

## Обзор методов эффективного прогнозирования характеристик речного стока в горных и полугорных районах

Гайдукова Екатерина Владимировна, кандидат технических наук, доцент  
Российский государственный гидрометеорологический университет (г. Санкт-Петербург)

Маргарян Вардуи Гургеновна, кандидат географических наук, доцент  
Ереванский государственный университет (г. Ереван)

Мякишева Наталия Вячеславовна, доктор географических наук, профессор  
Павлов Максим Романович, магистрант

Хаустов Виталий Александрович, кандидат технических наук, доцент  
Российский государственный гидрометеорологический университет (г. Санкт-Петербург)

DOI: 10.5281/zenodo.5168514

### Введение

Водные ресурсы являются основой энергетики и сельского хозяйства горных районов России и стран, территории которых расположены в горной местности. Данные отрасли нуждаются в заблаговременных прогнозах водного режима, в том числе величин максимального стока, а также стока в период весеннего половодья. От эффективности методов и методик зависит достоверность определения характеристик речного стока.

Существуют различные методы прогноза стока горных и полугорных рек. Большинство из них основано на использовании фактических наблюдений за характеристиками речного стока за предшествующий дате прогноза период. Есть подходы основанные на методах водного баланса, которые учитывают и влияние на сток изменений климата. В практике оперативного прогноза стока горных рек часто применяются методы, опирающиеся на концептуальные модели формирования стока, в основе которых полуэмпирические уравнения, или на физико-статистические зависимости характеристик речного стока от гидрометеорологических факторов.

Цель исследования заключается в анализе методов эффективного прогнозирования характеристик речного стока в период паводков и половодья в горных и полугорных районах. Рассмотрены и проанализированы следующие подходы: регрессионные зависимости, методы теории АРСС (модель авторегрессии, смешанные модели, модель авторегрессии проинтегрированного скользящего среднего), прогнозирование с помощью искусственных нейронных сетей, динамическое и стохастическое моделирование.

### Материалы и методы

#### Регрессионные зависимости

Разработка надежных моделей прогнозирования речного стока и опасных гидрологических процессов является актуальной задачей настоящего и будущего. В условиях, когда в силу различных причин применение концептуальных и физико-математических моделей невозможна, а потребность в прогнозировании гидрологических характеристик велика, применяют модели, основанные на эмпирических зависимостях. К таким зависимостям можно предъявить ряд требований, обусловленных как общими законами и опытом разработки прогностических моделей, так и современным состоянием гидрометеорологической сети наблюдений: – число предикторов должно быть минимально; – предикторы должны однозначно определяться; – предикторы должны измеряться непосредственно на наблюдательной сети; – заблаговременность прогнозов должна быть не менее, чем у существующих методик; – качество выпускаемых прогнозов должно быть удовлетворительным.

Таким образом, ввиду особенностей современного этапа развития практики гидрологических прогнозов, разработанные к настоящему времени прогностические уравнения, основываются, как правило, на методах математической статистики и регрессионного анализа. Наиболее распространенный подход при прогнозировании заключается в выявлении регрессионных зависимостей между прогнозируемой величиной и факторами, влияющими на нее.

Например, в работе [1] решалась задача прогнозирования расходов и уровней воды для восьми речных створов, расположенных на шести реках Черноморского побережья Кавказа на южном склоне Большого Кавказского хребта. В регрессионной модели для получения прогноза максимального расхода воды на сутки ( $t+1$ ), в качестве предикторов учитывались: максимальный расход воды  $Q_{\max(t)}$  за сутки составления прогноза; максимальный расход воды  $Q_{\max(t-1)}$  за предшествующие сутки; слой осадков на метеостанции  $P(t)$  за сутки составления прогноза; среднюю приземную температуру воздуха на метеостанции  $T(t)$ ; прогноз суточного слоя осадков  $P_{(t+1)}$  на метеостанции; прогноз среднесуточной приземной температуры воздуха  $T_{(t+1)}$ . Расчет среднесуточного прогнозируемого расхода воды производился по формуле:

$$\begin{aligned} \tilde{Q}(t+1) = & a_0 + a_1 Q(t) + a_2 Q(t-1) + a_3 [T(t+1) - T_{\min,S}]^2 + a_4 [T(t+1) - T_{\min,S}] + a_5 P(t+1) [T(t+1) - T_{\min,P}]^2 + \\ & + a_6 P(t+1) [T(t+1) - T_{\min,P}] + a_7 P(t+1) + a_8 [T(t) - T_{\min,S}]^2 + a_9 [T(t) - T_{\min,S}] + a_{10} P(t) [T(t) - T_{\min,P}]^2 + \\ & + a_{11} P(t) [T(t) - T_{\min,P}] + a_{12} P(t). \end{aligned} \quad (1)$$

Для всех речных створов и в течение всего года формула (1) позволила получить практически минимальную погрешность прогноза. Параметры в формуле оценивались методом наименьших квадратов для каждого месяца, таким образом учитывались различия в состоянии почвенного и растительного покрова водосборов в течение года, а также влияние метеоэлементов на сток.

В работе [2] отмечено, что использование спутниковой информации облегчает процесс анализа снеготаяния и условий формирования весеннего половодья и имеет практическую направленность в части прогноза водности.

### Методы теории АРСС

В условиях существующего по-прежнему дефицита исходной информации широкие возможности для прогнозирования гидрометеорологических процессов открывает использование временных рядов фактических наблюдений, которые рассматриваются как случайные процессы, с привлечением методов, основанных на экстраполяции.

Методы теории АРСС (авторегрессионные модели скользящей средней) разработаны и доведены до практического применения Дж. Боксом и Г. Дженкинсом [3]. Они позволяют не только описывать корреляционную и спектральную структуру временных рядов в терминах модельных процессов АРСС и отражать их статистическую взаимосвязь в терминах моделей передаточных функций, но и составлять прогноз, поскольку упомянутые модели фактически являются прогнозирующей функцией. Основная трудность в применении этих методов для решения практических задач гидрометеорологии заключается в идентификации модели для конкретного временного ряда, т. е. в подборе для него соответствующего модельного выражения.

Обобщением модели АРСС на случай нестационарных временных рядов является модель авторегрессии проинтегрированного скользящего среднего АРПСС ( $p, d, q$ ), где  $p$  – параметр авторегрессии,  $d$  – порядок операции взятия разностей,  $q$  – параметр скользящего среднего.

#### Модель авторегрессии (АР)

В этой модели текущие значения случайного процесса выражаются в виде конечной линейной комбинации предыдущих его значений и белого шума:

$$\dot{X}_t = \phi_1 \dot{X}_{t-1} + \phi_2 \dot{X}_{t-2} + \dots + \phi_p \dot{X}_{t-p} + a_t,$$

где:  $\dot{X}_t$  – центрированный случайный процесс,  $X_t = X_t - m_x$ ;  $a_t$  – белый шум с нулевым математическим ожиданием и среднеквадратическим отклонением  $\sigma_a$ .

Модель содержит  $p+2$  параметров:  $\phi_1, \phi_2, \dots, \phi_p, m_x, \sigma_a$ , где  $m_x$  – математическое ожидание случайного процесса  $X(t)$ ;  $\phi_1, \phi_2, \dots, \phi_p$  – коэффициенты модели (константы). Модель называют моделью авторегрессии  $p$ -ого порядка и обозначают АР( $p$ ).

#### Модель скользящего среднего (СС)

Модель скользящего среднего может быть получена из, так называемой, общей линейной модели (ОЛМ), если предположить, что ОЛМ содержит конечное число членов. В этой модели текущие значения процесса  $X(t)$  выражаются через предыдущие значения белого шума  $a_{t-1}, a_{t-2}, \dots, a_{t-q}$ :

$$\dot{X}(t) = a_t - \psi_1 a_{t-1} - \psi_2 a_{t-2} - \dots - \psi_q a_{t-q}.$$

Модель содержит  $q+2$  параметров:  $\psi_1, \psi_2, \dots, \psi_q, m_x, \sigma_a$ , где  $\psi_1, \psi_2, \dots, \psi_q$  – коэффициенты модели (константы). Выражение называют моделью скользящего среднего  $q$ -ого порядка и обозначают СС( $q$ ).

#### Смешанные модели (АРСС)

Иногда целесообразно объединить модели АР и СС. В этом случае получают смешанную модель АРСС( $p, q$ ), где  $p$  – порядок авторегрессии,  $q$  – порядок скользящего среднего. Выражение для АРСС( $p, q$ ) имеет вид:

$$\dot{X}_t = \phi_1 \dot{X}_{t-1} + \phi_2 \dot{X}_{t-2} + \dots + \phi_p \dot{X}_{t-p} + a_t - \psi_1 a_{t-1} - \psi_2 a_{t-2} - \dots - \psi_q a_{t-q}.$$

Такая модель может оказаться подходящей, например, когда наблюдаемый временной ряд является суммой двух или более независимых составляющих, каждая из которых описывается либо моделью АР, либо моделью СС, но которые непосредственно не измеряются.

#### Модель авторегрессии проинтегрированного скользящего среднего (АРПСС)

Рассмотренные выше модели АР, СС и АРСС относятся к классу стационарных моделей, которые описывают процессы, для которых математическое ожидание и дисперсия являются константами. Однако в природе существует неограниченное число различных проявлений нестационарности.

Исследования Дж. Бокса и Г. Дженкинса показали, что во многих случаях от нестационарности можно избавиться, заменяя исходный ряд на ряд разностей  $Y_t = X_t - X_{t-1}$ . Если от нестационарности избавиться не удалось можно взять разность повторно  $Z_t = Y_t - Y_{t-1}$ .

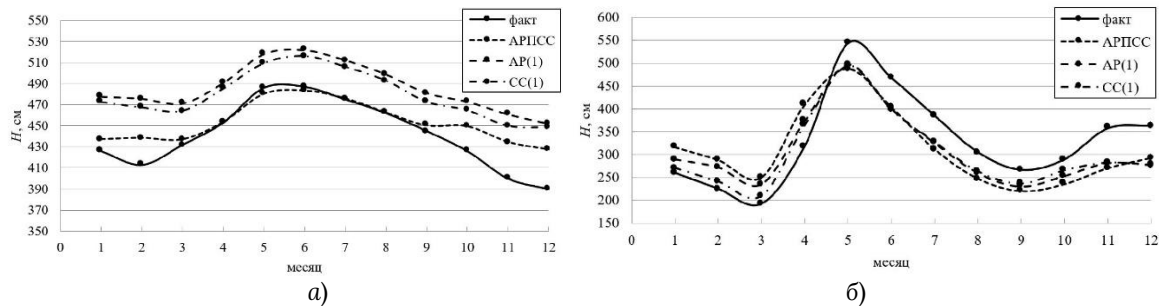
После проведенных преобразований к исходному ряду можно применить модель АРСС.

Полученную на основе таких рассуждений модель называют моделью Бокса-Дженкинса или моделью авторегрессии проинтегрированного скользящего среднего АРПСС ( $p, d, q$ ). В этой модели:  $p$  – порядок авторегрессии,  $d$  – порядок разности,  $q$  – порядок скользящего среднего.

Рассмотрим некоторые примеры прогнозирования временных рядов месячной дискретности. В качестве объектов исследования выбраны разнотипные озера – Ладожское и Ильмень. Прогнозируемой характеристикой является уровень воды для характерных по водности лет (маловодный, многоводный, средний). Временной ряд уровней воды Ладожского озера имеет продолжительность 117 лет (1881 – 1997), озера Ильмень 44 года (1945 – 1988). Отметим, что уровенный режим озера Ильмень близок по своим особенностям к режиму речного притока в водоем.

Генерирование прогнозов осуществлялось двумя способами. Первый способ заключался в использовании модели АРПСС, учитывающей как эволюционную, так и сезонную нестационарность. Прогнозирование осуществлялось с упреждением 12 месяцев (с января по декабрь). Модель включала один обычный и один сезонный параметр скользящего среднего. Исходный ряд трансформировался трижды в ходе логарифмирования, взятия разности с шагом 1 (для устранения эволюционной нестационарности) и взятия разности с шагом 12 (для устранения сезонной нестационарности).

Результаты применения моделей АРПСС, АР(1) и СС(1) для Ладожского озера (1920 год) и озера Ильмень приведены на рис. 1. Для Ладожского озера прогнозы по модели АРПСС относятся к категории «отличных», а по моделям АР(1) и СС(1) – к категории «хороших». Для озера Ильмень прогнозы по модели АРПСС относятся к категории «хороших», а по моделям АР(1) и СС(1) – к категории «отличных».



**Рис. 1. Фактические и прогностические значения внутригодовых колебаний уровней Ладожского озера за 1920 год (а) и озера Ильмень за 1985 год (б).**

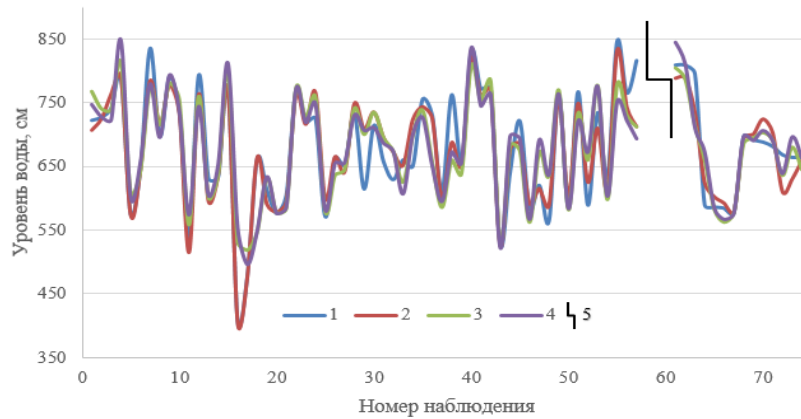
#### Прогнозирование с помощью искусственных нейронных сетей

Искусственные нейронные сети (ИНС) все чаще используются в качестве альтернативного способа решения широкого диапазона гидрологических задач [4].

Методы обучения ИНС наравне с регрессионными методами и методами авторегрессии проинтегрированного скользящего среднего относятся к моделям типа «черного ящика». Основным отличием методов обучения ИНС от стандартных регрессионных моделей является возможность нелинейных преобразований внутри модели, а при прогнозировании временных рядов возможность использования дополнительных предикторов. Также одним из преимуществ нейронных сетей является возможность сокращения числа предикторов непосредственно внутри модели.

Представление об искусственных нейронных сетях сводится к тому, что нейронная сеть представляет собой многослойную структуру из слоев нейронов, причем каждый нейрон предыдущего слоя, как правило, связан с каждым нейроном последующего слоя, в случае, когда обратные связи отсутствуют, такая нейронная сеть называется сетью прямого распространения. В самом простом случае нейронная сеть состоит из входного слоя, т. е. слоя предикторов, которых может быть неограниченно много, скрытого слоя, с определенным числом скрытых нейронов и в котором происходит преобразование исходной информации посредством активационной функции и весовых коэффициентов (в более сложном случае может быть несколько скрытых слоев), и выходного слоя предиктантов.

Рассмотрим, в качестве примера, результаты обучения ИНС в целях прогнозирования высшего уровня воды за период ледохода на реке Печоре в районе села Оксина. При разработке модели прогнозирования в качестве предикторов использованы максимальный ледоходный уровень воды в селе Ермицы, расположенном выше по течению реки, и максимальный предледоходный уровень воды на посту в с. Оксина. Средняя заблаговременность прогноза составила 4 дня. В среде программирования Python 3 была создана модель, содержащая 3 и 5 скрытых нейрона на каждом скрытом слое соответственно, далее Seq 2-3-5-1. В программе Statistica 12 была использована функция автоматического обучения нейронных сетей. Лучшая искусственная нейронная сеть MLP 2-8-1 содержит 8 скрытых нейронов, в качестве функции активации использован гиперболический тангенс. В качестве критерия качества выпускаемых прогнозов использовано отношение стандартной ошибки прогностической модели (S) к среднеквадратическому отклонению прогнозируемой переменной от нормы ( $\sigma$ ). Можно отметить, что при решении данной задачи лучше всего зарекомендовали себя нейронные сети, обученные в программе Statistica 12 (см., рис. 2).



**Рис. 2. Результаты прогнозирования максимального ледоходного уровня воды в створе гидрологического поста в с. Оксино (1) с использованием нейросетевых моделей MLP 2-8-1 (2), Seq 2-3-5-1 (3) и модели множественной линейной регрессии (4); обучающая и тестовая выборка разделены условной линией (5).**

Анализируя используемые модели, можно прийти к выводу, что MLP 2-8-1 показала лучшие результаты на всех подвыборках, однако на тестовой подвыборке качество модели незначительно упало, почти сравнявшись с Seq 2-3-5-1.

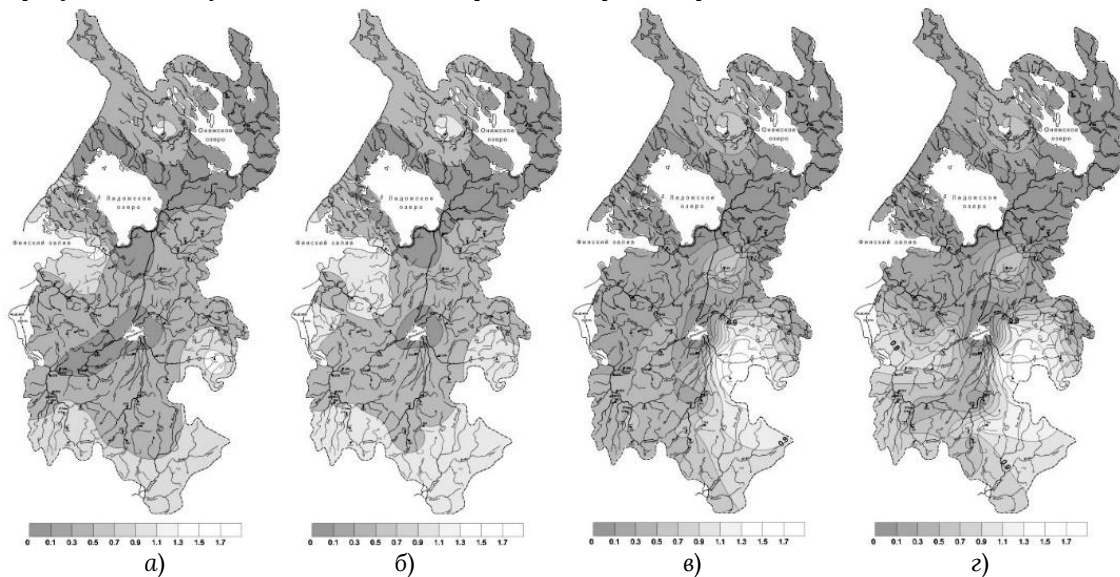
Использование методов обучения искусственных нейронных сетей зачастую дает ощутимое улучшение качества выпускаемых прогнозов по сравнению с регрессионными зависимостями. Например, в работах [5, 6] доказана более высокая эффективность нейросетевого моделирования при прогнозировании стока с различных водосборов включая горные, чем при использовании регрессионных зависимостей. В 38 из 40 случаев применения результаты прогнозирования с использованием искусственных нейронных сетей превосходили в пределах 5 % методы авторегрессии [6]. В работе [7] приводятся результаты использования ИНС для прогнозирования дождевого стока на реке Апуре в Венесуэле. Авторы отмечают, что оценка качества выпускаемых прогнозов на независимом материале при обучении ИНС оказалась выше на 10 %, чем у откалиброванной концептуальной модели формирования стока. В работе [8] рассматривается прогнозирование паводочного стока реки Shoor Ghayen River, расположенной в Иране, бассейн которой в среднем имеет высоту порядка 1420 метров над уровнем моря. Результаты работы указывают на оптимальную производительность искусственных нейронных сетей для прогнозирования паводочного стока. Точность прогнозирования в исследовании оценена как с использованием стандартных ошибок прогноза, так и коэффициентов корреляции между прогнозируемыми и фактическими значениями расходов воды. Максимальный коэффициент корреляции при тестировании искусственной нейронной сети на независимом материале составил 0,99 в апреле и сентябре, а минимальный 0,93 за август. В работе, посвященной прогнозированию речного стока малой реки Tuxi в Китае, использованы искусственные нейронные сети различной конфигурации, включая рекуррентные. Выявлено превосходство всех искусственных нейронных сетей над регрессионными методами, при этом лучшими для краткосрочного прогнозирования временных рядов являются LSTM сети [9].

В отечественной гидрологической практике использование нейронных сетей пока не широко распространено, но уже показывает хорошие результаты. К примеру, в работе [10] рассматривается возможность прогнозирования максимальных расходов воды за весеннее половодье и среднемесячных расходов воды реки Северной Двины. Показано превосходство искусственных нейронных сетей над аналогичными им по используемым предикторам моделям линейной регрессии на 10–20 %. В работе [11] рассмотрено применение аппарата нейронных сетей для анализа и сверхкраткосрочного прогноза приземной температуры с использованием созданной базы метеорологических данных, получаемых от автоматической метеорологической станции РГГМУ. В работе [12] была решена задача оценки обстановки в ближней морской зоне для выбора маршрутов или районов безопасного маневрирования судов с учетом различных территориальных факторов: ледовая обстановка, ветер, течения, экологические ограничения, хозяйственная активность, социальные факторы и др. В работе [13] разработана комплексная модель прогноза гидрологических процессов в условиях изменяющегося климата и антропогенной нагрузки с помощью элементов искусственного интеллекта (искусственных нейронных сетей и генетического алгоритма). Модели прогнозирования гидрологических показателей апробированы на примере р. Белой – крупнейшей водной артерии Республики Башкортостан. Результаты, полученные в приведенных работах, признаны удовлетворительными.

Одной из специфических проблем при использовании нейронных сетей в практике гидрологических прогнозов является выбор правильной архитектуры сети и оптимального количества скрытых нейронов. Недостаточное число нейронов не позволит решить сложную задачу, а слишком большое их количество сильно замедлит процесс обучения и приведет к переобучению – большое количество нейронов позволит сети не аппроксимировать зависимость между входом и выходом, а лишь запомнить все подаваемые на вход данные и сопоставить им соответствующие выходы. Данный подход оказывается ошибочным, что проявляется при тестировании нейронной сети на независимом материале.

**Динамическое и стохастическое моделирование**

В РГГМУ разработана и успешно используется методика, основанная на применении динамических моделей формирования суточных расходов воды в виде дифференциальных уравнений первого и второго порядка для фонового прогнозирования процесса изменения модулей стока с предоставлением прогностической информации в виде соответствующих карт, с помощью которых можно с недельной заблаговременностью прогнозировать траектории смещения экстремальных значений стока (см., например, [14]). На рис. 3 для примера показаны результаты, полученные по методике фонового прогнозирования водности.



**Рис. 3. Прогнозные изменения распределения модуля стока на территории Северо-Западного региона за восемь суток, схемы представлены через двое суток.**

Для краткосрочного прогнозирования водности рек наиболее подходящими являются модели первого и второго порядка соответственно:

$$\frac{dQ}{dt} = -\frac{1}{k\tau}Q + \dot{X}, \quad (2)$$

$$\tau_2 \frac{d^2Q}{dt^2} + \left(\frac{\tau_2}{k\tau_1} + 1\right) \frac{dQ}{dt} + \frac{1}{k\tau_1}Q = \frac{1}{\tau_1} \dot{X}, \quad (3)$$

где:  $Q$  – расход (модуль, слой) стока;  $\dot{X}$  – интенсивность осадков;  $k$  – коэффициент стока;  $\tau$  – время релаксации речного бассейна;  $\tau_1$  – время добегающего поверхностного стока;  $\tau_2$  – время добегающего подземного стока.

Схема алгоритма прогноза заключается в следующем:

- для параметризации модели берутся 15 суток (или 30 суток), предшествующие дню выпуска прогноза;
- параметры модели считаются оптимальными, если соотношение среднеквадратической погрешности поверочных прогнозов к среднеквадратическому отклонению прогнозируемой величины за период заблаговременности  $S/\sigma_{\Delta}$  минимально, а число оправдавшихся поверочных прогнозов  $P$  (%) максимально;
- по периоду параметризации проводится фрактальная диагностика, основанная на расчете корреляционной размерности, показывающая число фазовых переменных необходимых для надежного прогноза, т. е. размерность прогностической модели: первого или второго порядка (считается, что порядок модели сохранится и на период заблаговременности прогноза);
- дается прогноз с заблаговременностью, например, сутки, затем при прохождении суток период параметризации сдвигается к дате выпуска прогноза – применяется динамическая параметризация [14].

Например, в статье [14] было показано применение динамических моделей формирования суточных расходов воды в виде дифференциальных уравнений первого и второго порядка для прогнозирования процесса изменения речного стока с водосборов Колумбии, которые расположены в полугорной местности и для которых характерны кратковременные паводки дождевого происхождения. В ходе выполнения поверочных прогнозов расходов воды было экспериментально доказано, что для условий формирования суточного стока рек Колумбии более надежные результаты дает дифференциальное уравнение (модель) первого порядка.

Методика фонового стохастического прогнозирования основана на использовании системы дифференциальных уравнений для начальных моментов распределения плотности вероятности модулей суточного стока. Данная методика дает возможность получения оперативных прогнозов состояния водных объектов, выпускается прогноз вероятностных характеристик расходов воды (уровней).

Для реализации методики фонового стохастического прогнозирования необходим метеорологический прогноз изменения осадков и температуры воздуха (в случае прогнозирования весеннего половодья), стандартные сетевые гидрометеорологические наблюдения.

Динамический прогноз ограничивается указанием конкретных значений расходов (уровней) в узлах расчетной сетки. Такой строго детерминистический подход игнорирует случайные факторы формирования стока, а также погрешности задания начальных данных, параметров моделей и внешних воздействий (ход прогнозных осадков). В случае стохастического описания процесса знание кривых распределений плотности вероятности расходов  $p(Q)$  или уровней  $p(H)$  (или прогнозных распределений) позволяет приписывать любому

прогнозируемому значению расхода (уровня) вероятность его появления. Это расширяет возможности оценки риска принятия ошибочных решений для экономики.

Применяется уравнение Фоккера–Планка–Колмогорова (ФПК), которое для прогнозов аппроксимируется системой обыкновенных дифференциальных уравнений [15]:

$$\begin{aligned} dm_1/dt &= -(\bar{c} - 0,5G_{\bar{c}})m_1 + \bar{N} - 0,5G_{\bar{c}\bar{N}}; \\ dm_2/dt &= -2(\bar{c} - G_{\bar{c}})m_2 + 2\bar{N}m_1 - 3G_{\bar{c}\bar{N}}m_1 + G_{\bar{N}}; \\ dm_3/dt &= -3(\bar{c} - 1,5G_{\bar{c}})m_3 + 3\bar{N}m_2 - 7,5G_{\bar{c}\bar{N}}m_2 + 3G_{\bar{N}}m_1; \\ dm_4/dt &= -4(\bar{c} - 2G_{\bar{c}})m_4 + 4\bar{N}m_3 - 4 \cdot 3,5G_{\bar{c}\bar{N}}m_3 + 6G_{\bar{N}}m_2, \end{aligned} \quad (4)$$

где:  $m_i$  – начальные статистические моменты  $i$ -го порядка;  $c = 1/k\tau$ ,  $N = \dot{X}/\tau$ ,  $k$  – коэффициент стока;  $\tau$  – время релаксации речного бассейна;  $\dot{X}$  – интенсивность осадков;  $G_{\bar{c}}$ ,  $G_{\bar{N}}$ ,  $G_{\bar{c}\bar{N}}$  – интенсивности белых гауссовских шумов. Первых трех уравнений достаточно для получения эволюции асимметричных вероятностных распределений.

Возможны различные варианты параметризации системы (4). С учетом того что  $c = 1/k\tau$ ,  $N = \dot{X}/\tau$  и при этом  $k$  и  $\tau$  известны из оптимизации модели, а  $\dot{X}$  – из метеопрогноза, необходимо определить только интенсивности  $G_{\bar{c}}$ ,  $G_{\bar{N}}$  и  $G_{\bar{c}\bar{N}}$  из первых трех уравнений системы (4) при известных  $m_1$ ,  $m_2$  и  $m_3$ . Они могут быть определены на основе 30-дневных наблюдений за стоком в створе, для которого дается прогноз.

В течение суток происходят изменения расходов воды, которые не измеряются и не фиксируются, – на практике используют только среднесуточные значения, делая как бы статистическое обобщение внутрисуточных вариаций расходов воды. Решением системы уравнений для начальных моментов (4) являются прогнозные значения трех первых моментов, которые характеризуют среднесуточное значение, вариацию расходов воды внутри суток и отклонение среднего значения от модального.

### Заключение

В результате анализа рассмотренных подходов прогнозирования характеристик речного стока выявлены следующие, важные для практических целей, особенности:

- регрессионные зависимости достаточно просты в получении, но требуют полной текущей информации о всех предикторах в модели;
- методы теории АРСС (модель авторегрессии, смешанные модели, модель авторегрессии проинтегрированного скользящего среднего) возможно применять, имея ретроспективные ряды наблюдений за речным стоком без знания метеорологической оставляющей, но есть вероятность получения неудовлетворительных результатов из-за своеобразия условий формирования стока для года, для которого выпускается прогноз;
- прогнозирование с помощью искусственных нейронных сетей предполагает наличие достаточного объема ретроспективной информации и знания вычислительных алгоритмов для получения эффективной модели;
- динамическое и стохастическое моделирование процессов формирования речного стока позволяют получать надежные результаты за счет вариации значений модели, а также возможного изменения их числа [16]; результатами стохастического моделирования являются прогнозы в виде вероятности осуществления явления.

### Благодарность

Исследование выполнено при финансовой поддержке КН РА (20RF-039) и РФФИ РФ (20-55-05006\20) в рамках совместной научной программы «Краткосрочный вероятностный прогноз стока рек в период весеннего половодья».

### Литература:

1. Борщ С.В., Симонов Ю.А., Христофоров А.В. Система прогнозирования паводков и раннего оповещения о наводнениях на реках Черноморского побережья Кавказа и бассейна Кубани. Глава 3, стр. 67. [Электронный ресурс]. – Режим доступа: [www.elibrary.ru](http://www.elibrary.ru) (Дата обращения 21.01.2021).
2. Москвич Т.И., Крамарев В.Ю. Оценка динамики снеготаяния с использованием многозональной информации ИЗС NOAA [Электронный ресурс]. – Режим доступа: [www.elibrary.ru](http://www.elibrary.ru) (Дата обращения 22.01.2021).
3. Бокс Дж., Дженкинс Г. Анализ временных рядов. Прогноз и управление. Вып. 1. М., 1974.
4. Руководство по гидрологической практике (ВМО–№ 168), Том II – Управление водными ресурсами и практика применения гидрологических методов, 2012. – С. 324.
5. Akhtar M. K. et al. River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information: case study of the Ganges river basin // Hydrology and Earth System Sciences, Т. 13, №. 9, 2009. – P. 1607–1618.
6. Shamseldin A.Y., O'Connor K.M. A Non-Linear Neural Network Technique for Updating of River Flow Forecasts // Hydrology and Earth System Sciences, Vol. 5 (№ 4), 2001. – P. 577–597.
7. Dibike Y. B., Solomatine D. P. River flow forecasting using artificial neural networks // Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere, Т. 26, №. 1, 2001. – С. 1–7.
8. Rezaei M. et al. River Flow Forecasting using artificial neural network (Shoor Ghaen) // Ciência e Natura, Т. 37, №. 6-1, 2015. – С. 207–215.
9. Hu Y. et al. Stream-Flow Forecasting of Small Rivers Based on LSTM // arXiv preprint arXiv:2001.05681. – 2020.

10. Sumachev A.E., Kuzmin V.A., Borodin E.S., River Flow Forecasting Using Artificial Neural Networks, International Journal of Mechanical Engineering and Technology, 9(10), 2018. – P. 706–714.
11. Алдошкина Е. С. и др. Опыт использования аппарата нейронных сетей для анализа и прогноза временного ряда температуры воздуха // Ученые записки РГГМУ, №. 11, 2009. – С. 91–100.
12. Биденко С. И., Храмов И. С., Шилин М. Б. Оценка территориальной ситуации с использованием искусственных нейронных сетей // Ученые записки РГГМУ, №. 54, 2019. – С. 109–123.
13. Красногорская Н. Н., Ферапонтов Ю. И., Нафикова Э. В. Разработка методов прогнозирования гидрологических процессов для задач управления водными ресурсами // Ученые записки РГГМУ, №. 28, 2013. – С. 43–50.
14. Эспития С.Э.Ф., Гайдукова Е.В., Коваленко В.В. Краткосрочный прогноз расходов воды на реках Колумбии с использованием фрактальной диагностики // Ученые записки РГГМУ, № 47, 2017. – С. 16–24.
15. Баймаганбетов А.Е., Гайдукова Е.В. Применение метода стохастического фонового прогноза к речным бассейнам Казахстана // Гидрометеорология и экология, № 59, 2020. – С. 41–50. DOI: 10.33933/2074-2762-2020-59-41-50.
16. Kovalenko, V.V., Gaidukova, E.V. The phenomenon of nonzero norm of long-term changes in the total water supply in river basins / American Journal of Environmental Sciences, 11(2), 2015. – С. 76–80.