CaO}{2.8SiO_2 + 1.18Al_2O_3 + 0.65Fe_2O_3}.$$

В литературе описано множество методов прогнозирования и моделирования. Обычно в горной промышленности применяется метод оценки геостатистических данных [4–9]. Однако у геостатистических методов, как и у других методов оценки, есть свои преимущества и недостатки [9–11]. Поэтому разработан новый метод, который относится к мягким методам вычислений и может заменить геостатистические методы. Мягкие методы вычислений использовались в разных областях науки, начиная с теории управления и заканчивая анализом данных. Большинство исследований в области инженерно-технического проектирования, в особенности в моделировании и оценивании, проведено с помощью мягких вычислений [12–14]. Эти методы использовались также применительно к геонаукам, в контексте анализа пространственных данных, геоэкологическом анализе и оценке региональных параметров [15–17].

Исследования показывают, что коэффициент насыщения можно прогнозировать, используя различные методы. Для того чтобы определить наиболее подходящий метод, проведено сравнение результатов. В отличие от предыдущих исследований, где применялся мягкий метод вычислений данных в формате 2D, в настоящей работе набор данных представлен в трехмерном формате.

МЕТОДОЛОГИЯ

Кригинг. В основе геостатистических методов лежит теория региональных переменных. Геостатистические методы наиболее часто применяются для оценки месторождений полезных ископаемых в горной промышленности. Основной чертой этой теории является значительная взаимосвязь региональных переменных. Эта взаимосвязь определяется использованием функций семивариограмм, представленных в виде пространственной изменчивости диапазона переменных. Функция семивариограммы $\gamma(h)$ рассчитывается как

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2,$$

где h — вектор разделения; $N(h)$ — количество пар данных; $Z(x)$ — случайная переменная, определенная в точке x [18].

Подтверждена достоверность модели семивариограммы и проведена оценка метода обычного кригинга с использованием полученной модели и ее параметров. Формула оценки обычного кригинга неизвестной средней величины в точке x_0 при $Z^*(x_0)$:

$$Z^*(x_0) = \sum_{i=1}^N \lambda_i Z(x_i),$$

где λ_i — вес; $Z(x_i)$ — рассматриваемая величина. Чтобы убедиться в объективности оценки, значение весов должно быть приближено к единице [19].

Адаптивная сеть на основе системы нечеткого вывода (ANFIS). ANFIS разработана в начале 90-х годов XX в. [20–22]. Метод ANFIS интегрирует искусственную нейронную сеть (ИНС) с принципами нечеткой логики [23, 24]; это метод оценки, который обычно используется по многим направлениям инженерного дела. Моделирование ANFIS происходит с применением карты портов “ввода–вывода”, основанной на человеческих знаниях в виде нечетких правил импликации и заданных пар данных “ввода–вывода” [25, 26]. Метод работает на основе гибридного алгоритма обучения, который связан с методом градиентного спуска и методом наименьших квадратов. Параметры, необходимые для ANFIS, определяются этим алгоритмом. По основному правилу ANFIS имеет две входные переменные x , y и одну выходную z : если x есть A_1 и y есть B_1 , то $f_1 = p_1x + q_1y + r_1$. На рис. 1 представлена базовая архитектура модели ANFIS.

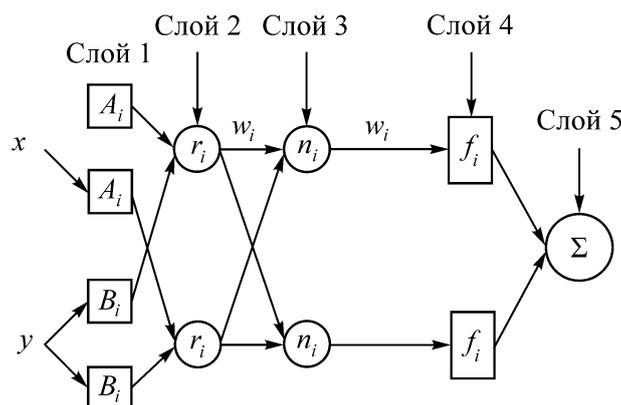


Рис. 1. Основы системы ANFIS

Система ANFIS состоит из пяти слоев. Слой 1 представляет нечеткие множества. Его границы и расположение центра каждого нечеткого множества определены. В настоящем исследовании использовались гауссовы и обобщенные колоколообразные функции принадлежности. Функции принадлежности могут быть записаны в виде:

$$\mu_{A_i}(x) = e^{-(x-C_i)^2/2\sigma_i^2}, \quad \mu_{A_i}(x; A_i, B_i, C_i) = \frac{1}{1 + \left[\frac{x - C_i}{A_i} \right]^{B_i}},$$

здесь x — один из показателей ввода; A, B, C — набор параметров; σ_i — рассеивание функции принадлежности; A — языковое понятие.

Слой 2 вычисляется по степени принадлежности к нечетким правилам:

$$Q_i^2 = w_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1, 2,$$

где μ_A, μ_B — нечеткие множества, установленные для переменных x, y .

В слое 3 степени принадлежности унифицированы:

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2,$$

В слое 4 вычисляются взвешенные результирующие значения установленных нечетких правил, где каждое стандартизированное правило ассоциируется с функцией логической последовательности:

$$Q_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i),$$

где \bar{w}_i — выход слоя 3; p_i, q_i, r_i — набор параметров.

Слой 5 — слой выхода, в котором суммируются все выходы предыдущих слоев, а реальное значение выхода получают из ANFIS [27]:

$$Q_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}.$$

Искусственная нейронная сеть (ИНС). Основой сети является определенный тип модели обучения, опирающийся на принципы работы человеческого мозга и возникший в попытке создания математической модели. ИНС моделирует работу головного мозга и представляет

взаимодействующие между собой узлы (нейроны) [28]. Она состоит из слоев с заданными параметрами и ее работа основана на процессе обучения. Поступающая информация передается по узлам сети нейронов. Таким образом, обработка данных и вычислительные возможности ИНС переходят от параллельной распределенной структуры и основываются на возможности обобщений.

На рис. 2 изображена структура ИНС, которая состоит из пяти элементов: входы, веса, функции сложения, функции активации и выхода(ов). Использование различных типов активации функций, количество слоев и узлов определяют, насколько удачной будет ИНС. В настоящем исследовании изучался многослойный перцептрон Румельхарта (MLP), который представляет одну из моделей ИНС [1, 29].

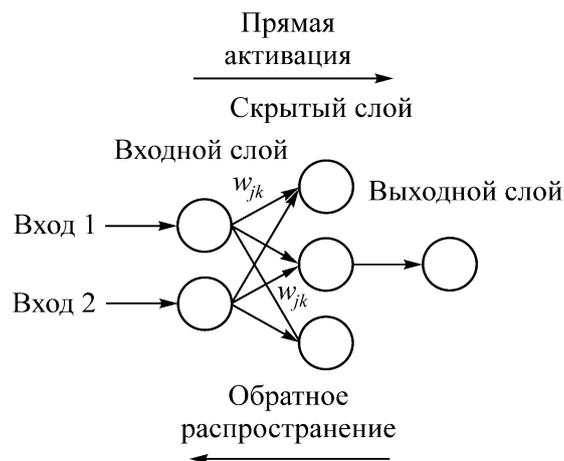


Рис. 2. Структура искусственной нейронной сети

ТЕМАТИЧЕСКИЕ ИССЛЕДОВАНИЯ

Описание месторождения и набор данных. Изучаемый участок — месторождение цементного сырья, расположенное в г. Джейхан (провинция Адана, в 12 км от г. Аданы) (рис. 3). Набор данных, полученный на цементном заводе Аданы (Ояк) в Турции, использовался при определении качества цементного сырья.

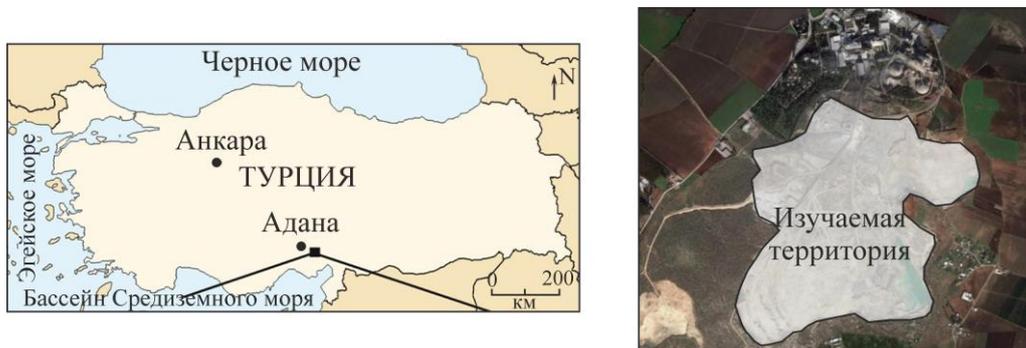


Рис. 3. Схема расположения района исследований

Данные, полученные из 34 буровых разведочных скважин (рис. 4), взяты на основе значений координат x, y, z с применением коэффициента насыщения. Сводная статистика набора данных представлена в табл. 1.

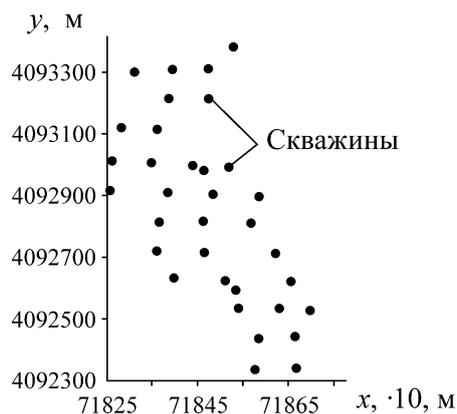


Рис. 4. Расположение буровых разведочных скважин

ТАБЛИЦА 1. Обобщенная статистика набора данных

Параметр	CaO	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	Коэффициент насыщения
Среднее значение	33.01	20.42	4.85	2.70	153.26
Стандартное отклонение	10.61	12.88	3.13	1.64	228.23
Среднее отклонение	112.64	165.87	9.81	2.70	52089.03
Минимум	50.92	61.81	10.19	6.21	1303.88
Максимум	9.41	0.45	0.46	0.31	5.00
Количество	152	152	152	152	152

Данные в случайном порядке разделяли на подклассы. Данные для обучения (80 % от общего количества 127 образцов) были зарезервированы, а остальные (25 образцов) отобраны для тестирования. Кроме того, данные были нормализованы в диапазоне 0–1 с применением формулы $A = (A_i - A_{\min}) / (A_{\max} - A_{\min})$, где A — нормализованное значение; A_i — фактическое i -е значение; A_{\max} , A_{\min} — максимальное и минимальное фактические значения.

Модель обычного кригинга. Распространенным методом геостатистической оценки является обычный кригинг (ОК). Параметры, используемые в процессе оценивания, определяются на основе анализа вариограмм. Анализ проводят с учетом экспериментальных вариограмм и теоретических моделей вариограмм, соответствующих экспериментальным вариограммам. Таким образом, данное исследование основывается на 3D-оценке вариограмм по вертикальному и горизонтальному направлению. На рис. 5 показаны модели вариограмм, а в табл. 2 приведены параметры вариограмм, полученные для проведения оценки.

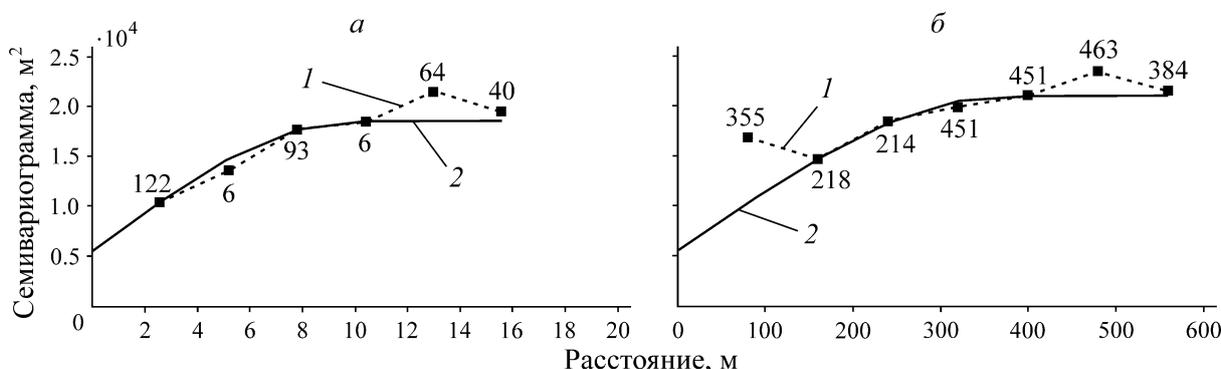


Рис. 5. Модели вариограмм по вертикальному (а) и горизонтальному (б) направлению: 1 — экспериментальная модель; 2 — сферическая

ТАБЛИЦА 2. Параметры теоретических моделей вариограмм

Направление	Модель	Наггет-эффект C_0 , м ²	Силл $C_0 + C_1$, м ²	Диапазон a , м
Горизонтальное	Сферическая	5 500	21 000	380
Вертикальное			18 500	10

Модель ANFIS. Использована модель, основанная на данных трех входов и одного выхода. Входные аргументы x , y , z определяют значения входных переменных, а выходная переменная устанавливается коэффициентом насыщения. Для определения лучшей модели рассматривались модели, разработанные на основе разных параметров, некоторые из них (табл. 3) соотносятся с параметрами и коэффициентами корреляции r . Интервал времени для периода дискретизации взят в качестве постоянного значения 50. Дефазификация применялась по методу центра тяжести. Значение r определило наилучшую нечетко-логическую модель. Общий вид такой модели представлен на рис. 6.

Значения, полученные в результате теста, оценивались по параметрам модели. Промежуточные и смоделированные различия значений, а также взаимосвязи между x , y и параметрами коэффициента насыщения отражены на рис. 7 и показывают, как параметры x , y влияют на коэффициент насыщения.

ТАБЛИЦА 3. Параметры модели ANFIS

Номер модели	Функция принадлежности	Номер кластера	Метод оптимизации	Тип функции выхода	Коэффициент корреляции r
1	Колоколообразная	7, 7, 8	Гибридный	Линейный	0.776
2	Гауссовская	7, 7, 8		Линейный	0.726
3	Гауссовская	6, 6, 8		Линейный	0.595
4	Гауссовская	5, 5, 7		Постоянный	0.593

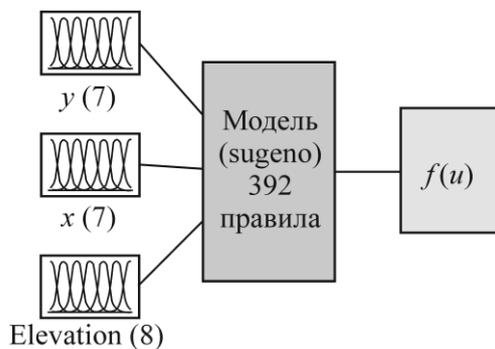


Рис. 6. Общая структура разработанной модели ANFIS

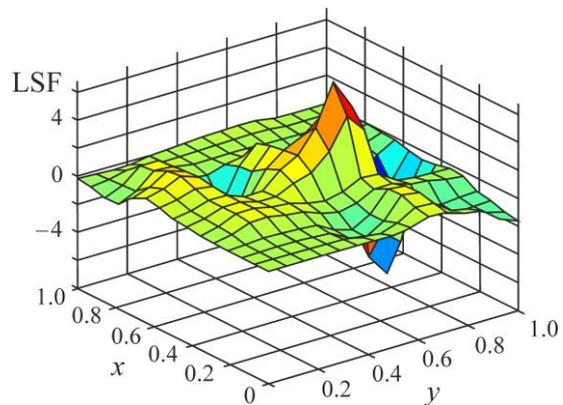


Рис. 7. Данные в системе координат с учетом коэффициента насыщения

Модель ИНС. Структура сети MLP состоит из трех частей: входной слой, скрытый слой и выходной слой. Имеется три входных значения локализации (x , y , коэффициент насыщения) и одно выходное, определяющееся значением коэффициента насыщения. В скрытом слое используется сигмоидная функция для сглаживания данных, а в выходном — линейная функция для оценки входного значения. Для обучения использовалась функция тренировки сети “Trainlm”, в которой сеть подстраивает значения весов и смещений в соответствии с методом оптимизации Левенберга – Маркара (LMA). Основная архитектура ИНС приведена на рис. 8.

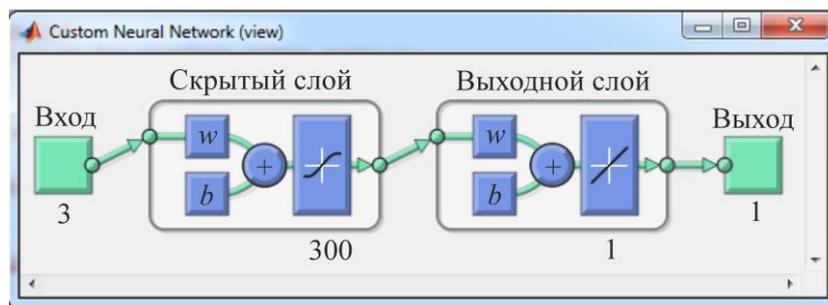


Рис. 8. Структура нейронной сети

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

В данном исследовании значения коэффициента насыщения смоделированы согласно геостатистическому методу и методам мягких вычислений, таких как ANFIS и ИНС. Для установления точности разработанных моделей должны быть оценены взаимосвязи между прогнозируемыми и измеренными значениями. Существует много показателей для определения такой оценки. Наиболее известными являются среднеквадратичная ошибка RMSE, расчет значений фактора корректировки стоимости VAF и коэффициент корреляции r [30]. RMSE и VAF вычисляются по следующим соотношениям:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - y_i^*)^2}{N}}, \quad VAF = \frac{1 - [\text{var}(y - y^*)]}{\text{var}(y)} \cdot 100,$$

здесь y , y^* — измеренные и прогнозируемые значения; N — количество данных.

Оценка результатов по каждой модели проводилась при помощи этих показателей. Согласно оптимальной модели, RMSE должна быть минимальной, VAF — максимальным, а r приближен к 1. Оценка результатов проведенных измерений, представленная в табл. 4, свидетельствует о том, что наименьшая RMSE (0.117) и примерная STD (0.141) были получены в модели ОК, тогда как наибольшие значения r (0.776) и VAF (99.866) — при использовании модели ANFIS.

ТАБЛИЦА 4. Оценка результатов измерений

Показатель	Измерение	Обычный кригинг	Искусственная нейронная сеть	Адаптивная сеть на основе системы нечеткого вывода
STD	0.216	0.141	0.415	1.148
r	—	0.689	0.732	0.776
VAF	—	98.528	98.879	99.866
RMSE	—	0.117	0.545	1.110

ВЫВОДЫ

В современном мире цемент — важный материал для строительства и его качество — значимый аспект. Для сравнения параметров коэффициента насыщения при оценке качества цемента использовались ANFIS, ОК и ИНС модели с различными показателями оценки (STD, r , VAF, RMSE), а также трехмерные данные. Наилучшее планирование при моделировании горных работ достигается при трехмерном формате данных.

Результаты показали, что ИНС и ANFIS могут успешно применяться при расчетах качества цемента, а методы оценки, основанные на мягких вычислениях и предлагающие новые способы ее проведения, будут совершенствоваться.

СПИСОК ЛИТЕРАТУРЫ

1. **Tutmez B.** A data-driven study for evaluating fineness of cement by various predictors, *Int. J. Mach. Learn. & Cyber*, 2015, 6. — P. 501–510.
2. **Sorrentino F.** Lime saturation factor: New insight, *Cement WapnoBeton*, 2008, 2. — P. 82–88.
3. **Boughanmi S., Iabidi I., Tiss H., and Megriche A.** The effect of marl and clay compositions on the Portland cement quality, *J. of the Tunisian Chemical Society*, 2016, 18. — P. 43–51.
4. **Isaaks E. H. and Srivastava R. M.** *An Introduction to Applied Geostatistics*, New York, Oxford University Press, 1989.
5. **Cressie N.** *The Origins of Kriging, Mathematical Geology*, 1990, Vol. 22.
6. **Uygucgil H. and Konuk A.** Reserve estimation in multivariate mineral deposits using geostatistics and GIS, *J. of Mining Science*, 2015, Vol. 51, No. 5. — P. 993–1000.
7. **Sides E. J.** Geological modelling of mineral deposits for prediction in mining, *GeolRundsch*, 1997, 86. — P. 342–353.
8. **David M.** The geostatistical estimation of porphyry-type deposits and scale factor problems, *Proceedings, Pribram Mining Symposium, Pribram, Czechoslovakia*, 1970.
9. **Diehl P.** Quantification of the term geological assurance in coal classification using geostatistical methods, *Schriftenreihe der GDMB Klassif, Von Lagerstätten*, 1997, 79. — P. 187–203.
10. **Bardossy G. and Fodor J.** Traditional and new ways to handle uncertainty in geology, *Natural Resources Research*, 2001, 10. — P. 179–187.
11. **Dag A. and Mert B. A.** Evaluating thickness of bauxite deposit using indicator geostatistics and fuzzy estimation, *Resource Geology*, 2008, 58 (2). — P. 188–195.
12. **Chang L. C. and Chang F. J.** Intelligent control for modeling of real-time reservoir operation, *Hydrogeological Processes*, 2001, 15 (9). — P. 1621–1634.
13. **Pahm T. D.** Grade estimation using fuzzy-set algorithms, *Mathematical Geology*, 1997, 29. — P. 291–304.
14. **Wong P., Aminzadeh F., and Nikravesh M.** *Soft computing for reservoir characterization and modeling*, Physica-Verlag, Heidelberg, 2001.
15. **Bardossy G. and Fodor J.** *Evaluation of uncertainties and risks in geology*, Springer-Verlag, Heidelberg, 2004.
16. **Amini M., Afyuni M., Fathianpour N., Khademi H., and Flühler H.** Continuous soil pollution mapping using fuzzy logic and spatial interpolation, *Geoderma*, 2005, 124 (3, 4). — P. 223–233.
17. **Tutmez B.** An uncertainty oriented fuzzy methodology for grade estimation, *Computing Geoscience*, 2007, 33. — P. 280–288.
18. **Goovaerts P.** *Geostatistics for natural resources evaluation*, Oxford University Press, New York, 1997.
19. **Webster R. and Oliver M.** *Geostatistics for environmental scientists*, 2nd edn. John Wiley & Sons, Chichester, UK, 2007, 318.
20. **Jang J. S. R., Sun C. T., and Mizutani E.** *Neuro-Fuzzy and soft computing: A computational approach to learning and machine intelligence*, Prentice-Hall International (UK) Limited, London, 1997, 614.
21. **Jang J. S. R.** ANFIS: adaptive network-based fuzzy inference system, *IEEE Transactions on System, Man and Cybernetics*, 1993, 23 (3). — P. 665–685.
22. **Ozkan G. and Inal M.** Comparison of neural network application for fuzzy and ANFIS approaches for multi-criteria decision making problems, *Applied Soft Computing*, 2014, 24. — P. 232–238.

23. **Kosko B.** Neural networks and fuzzy systems, A Dynamical Systems Approach, Englewood Cliffs., NJ, Prentice Hall, 1991, 2.
24. **Jang J. S. R. and Sun C. T.** Neuro-Fuzzy modeling and control, proceedings of the IEEE, 1995, 83 (3).
25. **Fuller R.** Introduction to Neuro-Fuzzy systems, Physica-Verlag, Heidelberg, 1999, 289.
26. **Tutmez B., Hatipoglu Z., and Kaymak U.** Modelling electrical conductivity of groundwater using an adaptive neuro-fuzzy inference system, Computers & Geosciences, 2006, 32. — P. 421–433.
27. **Jang J. S. R.** Fuzzy modeling using generalized neural networks and kalman filter algorithm, Department of Electrical Engineering and Computer Science, University of California, Berkeley, CA 94720, 1992.
28. **Hayer H. and KhosraviNikou M. R.** Multi-component catalyst design for oxidative coupling of methane using ANFIS and ANN, Petroleum Science and Technology, 2014, 32. — P. 1357–1364.
29. **Hu C. and Cao L.** A system identification method based on multi-layer perception and model extraction, Adv. Neural Netw, 2004, ISNN 3174. — P. 218–223.
30. **Akay M. F., Aci Ç. İ., and Abut F.** Predicting the performance measures of a 2-dimensional message passing multiprocessor architecture by using machine learning methods, Neural Network World, 2015, 3/15. — P. 241–265.

Поступила в редакцию 10/IV 2018