

**МЕТЕОРОЛОГИЯ / METEOROLOGY**

УДК 550.51

**ПРОГНОЗИРОВАНИЕ ВРЕМЕННЫХ РЯДОВ ТЕМПЕРАТУРЫ ГИБРИДНЫМИ МОДЕЛЯМИ С ИСПОЛЬЗОВАНИЕМ ВЕЙВЛЕТ-РАЗЛОЖЕНИЯ И НЕЙРОННОЙ СЕТИ****М.Л. АРУШАНОВ<sup>1\*</sup>, Х.У. УМЕРОВ<sup>1</sup>, А.И. ВДОВЕНКО<sup>2</sup>**<sup>1</sup> Научно-исследовательский гидрометеорологический институт, mikl-arushanov@rambler.ru<sup>2</sup> Центр гидрометеорологической службы Республики Узбекистан

**Аннотация.** В данном исследовании проанализировано влияние преобработки временных рядов на основе вейвлет-разложения в сочетании с нейронными сетями в целях прогноза рядов реконструированных температур. Рассмотрены подходы с использованием нескольких моделей и анализируются их прогностические возможности в гибридном сочетании. Вейвлет-преобразование используется, как инструмент подавления шумовой составляющей временного ряда температуры, а прогностическая модель строится на основе технологий Нейронных сетей и регрессионных методов прогноза временных рядов.

**Ключевые слова:** временные ряды, реконструированные температуры, вейвлет-разложение, нейронные сети, прогнозирование, гибридные модели.

**Введение.** Прогнозирование временных рядов – одно из основных направлений в метеорологии. Существует множество динамико-стохастических моделей прогноза, начиная от базовых моделей (простая скользящая средняя, линейная регрессия и пр.), до более продвинутых моделей, таких как авторегрессионная интегрированная скользящая средняя (ARIMA) и нейронные сети.

Динамико-стохастические прогностические модели представляются в виде детерминированной составляющей и случайного шума  $\varepsilon_t$ :

$$y_{t+1} = A(y_t) + \varepsilon_t, \quad (t=1, 2, \dots)$$

где  $A$  – определённый прогностический оператор.


Таким образом, основная задача моделирования сводится к минимизации шумовой составляющей с использованием различных разложений исходной функции, например, таких как, Фурье и вейвлет-преобразования [Арушанов, 2015; Будаков, Фомин, 1967; Витязев, 2001]. Последнее обладает существенным преимуществом по сравнению с преобразованием Фурье, поскольку вейвлет-преобразование позволяет судить не только о частотном спектре сигнала, но и о том, насколько устойчив период колебаний той или иной гармоники во времени.

Вейвлет-преобразование стало очень популярным во многих областях науки, включая физико-математические, экономические и социальные [Ли, 1998; Малла, 2005; Риуль, Веттерли, 1991; Alexandridis, Zapranis, 2013]. Однако, в метеорологии в целях решения задач прогноза вейвлет-преобразование и нейронные сети пока не нашли широкого использования.

\* Ответственный автор: mikl-arushanov@rambler.ru, тел.: +998 90 997-61-46

В данной статье сделана попытка в некоторой степени возместить этот пробел путём рассмотрения гибридных моделей прогноза среднегодовых температур на основе вейвлет-преобразования, нейронных сетей [Медведев, Потемкин, 2001] и классических методов [Пановский, Брайер, 1972].

**Используемый материал.** В работе использованы дендрологические данные реконструированной температуры на территории полуострова Ямал [Hantemirov et al., 2022] за 8 тысячелетий (взято 1220 лет – 800-2020 гг.). На рис. 1 приведен временной ход реконструированной температуры воздуха на территории полуострова Ямал и её тренд на 1220-летнем периоде.



**Рис. 1. Временной ход температуры воздуха на территории полуострова Ямал, реконструированный по колебаниям ширины годичных колец деревьев**

**Fig. 1. Time variation of the reconstructed air temperature on the territory of the Yamal Peninsula based on fluctuations in the width of annual tree rings**

**Методы исследования.** Для разложения исходных рядов с помощью вейвлет-преобразования используется следующая формула [Алексеев, 2013]:

$$W(f(a,b)) = \langle f, \psi_{a,b} \rangle = \frac{1}{|a|^{1/2}} \int_{-\infty}^{\infty} f(t) \cdot \psi\left(\frac{t-b}{a}\right) \cdot dt \quad (1)$$

где  $\psi_{a,b} = \frac{1}{|a|^{1/2}} \cdot \psi\left(\frac{t-b}{a}\right)$  – функция материнского вейвлета;  $a$  – масштабирующий параметр,  $b$  – параметр сдвига,  $1/(|a|^{1/2})$  – параметр нормировки вейвлет-функции, обеспечивающий  $\|\psi_{a,b}\| = 1$ . Прямое вейвлет-преобразование (1) можно рассматривать как разложение сигнала по всем возможным сдвигам и растяжениям/сжатиям сигнала  $f(t)$ . Преобразование (1) при задании вектора  $a$  в некотором диапазоне ( $a_{min} \div a_{max}$ ) позволяет получить из исходной функции  $f(t)$  множество функций  $W[f(a,b)]$ , изменяющихся с разными частотами (от высокочастотных до низкочастотных). При таком подходе обработки сигнала  $f(t)$  характерные детали, которые скрыты при одном разрешении, могут быть обнаружены при другом.

Используя анализ с несколькими разрешениями, можно исследовать, как общую структуру, так и детали мелкой структуры ряда. Шумоподавление с разным разрешением с использованием вейвлет-преобразования позволяет получить более гладкий ряд, не изменяя при этом его основную структуру. Это оказывается полезным в задачах прогностических моделей [Ли, 1998; Jin, Kim, 2015].

Концептуально, вейвлет-коэффициенты описывают особенности ряда, а их малые значения, как правило, представляют шумовую составляющую, которая легко исключается путём отбрасывания малых коэффициентов по заданному пороговому значению. В этом достоинство вейвлет-преобразования, которое по своему содержанию аналогично фильтрации исходных рядов с помощью разложений по системе естественных ортогональных составляющих [Мещерская и др., 1970].

В метеорологии, как правило, данные выражаются дискретными последовательностями, для разложения которых используется дискретное вейвлет-преобразование (DWD) [Арушанов, 2015].

Процесс DWD может быть выполнен путем пропускания последовательности через полуполосные цифровые фильтры нижних и верхних частот [Канасевич, 1985]. При этом разрешение по частоте удваивается, потому что в отфильтрованных последовательностях существует только половина исходной полосы. После пропуска последовательностей через фильтры половина выборок может быть отсеяна по критерию Найквиста (т.е. половина выборок является избыточной). Следовательно, после субдискретизации на два, временное разрешение уменьшается вдвое. Восстановление исходного ряда  $f(t)$  по вычисленным масштабирующим (аппроксимирующим) информативным коэффициентам производится путем обратного преобразования [Алексеев, 2013]:

$$f(t) = \frac{1}{\sqrt{M}} \sum_k W_\varphi(j_0, k) \cdot \varphi_{j_0, k}(t) + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi(j, k) \cdot \psi_{j, k}(t) \quad (2)$$

Введем обозначения:  $a_1, a_2, \dots, a_m$  – аппроксимации ряда на уровнях ( $1 \dots m$ );  $d_1, d_2, \dots, d_m$  – детали распределения ряда на соответствующих уровнях. Тогда исходный ряд  $f(t)$  в формуле (2) на нулевом уровне с некоторой точностью (точностью заданного числа уровней детализации) может быть представлен в виде:

$$f = a_m + d_m + d_{m-1} + \dots + d_1 \quad (3)$$

здесь  $a$  – низкочастотные функции, а детали  $d_i$  с малыми значениями  $i$  очень малы, как высокочастотные функции.

В формуле (3) аппроксимации  $a_i$  и детали  $d_i$  с увеличением уровня аппроксимации  $i$  стремятся к const. По сути,  $a_i$  и  $d_i$  – это временной ряд той или иной степени гладкости. Заметим, что из-за значимых искажений на границах вейвлет-преобразования, следует исключать граничные значения в разложение [Alexandridis, Zapranis, 2013].

Описанную выше процедуру можно повторить для дальнейшего разложения. Рис. 2 иллюстрирует этот процесс для 3-уровневой декомпозиции, где  $f$  – исходная последовательность,  $D1$  – дискретные вейвлет-коэффициенты (DWC) первого уровня,  $D2$  – DWC второго уровня,  $D3$  и  $A3$  – DWC третьего уровня [Jin, Kim, 2015]. Заметим, что исходная последовательность  $f$  может быть синтезирована последовательностями низких и высоких частот, т.е.  $f = a_3 + d_3 + d_2 + d_1$ .

### Сценарии моделирования.

1. Применим непрерывное вейвлет-преобразование к исходному ряду.
2. Используем дискретное вейвлет-разложение (DWT) ряда реконструированных среднегодовых температур июля на полуострове Ямал на ряд приближений (аппроксимаций) и ряды деталей компонентов: одну аппроксимационную составляющую (аппроксиматор) и пять детализированных компонент. Аппроксимационный компонент можно рассматривать как тренд исходного ряда. Детализированные компоненты могут представлять зашумленность исходного ряда.

3. Выберем методы прогнозирования для аппроксиматора и рядов детализации. Определим структурные параметры выбранных моделей.
4. Применим методы прогнозирования для каждого компонента.
5. Проведём восстановление прогнозируемого ряда и сравним результаты. Впоследствии, как ожидается, можно сделать вывод о том, представляют ли компоненты детализации шум или являются информационным компонентом.

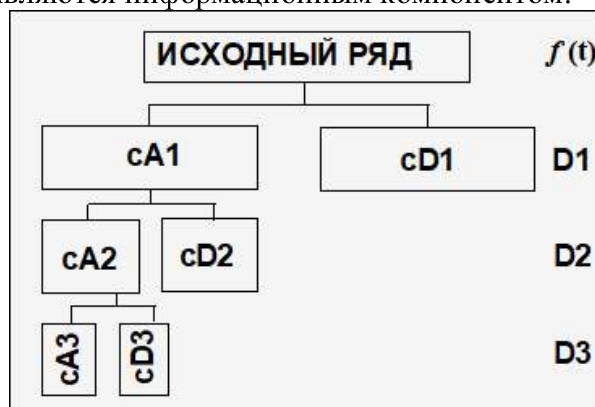


Рис 2. Структура вейвлет-разложения

Fig 2. The structure of the wavelet decomposition

**Выбор моделей.** Наиболее распространенными моделями в прогнозировании временных рядов, особенно при параметрической оценке, являются авторегрессионные интегрированные скользящие средние (ARIMA) и обобщенные авторегрессионные модели условной гетероскедастичности (GARCH). GARCH модели основаны на идее несогласованной дисперсии в общем временном ряде [Алексеев, 2013; Росси, 2004].

Сплайн-модели [Вагер, Серков, 1987] широко используются при интерполяции различных пространственно-временных рядов, а с использованием стратегии экстраполяции могут применяться и в задачах прогноза.

Отметим так же, что в последнее время набрали популярность методологии машинного обучения, такие как искусственные нейронные сети (ИНС), которые используются во многих прогнозных исследованиях [Риуль, Веттерли, 1991; Alexandridis, Zapranis, 2013; Jin, Kim, 2015], поскольку универсальность этих моделей позволяет применять их к любым геофизическим процессам, в частности, атмосферным.

На основании вышесказанного, рассматриваются следующие модели прогноза.

1. GARCH (*Generalized AutoRegressive Conditional Heteroscedasticity*) – обобщенные авторегрессионные модели условной гетероскедастичности [Jin, Kim, 2015] (модель условной дисперсии со смещением (распределение Гаусса) – временной ряд  $u(t)$  с функцией условной дисперсии)

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i u_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2$$

где  $p$  – порядок GARCH-членов условной дисперсии  $\sigma^2$  (прошлые условные отклонения);  $q$  – порядок ARCH-членов  $u^2$  (прошлые значения временного ряда). Выбор ARCH и GARCH лагов проводился экспериментально.

2. Сплайн-модель, основанная на кубической сплайн-интерполяции, со стратегией экстраполяции различных кубических полиномов. На каждом отрезке функция приближается кубическим многочленом

$$f(x) = a(x-x_1)^3 + b(x-x_1)^2 + c(x-x_1) + d$$

для коэффициентов  $a, b, c, d$  на интервале  $[x_1, x_2]$ .

Для регулярной сетки узлы алгоритма экстраполяции представляются в виде последовательности разложений по координатам точек, а коэффициенты разложений представлены аналитически. В итоге ордината прогнозируемой точки не зависит от шага сетки, что существенно для оценки ближайшего соседа, следующего в серии регулярных наблюдений, когда принципиальна не величина интервала между измерениями, а его неизменность. Моделирование проводилось функцией МАТЛАБа `interp1(X1,Y1,dTest,'spline','extrap')` [Дьяконов, 2012].

3. ANN (*Artificial Neural Networks*) – искусственные нейронные сети с временной задержкой [Медведев, Потемкин, 2001] (рис. 3).




Рис. 3. Нейросеть прямого распространения (ANN):

а) графическая схема, б) структурная схема

Fig. 3. Feed-forward neural network (ANN): a) graphic diagram, b) block diagram

4. NarNET - Нелинейная авторегрессионная нейронная сеть [Медведев, Потемкин, 2001] (рис. 4.).




Рис. 4. Структура нелинейной авторегрессионной нейронной сети

Fig. 4. Structure of a nonlinear autoregressive neural network

С помощью команды `closeloop(net)`, замыкался контур этой сети для получения рекуррентной сети – генератора. Шаг запаздывания и количество нейронов скрытого слоя подбирались экспериментально и составили 2/14 и 3/12 для ANN и NarNET соответственно.

Оценка точности прогнозирования производилась по среднеквадратичной ошибке:

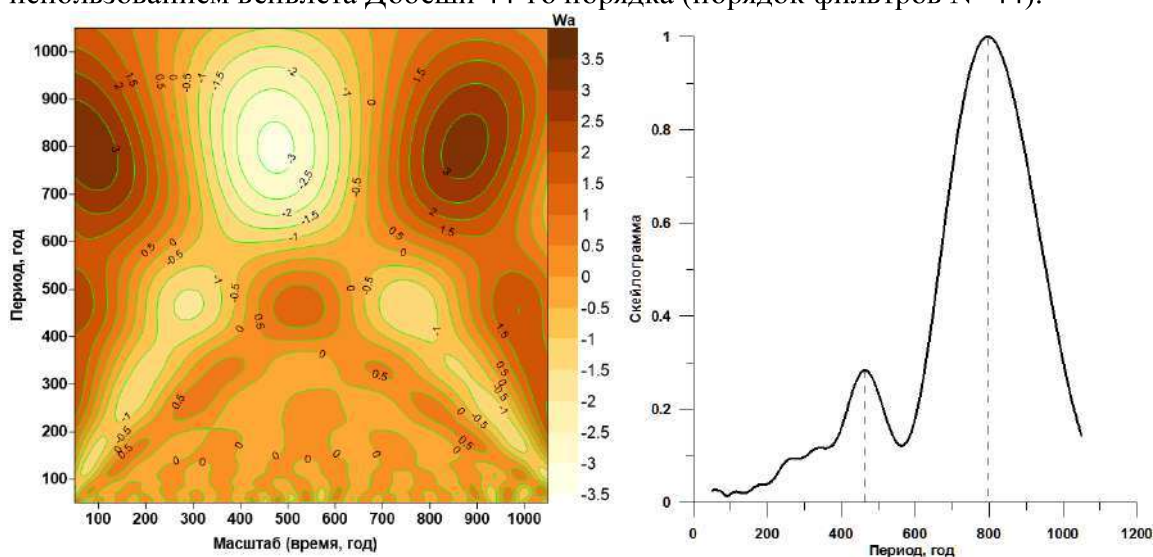
$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4)$$

где  $\hat{Y} = \{ \hat{Y}_i \}$  – вектор прогнозов, который генерируется из выборки  $n$  точек данных (учебная выборка) по всем переменным;  $Y = \{ Y_i \}$  – вектор наблюдаемых значений прогнозируемой переменной (независимая выборка).

В рамках предварительного анализа с использованием вейвлета Morle были получены амплитудная вейвлет-функция (АВФ) и скейлограмма температурного ряда за период с 881-2019 гг. (рис. 5). АВФ отображает детали частотного образа температурного ряда: в нижней части отчетливо видны высокочастотные компоненты с периодом 50 лет, а в средней и верхней – устойчивые колебания на частотах, соответствующих периодам 480 и 800 лет, отчетливо проявившиеся в интегральном спектре – скейлограмме.

На основании анализа полученных результатов и с учетом эффекта переобучения нейронных сетей (на отметке 600 лет переобучение проявилось отчетливо) был выбран период исследования в 320 лет. Из них ряд в 300 лет составил учебную выборку, ряд в 20 лет – независимую.

**Основные результаты и их обсуждение.** Все расчёты выполнялись в среде МАТЛАБ. Для расчета дискретных преобразований обычно применяются вейвлет-функции семейства Добеши порядка «db<sub>4</sub>», «db<sub>26</sub>» и «db<sub>44</sub>» [Жмурко, 2017]. Нами, в качестве базисного вейвлета, был выбран «db<sub>44</sub>». На рис. 6 показано пятиуровневое вейвлет-разложение исследуемого ряда в течение 300 лет за период 1800-1999 гг. с использованием вейвлета Добеши 44-го порядка (порядок фильтров  $N=44$ ).



**Рис. 5. Амплитудная вейвлет-функция  $W_a$  (а) и скейлограмма температуры воздуха (б)**

**Fig. 5. Wavelet amplitude function  $W_a$  (a) and air temperature scalogram (b)**

Простая структура аппроксиматора  $A$  показывает тенденцию изменения температур, т.е. общую картину, так называемый «лес». При рассмотрении «деревьев», т.е. детализации, на уровне  $d_5$ , например, можно видеть, что периоды относительной стабилизации температур по шкале 10-60 лет (1710-1760 гг.) и 150-220 лет (1856-1920 гг.) сменялись значительными перепадами на остальных периодах. Если мы рассмотрим  $d_4$ , то временное разрешение увеличится, и мы сможем более подробно отразить периоды стационарности и значимых колебаний.

Вейвлет-реконструкция исследуемого ряда, представлена на рис. 6. Среднеквадратичная ошибка реконструкции составила  $\sigma=8,2065 \cdot 10^{-6}$ , что вполне обосновывает использование вейвлет анализа для решения поставленной задачи.




Рис. 6. Вейвлет-разложение исходного ряда на 5 уровней

Fig. 6. Wavelet decomposition of the original series into 5 levels

На рис. 7 приведена графика аппроксиматора (низкочастотная часть вейвлет-разложения), которая четко описывает основную тенденцию изменения временного ряда температуры.

Методология гибридных моделей предполагает обучение нескольких моделей на одном и том же временном ряде. Далее выполняется оценка полученных по разным моделям прогнозов, которые могут быть усреднены.

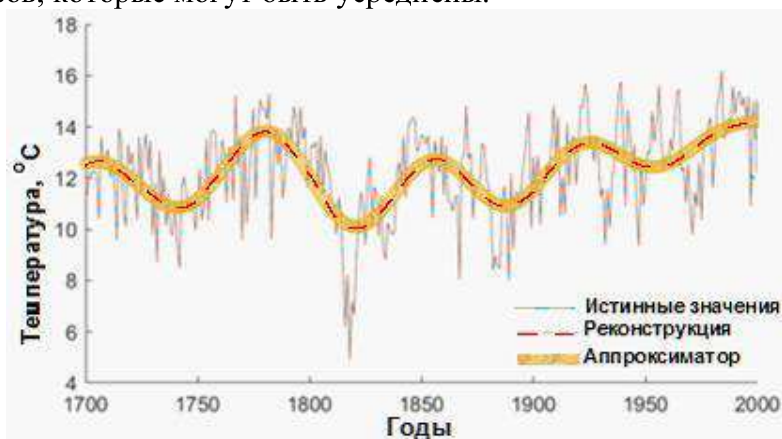


Рис. 7. Вейвлет-реконструкция температурного ряда

Fig. 7. Wavelet reconstruction of the temperature series

На рис. 8 представлены результаты прогноза аппроксиматора  $A$  различными моделями. Итоги подтвердили выбор моделей для прогноза коэффициентов вейвлет-разложения: spline и ANN.

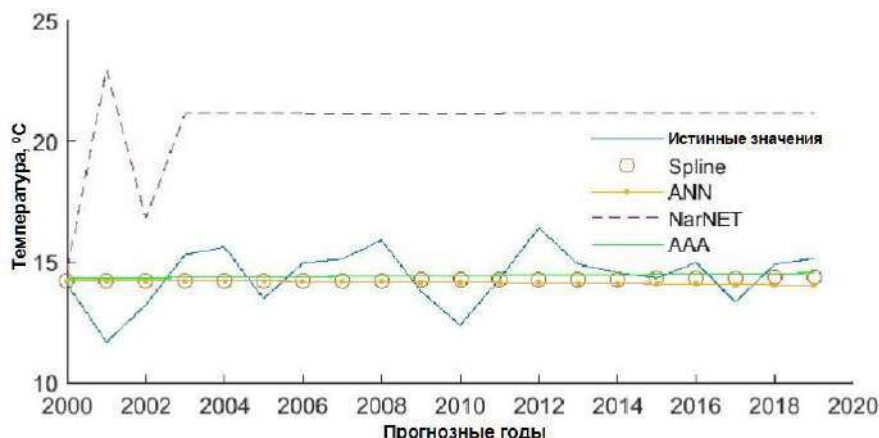


Рис. 8. Прогноз аппроксиматора различными моделями

Fig. 8. Approximator prediction by various models

Полученные ряды коэффициентов  $a_5$ ,  $d_5$ ,  $d_4$ ,  $d_3$ ,  $d_2$  и  $d_1$  прогнозировались на 20 шагов (лет). Для прогнозирования  $a_5$  использовалась модель ANN с двумя шагами задержки и 14-ю шагами нейросети скрытого слоя. Для прогноза  $d_4$ ,  $d_3$ ,  $d_2$  и  $d_1$  использовалась сплайн-модель со стратегией экстраполяции – `interp1(X1,Y1,dTest,'spline','extrap')`. На рис. 9 представлены результаты прогноза.

Далее, сигнал преобразуется обратно во временную область путем выполнения обратного преобразования (2). Одним из недостатков является то, что разложение сигнала путем преобразования приводит к перекрытиям на краях соответствующих частотно-временных рядов и усиливается выбором уровня декомпозиции [Rumaih et al., 1996].

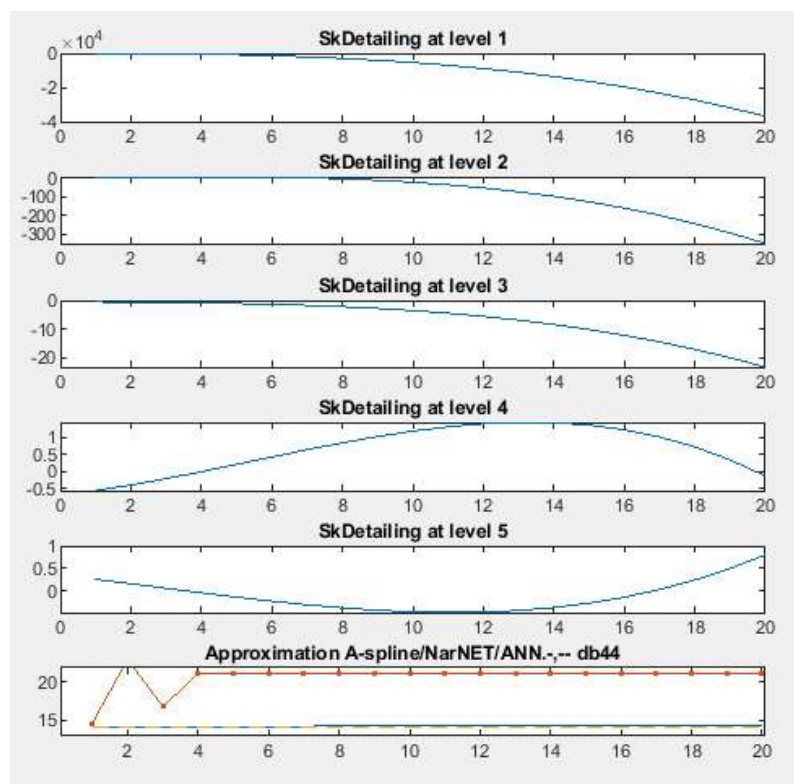
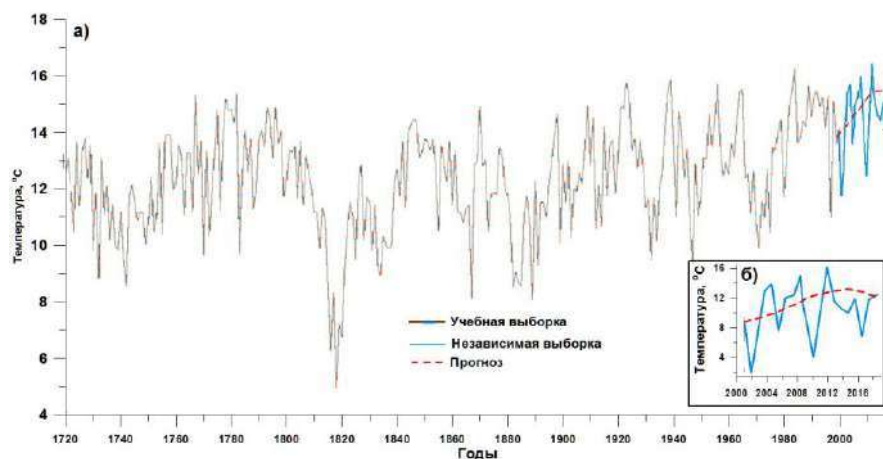


Рис. 9. Прогноз на 20 шагов (лет) вейвлет разложения

Fig. 9. Forecast for 20 steps (years) of the wavelet decomposition

При оценке полученных коэффициентов детализации на этапе реконструкции прогноза первые три уровня высокочастотного разложения не учитывались, т.к. прогнозные оценки выходили за допустимый уровень. В результате суммирования прогнозных оценок была получена реконструкция прогноза на 20 лет (2000-2019 гг.). Далее полученные результаты сравнивались с данными независимой выборки. На рис. 10 представлены результаты прогноза, а на рис. 11 – прогноз с предварительной реконструкцией.

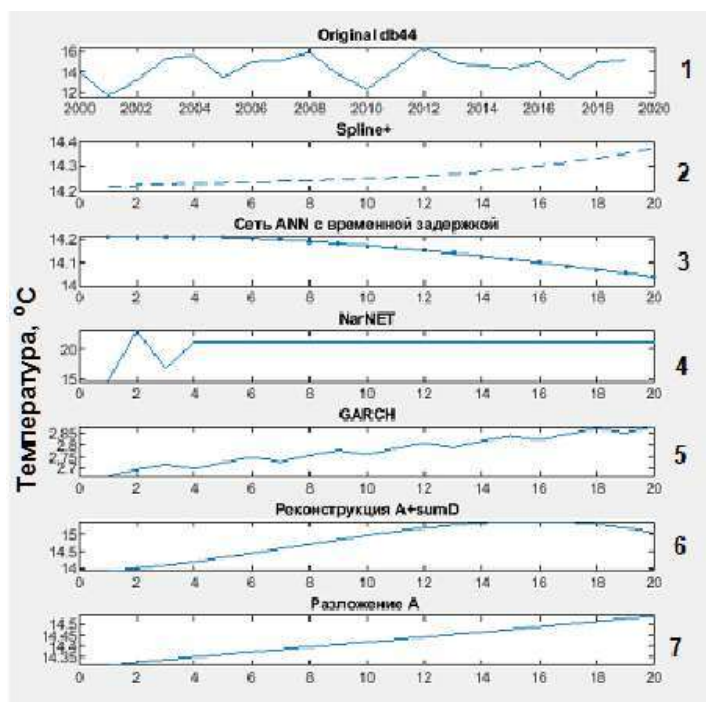


**Рис. 10. Результаты прогноза с использованием вейвлет-разложения**

*Примечание:* а) временной ход ряда учебной выборки температуры + прогноз;  
б) прогноз на период 2000-2019 гг.

**Fig.10. Prediction results using wavelet decomposition**

*Note:* а) the time course of a series of training sample temperature + forecast;  
б) forecast for the period 2000-2019.



**Рис. 11. Результаты прогноза температуры различными моделями**

**Fig. 11. Temperature forecast results by various models**

Также были проведены расчеты прогноза ряда с обучением по аппроксиматору различными моделями и сравнение результатов с оригинальным рядом (рис. 11). Первый ряд – исходные данные, 2-5 прогнозы по различным моделям, 6 – реконструкция  $f = a_5 + d_5 + d_4$ , 7 – распределение аппроксиматора  $a_5$ .

В таблицах 1-2 представлены оценки полученных результатов в виде среднеквадратичной ошибки прогнозов, рассчитанные по данным независимой выборки, и коэффициенты корреляции моделей прогноза и аппроксиматора в зависимости от объема учебной выборки, соответственно.

По полученным результатам видно, что выборка в 200 лет практически по всем показателям уступает другим (300, 400 лет). При этом модель GARCH дала значительно смещенный прогноз, что выразилось высоким среднеквадратичным отклонением, при значимом коэффициенте корреляции. Модель NarNET дала неудовлетворительный результат и по среднеквадратичному отклонению и коэффициенту корреляции. Хотя на выборке 400 лет – результат значительно улучшился. Следует отметить, что при прямом прогнозировании, без использования вейвлетов, все модели, кроме ANN, дали неудовлетворительные результаты. Как следует из таблиц 1, 2 модель «A+sumD» показала высокие результаты.

Таблица 1

**Среднеквадратичное отклонение между моделями прогноза  
и данными независимой выборки**

Table 1

**Standard deviation between forecast models and independent sample data**

Модель	Объем учебной выборки, лет		
	200	300	400
	Среднеквадратичная ошибка		
SPLINE	1,344	1,316	1,317
ANN	1,339	1,411	1,351
NarNET	41,847	43,433	2,660
GARCH	132,595	136,820	137,105
A+sumD	208,424	<b>1,418</b>	<b>1,413</b>
AAA	1,293	<b>1,274</b>	<b>1,274</b>

Таблица 2

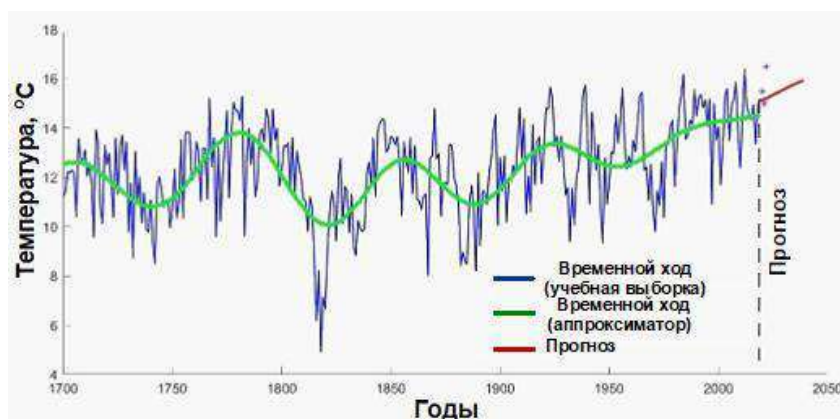
**Корреляция моделей прогноза и аппроксиматора**

Table 2

**Correlation of forecast and approximator models**

Модель	Объем выборки, лет		
	200	300	400
	Коэффициент корреляции		
SPLINE	-0,624	0,944	0,944
ANN	-0,613	-0,970	-0,647
NarNET	-0,608	0,393	0,588
GARCH	0,558	0,981	0,981
A+sumD	0,681	0,907	0,907

По выбранной методике проводилось вейвлет разложение, обучающие процедуры по технологиям Нейронных сетей за период с 1700 по 2019 гг. и рассчитывался прогноз на последующие годы, начиная с 2020 до 2040 года (рис. 12).



**Рис.12. Результаты прогнозирования по разработанной модели**

**Fig.12. Results of forecasting according to the developed model**

**Выводы.** В итоге можно отметить, что выбранный подход в целом себя оправдал и для долгосрочного прогнозирования можно использовать вейвлет-разложение вместе с нейронными сетями. Особое внимание необходимо уделять корректному исключению шумовых компонентов в вейвлет-разложении, «не выплеснув ребёнка вместе с водой».

Построение модели включает следующие этапы: 1) декомпозиция ряда с использованием заданной вейвлет-функции и вычисление вейвлет-частотных характеристик ряда; 2) декомпозиция ряда на аппроксимирующие составляющие с последующим их прогнозированием с использованием технологий Нейронных сетей.

**Вклад авторов.** **М.Л. Арушанов:** постановка задачи, анализ, редакция текста; **Х.Н. Умеров:** разработка алгоритма гибридных моделей, программная реализация в оболочке МАТЛАБ, анализ. **А.И. Вдовенко:** подготовка базы данных реконструированных температур. Все авторы прочитали и согласны с подготовленной к публикации версией рукописи.

## ЛИТЕРАТУРА

*Алексеев В.И.* Анализ и прогнозирование циклических временных рядов с использованием вейвлетов и нейросетевых нечетких правил вывода // Вестник Югорского госуниверситета, 2013. Вып. 3(30). – С. 3-10.

*Арушанов М.Л.* Практические вопросы использования вейвлет-преобразования в метеорологии. – Ташкент: НИГМИ, 2015. – 51 с.

*Витязев В.П.* Вейвлет-анализ временных рядов. – СПб.: СПУ. 2001. – 58 с.

*Дьяконов В.П.* Матлаб. – М.: ДМК. 2012. – 768 с.

*Жмурко Д.Ю.* Анализ данных сахарного подкомплекса АПК с применением вейвлет-преобразования (часть 2 – дискретные вейвлет преобразования) // Научный журнал КубГАУ, 2017. №130(06). – С. 12-19.

*Канасевич Э.Р.* Анализ временных последовательностей в геофизике. – М.: Недра, 1985. – 399 с.

*Ли Г.* Вейвлеты и оценка вейвлетов // Журнал экономической теории и эконометрики, 1998. №4(1). – С. 123-157.

*Малла С.* Вейвлеты в обработке сигналов. – М.: Мир, 2005. – 671 с.

*Медведев В.С., Потемкин В.Г.* Нейронные сети. МАТЛАБ 6. – М.: ДИАЛОГ-МИФИ. 2001. – 630 с.

*Мещерская А.В., Руховец Л.В., Юдин М.И., Яковлева Н.И.* Естественные составляющие метеорологических полей. – Л.: Гидрометеоздат, 1970. – 199 с.

*Росси Э.* Одномерные GARCH-модели // Квантиль. 2004. №8. – 67 с.

Alexandridis A.K., Zapranis A.D. Wavelet neural networks: A practical guide // Neural Networks, 2013. №42. – С. 3–27.

Hantemirov R.M., Corona C., Guillet S., Shiyatov S.G., Stoffel M., Osborn T.J., Melvin T.M., Gorlanova L.A., Kukarskih V.V., Surkov A.Y., Arx G., Fonti P. Current Siberian heating is unprecedented during the past seven millennia // Nature Communications, 2022. No. 3. – PP. 3-10.

Jin J., Kim J. Forecasting Natural Gas Prices Using Wavelets, Time Series, and Artificial Neural Networks // PLoS ONE, 2015. 10(11). – PP. 11-21.

Rioul O., Vetterli M. Wavelets and Signal Processing // IEEE SP Magazine, 1991. No. 10. – PP. 14-38.

Rumaih A., Ejaz Ahmed R., Bakry S.H., Al Dhalaan A. A methodology for network topology design with link and node failure tolerances // International Journal of Network Management, 1996. No. 6(1). – PP. 42–63.

## ВЕЙВЛЕТ-ЁЙИШ ВА НЕЙРОН ТАРМОҚЛАРИДАН ФОЙДАЛАНУВЧИ ГИБРИД МОДЕЛЛАР ЁРДАМИДА ҲАРОРАТ ВАҚТ ҚАТОРЛАРИНИ ПРОГНОЗЛАШ

М.Л. АРУШАНОВ<sup>1</sup>, Х.У. УМЕРОВ<sup>1</sup>, А.И. ВДОВЕНКО<sup>2</sup>

<sup>1</sup> Гидрометеорология илмий-тадқиқот институти, mikl-arushanov@rambler.ru

<sup>2</sup> Ўзбекистон Республикаси Гидрометеорология хизмати маркази

**Аннотация.** Тадқиқот ишида реконструкцияланган ҳароратлар қаторларини прогнозаши мақсадида нейрон тармоқларидан фойдаланган ҳолда вақт қаторларини вейвлет-ёйиш асосида маълумотларни қайта ишлашнинг таъсири таҳлил қилинган. Бир нечта моделлардан фойдаланиши ёндашуви кўриб чиқилган ва уларнинг гибрид комбинациясининг прогноз имкониятлари таҳлил қилинган. Вейвлет алмаштиришидан ҳарорат вақт қаторининг шовқин компонентини бартараф этиши воситаси сифатида фойдаланилади, прогнозаши модели эса нейрон тармоғи технологиялари ва вақт қаторларини прогнозашининг регрессион усуллари асосида қурилган.

**Калим сўзлар:** вақт қаторлари, реконструкцияланган ҳароратлар, вейвлет-ёйиш, нейрон тармоқлар, прогнозаши, гибрид моделлар.

## PREDICTION OF THE TIME SERIES OF TEMPERATURE BY HYBRID MODELS USING WAVELET DECISION AND NEURAL NETWORK

M.L. ARUSHANOV<sup>1</sup>, H.U. UMEROV<sup>1</sup>, A.I. VDOVENKO<sup>2</sup>

<sup>1</sup> Hydrometeorological Research Institute, mikl-arushanov@rambler.ru

<sup>2</sup> Centre of Hydrometeorological Service of the Republic of Uzbekistan

**Abstract.** This study analyzes the impact of time series preprocessing based on wavelet decomposition in combination with neural networks in order to predict the reconstructed temperature series. Approaches using several models are considered and their predictive capabilities in a hybrid combination are analyzed. The wavelet transform is used as a tool for suppressing the noise component of the temperature time series, and the predictive model is built on the basis of Neural Network technologies and regression methods for forecasting time series.

**Keywords:** time series, reconstructed temperatures, wavelet decomposition, neural networks, forecasting, hybrid models.

## REFERENCES

Alekseev V.I. Analiz i prognozirovanie tsiklicheskih vremennih ryadov s ispolzovaniem veyvletov i neurosetevih nechetkih pravil vivoda [Analysis and forecasting of cyclic time series using wavelets and

neural network fuzzy inference rules] // Vestnik Yugorskogo Gosuniversiteta, 2013. Vyp. (30). – S. 3-10. (in Russian)

Arushanov M.L. *Practicheskie voprosi ispolzovaniya veivlet-preobrazovaniya v meteorologii* [Practical issues of using the wavelet transform in meteorology]. – Tashkent: NIGMI, 2015. – 51 s. (in Russian)

Vityazev V.P. *Veivlet analiz vremennih ryadov* [Wavelet analysis of time series]. – SPb.: SPU. 2001. – 58 s. (in Russian)

Dyakonov V.P. *Matlab* [MATrix LABoratory]. – M.: DMK. 2002. – 768 s. (in Russian)

Jmurko D.Yu. *Analiz danih sahnogo podkompleksa s primeneniem veivlet preobrazovaniya* [Analysis of data from the sugar subcomplex of APK using wavelet transform] // Nauchnyy jurnal KubGAU, 2017. No. 130(06). – S. 12-19. (in Russian)

Kanasevich E.R. *Analiz vremennih posledovatel'nostey v geofizike* [Analysis of time sequences in geophysics] – M.: Nedra, 1985. – 399 s. (in Russian)

Li G. *Veivleti i ochenki veivletov* [Wavelets and Wavelet Estimation] // Jurnal ekonomicheskoi teorii i ekonomicheskikh issledovaniy, 1998. No. 4(1). – S. 123-157. (in Russian)

Malla S. *Veivlety i obrabotka signalov* [Wavelets in signal processing]. – M.: Mir, 2005. – 671 s. (in Russian)

Medvedev V.S., Potemkin V.G. *Neironnie seti. MATLAB 6* [Neural networks. MATLAB 6]. – M.: DIALOG-MIFI. 2001. – 630 s. (in Russian)

Meshcherskaya A.V., Rukhovets L.V., Yudin M.I., Yakovleva N.I. *Yestestvennye sostavlyayushie meteorologicheskikh poley* [Natural components of meteorological fields]. – L.: Gidrometeoizdat, 1970. – 199 s. (in Russian)

Rossi E. *Odnomernie GARCH-modeli* [One-Dimensional GARCH Models] // Kvantil, 2004. No. 8. – 67 s. (in Russian)

УДК: 551.582

## КЕНГ МИҚЁСДАГИ АТМОСФЕРА ЖАРАЁНЛАРИНИНГ ЎЗБЕКИСТОНДА МАВСУМИЙ ЁҒИНГАРЧИЛИККА ТАЪСИРИНИ БАҲОЛАШ (ШАРҚИЙ АТЛАНТИКА – ҒАРБИЙ РОССИЯ ТЕБРАНИШИ МИСОЛИДА)

З.Ш. ЎСАРОВ<sup>1\*</sup>, З.Э. ҚУРАНБОЕВА<sup>1</sup>

<sup>1</sup> Гидрометеорология илмий-тадқиқот институти, usarovzohid94@gmail.com

**Аннотация.** Мақола кенг миқёсдаги атмосфера циркуляцияларидан бири бўлган Шарқий Атлантика – Ғарбий Россия (EATL/WRUS) тебранишининг Ўзбекистон ҳудудида шаклландиган мавсумий ёғингарчиликка таъсирини миқдорий баҳолаш масалаларига бағишланган. Тадқиқотни бажаришида республикада жойлашган 15 та метеорологик станцияларнинг 1990-2020 йилларда қайд этилган ўртача ойлик ёғингарчилик маълумотларидан фойдаланилди. Олиб борилган таҳлилларга кўра, мамлакатимизда Шарқий Атлантика – Ғарбий Россия (EATL/WRUS) атмосфера жараёни билан мавсумий ёғингарчилик орасида боғлиқлик борлиги аниқланди. Пирсон корреляцияцион усули асосида аниқланган мавсумий боғлиқлик бўйича энг юқори боғланиш Қарши (0,61) ва Самарқанд (0,54) метеостанцияларида кузатилган бўлса, энг паст боғланиш республиканинг шимолий чўл ҳудудларида аниқланди.

**Калит сўзлар:** Шарқий Атлантика – Ғарбий Россия тебраниши (EATL/WRUS), атмосфера циркуляциялари, синоптик жараёнлар, Пирсон корреляцияси.

**Кириш.** Шарқий Атлантика – Ғарбий Россия тебраниши (East Atlantic – Western Russia EATL/WRUS) йил давомида Евросиё қитъасига таъсир кўрсатувчи асосий учта

\*Масъул муаллиф: usarovzohid94@gmail.com, тел.: +998 97 391-10-94