
ИНЖЕНЕРНО-ТЕХНИЧЕСКИЕ НАУКИ

ENGINEERING AND TECHNICAL SCIENCES

УДК 628.1:510.6

В.Н. Коваленко

*Белорусский государственный университет транспорта,
г. Гомель, Республика Беларусь*

Д.В. Макаров

*ФГБОУ ВО «Уфимский государственный нефтяной
технический университет»,
г. Уфа, Российская Федерация*

Р.Н. Вострова

*Белорусский государственный университет транспорта,
г. Гомель, Республика Беларусь*

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В СИСТЕМЕ ВОДОСНАБЖЕНИЯ

Аннотация. В статье описывается краткая классификация нейронных сетей и возможности их применения в различных отраслях жизнедеятельности человека. Основное внимание направлено на применении рассматриваемой технологии в сфере водоснабжения промышленных предприятий, использующих неподготовленную воду в технологических процессах. Исследование проводилось на филиале «Гомельская ТЭЦ-2» Республиканское унитарное предприятие «Гомельэнерго», г. Гомеля (Республика Беларусь). Главной задачей исследования, являлось выполнение помесячных расчёт реагентов, используемых в целях подготовки исходной воды, основываясь на спрогнозированных значениях искусственной нейронной сетью. Для этого, были собраны результаты анализов исходной воды из реки Сож за десятилетний период наблюдений, в течении которого, контроль качества воды проводится по семи показателям. Проведён сравнительный анализ концентраций, содержащихся в исходной воде, с текущими предельно-допустимыми концентрациями, установленными нормативами для теплоэлектроцентрали. Определена зависимость количества содержащихся веществ в исходной воде от времени года, в результате построены скрипичные графики, отражающие область распределения значений, а также линии тренда за период наблюдений. Для получения результата прогнозирования использовалась искусственная нейронная сеть с тождественной функцией активации. Функция основана на том, что входной сигнал для элемента сети в точности равен сигналу, выходящему из этого элемента. Исходя из среднеквадратичной ошибки и производительности каждой модели, были выбраны наиболее точные сети для прогнозирования. На основе полученного опыта и технологии прогнозирования существует возможность по внедрению на иные предприятия, использующие исходные водные ресурсы в процессе изготовления продукции.

Ключевые слова. Водоподготовка, загрязняющие вещества, искусственные нейронные сети (ИНС), исходная вода, предельно-допустимая концентрация, промышленность, реагенты, ТЭЦ (теплоэлектроцентраль).

Информация о статье. Дата поступления: 2 ноября 2020 г.

V.N. Kovalenko

*Belarusian State University of Transport,
Gomel, Republic of Belarus*

D.V. Makarov

*FSBEI of Higher Education «Ufa State Petroleum
Technological University»,
Ufa, Russian Federation*

R.N. Vostrova

*Belarusian State University of Transport,
Gomel, Republic of Belarus*

APPLICATION OF NEURAL NETWORKS IN THE WATER SUPPLY SYSTEM

Abstract. The article described a classification of neural networks and their application in various branches of human life. The authors mainly focused on the application of this technology in the field of water supply for industrial factory that uses untreated water in technological processes. The study was conducted at the Gomel TTP №2 branch of Republican unitary enterprise «Gomelenergo», Gomel (Republic of Belarus). The goal of the study was to conduct monthly calculations of reagents used for preparation of source water, based on predicted values by an artificial neural network. To do this, we collected the results of analysis of source water from the Sozh river, for a ten-year observation period, during which water quality control has been carried out using seven indicators. A comparative analysis of the concentrations contained in the source water with the current maximum permissible concentrations established by the standards for the thermal power plant was carried out. The dependence of the amount of substances contained in the source water on the time of the year was determined. As a result, treble graphs were constructed to reflect the area of distribution of values, as well as trend lines for the observation period. To obtain the prediction result, an artificial neural network with an identical activation function was used. The function is based on the fact that the input signal for a network element is exactly equal to the signal coming from this element. Based on the root-mean-square error and the performance of each model, the most accurate network for forecasting was selected. Based on the experience gained and the forecasting technology, it is possible to introduce it to other enterprises that use the source water resources for the production of products.

Keywords. Water treatment, pollutants, artificial neural network (ANN), source water, maximum permissible concentration, industry, reagents, TTP (thermal power plant).

Article info. Received 2 November, 2020.

Нейронная сеть — распределительный параллельный процесс, состоящий из элементарных единиц обработки информации, накапливающих экспериментальные знания и предоставляющих их для последующей обработки [1].

В общем случае представляет собой совокупность математических, физических, статистических методов и инструментов по обработке входящих данных, основанный на базе различных систем программного обеспечения. В зависимости от системы, направленной на решения задач в конкретной области, различают следующие функции активации ИНС:

- линейные;
- обобщённо-линейные;
- нелинейные.

Структура сети основывается на последовательном выстраивании цепочек (слоёв) нейронов. Как правило, ИНС различают: однослойная и многослойная [2].

Однослойные сети — состоят из входного слоя, где производятся все вычисления и выводится на второй слой — результат воздействия нейронной сети на массив данных. Сеть, с такой структурой имеет слабую производительность и редко используется для вычисления точных значений.

Многослойные — состоят из множества слоёв, однако первый слой выполняет роль ввода, последний слой роль вывода и никаким образом не влияют на производительность сети. Основную работу выполняют «скрытые нейроны», сеть такого вида подходит под более сложные задачи. Суть их деятельности заключается в том, что каждый последующий слой преобразует ранее полученный промежуточный результат в новый результат.

Основная масса нейронных сетей основывается на многослойной структуре и нелинейной функции активации [там же; 3]. Главным достоинством системы сводится к повышенной производительности сети (способности находить более сложные зависимости между свойствами задаваемых данных).

Стоит отметить, что со многими задачами машинное вычисление справляется хуже, чем человек, однако скорость их выполнении значительно выше, так же отсутствует вероятность появления ошибок, связанных с человеческой невнимательностью (человеческий фактор).

Так как существует значительная вариативность применения нейронных сетей в различных сферах деятельности, то можно классифицировать сети по назначению [2]:

- классификация образов. Определение принадлежности данных к классам по его свойствам. К известным системам относятся распознавание речи, букв, классификация сигнала электрокардиограммы, классификация клеток крови, деятельности биометрических сканеров и пр.;

- кластеризация. Алгоритм кластеризации основан на подобию образов и классифицирует близкие образы в один кластер. Отличающим моментом от других систем является отсутствие обучающей выборки. Применяются для сжатия и распределения данных, извлечения данных, исследования самого объекта и его свойств [4];

- функция аппроксимации. Применения данной ИНС осуществляется в случае, когда необходимо определить и оценить аргумент, скрываемый за множеством лишней информации. При-

мером использования такой сети является шумоподавление при приёме различных сигналов [4];

– оптимизация — одна из проблем в различных сферах деятельности человека и программного обеспечения, значительно влияющая на производительность труда. Задачей алгоритма оптимизации является нахождение такого решения, которое удовлетворяет системе ограничений и максимизирует или минимизирует целевую функцию. Примерами таких систем могут быть коммивояжёр, аппаратное ускорения в графических чипах и т.д.;

– ассоциативная память. Вид нейронной сети, определяющий и выдающий запрос заданного содержания. Содержимое памяти может быть определено по цельному или частичному входу информации. Основной областью применения такой ИНС является распознавание музыки, изображений, мультимедийных файлов из баз данных.

– управление. НИС с динамической системой управления, заложенной в базу данных для воздействия выхода на движения и изменения координат объекта в системе. Областью применения являются автопилоты в кораблях и самолётах, автомобилях, в том числе «контроль полосы».

– прогнозирование. Задача состоит в предсказании значения в некоторый будущий момент времени. Применение такого вида систем в бизнесе, промышленности, ЖКХ, транспорте может в значительной мере влиять на принятие решения. Сферами, где может применяться является сферой услуг (банковские системы, заведения общественного питания, игровые клубы и т.п.), прогноз погоды [там же].

Метод ИНС нашел широкое применение в прогнозировании показателе качества речной воды [3; 5–11]. В работе [12] нейросетевое моделирование позволило получить адекватные модели для прогнозирования уровня воды в озере, а в исследовании [13] - солёности, температуры, растворенного кислорода и мутности воды океана. Имеется успешный опыт применения метода при прогнозировании уровня подземных вод [14].

В исследовании данный метод используется для прогнозирования показателей качества речной воды. Прогнозные значения компонентов воды могут быть использованы для месячного перерасчёта реагентов для водоподготовки на «Гомельская ТЭЦ-2». Для реализации ИНС метода использованы программные комплексы Statistica 10.0 и MATLAB R2017a. Так как на теплоэлектростанции для водоподготовки используется постоянная, не изменяемая доза реагентов, данный расчёт может позволить сократить затраты в дальнейшем на их закупку.

Задачи, поставленные перед исследованием:

1. Проанализировать и сделать выводы о зависимости концентраций контролируемых веществ, от сезона года.

2. Проанализировать и сделать выводы о тенденциях роста и падения концентрации загрязняющих веществ за многолетний период.

3. Выполнить прогнозирование с помощью искусственных нейронных сетей и сравнить полученные значения с фактическими.

4. Выполнить помесечный расчёт реагентов согласно значениям, полученным в результате прогнозирования.

На ТЭЦ вода подаётся из реки Сож (исходная) и используется в двух технологических процессах: для восполнения потерь пара в оборотной сети, восполнения потерь воды в закрытых системах теплоснабжения. К воде, используемой для регенерации пара, внедрены повышенные требования, по сравнению с водой хозяйственно-питьевого назначения¹.

Для исследования были собраны временные ряды величин показателей за период с 2010 г., по сентябрь 2020 г., суммарное число значений составило 941 измерение. Контроль качества исходной воды осуществляется по 7 основным параметрам: водородный показатель (pH), взвешенные вещества, нефтепродукты, медь (Cu), железо (Fe), хлориды, сульфаты, окисляемость, цинк (Zn) и никель (Ni). Стоит отметить, что контроль за никелем был прекращён в 2011 г., цинком, медью и окисляемостью в 2018 г. В связи с малыми (зачастую ниже предела определения) значениями и стабильностью величин цинка, никеля, pH , данные показатели не анализировались.

Повышение концентрации загрязняющих веществ обычно наблюдается в весенний и осеней периоды. Это связано с увеличивающимся объёмом поверхностных сточных вод, попадающих в водный объект с прилегающей поймы. Для оценки сезонности показателей за многолетний период проведено построение скрипичных диаграмм (рис. 1).

В целом, можно отметить несколько меньший диапазон значений по хлоридам, железу, сульфатам (рис. 1). Наблюдается относительно большее число выбросов по нефтепродуктам и меди — наличие сезонности не прослеживается. Значения по нефтепродуктам и меди отражает наличие рисков и возможного единичного превышения ПДК. У показателей: хлориды, железо и сульфаты выражены минимальные риски в один из сезонов, однако ПДК не превышают. Несмотря на отсутствие сезонности компонентов, представляется интересным оценка тенденций изменения показателей за многолетний период (рис. 2, 3).

Линии тренда по взвешенным веществам, хлоридам и окисляемости — возрастают, однако не критично и предельно допу-

¹ СанПиН 10-124 РБ-99. Питьевая вода. Гигиенические требования к качеству воды централизованных систем питьевого водоснабжения. Контроль качества. Введ. 2000–01–01. Минск : Минздрав Респ. Беларусь, 2000. 9 с.

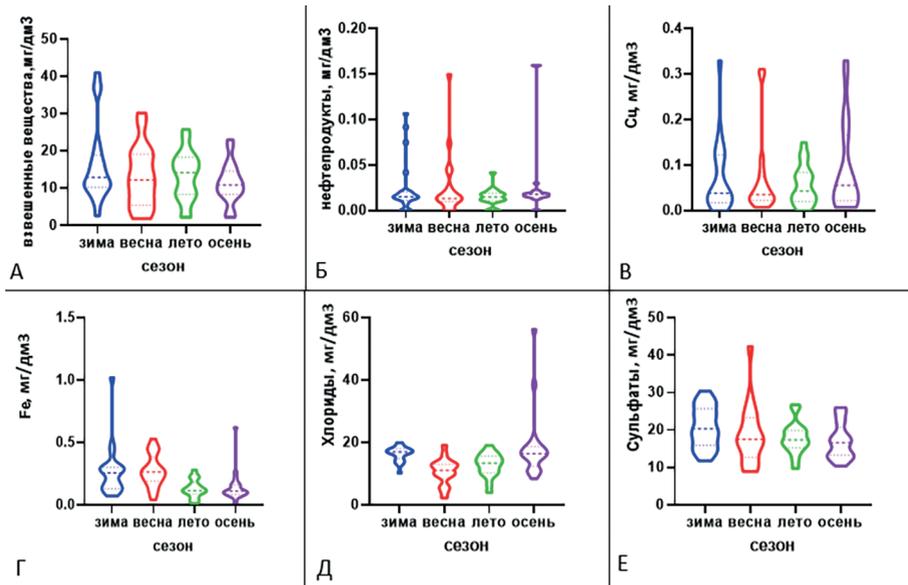


Рис. 1. Сезонная зависимость по показателям: А – взвешенные вещества; Б – нефтепродукты, В – медь, Г – железо, Д – хлориды, Е – сульфаты



Рис. 2. Линия тренда по показателю «Cu»

стимулю концентрацию не достигают; по меди, нефтепродуктам, железу наблюдается — снижение.

Для выполнения прогнозирования использовалась многослойная искусственная нейронная сеть с тождественной функцией активации; с классической архитектурой прямого распространения MLP (Multilayer Perceptron) (рис. 4) [15; 16]. Применение данной архитектуры обуславливается её производительностью и возможностью решать множество поставленных задач, однако основными проблемами являются многозадачность (число параметров 1 млн) и затухающие градиенты (в случае, если много слоёв), что усложняют их обучение [16].

Обучение ИНС проведено по выборкам, разделённым в соотношении 70 : 15: 15 % для обучающей, тестовой и валидаци-

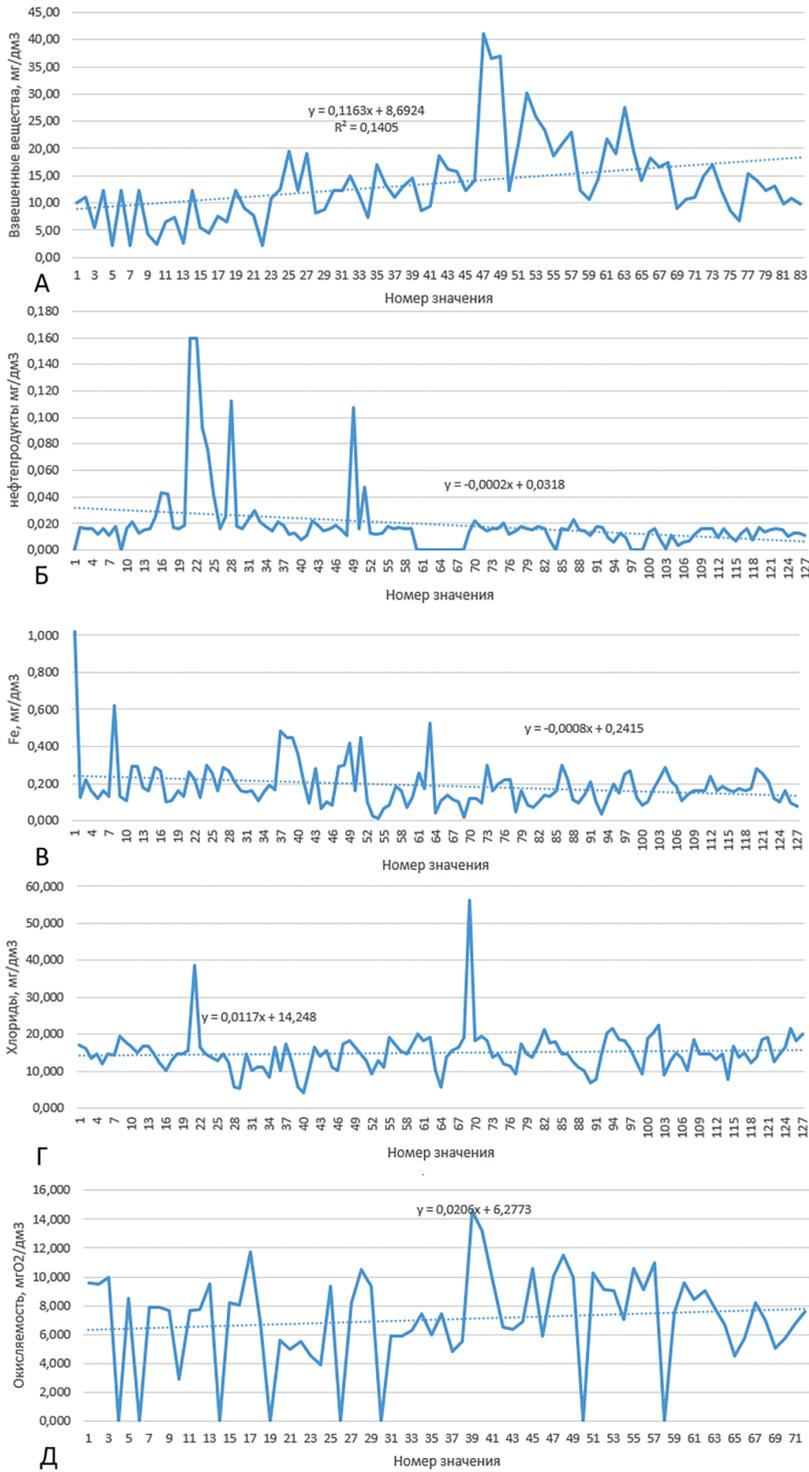


Рис. 3. Линии тренда по показателям: А — взвешенные вещества, Б — нефтепродукты, В — Fe, Г — хлориды, Д — окисляемость

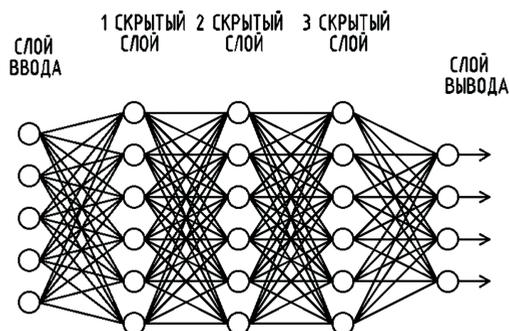


Рис. 4. Архитектура MLP

онной, соответственно. Среди ряда предложенных нейронных сетей одной архитектуры выбирались с наименьшей среднеквадратической ошибкой (mse), и с наибольшей производительностью [15; 17–21]. Для каждого из контролируемых параметров принята собственная нейронная сеть: определены производительность обучающей выборки и контрольная производительность; вычислены ошибки обучения, контрольные ошибки (табл.), удалось построить прогнозные модели по отдельным показателям (рис. 5, 6) [22].

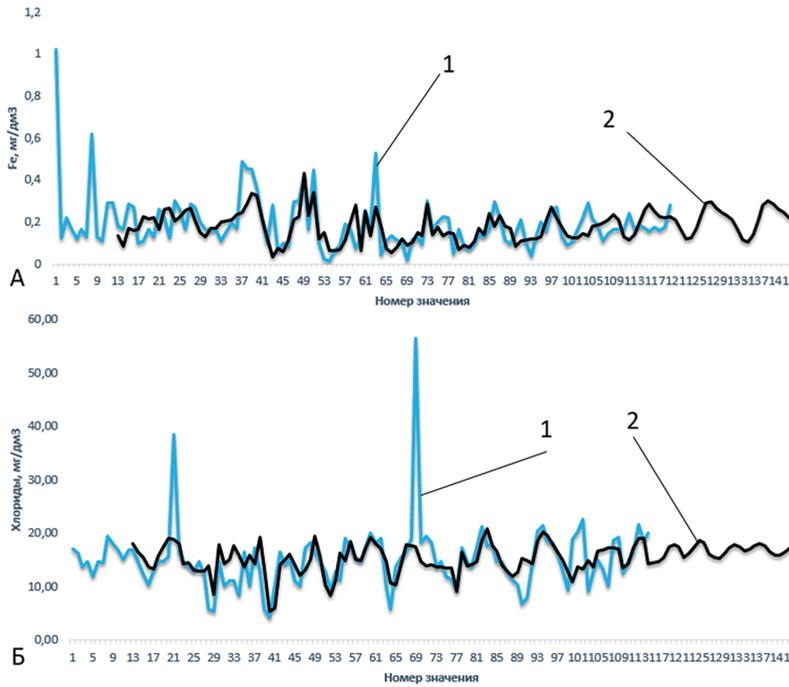
Таблица

Выборка наилучших нейронных сетей по каждому показателю

Показатель	Архитектура	Производительность сети	Ошибка обучения	Контрольная ошибка	Алгоритм обучения
Нефтепродукты	MLP 12-1-1	0,5732	0,0002	0,0002	BFGS 85
Железо	MLP 12-10-1	0,6974	0,0025	0,0042	BFGS 35
Хлориды	MLP 12-1-1	0,4501	0,3813	5,101	RBFT
Сульфаты	MLP 12-1-1	0,6686	6,9797	8,8504	BFGS 34

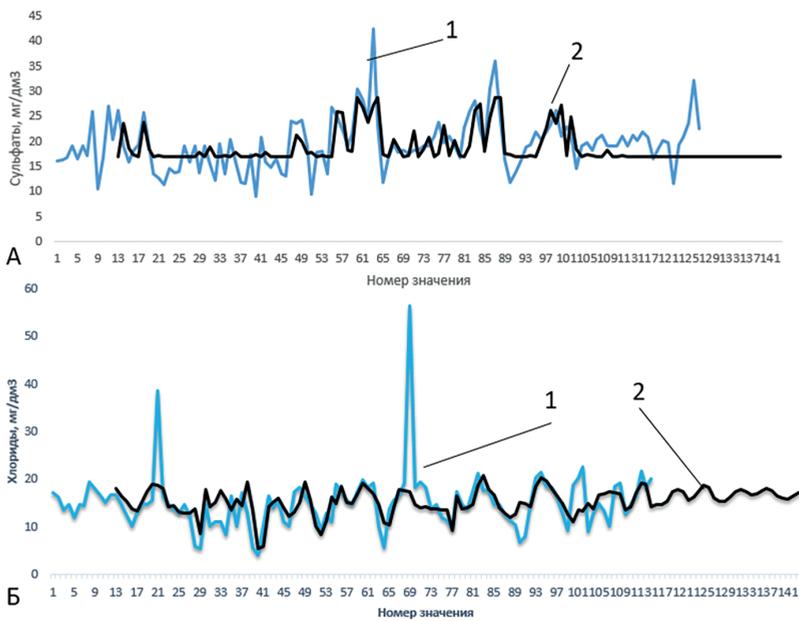
Использование ИНС позволило получить прогнозную модель с относительно высокой производительностью и низкими ошибками на обучающей и контрольных выборках (табл.). В связи с относительно низкой производительностью ИНС по нефтепродуктам, хлоридам и высокими величинами ошибок по сульфатам, практическое применение данных ИНС не представляется целесообразным.

Результат: опираясь на графические изображения на скрипичных диаграммах и линиях тренда, можно сделать вывод об отсутствии ярко выраженной сезонности. Оценка изменения хлоридов, взвешенных веществ, окисляемости показала тенденцию к увеличению показателей, по нефтепродуктам, меди, железу — к снижению. Применение ИНС позволило построить прогнозную



1 — фактические значения, 2 — спрогнозированные значения

Рис. 5. Машинное прогнозирование для: А — железа, Б — хлоридов



1 — фактические значения, 2 — спрогнозированные значения

Рис. 6. Машинное прогнозирование для: А — сульфатов, Б — нефтепродуктов

модель с относительно приемлемой производительностью (около 0,7) и ошибками на обучающей и контрольных выборках, не превышающих 0,25 и 0,45 %, соответственно. В целом, отмечается стабильность показателей исходной воды, поступающий для технологических нужд филиала «Гомельской ТЭЦ-2» РУП «Гомельэнерго», следовательно, помесечный расчёт доз реагентов не целесообразен.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Хайкин С. Нейронные сети: полный курс / С. Хайкин ; пер. с англ. — Москва : Вильямс, 2006. — 1104 с.
2. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. — 2-е изд., стереотип. — Москва : Горячая линия—Телеком, 2002. — 382 с.
3. Adamowski J. A Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting / J. Adamowski, H.F. Chan // *Journal of Hydrology*. — 2011. — Vol. 407, iss. 1-4. — P. 28–40.
4. Ширяев В.И. Финансовые рынки: Нейронные сети, хаос и нелинейная динамика / В.И. Ширяев. — Москва : Ленанд, 2019. — 232 с.
5. Ghiassi M. Urban Water Demand Forecasting with a Dynamic Artificial Neural Network Model / M. Ghiassi, D.K. Zimbra, H. Saidane // *Journal of Water Resources Planning and Management*. — 2008. — Vol. 134, iss. 2. — P. 138–146.
6. Wu W. Protocol for Developing ANN Models and its Application to the Assessment of the Quality of the ANN Model Development Process in Drinking Water Quality Modeling / W. Wu, G.C. Dandy, R.M. Holger // *Environmental Modelling & Software*. — 2014. — Vol. 54, iss. 1. — P. 108–127.
7. Kuruñça A. Performance of two stochastic approaches for forecasting water quality and streamflow data from Yeşilirmak River, Turkey / A. Kuruñça, K. Yürekli, O. Çevikb // *Environmental Modelling & Software*. — 2005. — Vol. 20, iss. 9. — P. 1195–1200.
8. Lee D.J. A Stochastic Model of River Water Quality: Application to Salinity in the Colorado River / D.J. Lee, R.E. Howitt, M.A. Mariño // *Water Resources Research*. — 1993. — Vol. 29, iss. 12 — P. 3917–3923.
9. Lehmann A. Long-Term Behaviour and Cross-Correlation Water Quality Analysis of the River Elbe, Germany / A. Lehmann, M. Rode // *Water Research*. — 2001. — Vol. 35, iss. 9. — P. 2153–2160.
10. Parmar K.S. Water Quality Management Using Statistical Analysis and Time-Series Prediction Model / K.S. Parmar, R. Bhardwaj // *Applied Water Science*. — 2014. — Vol. 4, iss. 4. — P. 425–434.
11. Zetterqvist L. Statistical Estimation and Interpretation of Trends in Water Quality Time Series / L. Zetterqvist // *Water Resources Research*. — 1991. — Vol. 27, iss. 7. — P. 1637–1648.
12. Leontaritis I.J. Input-Output Parametric Models for Non-Linear Systems Part I: Deterministic Non-Linear Systems / I.J. Leontaritis, S.A. Billings // *International Journal of Control*. — 1985. — Vol. 41, iss. 2. — P. 303–328.
13. Maier R.H. The Use of Artificial Neural Networks for the Prediction of Water Quality Parameters / R.H. Maier, C.G. Dandy // *Water Resources Research*. — 1996. — Vol. 32, iss. 4 — P. 1013–1022.
14. Chen S. Representations of Non-Linear Systems: the NARMAX Model / S. Chen, S.A. Billings // *International Journal of Control*. — 1989. — Vol. 49, iss. 3. — P. 1013–1032.

15. Рогозина Т.А. Исследование качества речных вод в условиях антропогенного воздействия (на примере Уфимского бассейна) : дис. ... канд. географ. наук : 25.00.36 / Т.А. Рогозина. – Санкт-Петербург, 2008. — 202 с.
16. Игнатьев Н.А. Выбор минимальной конфигурации нейронных сетей / Н.А. Игнатьев // Вычислительные технологии. — 2001. — Т. 6, № 1. — С. 23–28.
17. Степанов П.П. Искусственные нейронные сети / П.П. Степанов // Молодой ученый. — 2017. — № 4 (138). — С. 185–187.
18. Потылицына Е.Н. Использование искусственных нейронных сетей для решения прикладных экологических задач / Е.Н. Потылицына, Л.В. Липинский, Е.В. Сугак // Современные проблемы науки и образования. — 2013. — № 4. — URL: <http://science-education.ru/ru/article/view?id=9779>.
19. Sarkara A. River Water Quality Modelling using Artificial Neural Network Technique / A. Sarkara, P. Pandey // Aquatic Procedia. — 2015. — Vol. 4. — P. 1070–1077.
20. Прогнозирование значений цветности питьевых и исходных вод с помощью ARIMA-модели и нейронной сети / Д.В. Макаров, Е.А. Кантор, Н.А. Красулина [и др.] // Юг России: экология, развитие. — 2019. — Т. 14, № 1. — С. 159–168.
21. Gorban A.N. Neuroinformatics: What are us, where are we going, how to measure our way? / A.N. Gorban. — Washington, 1999. — 9 p. — URL: <https://arxiv.org/ftp/cond-mat/papers/0307/0307346.pdf>.
22. Осовский С. Нейронные сети для обработки информации / С. Осовский ; пер. с пол. — Москва : Финансы и статистика, 2004. — 344 с.

REFERENCES

1. Haykin S. *Neural Networks*. Upper Saddle River, Prentice Hall, 1999. 897 p. (Russ. ed.: Haykin S. *Neironnye seti: polnyi kurs*. Moscow, Vil'yams Publ., 2006. 1104 p.).
2. Kruglov V.V., Borisov V.V. *Iskusstvennyye neironnye seti. Teoriya i praktika* [Artificial Neural Networks. Theory and Practice]. 2nd ed. Moscow, Goryachaya liniya–Telekom Publ., 2002. 382 p.
3. Adamowski J., Chan H.F. Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting. *Journal of Hydrology*, 2011, vol. 407, iss. 1-4, pp. 28–40.
4. Shiryayev V.I. *Finansovye rynki: Neironnye seti, khaos i nelineinaya dinamika* [Financial Markets: Neural Networks, Chaos and Nonlinear Dynamics]. Moscow, Lenand Publ., 2019. 232 p.
5. Ghiassi M., Zimbra D.K., Saidane H. Urban Water Demand Forecasting with a Dynamic Artificial Neural Network Model. *Journal of Water Resources Planning and Management*, 2008, vol. 134, iss. 2, pp. 138–146.
6. Wu W., Dandy G.C., Holger R.M. Protocol for Developing ANN Models and its Application to the Assessment of the Quality of the ANN Model Development Process in Drinking Water Quality Modeling. *Environmental Modelling & Software*, 2014, vol. 54, iss. 1, pp. 108–127.
7. Kurunça A., Yürekli K., Çevikb O. Performance of two stochastic approaches for forecasting water quality and streamflow data from Yeşilirmak River, Turkey. *Environmental Modelling & Software*, 2005, vol. 20, iss. 9, pp. 1195–1200.
8. Lee D.J., Howitt R.E., Mariño M.A. A Stochastic Model of River Water Quality: Application to Salinity in the Colorado River. *Water Resources Research*, 1993, vol. 29, iss. 12, pp. 3917–3923.
9. Lehmann A., Rode M. Long-Term Behaviour and Cross-Correlation Water Quality Analysis of the River Elbe, Germany. *Water Research*, 2001, vol. 35, iss. 9, pp. 2153–2160.

10. Parmar K.S., Bhardwaj R. Water Quality Management Using Statistical Analysis and Time-Series Prediction Model. *Applied Water Science*, 2014, vol. 4, iss. 4, pp. 425–434.
11. Zetterqvist L. Statistical Estimation and Interpretation of Trends in Water Quality Time Series. *Water Resources Research*, 1991, vol. 27, iss. 7, pp. 1637–1648.
12. Leontaritis I.J., Billings S.A. Input-Output Parametric Models for Non-Linear Systems Part I: Deterministic Non-Linear Systems. *International Journal of Control*, 1985, vol. 41, iss. 2, pp. 303–328.
13. Maier R.H., Dandy C.G. The Use of Artificial Neural Networks for the Prediction of Water Quality Parameters. *Water Resources Research*, 1996, vol. 32, iss. 4, pp. 1013–1022.
14. Chen S., Billings S.A. Representations of Non-Linear Systems: the NAR-MAX Model. *International Journal of Control*, 1989, vol. 49, iss. 3, pp. 1013–1032.
15. Rogozina T.A. *Issledovanie kachestva rechnykh vod v usloviyakh antropogennogo vozdeistviya (na primere Ufimskogo basseina)*. Kand. Diss. [The study of river water quality under the anthropogenic impact (using the example of Ufa basin) Cand. Diss.]. Saint-Petersburg, 2008. 202 p.
16. Ignatyev N.A. Selection of the Minimum Configuration of Neuron Networks. *Vychislitel'nye tekhnologii = Computational Technologies*, 2001, vol. 6, no. 1, pp. 23–28. (In Russian).
17. Stepanov P.P. Artificial Neural Networks. *Molodoi uchenyi = Young Scientist*, 2017, no. 4 (138), pp. 185–187. (In Russian).
18. Potylitsyna E.N., Lipinskiy L.V., Sugak E.V. The Use of Artificial Neural Networks for Applied Environmental Problems. *Sovremennye problemy nauki i obrazovaniya = Modern Problems of Science and Education*, 2013, no. 4. Available at: <http://science-education.ru/ru/article/view?id=9779>. (In Russian).
19. Sarkara A., Pandey P. River Water Quality Modelling using Artificial Neural Network Technique. *Aquatic Procedia*, 2015, vol. 4, pp. 1070–1077.
20. Makarov D.V., Kantor E.A., Krasulina N.A., Greb A.V., Berezhnova Z.Z. Forecasting Values of Chromaticity of Drinking and Source Waters using Arima Model and Neural Network. *Yug Rossii: ekologiya, razvitie = South of Russia: ecology, development*, 2019, vol. 14, no. 1, pp. 159–168. (In Russian).
21. Gorban A.N. *Neuroinformatics: What are us, where are we going, how to measure our way?* Washington, 1999. 9 p. Available at: <https://arxiv.org/ftp/cond-mat/papers/0307/0307346.pdf>.
22. Osowski S. *Sieci neuronowe do przetwarzania informacji*. Warszawa, Oficyna Wydawnicza Politechniki Warszawskiej, 2000. 327 s. (Russ. ed.: Osowski S. *Neironnye seti dlya obrabotki informatsii*. Moscow, Finansy i statistika Publ., 2004. 344 p.).

ИНФОРМАЦИЯ ОБ АВТОРЕ

Коваленко Виталий Николаевич — студент, строительного факультета; техник, кафедра водоснабжение, химия и экология, Белорусский государственный университет транспорта, г. Гомель, Республика Беларусь, e-mail: kovalbuu@gmail.com.

Дмитрий Вадимович Макаров — учебный мастер кафедры Физика Федерального государственного бюджетного образовательного учреждения высшего образования, Уфимский государственный нефтяной технический университет, г. Уфа, Российская Федерация, e-mail: dmitrij.makarov-1990@yandex.ru.

Регина Николаевна Вострова — кандидат технических наук, доцент кафедры водоснабжение, химия и экология, Белорусского государственного университета транспорта, г. Гомель, Республика Беларусь, e-mail: vostrova@tut.by.

INFORMATION ABOUT THE AUTHOR

Vitali Nikolaevich Kovalenko — Student, Department of Transportation Engineering and Construction; Technician of department engineer, water supply, chemistry and ecology, Belarusian State University of Transport, Gomel, Republic of Belarus, e-mail: kovalbyy@gmail.com.

Dmitry Vadimovich Makarov — teaching master of Physics department, Federal State Budgetary Educational Institution of Higher Education, Ufa State Petroleum Technological University, Ufa, Russian Federation, e-mail: dmitrij.makarov-1990@yandex.ru.

Regina Nikolaevna Vostrova — candidate of Technical Sciences, Associate Professor of engineering, water supply, chemistry and ecology, Belarusian State University of Transport, Gomel, Republic of Belarus, e-mail: vostrova@tut.by.

ДЛЯ ЦИТИРОВАНИЯ

Коваленко В.Н. Применение нейронных сетей в системе водоснабжения / В.Н. Коваленко, Д.В. Макаров, Р.Н. Вострова // *System Analysis & Mathematical Modeling*. — 2020. — Т. 2, № 3. — С. 62–74.

FOR CITATION

Kovalenko V.N., Makarov D.V., Vostrova R.N. Application of Neural Networks in the Water Supply System. *System Analysis & Mathematical Modeling*, 2020, vol. 2, no. 3, pp. 62–74. (In Russian).