

Прогнозирование максимального уровня воды рек как обобщенного параметра состояния сложной нелинейной системы на основе использования многослойной нейронной сети

ISSN 1996-8493

DOI:10.54234/CST.19968493.2022.19.2.72

© Технологии гражданской безопасности, 2022

Н.А. Саноцкая, Д.А. Лоскутов, К.В. Ромашова

Аннотация

В связи с развитием Арктической зоны Российской Федерации повышается необходимость предоставления качественных прогнозов гидрометеорологических характеристик. В статье предложена и реализована модель прогнозирования максимального уровня воды рек как параметра сложной нелинейной системы на основе многослойной нейронной сети в условиях пропусков значений отдельных параметров. Представлены результаты практической отработки предлагаемой модели на реальных данных сложной нелинейной системы. В качестве объекта исследований выбрана река Пур в створе Уренгой. Проанализированы факторы, формирующие максимальный уровень воды, и выбрано 20 параметров в качестве исходных данных. После произведенных расчетов получен хороший результат прогнозирования на независимом материале.

Ключевые слова: уровень воды; нелинейная система; многослойные нейронные сети.

Rivers Maximum Water Level Prediction as a Generalized Parameter of the Complex Nonlinear System State Based on the Use of a Multilayer Neural Network

ISSN 1996-8493

DOI:10.54234/CST.19968493.2022.19.2.72

© Civil Security Technology, 2022

N. Sanotskaya, D. Loskutov, K. Romashova

Abstract

Due to the development of the Arctic zone of the Russian Federation, the need to provide high-quality forecasts of hydrometeorological characteristics is increasing. The article proposes and implements a model for predicting the maximum water level of rivers as a parameter of a complex nonlinear system based on a multilayer neural network in conditions of missing values of individual parameters. The practical testing results of the proposed model on real data of a complex nonlinear system are presented. The Pur River in the Urengoy range was chosen as the object of research. Factors forming the maximum water levels are analyzed and 20 parameters are selected as initial data. After the calculations performed, a good prediction result was obtained on an independent material.

Key words: water level; nonlinear system; multilayer neural networks.

Введение

Важное значение для обеспечения следующих национальных интересов Российской Федерации в Арктике согласно Указу Президента РФ от 5 марта 2020 г. № 164 «Об Основах государственной политики Российской Федерации в Арктике на период до 2035 года» имеет решение следующих задач [1]:

1. Обеспечение высокого качества жизни и благосостояния населения Арктической зоны Российской Федерации (АЗРФ).

2. Развитие АЗРФ в качестве стратегической ресурсной базы и ее рациональное использование в целях ускорения экономического роста Российской Федерации.

3. Развитие Северного морского пути в качестве конкурентоспособной на мировом рынке национальной транспортной коммуникации Российской Федерации.

4. Охрана окружающей среды в Арктике, защита исконной среды обитания и традиционного образа жизни коренных малочисленных народов, проживающих на территории Арктической зоны Российской Федерации.

Среди перечисленных задач можно особо выделить задачу развития Северного морского пути, эффективность решения которой во многом определяется природными условиями данного региона. Следовательно, задача влияния природных факторов на функционирование Северного морского пути может быть сведена к оцениванию и прогнозированию гидрометеорологических параметров [2]. Данная задача тесно связана с обеспечением безопасности судоходства в рассматриваемом регионе. В качестве обобщенного параметра целесообразно использовать максимальный уровень воды в исследуемом створе, который формируется на своем водосборе. В данном случае водосбор реки необходимо рассматривать как сложную нелинейную систему с динамикой уровня воды в расчетном створе. Проведенный анализ подходов к построению прогнозных моделей показал, что для описания изменения отдельных нелинейных параметров состояния сложных систем широкое применение получили регрессионные

модели, реализующие описание аттрактора анализируемой системы [3]. В то же время одним из наиболее эффективных подходов к прогнозированию параметров сложных нелинейных систем являются нейронные сети, так как они позволяют учесть нелинейный характер и взаимовлияние между разнородными параметрами их состояния [4].

В данной работе решается задача оценивания возможности применения нейронных сетей для повышения точности прогнозирования уровня воды рек Арктического региона на основе статистических данных р. Пур.

Обоснование актуальности и анализ существующих методов прогнозирования

На рис. 1 приведены данные Росгидромета [5] о динамике количества гидрометеорологических опасных явлений (ОЯ) за 1996–2019 гг., относящиеся лишь к опасным явлениям и комплексам гидрометеорологических явлений (включая гидрологические и агрометеорологические явления), которые нанесли значительный ущерб отраслям экономики и жизнедеятельности населения (общее число и количество непредусмотренных ОЯ). 2019 год стал четырнадцатым по количеству ОЯ, нанесших ущерб. Число непредусмотренных ОЯ в 2019 г. составило 17. Это свидетельствует о том, что задача прогнозирования чрезвычайных ситуаций природного характера, и в том числе наводнений, является актуальной и востребованной.

Если в основу классификации положить признаки, характеризующие способ преобразования прогнозистической информации и природу знания, лежащего в основании прогноза, то получится следующее разделение на группы [6]:

- эвристические методы прогнозирования;
- математические методы временной экстраполяции;
- математические методы пространственной экстраполяции;
- методы моделирования процессов развития;
- логические и структурные методы искусственного интеллекта (ИИ).




Рис. 1. Распределение гидрометеорологических опасных явлений по годам: общее количество (синий) и количество непредусмотренных ОЯ (красный)

Эвристическое прогнозирование заключается в интуитивном выборе из бесконечно большого количества вариантов. В среднем эксперты дают неплохие результаты. Существуют методы индивидуальных экспертных оценок (интервью, аналитические экспертные оценки) и коллективных экспертных оценок (методы комиссий, «Делфи», матричный метод и др.). К недостаткам этих методов относятся: субъективность, необходимость наличия эксперта с нужной квалификацией.

К математическим методам временной экстраполяции относятся такие методы, как: прямой воднобалансовый расчет; физико-статистический воднобалансовый метод, а также статистические методы, включающие в себя главным образом корреляционные зависимости.

Пространственная экстраполяция связана с прогнозированием в пространстве параметров и состоит в прогнозной оценке значений векторного поля, получаемого по отдельным наблюдениям. К этим методам относится, например, построение карт снежного покрова для оценки снегозапасов перед началом половодья.

Методы моделирования процессов развития подразделяются на физическое моделирование (в гидравлических лабораториях), математическое моделирование и имитационное моделирование (например, с использованием программы NEC-RAS).

К логическим и структурным методам ИИ относятся морфологический анализ, непосредственно сами логические методы прогнозирования, лингвистические методы.

При сравнении перечисленных методов получается картина, представленная в табл. 1.

Из табл. 1 видно преимущество методов пространственной интерполяции и физического моделирования. Существенным недостатком метода физического моделирования является высокая стоимость реализации, а недостатком метода пространственной интерполяции является, зачастую, невысокая точность прогноза. Уточнить прогноз можно путем учета задержанных значений параметров состояния и реализации тем самым пространственно-временной

экстраполяции временных рядов параметров состояния. При этом размерность вектора входных данных прогнозной модели может стать неприемлемо большой. Вариантом нивелирования данного недостатка является использование нейросетевых алгоритмов прогнозирования многомерных временных рядов параметров состояния.

Постановка задачи

Дано: временные ряды j -х параметров состояния сложной нелинейной системы (СНС) $x_{j,k}^j, x_{j,k-1}^j, \dots, x_{j,k-L+1}^j$, где: j — номер параметра состояния СНС, $j = 1 \dots N$; N — количество параметров состояния СНС; k — номер дискретного отсчета времени; L — заданное для каждого параметра «окно наблюдения».

Прогнозированию подлежит один из N параметров — обобщенный параметр состояния СНС x_g , связанный с остальными параметрами состояния x_j . При прогнозировании будем учитывать текущие значения всех параметров состояния $x_j: x_{1,k}, x_{2,k}, \dots, x_{N,k}$, а также задержанные на L отсчетов значения g -го обобщенного параметра: $x_{g,k-1}, \dots, x_{g,k-L+1}$. В результате прогнозирования получаем прогнозное значение обобщенного параметра состояния СНС с временем упреждения прогноза $T: \hat{x}_{g,k+T}$.

В качестве показателя эффективности решения задачи прогнозирования g -го обобщенного параметра состояния нелинейных систем будем использовать целевую функцию E :

$$E(\{m_r\}, N, L, T) = \sqrt{\frac{1}{M-T+1} \sum_{k=1}^{M-T+1} \left(x_{g,k+T} - \hat{x}_{g,k+T}(\{m_r\}, N, L, T) \right)^2}, \quad (1)$$

где:

M — количество отсчетов в проверочной и тестовой выборке;

$x_{g,k}$ — истинное значение обобщенного параметра состояния СНС;

$\{m_r\}$ — параметры модели прогнозирования.

Таблица 1

Условная оценка основных методов прогнозирования

Требования, предъявляемые к методу прогнозирования	Эвристические методы	Математические методы временной экстраполяции	Математические методы пространственной экстраполяции	Математическое моделирование	Физическое моделирование	Логические методы	Структурные методы
Способность выдавать многопараметрический прогноз с учетом эмерджентности явлений	–	–	+	+	+	–	–
Нечувствительность к недостатку априорной информации	+	–	+	–	+/-	–	+/-
Возможность прогнозирования не наблюдавшихся ранее событий	+	–	+	+/-	+	+/-	+
Возможность строгой формализации и алгоритмизации методик прогнозирования	–	+	+/-	+/-	–	+/-	+/-
Возможность решения слабоформализованных задач	+	–	+	–	+	+/-	+/-

При прогнозировании параметров состояния необходимо решить задачу оптимизации целевой функции E :

$$(\{m_r\}, N, L, T)_{opt} = \arg \min_{N, L, \{m_r\}} E \Big|_{\substack{E \leq E_{зад} \\ T = T_{зад}}} \quad (2)$$

где:

- $(\{m_r\}, N, L, T)_{opt}$ — набор оптимальных значений параметров прогнозной модели;
- $E_{зад}$ — заданное значение целевой функции;
- T — время упреждения прогноза;
- $T_{зад}$ — заданное время упреждения прогноза.




Рис. 2. Структурная схема многослойной нейронной сети для прогнозирования обобщенного параметра состояния сложной нелинейной системы

Все данные по уровням воды разбиваются на три выборки: обучающую, проверочную и тестовую выборку. Каждая выборка включает в себя обучающие пары векторов $\langle X_k, \hat{X}_{k+T} \rangle$, формируемые в соответствии с табл. 2 в произвольные моменты времени на всей реализации анализируемых параметров. То есть в каждую выборку попадают обучающие векторы из различных областей временного ряда, что просто необходимо в случае его нестационарности. В табл. 2 представлен общий вид обучающей пары векторов $\langle X_k, \hat{X}_{k+T} \rangle$. В процессе обучения на данных обучающей выборки решаются задача (2) и минимизация среднеквадратической погрешности прогнозирования на проверочной выборке. Окончательно обученная выборка проверяется на данных тестовой выборки. В случае, если на проверочной и тестовой выборках достигнута удовлетворяющая точность прогнозирования, нейронная сеть используется на вновь поступающих данных об уровне воды.

Алгоритм обучения и прогнозирования максимального уровня воды на основе многослойной нейронной сети можно представить в следующем виде:

1. Формируется обучающая, проверочная и тестовая выборки; задаются матрицы весовых коэффициентов H^l и H^l_s , $l = \overline{1,3}$, $E_m = 1$, $E_{зад}$, $T_{зад}$.

2. Задается структура модели: количество слоев, количество нейронов в каждом слое, начальные значения весовых коэффициентов матриц V^l и S^l ; присваиваются нулевые значения элементам матриц изменений весовых коэффициентов dV^l_k и dS^l_k ; задаются параметры обучения: количество циклов обучения $N_{но}$, μ — скорость обучения сети, ρ — момент инерции. Параметры прогнозной модели $\{m_r\}$ включают: коэффициенты матриц V^l и S^l ; количество слоев сети; количество нейронов в каждом слое сети; параметры $\mu, \rho, N_{но}$.

3. Задается значение счетчика циклов обучения $q = 1$.

4. Задается значение счетчика количества обучающих пар векторов $k = 1$.

5. На вход нейросети подается обучающая пара векторов — строк $\langle X_k, \hat{X}_{k+T} \rangle$ из обучающей выборки. Вычисляются:

$$z^l_k \equiv [z^l_v] = X_k V^l_k + S^l_k,$$

$$y^l_k \equiv [y^l_v] = \left(y_v = f(z^l_v) = \frac{1}{1 + \exp(-z^l_v)} \right),$$

$$\hat{X}_{k+T} \equiv [\hat{x}_{k+T}] = f(f(f(X_k V^l_k + S^l_k) V^2_k + S^2_k) V^3_k + S^3_k).$$

6. Выполняется процедура обратного распространения ошибки:

$$\Delta \equiv [\delta_v] = X_{k+T} - \hat{X}_{k+T},$$

$$\Delta^l_k \equiv [\delta^l_v] = (\delta_v = y^l_v(1 - y^l_v)\delta_v),$$

$$D \equiv [d^l_v] = \Delta^l_k V^{lT}_k,$$

$$\Delta^{l-1}_k \equiv [\delta^{l-1}_v] = (\delta^{l-1}_v = y^{l-1}_v(1 - y^{l-1}_v)d^l_v).$$

7. Корректируются матрицы весовых коэффициентов:

$$dV^l_k = \mu Y^{l-T}_k \Delta^l_k + \rho dV^l_{k-1},$$

$$dV^l_{k+1} = V^l_k + dV^l_k,$$

$$dS^l_k = \mu \Delta^l_k + \rho dS^l_{k-1},$$

$$dS^l_{k+1} = S^l_k + dS^l_k.$$

8. Проверяется условие $k \leq M$. До тех пор, пока оно выполняется, повторяются действия 5–8.

9. На каждом цикле обучения определяется значение целевой функции на проверочной выборке:

$$E^{(n)}(\{m_r\}, N, L, T) = \sqrt{\frac{1}{(M-T+1)} \sum_{k=1}^{M-T+1} \left(x_{g,k+T}(\{m_r\}, N, L, T) - x_{g,k+T} \right)^2}.$$

10. Проверяется условие: $E^{(n)} \leq E_m$. В случае успешной проверки осуществляется запоминание настраиваемых параметров сети $E_m = E^{(n)}$; $H^l_v = V^l_k$, $H^l_s = S^l_k$.

Таблица 2

Обучающая пара векторов

Входной вектор X_k										Выходной вектор \hat{X}_{k+T}	
$x_{1,k}$	$x_{2,k}$...	$x_{g,k}$...	$x_{j,k}$...	$x_{N,k}$	$x_{g,k-1}$...	$x_{g,k-L+1}$	$\hat{x}_{g,k+T}$

11. Проверяется условие: $q \leq N_{\text{ш}}^*$. В случае успешной проверки осуществляется переход на шаг 4, иначе — на шаг 12.

12. Определяется значение целевой функции на тестовой выборке для параметров сети $V_k^l = H_{\nu}^l$, $S_k^l = H_s^l$:

$$E^{(r)}(\{m_r\}, N, L, T) = \sqrt{\frac{1}{(M-T+1)} \sum_{k=1}^{M-T+1} \left(\hat{x}_{g,k+T}(\{m_r\}, N, L, T) - x_{g,k+T} \right)^2}.$$

13. Проверяется условие $E^{(r)} \leq E_{\text{зад}}$. В случае успешной проверки осуществляется переход на шаг 14, иначе — на шаг 2.

14. Загружаются новые значения параметров состояния, которых не было в тестовой выборке; формируется вектор X_k^* , обнуляется счетчик $k = 1$. Выполняются операции: $V_k^l = H_{\nu}^l$, $S_k^l = H_s^l$.

15. Вектор X_k^* подается на вход обученной нейронной сети и вычисляется прогнозное значение уровня воды \hat{X}_{k+T}^* :

$$\hat{X}_{k+T}^* \equiv [\hat{x}_{k+T}^*] = f(f(f(X_k^* V_k^1 + S_k^1) V_k^2 + S_k^2) V_k^3 + S_k^3).$$

С течением времени размер обучающей, проверочной и тестовой выборки увеличивается, нейронная сеть дообучается на новых данных, а формируемый прогноз уровня воды становится более точным.

Анализ результатов моделирования

Качество прогнозирования уровней воды подвержено существенным колебаниям по причинам природного характера, в первую очередь из-за колебаний климата. Также негативное влияние на качество прогнозирования уровней воды оказывает сокращение гидрологических постов в Арктическом регионе.

Река Пур расположена в Арктической зоне Российской Федерации (АЗРФ). Судоходство на этой реке обеспечивает снабжение таких поселений, как: г. Тарко-Сале, пос. Уренгой, пос. Коротчаево, с. Самбург.

В формировании водного режима р. Пур преобладающее влияние оказывают климатические факторы. Характерной особенностью рассматриваемой территории является наличие многолетней мерзлоты, которая по-своему влияет на формирование стока. На рис. 3 представлены: ледовые условия (кривая 1); уровень воды (кривая 2); температура воздуха (кривая 3).

Главной фазой водного режима района является весеннее половодье, формирование которого происходит при интенсивном снеготаянии, мерзлых почвах, исключая потери на фильтрацию и значительную аккумуляцию талых вод в бассейнах рек.

В результате формируется однопиковая волна половодья с крутой ветвью подъема и плавной продолжительной ветвью спада. В последние годы максимальный уровень воды весеннего половодья, как правило, проходит при свободном от льда русле.

В качестве объекта исследований была выбрана система р. Пур. Река Пур образуется от слияния рек




Рис. 3. Ход уровня воды в период максимального стока, р. Пяку-Пур-п. Тарко-Сале, 2012 г.

Пяку-Пур и Айваседа-Пур. Площадь бассейна при слиянии равна 55 460 км², поэтому р. Пур уже в самом начале является довольно крупной рекой. Затем благодаря впадению многочисленных притоков площадь бассейна увеличивается и к устью достигает 110 900 км². Впадает р. Пур в Тазовскую губу. Протяженность реки составляет 1020 км. Климат в бассейне р. Пур суровый. Отсутствие защищенности территории с севера и юга способствует воздухообмену с северными и южными районами и вызывает резкое повышение или понижение температуры воздуха.

Долина реки сложена в нижних слоях суглинками, в верхних — песками. Грунты, слагающие русло реки и берега, представлены мелкозернистыми песками, рыхлыми и средней плотности. Берега реки размываются и в отдельных местах обрушение происходит вместе с растущими деревьями. В результате размыва берегов прибрежные участки русла засорены упавшим лесом.

Гидрологический режим водных объектов обуславливается множеством факторов. Среди них есть существенно изменчивые — метеорологические — и относительно стабильные — факторы подстилающей поверхности (рельеф, почвогрунты, растительность и пр.). Значительная пространственно-временная изменчивость факторов определяет сложность решения задачи гидрологического прогнозирования, требует раскрытия закономерностей развития процессов и их адекватного описания с применением современного научного аппарата.

Для прогнозирования максимальных уровней воды р. Пур в створе Уренгоя используется 20 параметров, обозначенных в модели как x_1, x_2, \dots, x_{20} : осадки за холодный период, осадки за апрель, осадки за год; температуры воздуха по месяцам; количество дней от 1 марта до даты устойчивого перехода через 0°; продолжительность солнечного сияния; дата начала ледостава; среднегодовые уровни воды по постам. Метеорологические параметры приняты по метеостанции Тарко-Сале. Гидрологические данные получены по постам р. Пур-Уренгой и р. Пяку-Пур-Тарко-Сале.

В качестве обобщенного параметра x_g , подлежащего прогнозированию, используется максимальный уровень воды (x_{21}).

Исходные данные сведены в табл. 3, при этом пропуски значений параметров обозначены числом «1111». Для формирования обучающей, проверочной и тестовой выборок разработан алгоритм, выбирающий только те векторы входных/выходных значений, в которых отсутствуют пропуски значений параметров.

Таблица 3

Исходные данные для построения прогнозной модели и прогнозирования параметров состояния

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	x_{16}	x_{17}	x_{18}	x_{19}	x_{20}	x_{21}
-33,4	-24,5	-15,3	-7,8	3,6	-2,4	-21,4	-27,3	-6,5	1111	1111	1111	487	1111	22,28	24,66	701	939	447	10,29	910
-25,7	-32,9	-18,8	-1,8	7,2	-3,5	-14,9	-20	-5,8	1111	1111	1111	470	1111	22,08	25,36	681	1009	428	10,1	848
-23	-20,4	-24,7	-9,4	8,6	-1,9	-16,5	-16,8	-5,8	1111	1111	1111	613	1111	22	25,28	673	1001	411	9,93	825
-23,1	-21,9	-18,2	-2,6	7,6	-8,4	-25,7	-31,3	-8,4	1111	1111	1111	521	1111	22,07	24,21	680	894	406	9,88	830
-23,1	-32,2	-16,	-7	4,9	-4,8	-23	-16,4	-5,1	1111	1111	1111	530	1111	22,17	25,52	690	1025	427	10,09	841
-15,2	-29,7	-21,7	-5	6,4	-1,5	-16,8	-20,4	-6,0	1111	1111	1111	554	1111	22,29	25,3	702	1003	447	10,29	846
-21,7	-24,2	-13,8	-12,2	5	0	-16,4	-33	-6,3	1111	1111	1111	556	1111	22,4	25,61	713	1034	457	10,39	784
-22,2	-24,5	-24	-9,6	3,9	-6,1	-14,4	-20,3	-5,5	1111	1111	1111	441	1111	22,14	24,92	687	965	426	10,08	892
-21,4	-23,5	-24,7	-14,2	7,5	-6	-26,1	-24,6	-7,1	1111	1111	1111	457	1111	21,96	26,32	669	1105	401	9,83	879
-21,2	-25,1	-13,7	-12,9	2,3	-5,7	-16,4	-33,4	-8,7	1111	1111	1111	448	1111	22,42	25,21	715	994	460	10,42	925
-31,3	-29,1	-25,7	-11,6	7,2	-6,6	-16,1	-24,8	-6,3	1111	1111	1111	503	1111	22,34	25,76	707	1049	447	10,29	738
-26	-22	-6,9	-6,1	6,7	-8,5	-22,6	-20,2	-9,3	1111	1111	1111	426	1111	22,35	25,27	708	1000	453	10,35	1026
-17,4	-17,2	-14,4	-5,9	5,9	-9,1	-18,2	-22,7	-6,0	1111	1111	1111	401	1111	22,11	26,2	684	1093	447	10,29	906
-23	-18,3	-21,4	-10,6	7,3	-6,9	-14,7	-21,2	-3,9	1111	1111	1111	397	281	21,98	25,07	671	980	421	10,03	910
-28,9	-23,9	-23,3	-14,5	4,4	-2,2	-16,5	-29,4	-6,7	1111	1111	1111	524	297	22,23	25,37	696	1010	444	10,26	878
-25,9	-25,4	-13,2	-9,8	8,2	-6,6	-20,2	-21,2	-7,9	1111	1111	1111	481	289	22,22	25,58	695	1031	435	10,17	882
-25,2	-35,4	-21,3	-13,3	5,1	-4,2	-25,6	-23,1	-7,1	85	1111	1111	597	297	22,56	24,79	729	952	471	10,53	869
-24,9	-24,8	-9,5	-3,9	7,1	-9,4	-17,4	-21,4	-8,6	88	243	522	372	288	22,62	25,71	735	1044	472	10,54	952
-27,9	-19	-7,6	-9,6	4,6	0,5	-10,6	-15,7	-3,5	1111	213	380	349	301	1111	1111	1111	1111	1111	1111	893
-35,6	-33	-19,8	-12	3,1	-5,7	-28,9	-34,8	-8,3	74	123	485	746	292	22,25	25,66	698	1039	444	10,26	788
-28,8	-23	-16,2	-11,4	3,8	-7,9	-9,5	-21,4	-8,7	95	177	427	465	292	22,18	24,7	691	943	405	9,87	876
-25,4	-30,7	-19,5	-13,2	6,9	-8,4	-17,2	-24	-8,1	101	220	488	520	283	22,17	25,3	690	1003	449	10,31	868
-31,7	-23,2	-20,3	-6,6	6	-5,4	-9,5	-20,1	-6,7	1111	217	567	467	299	1111	25,35	1111	1008	1111	1111	907
-29,2	-18,2	-14,9	-7,1	2,2	-3,2	-21,5	-24,6	-8,1	98	196	534	408	296	22,49	25,48	722	1021	459	10,41	884

В процессе обучения формировался вывод о прогнозном значении обобщенного параметра — максимального уровня воды р. Пур в створе Уренгой. Результаты прогнозирования представлены в табл. 4 и на рис. 4.

Таблица 4
Результаты прогнозирования максимального уровня воды р. Пур–Уренгой

Год	Фактический уровень воды, см	Прогнозный уровень воды, см
2016	842	861
2017	822	798
2018	834	846
2019	854	836

В качестве числовой оценки эффективности метода прогнозирования целесообразно использовать следующее отношение $\frac{E}{\sigma}$, где σ — среднее квадратичное отклонение значений обобщенного параметра от его среднего значения. Приемлемыми прогнозами принято считать такие, для которых отношение $\frac{E}{\sigma}$ не превышает 0,8. В данном случае $\frac{E}{\sigma} = 0,31$, поэтому полученное качество прогноза уровня воды является хорошим.

Литература

1. Указ Президента РФ от 5 марта 2020 г. № 164 «Об Основах государственной политики Российской Федерации в Арктике на период до 2035 года».
2. Болгов М.В., Коробкина Е.А., Осипова Н.В., Филиппова И.А. О методах оценки и прогнозирования экстремальных гидрологических событий в условиях изменений климата // В кн.: Тезисы докладов Всероссийской научной конференции «Мониторинг состояния и загрязнения окружающей среды. Основные результаты и пути развития». М.: ФГБУ «Институт глобального климата и экологии Росгидромета и РАН». 2017. С. 183–184.
3. Анищенко В. С., Астахов В.В. Нелинейные эффекты в хаотических и стохастических системах. М.–Ижевск: Институт компьютерных исследований, 2003. 529 с.

Сведения об авторах

Саночкая Надежда Александровна: к.ф.-м.н., ФГБОУ ВО «Российский государственный гидрометеорологический университет», доц. каф. водно-технич. изысканий; ФГБУ «Арктический и антарктический научно-исследовательский институт», с. н. с. отд. гидрологии устьев рек и водных ресурсов. Санкт-Петербург, Россия. SPIN-код: 3807-0526.

Лоскутов Дмитрий Андреевич: Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), студент. Санкт-Петербург, Россия. SPIN-код: 5453-0918.

Ромашова Ксения Владимировна: ФГБУ «Арктический и антарктический научно-исследовательский институт», н. с. отдела гидрологии устьев рек и водных ресурсов. Санкт-Петербург, Россия. SPIN-код: 4950-7419.




Рис. 5. Хронологический график колебаний максимального уровня воды р. Пур–Уренгой: 1 — наблюдавшиеся значения, 2 — прогнозные уровни

Дальнейшим направлением совершенствования рассмотренного подхода видится создание двухэтапной модели нейронной сети, в которой на первом этапе будет реализована процедура восстановления пропусков данных, что позволит увеличить количество используемых на этапе обучения нейронной сети обучающих пар векторов на 20–30%.

4. Хайкин С. Нейронные сети: полный курс. М.: Издательский дом «Вильямс», 2006. 1104 с.
5. Доклад об особенностях климата на территории Российской Федерации за 2019 год. М.: Росгидромет, 2020. 97 с.
6. Рыкова Т.Л., Казаков Д.Ю. Долгосрочное прогнозирование стоковых характеристик методом математического моделирования гидрологических процессов // Наука и технологии трубопроводного транспорта нефти и нефтепродуктов. 2020. Т. 10. № 4. С. 352–363.
7. Назаров А.В., Лоскутов А.И. Нейросетевые алгоритмы прогнозирования и оптимизации систем. СПб.: Наука и Техника, 2003. 384 с.
8. Назаров А.В., Якимов В.Л. Прогнозирование технического состояния малых космических аппаратов с использованием многослойных нейронных сетей // Известия вузов. Приборостроение. 2006. №1. С. 7–12.

Information about author

Sanotskaya Nadezhda A.: PhD (Physics and Mathematics Sc.), Russian State Hydrometeorological University, Senior Researcher, Associate Professor of the Department of Water Engineering Surveys; Arctic and Antarctic Research Institute, Senior Researcher, Department of Hydrology of River Mouths and Water Resources. St. Petersburg, Russia. SPIN-scientific: 3807-0526.

Loskutov Dmitry A.: St. Petersburg State Electrotechnical University named after V. I. Ulyanov (Lenin), Student. St. Petersburg, Russia. SPIN-scientific: 5453-0918.

Romashova Ksenia V.: Arctic and Antarctic Research Institute, Researcher, Researcher, Department of Hydrology of River Mouths and Water Resources. St. Petersburg, Russia. SPIN-scientific: 4950-7419.