

CONTENTS

METEOROLOGY

- M.L. Arushanov, H.U. Umerov**
Long-term temperature forecast using ensemble of recurrent and autoregressive neural networks 8
- G.Kh. Kholbaev, Kh.T. Egamberdiev, J.M. Kuziev, K.M. Makhmudov**
Transition dates of the average air temperature through different gradations in the irrigated areas of Uzbekistan 19
- S.T. Abdurakhmanov, M.R. Koriyev**
Estimation of possibilities of saving irrigation water and use of atmospheric moisture in arid conditions 31

HYDROLOGY

- B.E. Adenbayev, Kh.A. Baratov**
Change in groundwater regime Middle Zeravshan oases under the influence of irrigation 43
- B.F. Khikmatov**
Methods for calculation of maximum water discharge of rivers and their improvement issues 54
- V.A. Rafikov**
Main directions for solving the problem of the Aral Sea and the Priaralye 64

ENVIRONMENTAL MONITORING

- Z.M. Ubaydullaeva, B.E. Nishonov**
Analysis of radioactive pollution of atmospheric air in the Republic of Uzbekistan 74
- M.N. Rakhimova, E.I. Chembarisov**
Pollution of surface water in the middle current of the Syrdarya River 83

REVIEWS

- I.A. Karimov, B.E. Nishonov, A.N. Grankina, M.A. Plotsen**
Atmospheric air pollution in Uzbekistan in 2022 91

CHRONICLE AND ANNIVERSARIES

- Alek Alekseevich Starovarov is 85 Years Old! 98
- Alexander Vasilyevich Pak is 70 Years Old! 99
- Khasan Imamjanov is 75 Years Old! 100
- In memory of Vladimir Pavlovich Kurbatkin (on the occasion of his 85th birthday) 102

МЕТЕОРОЛОГИЯ / METEOROLOGY

УДК 519.7:561.58

**ДОЛГОСРОЧНЫЙ ПРОГНОЗ ТЕМПЕРАТУРЫ С ПОМОЩЬЮ
АНСАМБЛЯ РЕКУРРЕНТНОЙ И АВТОРЕГРЕССИОННОЙ
НЕЙРОННЫХ СЕТЕЙ****М.Л. АРУШАНОВ^{1*}, Х.У. УМЕРОВ¹**

¹ Научно-исследовательский гидрометеорологический институт,
miki-arushanov@rambler.ru

Аннотация. Прогнозирование является одним из важнейших элементов современных информационных технологий принятия решений в управлении. Эффективность того или иного решения оценивается по событиям, произошедшим постфактум. Поэтому прогностическая оценка того или иного события является определённым критерием принятия решения. Рассматриваемая модель сетей длинной кратковременной памяти (LSTM), предполагает зависимость текущего значения величины $y(t)$, как функции от некоторого набора векторов (предикторов) прошлых значений.

В данной статье решается задача прогноза приземной температуры по реконструированным, упорядоченным во времени данным, с использованием текущих данных приземной температуры воздуха. Оценивается влияние числа нейронов в скрытом слое на качество прогноза. Используется метод комбинированных (гибридных) моделей прогнозирования с применением ансамбля нейросетевых моделей.

Выполненные оценки разработанной прогностической модели приземной температуры воздуха оказались достаточно высокими, что позволяет использовать ансамбли нейросетевых моделей в оперативной работе гидрометеорологических служб в задаче долгосрочного прогноза приземной температуры воздуха.

Ключевые слова: модели прогнозирования, рекуррентные нейронные сети, нелинейные авторегрессионные нейронные сети, нейронные сети длинной кратковременной памяти, приземная температура, среднеквадратичная ошибка, ансамбли моделей.

Постановка задачи. В настоящей работе рассматривается задача прогноза временных рядов, описывающих динамику системы в будущем (прогноз) по данным временного ряда в прошлом. Задача ставится таким образом, что на основе реализаций $\{y(1), \dots, y(N)\}$ выходных данных системы, необходимо спрогнозировать значения параметров $y(N+1), \dots, y(N+H)$, соответствующих будущим H шагам во времени, т.е.

$$y(t) = f[y(t-1), y(t-2), \dots]. \quad (1)$$

В настоящее время существует множество моделей прогнозирования временных рядов: регрессионные и авторегрессионные модели, нейросетевые модели, модели экспоненциального сглаживания, модели на базе цепей Маркова, классификационные модели и др. [Ефименко, Сеница, эл. рес.; Медведев, Потемкин, 2001; Шагалова, Ляхманов, 2014].

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

Наиболее популярными и широко используемыми являются классы авторегрессионных и нейросетевых моделей [Медведев, Потемкин, 2001], поскольку, основываясь на алгоритмах машинного обучения и распознавания образов в больших объемах данных, нейронные сети демонстрируют более высокий потенциал для получения более точных прогнозов, чем традиционные статистические методы. В частности, с их помощью решается широкий круг проблем: построение моделей объектов при их сильной зашумленности и недостатке информации, распознавании образов, кластеризации, прогнозирования и т.д. Заметим, что в последнее время нейронные сети продемонстрировали впечатляющие результаты при решении прикладных задач анализа данных. Как и любой метод, искусственные нейронные сети имеют свои достоинства и недостатки. К главному достоинству нейронных сетей относится их способность эффективно строить нелинейные зависимости, точно описывающие исходные данные, не предполагая никаких ограничений на характер входной информации. Другими достоинствами являются: параллелизм, адаптивность, устойчивость к зашумлению в данных, проектирование комплексной единой системы (*end-to-end*). К недостаткам нейросетевых моделей можно отнести работу в режиме «черного ящика», т.е. отсутствие прозрачности при построении моделей и интерпретации результатов их работы. Также накладываются определённые условия на используемые векторы данных, такие как, например, недостаточность их длины или наоборот избыток. В первом случае ограниченность длины ряда может негативно проявиться на этапе обучения, во-втором случае размерность потенциальных входов может оказаться слишком велика. Поэтому для корректного построения модели на предварительном этапе необходимо выполнения следующих условий: данные должны быть тщательно выверенными (исключать ошибки в данных, пропуски во временном ряде и пр.); адекватно выбраны метрики качества модели; модель должна отвечать высокому уровню обобщения. Среди нейронных моделей, рекуррентные нейронные сети (*RNN*) являются одной из самых мощных моделей для обработки временных рядов [LSTM, эл. рес.].

Используемые данные. В работе рассматриваются временные ряды палеоклиматических реконструкций приземной температуры воздуха по данным анализа ледовых кернов в Гренландии [Hantemirov et al., 2022] за последние 22000 лет, полученные с дискретностью 20 лет. На рис. 1 приведен временной ход реконструированной температуры воздуха в Гренландии за период с 19060 г. до н.э. по 2020 г. н.э.

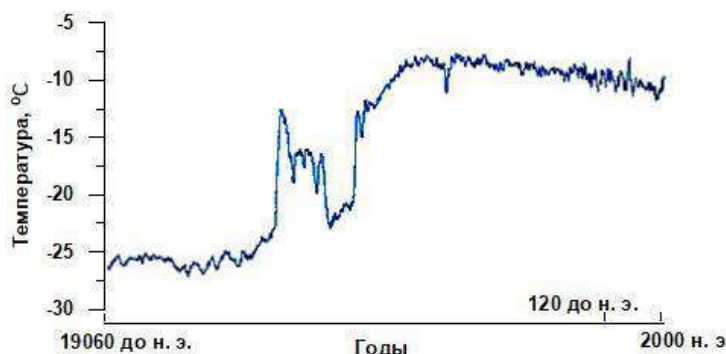


Рис. 1. Динамика реконструированной по данным изотопов N_2 , Ar ледовых кернов приземной температуры в Гренландии за последние 22000 лет с дискретностью 20 лет

Fig. 1. Dynamics of surface temperature ice cores reconstructed from N_2 , Ar isotope data in Greenland over the past 22000 years with a resolution of 20 years

Метод решения задачи. Нами рассматривается прогнозирование температур воздуха с помощью рекуррентной нейронной сети с долгой краткосрочной памятью с использованием в качестве предиктора данные о приземной температуре воздуха в прошлом. Это было обусловлено не только отсутствием экзогенных данных за рассматриваемый период, но и с целью проверки факта предсказуемости температуры воздуха без использования иных переменных при сильной дискретизации используемых данных.

Длинная кратковременная память (*LSTM*) – одна из самых успешных архитектур *RNN*. *LSTM* представляет собой ячейку памяти, вычислительную единицу, которая заменяет традиционные искусственные нейроны в скрытом слое сети. *RNN* с долгой краткосрочной памятью способны изменять вес лаговых переменных в зависимости от времени, тем самым, приспосабливаясь к изменениям весов тех или иных лагов с течением времени – оптимизация весовых коэффициентов. С помощью этих ячеек памяти сети способны эффективно связывать память и вводить удаленные данные во времени, следовательно, они выполняют функцию динамического понимания структуры данных с течением времени с высокой способностью предсказания.

Реализация метода. Сеть начинается со слоя ввода последовательности, за которым следует слой *LSTM*. Сеть заканчивается полностью подключенным слоем и выходным слоем коэффициентов регрессии. Упрощенная структура сети *LSTM* представлена на рис. 2.




Рис. 2. Структура сети LSTM

Fig. 2. LSTM network structure

Представляет интерес оценки качества прогноза *RNN LSTM* относительно авторегрессионной нейронных сети и сети с временной задержкой предиктора. Целью работы является не только сравнение различных моделей, но и их совместное использование. Отметим, что в современном прогнозировании наблюдается тенденция применения комбинированных (гибридных) моделей прогнозирования. Применение такого ансамбля нейросетевых моделей совместно с предобработкой данных в задачах прогнозирования временных рядов позволят создать комплексный единый механизм построения итогового решения, а также справится с рядом проблем, связанных с прогнозированием временных рядов – зашумленность и нестационарность данных, сложность выявления скрытых паттернов в динамики процессов.

Подход подразумевает объединение или согласование результатов прогнозов от базовых алгоритмов индивидуальных моделей прогнозирования с помощью метода усреднения или взвешивания. Он связан с тем, что при прогнозировании временных рядов часто оказывается, что ни один из алгоритмов не обеспечивает желаемого качества восстановления зависимости. В данной работе при разработке гибридной нейросетевой модели для прогнозирования временных рядов рассматриваются методы искусственного интеллекта – рекуррентные нейронные сети (*LSTM*), динамические сети с обратной связью *Narnet* и сети с временной задержкой (*ANN*), как одни из самых популярных методов нейросетевого анализа данных.

Перейдем к собственно процедуре разработки модели. Обычно модели, основанные на машинном обучении, имеют особенность переобучаться на данных. Одним из способов борьбы с данной проблемой является разбиение всей доступной выборки данных на обучающей набор и тестовый (этап верификации). Такой подход позволяет оценивать качество модели на данных независимой выборки. Таким образом можно оценить прогностические качества модели с использованием фактических данных.

Расчет проводился в среде МАТЛАБ. Параметры модели: размер выборки – 1054×20 лет; размер обучающей выборки – 949×20 лет; размер тестовой выборки – 105×20 лет; горизонт прогнозирования – 50-130 лет.

В процессе моделирования были рассмотрены различные архитектуры сети, в итоге была выбрана следующая:

- 1 скрытый слой;
- 40 нейронов на скрытом слое;
- сеть держит в памяти 12 последних значений;
- для построения модели использовалось 240 эпох;
- минимизировалась средняя квадратичная ошибка модели.

Для прогнозирования значения будущих временных шагов последовательности, указываются ответы в виде обучающих последовательностей со значениями, сдвинутыми на один временной шаг. Чтобы сделать прогнозы для временного шага i , используется предсказанное значение для временного шага $i-1$ в качестве ввода. Таким образом, на каждом временном шаге входной последовательности сеть *LSTM* обучается предсказывать значение следующего временного шага. Сетевая архитектура модели *LSTM* приведена на рис. 3.



Рис. 3. Визуализация сетевой архитектуры модели LSTM

Fig. 3. Visualization of the network architecture of the LSTM model

Анализ полученной сети глубокого обучения выполнялся с помощью функции МАТЛАБ «*analyzeNetwork*». Эта функция отображает интерактивную визуализацию сетевой архитектуры, обнаруживает невязки и проблемы с сетью и предоставляет подробную информацию об уровнях сети (рис. 4). На графике рис. 4 видно, что средний процент ошибки на верифицированных данных перестает уменьшаться уже после двухсотой эпохи. Далее может начинаться процесс переобучения модели, чего необходимо избегать.

Обнаруживаемые проблемы включают отсутствующие или отключенные слои, несоответствующие или неправильные размеры входных данных слоя, неправильное количество входных данных слоя и недопустимые структуры графа.

Нейронные сети чувствительны к нестандартизованным данным, поэтому при построении модели проводилась их стандартизация:

$$s_i = \frac{y_i - \bar{y}}{\delta} \tag{2}$$

где $\delta = \sqrt{\frac{1}{N-1} \sum_{i=1}^n (y_i - \bar{y})^2}$ – среднеквадратичное отклонение; $\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$ – среднее (норма).

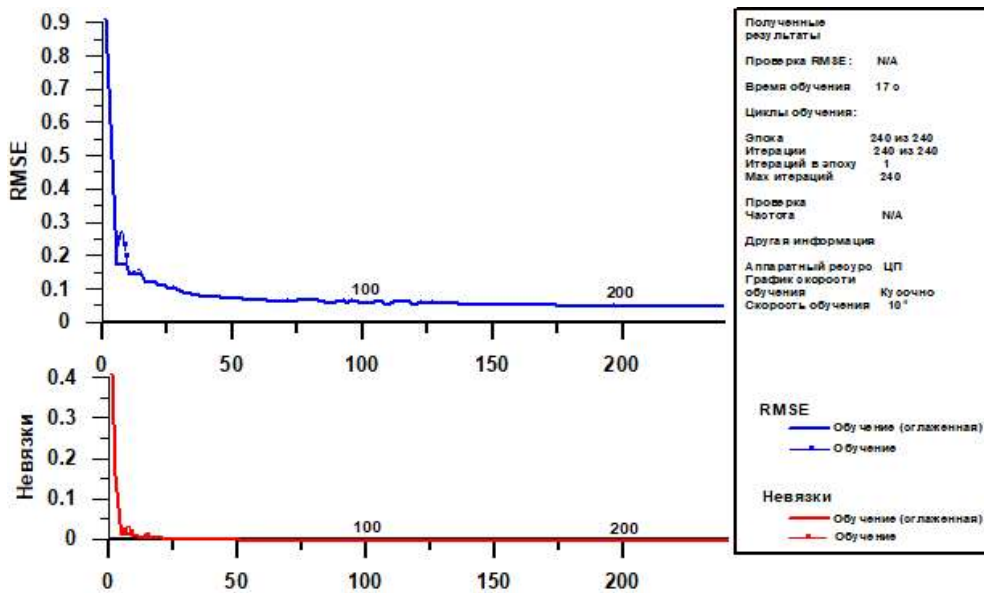


Рис 4. График итерационного обучения модели

Fig 4. Graph of iterative training of the model

По окончании расчетов проводилась натурализация для приведения данных в исходный масштаб:

$$y_i = \delta s_i + \bar{y} \tag{3}$$

Оценка точности прогнозирования производилась по среднеквадратичной ошибке MSE (Mean Squared Error):

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2} \tag{4}$$

где $Y'_i = \{Y'_i\}$ – вектор прогнозов, который генерируется из выборки n точек данных по всем переменным и $Y_i = \{Y_i\}$ – является вектором наблюдаемых значений прогнозируемой переменной.

Среднеквадратичная ошибка прогноза на данных обучающей выборки для отклонений от нормы составила $MSE=0,483^{\circ}\text{C}$, на натурализованных данных – $MSE=0,643^{\circ}\text{C}$. На рис. 5 приведены результаты прогноза модели по данным на обучающей выборке.

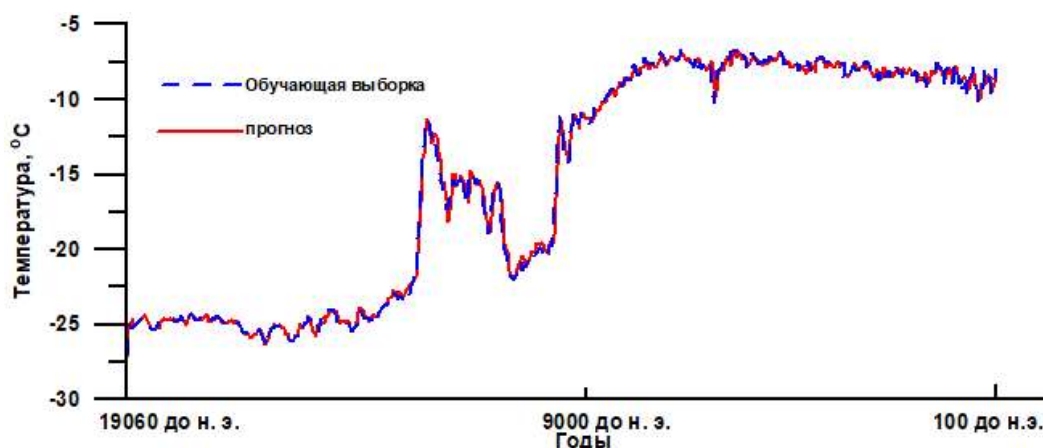


Рис. 5. Временной ход температуры и её прогноз (обучающая выборка)

Fig. 5. Time course of temperature and its forecast (training sample)

Далее полученная модель использовалась для прогнозирования на тестовых данных. Среднеквадратичная ошибка на тестовых данных составила $0,5^{\circ}\text{C}$. Результаты расчета представлены на рис. 6.

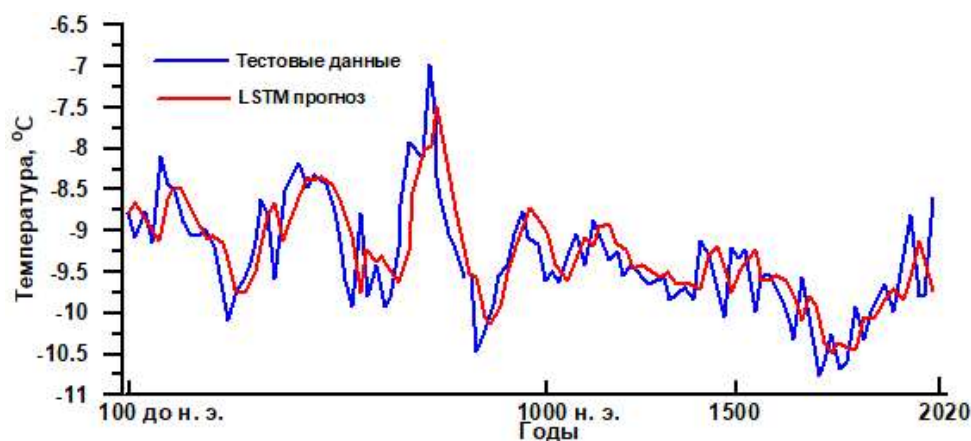


Рис. 6. Временной ход температуры и её прогноз (тестовая выборка)

Fig. 6. Time course of temperature and its forecast (test sample)

Структура формирования ошибок по шагам тестовой выборки показана на рис. 7.

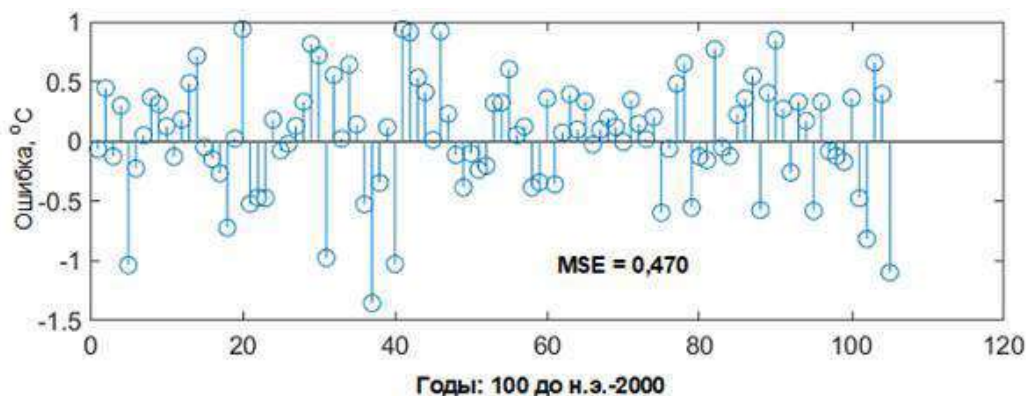


Рис. 7. Структура формирования ошибок модели LSTM-прогноза на тестовых данных

Fig. 7. The structure of the formation of errors in the LSTM forecast model on test data

Количество нейронов в скрытом слое подбиралась экспериментально. В табл. 1 представлены результаты экспериментов с их различными значениями. Наилучшие результаты были показаны при числе нейронов 40. Хотя следует отметить, что от 40 до 100 точность модели менялась незначительно, но при этом время расчета увеличивается с ростом числа нейронов.

Таблица 1

Зависимость точности LSTM моделей от числа нейронов в скрытом слое

Table 1

Dependence of the accuracy of LSTM models on the number of neurons in the hidden layer

Тип выборки	Число нейронов в скрытом слое						
	20	40	60	80	100	120	160
Обучающая	0,580	0,413	0,415	0,448	0,494	0,576	0,622
Тестовая	0,530	0,470	0,483	0,473	0,479	0,505	0,517

Примечание: Более высокие оценки по тестовой выборке относительно обучающей, по-видимому, объясняются различной длиной временных рядов.

Note: The higher test sample scores relative to the training sample seem to be due to the different lengths of the time series.

Для сравнения аналогичные нейросетевые модели строились на основе нелинейной авторегрессионной нейронной сети (NarNET) [Медведев, Потемкин, 2001] и искусственной нейронной сети с временной задержкой – Artificial Neural Networks (ANN) [Шагалова, Ляхманов, 2014]. Обе сети использовались с обратной связью. Структуры этих идентичных сетей приведена на рис. 8.

Параметры моделей: время задержки – 2; количество узлов скрытого слоя – 24.

Сеть Narnet определяет текущее значение в зависимости от количества прошлых значений k , а также по количеству узлов скрытого слоя. При прогнозировании сетью

NarNet необходимо сначала указать первые k значений в начальный момент прогноза, поскольку текущее значение определяется первыми k значениями. При пошаговом прогнозировании в качестве входных данных последовательно подаются последующие прогнозируемые значения.

Результаты сравнения полученных моделей при прогнозировании на тестовой выборке приведены на рис. 9. В табл. 2 приведены оценки прогнозов по моделям на тестовой выборке.




Рис. 8. Структура нелинейной нейронной сети с обратной связью

Fig. 8. Structure of a Nonlinear Neural Network with Feedback

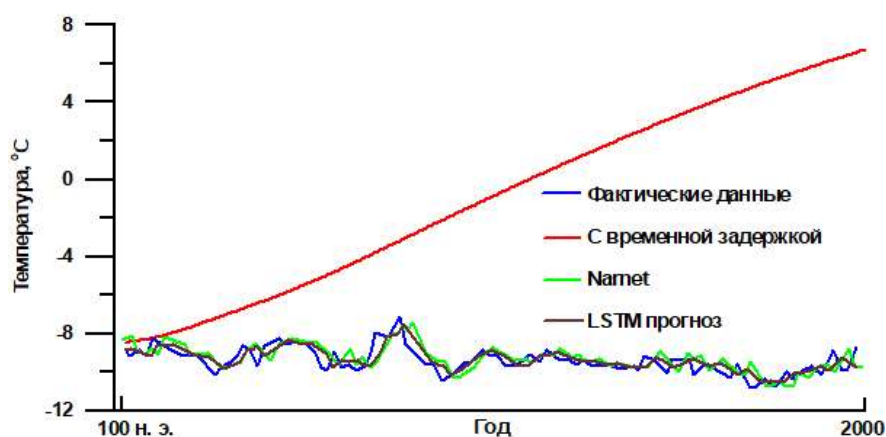


Рис. 9. Графическое сравнение моделей при прогнозировании на тестовой выборке

Fig. 9. Graphical comparison of models in forecasting on the test set

Оценки моделей прогноза

Таблица 2

Table 2

Forecast Model Estimates

№	Модель	Коэффициент корреляции	Время вычислений	MSE
1	ANN	-0,538	00:03:41	96,542
2	NarNET	0,709	00:00:15	0,272
3	LSTM	0,721	00:00:17	0,221

Примечание: корреляция рассчитывалась между модельными прогнозами и значениями тестовой выборки.

Note: the correlation was calculated between the model predictions and the values of the test sample.

Как следует из представленных оценок, рекуррентная нейронная сеть с долговременной краткосрочной памятью (*LSTM*) оказалась лучше других, рассмотренных в данной статье, а *ANN* – абсолютно неудовлетворительной, поэтому далее она не рассматривается. Вопреки ожиданиям модель *LSTM* оказалась ненамного точнее модели *NarNET*. Возможно, при построении многомерной модели прогноза разница будет заметнее.

Прогноз по ансамблю моделей строился в соответствии с выражением:

$$Y = \sum_{i=1}^M a_i Y_i, \quad (5)$$

где Y_i – выход i -й модели; M – количество моделей; a_i – весовой коэффициент вклада i -й модели в ансамбль, рассчитываемый по среднеквадратичной ошибке на тестовой выборке:

$$a_i = \frac{1}{MSE_i} \sum_{j=1}^M \frac{1}{MSE_j} \quad (6)$$

На рис. 10 приведен прогноз приземной температуры воздуха на период до 2130 года по модели *LSTM*, *NarNet* и гибридной модели (по ансамблю). В целом все три модели дают тенденцию к убыванию температуры в течении последующего столетия. Этот результат полностью совпадает с выводами, сделанными в цикле работ [Арушанов, 2012, 2014; Абдусаматов, 2002, 2004, 2009], в которых опровергаются пессимистические прогнозы экстремального потепления, выполненные на основе классических климатических моделей [Володин и др., 2010; Замолотчиков, 2016], оперирующие различными сценариями увеличения диоксида углерода в атмосфере.

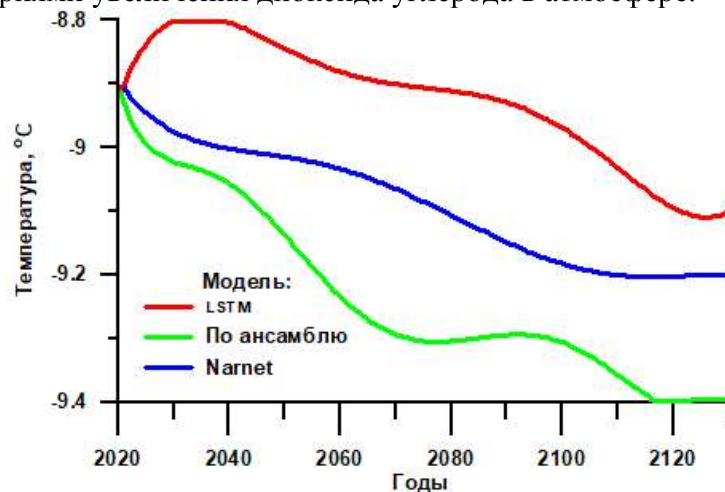


Рис. 10. Прогноз приземной температуры воздуха по отдельным моделям и гибридной модели

Fig. 10. Forecast of surface air temperature for individual models and hybrid model

Выводы. Численные эксперименты долгосрочного и сверхдолгосрочного прогноза температуры приземного воздуха на основе нейронных сетевых моделей показали, что в последних заложены большие потенциальные возможности улучшения долгосрочных

прогнозов погоды, что является одной из наиболее сложных проблем в метеорологии. В частности, результат прогноза на ближайшее столетие с тенденцией понижения температуры, еще раз показал, что катастрофические последствия глобального потепления, связанное с антропогенным загрязнением атмосферы углекислым газом – миф, выдуманный корпорациями, по наставлению которых исполняются политические партитуры.

Вклад авторов. М.Л. Арушанов: постановка задачи, анализ, редакция текста.
Х.У. Умеров: разработка алгоритма нейросетевых моделей, программная реализация в оболочке МАТЛАБ, анализ. Все авторы прочитали и согласны с подготовленной к публикации версией рукописи

ЛИТЕРАТУРА

Арушанов М.Л. Предикторы погоды на длительные сроки. – Hamburg: Lambert Academic Publishing (LAP), 2014. – 139 с.

Абдусаматов Х.И. О долговременных скоординированных вариациях активности, радиуса, светимости Солнца и климата / Тр. межд. конф. «Солнечная активность и космические лучи после смены знака полярного магнитного поля Солнца». – С-Пб. – 2002. – С. 13-18.

Абдусаматов Х.И. Солнце определяет климат // Наука и жизнь. – 2009. №1. – С. 34-40.

Володин Е.М., Дианский Н.А., Гусев А.В. Воспроизведение современного климата с помощью моделей общей циркуляции атмосферы и океана INMC 4.0 // Известия РАН. Физика атмосферы и океана. – 2010. Том 46, № 4. – С. 448-466.

Замолодчиков Д.Г. Прогноз роста глобальной температуры в XXI веке на основе простой статистической модели // Компьютерные исследования и моделирование. – 2016. Том 8, № 2. – С. 379-390.

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

Шагалова П.А., Ляхманов Д.А. Нейросетевые технологии в решении задач прогнозирования // Современные проблемы науки и образования. – 2014. № 6. – С. 6-13.

Abdusamatov H.I. About the long-term coordinated variations of the activity, radius, total irradiance of the Sun and the Earth's climatic / Proc. IAU Symposium №223. Cambridge: Univ. press. – 2004. – PP. 541-542.

Arushanov M.L. The natural reasons of change of a climate of a planet. – Hamburg: LAMBERT Academic Publishing (LAP), – 2012. – 170 p.

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

Электронные ресурсы:

Ефименко Г.А., Сеница А.М. Нейронные сети в MatLab. URL: <https://digiratory.ru/508>

LSTM – Long Short-Term Memory Networks. URL: <https://se.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>

РЕКУРРЕНТ ВА АВТОРЕГРЕССИОН НЕЙРОН ТАРМОҚЛАРИ АНСАМБЛИДАН ФЙДАЛАНИБ ХАВО ҲАРОРАТИНИ УЗОҚ МУДДАТЛИ ПРОГНОЗЛАШ

М.Л. АРУШАНОВ¹, Х.У. УМЕРОВ¹

¹ Гидрометеорология илмий-тадқиқот институти, mikl-arushanov@rambler.ru

Аннотация. Прогнозлаш бошқарувда қарор қабул қилиш учун замонавий ахборот технологияларининг энг муҳим элементларидан биридир. Қарорнинг самарадорлиги ҳақиқатдан

кейин содир бўлган воқеалар билан баҳоланади. Шунинг учун воқеани прогностик баҳолаш қарор қабул қилишининг маълум бир мезони ҳисобланади. Кўриб чиқилаётган қисқа муддатли катта хотира модели (LSTM) $y(t)$ қийматига боғлиқ ҳолда ўтган қийматларнинг маълум векторлари (прогноз қилувчилари) тўпламига боғлиқлигини назарда тутди.

Ушбу мақола реконструкция қилинган, вақт бўйича тартибланган ер усти ҳаво ҳарорати маълумотларидан фойдаланиб, уни прогноз қилиш муаммосини ҳал қилади. Яширин қатламдаги нейронлар сонининг прогноз сифатига таъсири баҳоланган. Нейрон тармоқ моделлари ансамблидан фойдаланган ҳолда бирлаштирилган (гибрид) моделлар ёрдамида прогнозлаш усули қўлланилган.

Ер усти ҳаво ҳарорати учун ишлаб чиқилган прогностик моделнинг баҳолари анча юқори бўлиб чиқди, бу эса гидрометеорология хизматларининг оператив фаолиятида узоқ муддатли прогнозлаш масаласида нейрон тармоқ моделлари ансамблларида фойдаланиш имконини беради.

Калит сўзлар: прогнозлаш моделлари, рекуррент нейрон тармоқлар, ночизиқли авторегрессив нейрон тармоқлар, қисқа муддатли катта хотира нейрон тармоқлар, ер усти ҳарорати, ўртача квадрат хато, моделлар ансамбллари.

LONG-TERM TEMPERATURE FORECAST USING ENSEMBLE OF RECURRENT AND AUTOREGRESSIVE NEURAL NETWORKS

M.L. ARUSHANOV¹, H.U. UMEROV¹

¹ Hydrometeorological Research Institute, mikl-arushanov@rambler.ru

Abstract. Forecasting is one of the most important elements of modern information technologies for decision-making in management. The effectiveness of a decision is evaluated by the events that occurred after the fact. Therefore, the prognostic assessment of an event is a certain decision-making criterion. The long-term short-term memory model (LSTM) under consideration assumes the dependence of the current value of $y(t)$ as a function of a certain set of vectors (predictors) of past values.

This article solves the problem of surface temperature forecasting from reconstructed, time-ordered data, using current data on surface air temperature. The influence of the number of neurons in the hidden layer on the quality of the forecast is estimated. The method of combined (hybrid) forecasting models using an ensemble of neural network models is used.

The estimates of the developed prognostic model of surface air temperature turned out to be quite high, which makes it possible to use ensembles of neural network models in the operational work of hydrometeorological services in the problem of long-term forecasting of surface air temperature.

Keywords: forecasting models, recurrent neural networks, non-linear autoregressive neural networks, neural networks with long short-term memory, surface temperature, root mean square error, ensembles of models.

REFERENCES

Arushanov M.L. Predictor pogody na dlitelnye sroki [Weather forecasters for long periods]. – Hamburg: LAP Lambert Academic Publishing, 2014. – 139 p. (in Russian)

Abdusamatov Kh.I. O dolgovremennyh skoordinirovannyh variatsiyah aktivnosti, radiusa, svetimosti Solnsa i klimata [On long-term coordinated variations in activity, radius, solar luminosity, and climate] / Tr. intl. conf. «Solar activity and cosmic rays after the sign change of the polar magnetic field of the Sun». – S-Pb. – 2002. – S. 13-18. (in Russian)

Abdusamatov Kh.I. Solnce opredelyaet klimat [The sun determines the climate] // Nauka i Jizn. – 2009. No 1. – S. 34-40. (in Russian)

Volodin E.M., Diansky N.A., Gusev A.V. Vosproizvedenie sovremennogo klimata s pomoshyu modeley obshey sirkulyatsii atmosfery i okeana [Reproduction of the modern climate using INMC 4.0

general circulation models of the atmosphere and ocean] // Izvestiya RAN. Fizika Atmosfery i okeana. – 2010. Tom 46, No. 4. – S. 448-466. (in Russian)

Zamolodchikov D.G. Prognoz rosta globalnoi temperatury v XXI veke na osnove prostoi statisticheskoi modeli [Forecast of global temperature growth in the 21st century based on a simple statistical model] // Kompyuternye issledovaniya i modelirovaniya.– 2016. Tom 8, No. 2. – S. 379–390. (in Russian)

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

Shagalova P.A., Lyakhmanov D.A. Neyrosetevie tehnologii v reshenii zadach prognozirovaniya [Neural network technologies in solving forecasting problems] // Sovremennye problemi v nauke i obrazovanii. – 2014. No. 6. – S. 6-13. (in Russian)

Electronic resources:

Ефименко Г.А., Сеница А.М. Нейронные сети в MatLab [Neural network in MatLab]. URL: <https://digiratory.ru/508>

LSTM – Long Short-Term Memory Networks. URL: <https://se.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>

УДК 630:551.58+633.18

ЎЗБЕКИСТОННИНГ СУҒОРИЛАДИГАН ҲУДУДЛАРИДА ЎРТАЧА ҲАВО ҲАРОРАТИНИНГ ТУРЛИ ДАРАЖАЛАРДАН ЎТИШИ

Г.Х. ХОЛБАЕВ^{1*}, Х.Т. ЭГАМБЕРДИЕВ¹, Ж.М. ҚЎЗИЕВ², Қ.М. МАХМУДОВ¹

¹ Мирзо Улуғбек номидаги Ўзбекистон Миллий университети, khgulmon@mail.ru

² Тупроқшунослик ва агрохимё илмий тадқиқот институти

Аннотация: Ўзбекистоннинг суғориладиган ҳудудларида 1991-2020 йй. даврида ўртача ҳаво ҳароратининг турли даражалардан ўтиши саналари аниқланган. Куз ва баҳорда ҳаво ҳароратининг турли даражалардан ўтиши I-минтақада II-IV-минтақаларга нисбатан баҳорда кечроқ, кузда эса эртароқ кузатилади. II-III-минтақаларда (Тошкент вилоятидан ташқари) куз ва баҳорда ҳаво ҳароратининг 0,0°C дан турғун ўтиши кузатилмайди. Ушбу маълумотлардан қишлоқ хўжалиги ўсимликларининг вегетация даври давомийлигини аниқлаш, агротехник тадбирларни ўтказиш ҳамда қишлоқ хўжалигига агрометеорологик хизмат кўрсатишида фойдаланиш мумкин.

Калит сўзлар: радиация, иқлимий давр, куз, баҳор, буғдой, ҳарорат, ҳарорат даражалари.

Кириш. Буғдой энг кўп тарқалган асосий донли экинлардан бири ҳисобланади. Бутун дунё халқларининг ярмидан кўпроғи озиқ-овқат сифатида буғдой нонидан фойдаланади. Буғдой нонининг таркибида оксил ва крахмал кўп. Оксил моддалар, асосан, клейковина таркибида бўлганлиги учун буғдой ундан сифатли нон тайёрланади. Ҳар бир мустақил давлатнинг, шу жумладан, Ўзбекистон агросаноат комплексининг асосий вазифаси – республикамизни озиқ-овқат ва қишлоқ хўжалик маҳсулотлари билан тўла таъминлашдир [Группер, 1998; Абдуллаев ва бошқ., 2003, 2005, 2006; Холбаев ва бошқ., 2003, 2020, 2022; Курбанов ва бошқ., 1999].

Маълумки, республикамизнинг турли районларининг иқлим шароитларини ҳар томонлама ҳисобга олиб ундан оқилона фойдаланганда ишлаб чиқариладиган қишлоқ

* Масъул муаллиф: khgulmon@mail.ru, +998 90 178-65-07