

Гидравлика и инженерная гидрология

Научная статья

УДК 556.11

DOI: 10.26897/1997-6011-2023-1-62-68

**ИДЕНТИФИКАЦИЯ ПРЕДПРИЯТИЙ-ЗАГРЯЗНИТЕЛЕЙ ВОДЫ
НА ОСНОВЕ НЕЙРОСЕТЕВОГО АНАЛИЗА****Розенталь Олег Моисеевич** [✉], д-р техн. наук, профессор

orcid 0000-0001-6261-6060; AuthorID: 639330; SPIN-код: 4857-7570; omro3@yandex.ru

Федотов Владислав Харитонович ², канд. хим. наук, доцент

orcid = 0000-0001-8395-6849; SPIN-код = 5111-9580; AuthorID = 8882; Web of Science ResearcherID = B-6529-2017; fvh@inbox.ru

¹ Институт водных проблем Российской академии наук; 119333, г. Москва, ул. Губкина, 3, Россия² Чувашский государственный университет им. И.Н. Ульянова; 428015, Чувашская Республика, г. Чебоксары, Московский пр-т, 15, Россия

Аннотация. Целью исследований явилось решение задачи повышения эффективности обнаружения крупных предприятий-загрязнителей природной воды из числа многих водопользователей промышленного региона. Для достижения цели были использованы искусственные нейронные сети (ИНС), позволяющие выявлять и оценивать веса связей между статистическими данными, что важно для изучения динамики формирования качества воды в условиях его пространственно-временной вариабельности. Работа выполнена на примере имеющихся 250 измерений концентрации каждого из четырех приоритетных металлов на гидрохимических створах р. Исеть в зоне г. Екатеринбурга. Нейросетевой анализ позволил обнаружить взаимозависимости отдельных показателей качества воды на соседних створах: в пунктах выше г. Екатеринбурга (+5,2 км, створ 1), в городе (створ 2) и ниже его (-4 км, створ 3), итого в $3 \times 4 \times 250 = 3000$ точках. Было установлено, в частности, что влияние содержания никеля в воде створа 2 на концентрацию других металлов створа 3, особенно на цинк, является достаточно высоким, так что коэффициент корреляции оказывается не ниже 0.6. Подобные результаты позволили установить логистические хозяйственные связи водопользователей и упростить идентификацию загрязнителей воды по «водному следу», оставленному предприятиями-смежниками. Тем самым показано, что ИНС обеспечивает выявление техногенного снижения качества воды на фоне ее природного загрязнения одними и теми же веществами. Достоверность выводов подтверждается возможностью удовлетворительно предсказывать качество воды створа, расположенного ниже по течению реки, по данным для створа, расположенного выше, как это установлено в работе путем прогноза качества воды с помощью ИНС.

Ключевые слова: качество воды, производственные сбросы, водный след, искусственные нейронные сети, нейросетевой анализ, гидрохимический створ

Формат цитирования: Розенталь О.М., Федотов В.Х. Идентификация предприятий-загрязнителей воды на основе нейросетевого анализа // Природообустройство. 2023. № 1. С. 62-68. DOI: 10.26897/1997-6011-2023-1-62-68.

Работа выполнена в рамках Государственного задания ФГБУН Института водных проблем РАН (тема № FMWZ-2022-0003)

© Розенталь О.М., Федотов В.Х., 2023

Original article

**IDENTIFICATION OF WATER POLLUTING ENTERPRISES
BASED ON NEURAL NETWORK ANALYSIS****Rozental Oleg Moiseevich** [✉], doctor of technical sciences, professor

orcid 0000-0001-6261-6060; AuthorID: 639330; SPIN-код: 4857-7570; omro3@yandex.ru

Fedotov Vladislav Kharitonovich², candidate of chemical sciences, associate professor

orcid = 0000-0001-8395-6849; SPIN-код = 5111-9580; AuthorID = 8882; Web of Science ResearcherID = B-6529-2017; fvh@inbox.ru

¹ Institute of Water Problems of the Russian Academy of Sciences; 119333, Moscow, st. Gubkina, 3, Russia

² Chuvash State University named after I.N. Ulyanova; 428015, Chuvash Republic, Cheboksary, Moskovsky Ave, 15, Russia

Annotation. *The aim of the work was to solve the problem of increasing the efficiency of identifying large enterprises that pollute natural water from among many water users of the industrial region. For this purpose, artificial neural networks (INS) were used to detect and evaluate the weights of connections between statistical data, which is important for studying the dynamics of water quality formation in conditions of its spatial and temporal variability. The work was carried out on the example of the available 250 measurements of the concentration of each of the four priority metals at the hydro chemical gates of the Iset River in the area of Yekaterinburg. Neural network analysis made it possible to detect the interdependencies of individual water quality indicators at neighboring sites. At points above Yekaterinburg (+5.2 km, target 1), in the city (target 2) and below it (–4 km, target 3), in total at $3 \times 4 \times 250 = 3000$ points. It was found, in particular, that the effect of the nickel content in the water of the gate 2 on the concentration of other metals of the gate 3, especially zinc, is quite high, so that the correlation coefficient is not lower than 0.6. Such results made it possible to identify the logistical economic ties of water users and simplify the identification of water pollutants by the “water footprint” left by related enterprises. Thus, it is shown that the INS provides the identification of a man-made decrease in water quality against the background of its natural pollution with the same substances. The reliability of the conclusions is confirmed by the ability to satisfactorily predict the water quality of the section located downstream of the river, according to the data for the section located above, as established in the work by predicting water quality using the INS.*

Keywords: *water quality, industrial discharges, water footprint, artificial neural networks, neural network analysis, hydro chemical gate*

Format of citation: *Rosenthal O.M., Fedotov V.Kh. Identification of water polluting enterprises based on neural network analysis // Prirodoobustrojstvo. 2023. No. 1. S. 62-68. DOI: 10.26897/1997-6011-2023-1-62-68.*

The work was carried out within the framework of the State Task of the FGBUN Institute of Water Problems of the Russian Academy of Sciences (topic No FMWZ-2022-0003)

Введение. Качество речной воды селитебных территорий позволяет судить о характере человеческой деятельности [1], например, для выявления ковида-19 [2]. Не менее важной является также идентификация источников загрязнения вод производственными отходами, что, однако, трудно выполнить в промышленных регионах ввиду обилия предприятий-загрязнителей [3]. Поэтому полезным является развитие методологии идентификации на основе независимой гидрометеорологической информации, позволяющей изучить динамику формирования качества воды в условиях его пространственно-временной variability.

Материалы и методы исследований. *Трудности идентификации предприятий-загрязнителей в существующей системе водно-экологического регулирования.* Идентификация предприятий-загрязнителей в существующей системе водно-экологического регулирования затруднена в условиях развитого промышленного региона. Проиллюстрируем это на результатах измерения качества воды, полученных в 1990-2010 гг. Уральским управлением Росгидромета на гидрохимических створах р. Исеть (правый приток Тобола).

Использовались результаты 250 измерений концентрации четырех приоритетных металлов в пунктах выше г. Екатеринбург (+5,2 км, створ 1), в городе (створ 2) и ниже его (–4 км, створ 3), итого $3 \times 4 \times 250 = 3000$ точек. Обнаружилось, что концентрация железа (здесь и далее – мг/дм³, для остальных металлов – в мкг/дм³) изменяется в диапазоне от 0,05 до 5; меди – от 2 до 500; цинка – от 1 до 1000; никеля – от 0 до 500. В результате наблюдается ситуация полного хаоса, при котором признаки variability: размах, амплитуда, среднее квадратическое отклонение концентрации – превышают их средние значения (рис. 1).

В подобной ситуации ограничиваются оценкой средних значений контролируемых показателей [4, 5], по которым нетрудно сравнить качество вод на разных створах. Так, из рисунка 2 следует, что на участке р. Исеть между створами 1 и 2 качество воды снижается по цветным металлам практически вдвое, а на участке 2→3 изменяется меньше по всем металлам, кроме цинка, среднее содержание которого повышается втрое.

Возникает первоочередная задача снижения сбросов соединений цинка как особо токсичного загрязнения [6]. Однако непросто выявить

основные предприятия-загрязнители в развитом промышленном регионе с его металлургическими, машиностроительными, металлообрабатывающими, химическими производствами, где соли цинка используются для нанесения покрытий, травления, обезжиривания и т.д. Как правило, эти производства оснащены очистными сооружениями, но резкий рост цинка на створе 3 означает, что часть из них не работает в плановом режиме, гарантирующем полноту водоподготовки. Неочевидным является и то, происходит точечное (сосредоточенное) загрязнение вод или преобладает неточечный (диффузный) сток с производственных площадок [7]. Здесь недостаточно используемых на практике методов оценки качества воды, поэтому рассмотрены возможности исследования динамики его формирования на основе искусственных нейронных сетей (ИНС).

Метод исследования: искусственные нейронные сети для бинарных и тернарной систем. Отличительной особенностью ИНС является их способность оценивать выходную статистическую информацию на основе входной в режиме самообучения, обеспечивающем наилучшее соответствие исходных и расчетных данных. Для этого задается типовая архитектура ИНС (линейные сети, временные ряды, многослойные перцептроны) и выбирается подходящий алгоритм оптимизации (обучения) [8, 9]. В результате осуществляется автоматизированный процесс описания данных, пригодный и для высоковариационных рядов, как показано на рисунке 1.

ИНС использовались для поиска взаимной зависимости «водных следов» [10] сбросов загрязнений на соседних створах реки. Такая зависимость возникает при наличии тесных логистических хозяйственных связей смежных

производств, работающих синхронно. Принималось, что тем самым удастся облегчить идентификацию предприятий-загрязнителей по признаку сходной вариабельности контролируемых показателей сбросов [1, 2].

Анализировали веса нейросвязей и статистику нейрорегрессий (характеристики их точности и множественные коэффициенты корреляции Пирсона) с учетом влияния суммы загрязнений на каждое из них и влияния каждого загрязнителя на каждый.

Результаты и их обсуждение. Взаимосвязь суммы металлов створа 1 на каждый из них на створе 2 исследовалась с помощью полносвязной бинарной линейной нейросети архитектуры «4-4», где первая цифра обозначает число металлов на входном, а вторая – на выходном створе (табл. 1).

В таблице 1 показатель Error Mean близок к нулю, то есть нейросеть, обученная на результатах замеров на створах 1 и 2, практически без ошибок воспроизводит исходные данные на этих створах. При этом разброс расчетных значений даже несколько меньше разброса исходных значений. Видим также, что Abs E. Mean больше Error Mean, то есть знаки разностей измеренных и расчетных значений примерно равномерно чередуются и при вычислении Error Mean взаимно погашаются. Кроме того, S.D. Ratio меньше единицы, то есть нейрорегрессия дает меньшие отклонения, чем исходные данные. Коэффициент корреляции здесь варьирует от среднего (влияние металлов створа 1 на Cu²⁺) до умеренного (Fe²⁺) и слабого (Zn²⁺, Ni²⁺) уровней. Это позволяет сделать предположение о возможном пополнении природных загрязнений воды медью

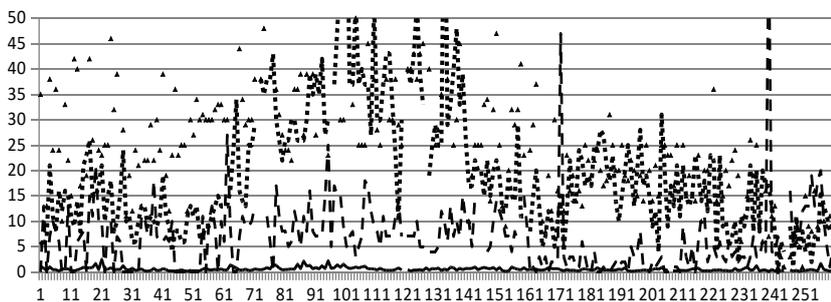


Рис. 1. Ежемесячные измерения концентрации соединений в 1990-2010 гг. на створе 1:

железа общего (сплошная линия); никеля (штриховая); меди (пунктирная); цинка (треугольные маркеры) (результаты, превышающие 50 абс. ед., исключены)

Fig. 1. Monthly measurements of the concentration of compounds in 1990-2010 on gate 1990-2010: total iron (solid line), nickel (dashed), copper (dotted), zinc (triangular markers).

Note: Results exceeding 50 abs. units, excluded

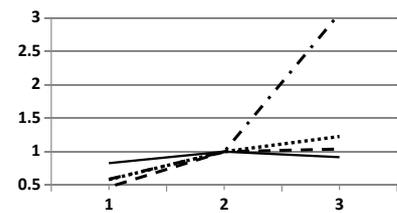


Рис. 2. Средняя концентрация загрязнителей по цветным металлам:

створ 2 – железа общего (сплошная линия); никеля (штриховая); меди (пунктирная); створ 1 и 3 – цинка (штрих-пунктирная)

Fig. 2. Average concentration of pollutants for non-ferrous metals: gate 2 – total iron (solid line), nickel (dashed), copper (dotted) target 1 and 3 – zinc (dash-dotted)

в предместье Екатеринбурга, а также об отсутствии избыточных сбросов соединений цинка и никеля на участке реки между створами 1 и 2.

Другой результат получен для участка реки между створами 2 и 3 (табл. 2), где повышенная корреляция наблюдается для Zn3 и Ni3. При этом снизился разброс корреляций – эффект, вероятно, связанный с однотипными системами очистки сточных вод на взаимозависимых производствах (цехах).

Из таблицы 2 следует, что показатель Error Mean, как и в таблице 1, близок к нулю, то есть нейросеть хорошо воспроизводит исходные данные. Показатель S.D. Ratio почти не изменился по сравнению с приведенным в таблице 1, но коэффициенты корреляции повысились, особенно

по Zn3 и Ni3. Это указывает на пополнение природных загрязнений сбросами.

Повышенное снижение разброса корреляций обнаруживается для полносвязной тернарной системы створов (1+2)→3, исследованной с помощью нейросети архитектуры «8-4» (табл. 3).

Из данных таблицы 3 следует, что нейросеть, обученная на результатах замеров на створах 1, 2 и 3, хорошо воспроизводит исходные данные. Разброс расчетных значений также меньше разброса исходных значений, а показатель S.D. Ratio снизился, свидетельствуя о том, что тернарная нейрорегрессия несколько точнее бинарной. Коэффициенты корреляции по всем металлам также стали выше, чем в таблицах 1 и 2.

Таблица 1. Результаты обучения нейросети «4-4» створов 1→2

Table 1. Learning results of neural network «4-4» gates 1→2

	Fe2	Cu2	Zn2	Ni2
Data Mean	0.67	34.01	47.83	13.94
Data S.D.	0.54	23.56	56.74	16.19
Error Mean	0	0	0	0.17
Error S.D.	0.48	18.59	55.85	15.53
Abs E. Mean	0.34	13.89	23.96	9.59
S.D. Ratio	0.89	0.78	0.98	0.95
Correlation	0.43	0.61	0.17	0.28

Примечание. Здесь и далее: цифра после обозначения металла соответствует номеру створа.

Data Mean – среднее значение концентрации вещества на выходном створе.

Data Standard Deviation (S.D.) – стандартное отклонение концентрации на выходном створе.

Error Mean – среднее значение разности между измеренным и расчетным (по нейросети) значениями концентрации на выходном створе.

Error S.D. – стандартное отклонение исходных данных от расчетных по нейросети.

Abs E. Mean – абсолютная средняя ошибка (среднее арифметическое модулей разностей между исходным и расчетным значениями концентрации на выходном створе).

S.D. Ratio = Error S.D./Data S.D. – относительная ошибка нейрорегрессии.

Correlation – коэффициент множественной корреляции.

Note to Table. 1. Hereinafter: the digit after the designation of the metal corresponds to the number of the gate.

Data Mean – the average value of the concentration of the substance on the output gate. Data Standard Deviation (S.D.) is a standard deviation of the concentration on the output gate.

Error Mean – the average value of the difference between the measured and calculated (according to the neural network) concentration values on the output gate.

Error S.D. – standard deviation of the initial data from the calculated ones on the neural network. Abs E. Mean – absolute mean error (the arithmetic mean of the modules of the differences between the initial and calculated values of the concentration on the output gate).

S.D. Ratio = Error S.D./Data S.D. – relative error of neuro regression.

Correlation – multiple correlation coefficient.

Таблица 2. Результаты обучения нейросети «4-4» створов 2→3

Table 2. Learning results of neural network «4-4» gates 2→3

	Fe3	Cu3	Zn3	Ni3
Data Mean	0.63	42.86	150.11	14.46
Data S.D.	0.58	39.21	266.74	13.58
Error Mean	0.00	0.17	1.22	0.23
Error S.D.	0.54	34.31	212.19	10.89
Abs E. Mean	0.36	19.34	123.62	7.92
S.D. Ratio	0.92	0.87	0.79	0.80
Correlation	0.37	0.48	0.60	0.59

Таблица 3. Результат обучения нейросети «8-4»

Table 3. Learning results of neural network «4-4» gates 8→4

	Fe3	Cu3	Zn3	Ni3
Data Mean	0.63	42.86	150.11	14.46
Data S.D.	0.58	39.21	266.74	13.58
Error Mean	0.00	0.17	1.22	0.23
Error S.D.	0.52	33.89	202.12	10.30
Abs E. Mean	0.35	19.34	123.50	7.39
S.D. Ratio	0.88	0.86	0.75	0.75
Correlation	0.45	0.50	0.65	0.65

Дополнительное по сравнению с данными таблиц 1 и 2 снижение разброса корреляций и их повышение в целом свидетельствуют о существовании тесных логистических хозяйственных связей предприятий рассматриваемого промышленного региона. Таков обмен сырьем, материалами и продуктами, вариабельность которого усиливается или ослабевает одновременно со сбросами.

Дифференцированное влияние загрязняющих воду металлов «каждого на каждый» рассчитывалось через веса нейросвязей (нейросетевые аналоги коэффициентов корреляции), дополняющих и уточняющих регрессионную статистику. В программе SNN веса подбираются с помощью нейросетевых оптимизационных алгоритмов обучения [8], обеспечивая наилучшее соответствие исходных и расчетных данных. Результаты обучения зависят от таких его параметров, как число эпох обучения (итераций), ошибка обучения, начальные веса связей и др. В данных исследованиях расчеты производились с использованием стандартных значений параметров обучения. Веса нейросвязей, рассчитанные для бинарных систем, приведены ниже.

Значения Threshold малы, как следует из таблиц 4 и 5, что указывает на незначительное влияние неучтенных факторов. Согласно данным таблицы 4 отчетливо проявляется влияние концентрации меди Cu1 на створе 1 на медь Cu2 на створе 2 (вес 0.65), что согласуется с данными таблицы 1 (где корреляция для Cu20.61). Это подтверждает вывод о природном

Таблица 4. Веса нейросвязей в системе Створ 1 → Створ 2

Table 4. Weights of neurocommunications in the system Gate 1 → Gate 2

	Fe2	Cu2	Zn2	Ni2
Threshold	-0.04	-0.06	-0.03	-0.04
Fe1	0.14	0.11	0.00	0.09
Cu1	-0.04	0.65	0.03	-0.11
Zn1	0.48	0.08	0.05	0.16
Ni1	0.15	0.00	-0.02	0.08

Таблица 5. Веса нейросвязей в системе Створ2 → Створ3

Table 5. Weights of neurocommunications in the system Gate 2 → Gate 3

	Fe3	Cu3	Zn3	Ni3
Threshold	-0.06	-0.05	-0.04	-0.07
Fe2	0.10	0.06	0.13	0.21
Cu2	0.08	-0.00	-0.23	-0.07
Zn2	0.19	0.06	0.18	0.17
Ni2	0.35	0.46	0.80	0.64

Примечание. Threshold – веса пороговых (неявных) связей, соединяющих «пороговые» нейроны с соответствующим выходным нейроном, отражающие влияние неучтенных факторов на выходной створ.

Note. Threshold – the weights of threshold (implicit) connections connecting the “threshold” neurons with the corresponding output neuron, reflecting the influence of unaccounted factors on the output gate.

происхождении меди, возможно, поступающей в речной поток при выщелачивании подстилающих пород в верховьях Исети. Согласно данным таблицы 5 отчетливо проявляется влияние Ni2 на металлы створа 3, особенно на Zn3, что согласуется с данными таблицы 2 (где коэффициент корреляции для Zn30.60).

На практике к настоящему времени основные предприятия-загрязнители установлены, и избыточное накопление солей цинка на створе 3 р. Исеть прекращено. Однако для этого потребовались немалые усилия межрегиональной прокуратуры с привлечением общественного экологического контроля. Между тем нейросетевая идентификация хозяйственных связей производителей и потребителей никельсодержащего сырья, сбрасывающих стоки в зонах створов 1÷2 и 2÷3 данного промышленного региона, позволила бы намного меньшими усилиями обеспечить нормальное водно-экологическое регулирование.

Дополнительная оценка достоверности выводов, полученных с использованием ИНС, была выполнена путем прогноза качества воды в форме его оценки на заданном створе на основе анализа данных вышерасположенных створов.

Результаты имеющихся данных были подразделены на обучающие (до 70-80%), проверочные (10-15%), тестовые (10-15%) и неучитываемые. Входные данные для прогноза выбирались как реальные, а выходные данные были заранее неизвестны. Ошибку прогноза оценивали по формуле $E = \{[\sum(C_i - C_i^*)/C_i]^2\}^{1/2}/4$, где C_i – измеренная концентрация загрязнителя на створе, по которому осуществляется прогноз; C_i^* – прогнозные значения концентрации на том же створе. Результаты приведены в таблицах 6-8.

Из данных таблиц 6-8 следует, что ошибка рассматриваемого прогноза преимущественно изменяется в диапазоне 4-40% и в среднем не превышает 20%, что существенно ниже погрешности измерения контролируемых показателей, приписанная норма которой для основных рассматриваемых металлов достигает 50% и более [11].

Таблица 6. Прогноз по системе Створ1→ Створ 2

Table 6. Forecast for the system Gate1→ Gate 2

NN _e образца Sample	Исходные данные. Створ 1 Initial data. Gate 1				Исходные данные. Створ 2 Initial data. Gate 2				Прогнозные данные, Створ 2 Forecast data. Gate 2				Ошибка прогноза E Forecast error
	Fe1	Cu1	Zn1	Ni1	Fe2	Cu2	Zn2	Ni2	Fe2	Cu2	Zn2	Ni2	
1	1.12	6	35	0	1.04	18	51	44	0.85	21.54	32.38	26.04	0.07
2	0.75	5	64	13	1.36	28	45	17	1.44	24.88	47.62	35.44	0.05
62	1.38	16	52	9	3.36	85	93	38	1.19	32.60	45.74	32.90	0.48
63	1.1	24	58	0	1.15	52	50	25	1.12	41.18	50.56	26.03	0.04
76	1.31	30	36	17	0.72	110	48	35	0.91	42.95	53.91	24.25	0.27
77	0.77	26	31	11	1.15	70	78	22	0.74	39.28	50.76	16.77	0.16
112	0.32	33	30	7	0.85	54	36	14	0.60	46.04	56.06	7.85	0.07
113	0.5	23	38	11	0.85	54	80	8	0.85	37.83	52.48	17.26	0.10
214	0.41	22	36	5	0.338	5	14	6	0.76	36.85	49.34	14.27	0.17
215	0.325	4	14	3	0.152	7	14	3	0.47	17.49	31.27	12.88	0.09
Средняя ошибка / Average error													0.15

Таблица 7. Прогноз по системе Створ2→ Створ 3

Table 7. Forecast for the system Gate2→ Gate 3

N образца Sample	Исходные данные. Створ 2 Initial data. Gate 2				Исходные данные. Створ 3 Initial data. Gate 3				Прогноз Forecast				Ошибка прогноза E Forecast error
	Fe2	Cu2	Zn2	Ni2	Fe3	Cu3	Zn3	Ni3	Fe3	Cu3	Zn3	Ni3	
6	0.74	14	75	13	2.62	140	1200	40	0.68	41.15	197.11	14.85	0.52
8	0.8	13	35	13	0.47	12	110	22	0.68	40.94	181.57	14.54	0.07
11	1.31	29	75	51	0.88	180	870	0	1.09	94.32	424.69	34.16	0.29
22	0.49	37	54	21	0.63	8	110	20	0.70	53.05	178.52	16.57	0.08
133	0.9	58	80	33	0.56	40	50	28	0.97	70.26	224.81	23.93	0.10
134	0.66	44	85	17	0.53	39	45	14	0.78	47.67	151.00	15.99	0.05
135	1.22	44	75	5	0.43	22	53	24	0.91	30.55	73.88	13.19	0.08
207	0.326	28	28	13	0.285	34	33	1	0.57	41.62	132.47	11.98	0.07
227	0.143	2	17	5	0.125	7	11	3	0.38	29.78	136.71	7.76	0.07
237	1	1	11	4	0.213	7	6	6	0.39	38.07	172.15	10.15	0.09
Средняя ошибка / Average error													0.14

Таблица 8. Прогноз по системе Створ 1 +2→ Створ 3

Table 8. Forecast for the system Gate 1 +2→ Gate 3

N образца Sample	Исходные данные. Створ 1 +2 Initial data. Gate 1 +2								Точные значения. Створ 3 Exact values. Gate 3				Прогноз Forecast				Ошибка прогноза E Forecast error
	Fe1	Cu	Zn1	Ni1	Fe2	Cu2	Zn2	Ni2	Fe3	Cu3	Zn3	Ni3	Fe3	Cu3	Zn3	Ni3	
6	0.48	8	36	8	0.74	14	75	13	2.62	140	1200	40	0.73	46.17	298.12	21.44	0.42
12	0.24	9	42	0	1.6	30	39	94	1.07	40	1800	12	1.03	180.29	776.98	47.31	0.42
13	0.4	14	40	6	0.37	15	29	15	1.23	48	370	47	0.55	44.34	176.63	14.63	0.20
14	0.61	8	17	7	0.86	24	40	0	1.37	58	540	61	19.19	162.74	13.28	19.19	0.31
15	0.94	21	67	8	1.86	37	34	18	0.43	24	210	28	48.80	309.22	25.31	48.80	0.07
207	15	15	5	0.326	28	28	13	15	0.285	34	33	1	0.44	37.9	112.44	12.95	0.06
208	23	14	0	0.163	32	34	3	23	0.16	37	51	4	0.46	30.41	26.10	6.34	0.04
214	22	36	5	0.338	5	14	6	22	0.08	43	28	11	0.42	31.53	89.17	6.67	0.06
215	4	14	3	0.152	7	14	3	4	0.406	39	33	3	0.23	25.23	134.20	8.06	0.05
237	4	1	1	0.138	1	1	11	4	0.213	7	6	6	0.14	38.70	170.71	7.64	0.07
Средняя ошибка / Average value																	0.17

Выводы

Способность ИНС обнаруживать и оценивать веса связей между статистическими данными является эффективной для изучения динамики формирования качества воды в условиях его пространственно-временной вариабельности.

На примере р. Исеть в зоне г. Екатеринбургa нейросетевой анализ позволил обнаружить взаимозависимости отдельных показателей качества воды на соседних створах и тем самым выявить логистические хозяйственные связи водопользователей. Это облегчает идентификацию приоритетных загрязнителей воды по «водному

следу» загрязнений, оставленному предприятиями-смежниками. Показано, что ИНС упрощает выявление техногенного снижения качества воды на фоне ее природного загрязнения. Также показано, что анализ массивов экспериментальных данных с использованием нейросетей может резко ограничить круг поиска предприятий-загрязнителей.

Достоверность полученных выводов подтверждается возможностью удовлетворительно предсказывать качество воды на некотором гидрохимическом створе по данным для створов, расположенных выше.

Список использованных источников

1. **Строганов С.Н.** Связь питания жителей и состава сточной воды: Питание Москвы в 1903-1922 гг.: Труды Совещания по очистке сточных вод, состоящего при Канализационном отделе М.К.Х. // Московское коммунальное хозяйство. 1923. Вып. 2.
2. **Virender K. Sharma, Eric Lichtfouse, Etienne Decroly.** COVID-19 epidemiologic surveillance using wastewater // *Environmental Chemistry Letters*. 2021. V. 19 (45). № 1. Pp. 1911-1915.
3. **Данилов-Данильян В.И., Веницианов Е.В., Аджиенко Г.В., Козлова М.А.** Оценка современных подходов к управлению качеством поверхностных вод и их охране // *Вестник РАН*. 2019. Т. 89, № 12. С. 1248-1259.
4. О состоянии и использовании водных ресурсов Российской Федерации в 2020 году: государственный доклад.
5. **Розенталь О.М., Александровская Л.Н., Кириллин А.В.** Байесовский подход к повышению достоверности контроля качества вод // *Аналитика и контроль*. 2018. Т. 22, № 3. С. 334-340.
6. **Яковлев С.В., Воронов Ю.В.** Водоотведение и очистка сточных вод: учебник. М.: АСВ, 2002. 704 с.
7. Диффузное загрязнение водных объектов: проблемы и решения: коллективная монография / Под рук. В.И. Данилова-Данильяна. М.: РАН, 2020. 512 с.
8. **Martin Anthony, Peter Bartlett.** *Neural Network Learning: Theoretical Foundations*. Cambridge University Press, Cambridge, New York, 2002. 504 p.
9. **Боровиков В.П.** Нейронные сети STATISTICA *Neural Networks: Metodologiya i tehnologiya sovremennogo analiza dannyh*: учебное пособие М.: StatSoft, 2015. 354 с.
10. ГОСТ Р ИСО 14046-2017. Экологический менеджмент. Водный след. Принципы, требования и руководящие указания.
11. ГОСТ 27384-2002. Вода. Нормы погрешности измерений показателей состава и свойств.

Критерии авторства

Розенталь О.М., Федотов В.Ф. выполнили практические и теоретические исследования, на основании которых провели обобщение и написали рукопись, имеют на статью авторское право и несут ответственность за плагиат.

Конфликт интересов

Авторы заявляют об отсутствии конфликтов интересов.

Вклад авторов

Все авторы сделали равный вклад в подготовку публикации.

Статья поступила в редакцию 22.11.2022

Одобрена после рецензирования 14.12.2022

Принята к публикации 19.12.2022

References

1. **Stroganov S.N.** Svyaz pitaniya zhitelej i sostava stochnoj vody: Pitanie Moskvy` v 1903-1922 gg. Tr. Soveshchaniya po ochistke stochnyh vod, sostoyashchego pri Kanalizatsionnom otdele M.K.H. // *Moskovskoe kommunalnoe hozyajstvo*; 1923 g. Vyp. 2.
2. **Virender K Sharma, Eric Lichtfouse, Etienne Decroly.** COVID-19 epidemiologic surveillance using wastewater. *Environmental Chemistry Letters*. 2021. V. 19(45). N1. P. 1911-1915.
3. **Danilov-Daniljyan V.I.** Otsenka sovremennyh podhodov k upravleniyu kachestvom poverhnostnyh vod i ih ohrane / Venitsianov E.V., Adzhienko G.V., Kozlova M.A. // *Vestnik RAN*. 2019. T. 89. № 12. S. 1248-1259.
4. Gosudarstvennyj doklad «O sostoyanii i ispolzovanii vodnyh resursov Rossijskoj Federatsii v 2020 godu» istina. msu.ru/publications/book/523146645/
5. **Rozental O.M., Aleksandrovskaya L.N., Kirilin A.V.** Bajesovskij podhod k povysheniyu dostovernosti kontrolya kachestva vod // *Analitika i kontrol*. 2018. T 22, № 3. S. 334-340.
6. **Yakovlev S.V., Voronov Yu.V.** Vodootvedenie i ochistka stochnyh vod. M.: ASV, 2002. 704 s.
7. *Diffuznoe zagryaznenie vodnyh objektov: problemy i resheniya. Kollektivnaya monografiya pod ruk. V.I. Danilova-Daniljyana.* M.: RAN, 2020. 512 s.
8. **Martin Anthony, Peter Bartlett.** *Neural Network Learning: Theoretical Foundations*. Cambridge University Press, Cambridge, New York, 2002. 504 p.
9. **Borovikov V.P.** Nejrionnye seti STATISTICA *Neural Networks: Metodologiya i tehnologiya sovremennogo analiza dannyh*. M.: StatSoft, 2015. 354 s.
10. GOST R ISO 14046-2017 *Ekologicheskij menedzhment. Vodnyj sled. Printsipy, trebovaniya i rukovodyashchie ukazaniya.*
11. GOST 27384-2002. Voda. Normy pogreshnosti izmenij pokazatelej sostava i sojstv.

Criteria of authorship

Rosenthal O.M., Fedotov V. H carried out practical and theoretical studies, on the basis of which they generalized and wrote the manuscript. They have a copyright on the article and are responsible for plagiarism.

Conflict of interest

The authors declare that there are no conflicts of interest.

Contributions of the authors

All the authors made an equal contribution to the preparation of the publication.

The article was submitted to the editorial office 22.11.2022

Approved after reviewing 14.12.2022

Accepted for publication 19.12.2022