

## Новый подход к использованию нейронных сетей для долгосрочного прогноза Эль-Ниньо и Ла-Нинья

А.С. Лубков<sup>1)\*</sup>, Е.Н. Воскресенская<sup>1)</sup>, О.В. Марчукова<sup>1),2)</sup>

<sup>1)</sup> Институт природно-технических систем,  
Россия, 299011, г. Севастополь, ул. Ленина, 28

<sup>2)</sup> Тюменский государственный университет,  
Россия, 625003, г. Тюмень, ул. Володарского, 6

\* Адрес для переписки: *andrey-ls2015@yandex.ru*

**Реферат.** В работе предложен новый подход к использованию методов нейронных сетей и множественной линейной регрессии (МЛР) для прогноза состояния Эль-Ниньо – Южное колебание (ЭНЮК). Моделируемые параметры (индексы Nino3, Nino3.4 и Nino4) разделялись на две компоненты: низкочастотную и высокочастотную. Для моделирования высокочастотной компоненты использовались многослойные нейронные сети (МНС), а для моделирования низкочастотной компоненты – МЛР. Особенностью предложенного подхода является детальный отбор предикторов как входных в модель данных и последующее моделирование с перебором и проверкой всех возможных конструкций многослойной нейронной сети.

На основе предложенного подхода разработана модель прогнозирования экстремальных фаз феномена ЭНЮК – NNM-ENSOv1 (Neural Network Model for ENSO forecast). Полученная модель отличается низкой чувствительностью к весеннему порогу предсказуемости, за счет чего прогнозирует состояние ЭНЮК с заблаговременностью более 7 месяцев значительно лучше по сравнению с динамическими моделями.

Верификация предложенной модели проводилась на контролльном промежутке с 2007 по 2022 годы. NNM-ENSOv1 достаточно хорошо воспроизводит не только события Эль-Ниньо, но и их тип с заблаговременностью до одного года. В подтверждение отметим, что четыре из пяти событий Эль-Ниньо, включая их тип, были предсказаны верно. Вероятность верного определения условий, характерных для событий Эль-Ниньо, достаточно высока и незначительно меняется в границах 76–83% при изменении заблаговременности прогноза в пределах одиннадцати месяцев, в то время как для Ла-Нинья вероятность верного определения с ростом заблаговременности уменьшается от 85 до 31%.

С помощью модели NNM-ENSOv1 в ноябре 2022 г. построен прогноз состояния ЭНЮК в 2023 году. Модель успешно предсказала эволюцию протекавшего до февраля 2023 г. в тот период Ла-Нинья, а затем последующие нейтральные условия в марте-апреле и начало Эль-Ниньо восточнотихоокеанского типа с мая 2023 года. В итоге, прогноз на первое полугодие 2023 года подтвердился. С результатами моделирования ЭНЮК в режиме реального времени можно ознакомиться на сайте модели: [neuroclimate.com](http://neuroclimate.com).

**Ключевые слова.** Эль-Ниньо, Ла-Нинья, система океан-атмосфера, долгосрочный прогноз, машинное обучение, моделирование.

## An innovative approach to long-term prediction of El Niño and La Niña using neural networks

A.S. Lubkov<sup>1)\*</sup>, E.N. Voskresenskaya<sup>1)</sup>, O.V. Marchukova<sup>1),2)</sup>

<sup>1)</sup> Institute of Natural and Technical Systems,  
28, Lenina str., 299011, Sevastopol, Russian Federation

<sup>2)</sup> Tyumen State University,  
6, Volodarskogo str., 625003, Tyumen, Russian Federation

\*Correspondence address: [andrey-ls2015@yandex.ru](mailto:andrey-ls2015@yandex.ru)

**Abstract.** The paper proposes a new approach to the use of neural network methods and multiple linear regression (MLR) to predict the state of El Niño – Southern Oscillation ENSO). The simulated parameters (Nino3, Nino3.4 and Nino4 indices), were decomposed into 2 components: low-frequency and high-frequency. Multilayer neural networks (MNN) were used to simulate the high-frequency component, and MLR was used to simulate low-frequency component. A feature of the proposed approach is the detailed selection of model input predictors and subsequent modeling through the search and verification of all possible constructions of a multilayer neural network.

On the basis of proposed approach the NNM-ENSOv1 model (Neural Network Model) has been developed to extreme ENSO phases predicting. This model is characterized by low sensitivity to the spring threshold of predictability, due to which it predicts the ENSO event state with a lead time of 7 and more months significantly better than dynamic models, and in the task of forecasting with a lead time of 11 months, the forecasting skills of the NNM-ENSOv1 model are comparable to modern statistical models based on machine learning principles.

Verification of the proposed model was carried out for the control period from 2007 to 2022. NNM-ENSOv1 reproduces quite well not only the El Niño events, but even the event types with a lead time of up to one year: 4 of 5 El Niño events were predicted correctly including their types. The probability of correctly determining the typical El Niño conditions varies slightly. It amounts to 76-83% within the forecast lead time, while the probability of correctly determining the La Niña conditions decreases from 85 to 31% when during the lead time increasing.

In November 2022, it was built a forecast of the state of ENSO 2023 using the NNM-ENSOv1 model. This model correctly predicted the evolution of La Niña, which took place at that time, until February 2023, the subsequent neutral conditions in March - April, and the beginning of East Pacific type El Niño in May 2023. As a result, the forecast for the first half of 2023 was confirmed. The results of the real-time ENSO simulation are presented on the model's website: [neuroclimate.com](http://neuroclimate.com).

**Keywords.** El Niño, La Niña, ocean-atmosphere system, long-scale forecast, machine learning, simulation.

## Введение

Эль-Ниньо – Южное колебание (ЭНЮК) – глобальный квазипериодический процесс межгодового масштаба, наблюдаемый в системе океан-атмосфера экваториальной зоны Тихого океана. Он является первой модой изменчивости глобальной ежемесячной аномалии температуры поверхности океана (ТПО), вклад которой составляет 18% от общей дисперсии (Philander, 1990; Wallace et al., 1998; Deser et al., 2010; Messie, Chavez, 2011). ЭНЮК характеризуется изменением ТПО и, как следствие, изменением давления на уровне моря. ЭНЮК имеет две противоположные фазы существования – теплую, называемую Эль-Ниньо (ЭН), и холодную – Ла-Нинья (ЛН). Для ЭН характерны перенос теплых экваториальных вод в восточном направлении, выравнивание термоклина у берегов Южной Америки, ослабление интенсивности ячейки Уокера и смещение центров действия атмосферы на экваторе (Larkin, Harrison, 2005; Rasmusson, Carpenter, 1982). Для ЛН характерно смещение теплого экваториального бассейна несколько западнее, выраженное поднятие термоклина у берегов Южной Америки и в центре Тихого океана и интенсификация ячейки Уокера (Philander, 1990).

Формирование и развитие аномалий ЭНЮК – это сложный механизм, включающий как пространственные, так и временные особенности. Длительное исследование этого процесса обнаружили наличие двух пространственных типов зарождения и распространения аномалий ТПО – Центрально-Тихоокеанский (ЦТ) и Восточно-Тихоокеанский (ВТ) типы, которые характерны как для ЭН (Ashok et al., 2007; Kug et al., 2009; Takahashi et al., 2011; Zheleznova, Gushchina, 2016), так и для ЛН (Yuan, Yan, 2013; Zhang et al., 2014; Voskresenskaya et al., 2017). При этом существуют различия в амплитуде и пространственной асимметрии между фазами ЭН и ЛН (An, Jin, 2004). А явления ЛН, в отличие от ЭН, могут длиться два и три года подряд (Hu et al., 2014; DiNezio et al., 2017; Wu et al., 2021).

Проявления фаз ЭНЮК и их типов отмечаются в аномалиях погоды и климата не только над тропической зоной Тихого океана, но и во внутротропических широтах посредством дальнодействующих связей системы океан-атмосфера (Philander, 1990; Voskresenskaya, Polonsky, 1993; McPhaden et al., 2006; Mokhov, Smirnov, 2006; Liu, Alexander, 2007). Такие планетарные отклики атмосферы обычно уникальны для каждого типа явлений ЭН и ЛН (McPhaden et al., 2006; Larkin, Harrison, 2005; Liu, Alexander, 2007; Lubkov et al., 2020; Voskresenskaya et al., 2018). Нередко последствия этих событий приводят к человеческим жертвам и существенным экономическим потерям (Ashok et al., 2007; Yuan et al., 2012). Таким образом, изучение и прогноз аномальных проявлений ЭНЮК и заблаговременное определение их типа является приоритетной задачей.

Прогнозирование ЭНЮК – одна из самых сложных и нерешенных до конца проблем наук о Земле. Важным вопросом является причина фазового переключения от явления ЭН к ЛН, что подтверждает невозможность большинства климатических моделей предсказать этот переход (Barnston et al., 2012).

---

В настоящее время существует два основных подхода к долгосрочному прогнозированию ЭНЮК: динамический и статистический. Динамический подход осуществляется на основе численного моделирования, включающего в себя, в первую очередь, атмосферную циркуляцию, процессы в океане и взаимодействие этих двух сред (Wang et al., 2017). Статистический подход подразумевает прогнозирование ЭНЮК на основе анализа исторических данных. Статистические модели могут быть линейными и нелинейными. Линейная статистическая модель строится с использованием методов множественной линейной регрессии, канонической корреляции, цепей Маркова и т.д. Второй, нелинейный подход чаще всего основан на методах машинного обучения, таких, как байесовские и нейросетевые (Fang et al., 2022). На сегодняшний день существует по меньшей мере 18 динамических и 8 статистических моделей, представленных на сайте международного исследовательского института климата и общества Колумбийского университета, которые применяются для прогнозирования ЭНЮК. В работах (Tippett et al., 2012; Barnston et al., 2012; Tang et al., 2018) отмечено, что динамические моделиправлялись с прогнозом ЭНЮК на порядок лучше, чем статистические.

Для всех моделей долгосрочного прогноза характерна относительно высокая способность прогнозирования для нейтральных условий или уже развивающихся явлений ЭНЮК, однако, вне зависимости от заблаговременности прогноза, способность прогнозирования летом, когда обычно только начинают развиваться явления ЭН и ЛН, резко ухудшаются. Поэтому если заблаговременность прогноза превышает 6 месяцев, то способность прогнозирования заметно уменьшается. Это связано с так называемым «весенним» порогом предсказуемости (ВПП) (Webster, Yang, 1992).

Последние несколько лет стали предлагаться весьма продуктивные решения для прогнозирования ЭНЮК, в основе которых лежат методы машинного обучения (Gavrilov et al., 2019; Ham et al., 2019; Ye et al., 2021; Geng, Wang, 2021; Fang et al., 2022). Зачастую эти решения значительно лучше прогнозируют цикл ЭНЮК в сравнении с динамическими моделями и способны смягчить ВПП. Авторы работы (Gavrilov et al., 2019) привели математическую модель, основанную на разложении на линейные динамические моды. В работе (Ham et al., 2019) для прогноза ЭНЮК использовалась свёрточная нейронная сеть (СНС), входными данными в которую были аномалии ТПО и теплосодержания океана в районе 0°–360°в.д. и 55°ю.ш.–60°с.ш. За счет использования климатических моделей семейства CMIP5 авторы смогли существенно увеличить обучающую выборку, что улучшило способность прогнозирования модели. Несколько позже, в работах (Ye et al., 2021) и (Geng, Wang, 2021) был использован тот же подход к блоку входных данных, однако моделирование осуществлялось с помощью архитектуры свёрточной нейронной сети с длинной цепью элементов краткосрочной памяти (СДКП), обладающей свойствами рекуррентных и свёрточных нейросетей.

Несмотря на заметные успехи СНС в прогнозировании ЭНЮК, в обзорной работе (Fang et al., 2022) в качестве недостатка этой архитектуры отмечено, что фиксированный размер входного вектора и непоследовательный

размер входных и выходных наборов данных ограничивают применение СНС в прогнозировании временных рядов. В то же время СДКП не так хорош для прогнозов слабых аномалий Эль-Ниньо.

Одним из главных недостатков современных методов машинного обучения является отсутствие возможности интерпретировать построенную модель с точки зрения физического анализа дальнейшую связей системы океан-атмосфера. Как известно, к примеру, из (Lin et al., 2019) механизм возникновения и смены ЭН и ЛН до сих пор является предметом дискуссий, и у исследователей нет однозначного мнения о его 2-7 летней квазипериодичности. Поэтому, помимо улучшения прогностических способностей современных моделей, возможность изучения используемых предикторов, которые привели к успешному прогнозу ЭНЮК, является не менее важной задачей.

В наших ранних работах были предприняты попытки прогнозировать события ЭНЮК с использованием модели, основанной на многослойной нейронной сети (МНС). В работе (Лубков и др., 2017а) моделировался индекс Южного колебания (ИЮК) с заблаговременностью прогноза, не превышающей 5 месяцев. Тогда в качестве входных векторов модели использовались широко известные индексы дальнейшую связей системы океан-атмосфера, описанные в работе (Barnston, Livezey, 1987), и был проведен анализ наиболее важных для модели индексов. Несколько позже в работах (Lubkov et al., 2019; Lubkov et al., 2020) нами была предпринята успешная попытка прогноза событий ЭНЮК с использованием аномалий ТПО в районе Nino 3.4. Заблаговременность модели МНС тогда составила 9 месяцев. В качестве входных индексов использовались только атмосферные предикторы, расположенные в Северном и Южном полушариях и экваториальных широтах. Несмотря на это, способность прогнозирования превосходила современные динамические модели и была сопоставима на тот момент с одной из последних успешных моделей машинного обучения, предложенной в (Gavrilov et al., 2019).

В текущей работе мы существенно переработали старый подход к моделированию ЭНЮК с использованием МНС и предложили новый подход. В разделе 2 детально описан алгоритм предложенной модели. В разделе 3 обсудим воспроизводимость событий Эль-Ниньо и Ла-Нинья моделью с учетом их пространственных типов и сравним способность прогнозирования с динамическими моделями. В завершение, будет рассмотрен полученный в ноябре 2022 года прогноз предстоящего в 2023 году события Эль-Ниньо.

## Данные и методы

Для наблюдения за циклом ЭНЮК традиционно используют атмосферный индекс Южного колебания, рассчитываемый как разница приземного давления между о. Таити и портом Дарвин (Австралия) (Walker, 1924), и океанические индексы, представляющие собой среднюю аномалию ТПО в регионах Nino1+2 ( $0\text{--}10^\circ\text{ю.ш.}$ ,  $90^\circ\text{з.д. -- }80^\circ\text{з.д.}$ ), Nino3 ( $5^\circ\text{с.ш. -- }5^\circ\text{ю.ш.}$ ,  $150^\circ\text{з.д. -- }90^\circ\text{з.д.}$ ), Nino3.4 ( $5^\circ\text{с.ш. -- }5^\circ\text{ю.ш.}$  и  $170^\circ\text{з.д. -- }120^\circ\text{з.д.}$ ) и Нино4 ( $5^\circ\text{с.ш. -- }5^\circ\text{ю.ш.}$ ,

160°в.д.-150°з.д.). Обычно для идентификации начала событий ЭН и ЛН используют океанические индексы (Petrosyants, Gushchina, 2002; Yeh et al., 2009; Webb, Magi, 2022). Океанических индексов вполне достаточно, чтобы идентифицировать и классифицировать экстремальную фазу ЭНЮК. Следовательно, в этой работе нами будет предложена модель для прогнозирования индексов Nino3, Nino3.4 и Nino4.

### ***Используемые массивы данных***

Для решения поставленной задачи необходим массив данных, который будет удовлетворять трем основным условиям: достаточная длина, однородность и оперативное обновление актуальных данных. Поэтому массивы данных, охватывающие только 40-летний временной период спутниковых наблюдений (к примеру, NCEP/DOE, MERRA-2), а также массивы с высоким пространственно-временным разрешением, требующие некоторого времени для обновления актуальных данных (к примеру, ERA5), не подходят для поставленной задачи. В то же время массивы, берущие свое начало с середины XIX века включают в себя неоднородные ряды данных, особенно в XIX веке и первой половине XX (к примеру, 20CR).

Для расчета атмосферных предикторов будем использовать среднемесечный реанализ NCEP/NCAR (Kistler et al., 2001). Данные этого реанализа доступны с 1948 года, время обновления составляет 3 дня, пространственное разрешение  $2.5^\circ \times 2.5^\circ$ .

В работе (Марчукова и др., 2020), посвященной анализу качества воспроизведения явлений ЭН и ЛН, по данным нескольких реконструкций ТПО, отмечено преимущество массива COBESST перед другими. Этот массив данных будет использоваться для расчета индексов Nino и набора предикторов модели. Массив COBESST (Hirahara et al., 2014) включает среднемесечные данные с 1891 года, время обновления составляет 10 суток, пространственное разрешение  $1^\circ \times 1^\circ$ . В работе будет использован промежуток данных массива COBESST с 1940 года.

Работоспособность предложенной модели сравнивалась с динамическими моделями, входящими в Североамериканский мультимодельный ансамбль (North American Multi-Model Ensemble или NMME) (Kirtman et al., 2014). Для сравнения были использованы модели NMME, которые включали ретроспективный период 2007-2018: GFDL-SPEAR, GEM-NEMO, CanSIPsV2, CanCM4i, CanSIPS-IC3. Модель NASA-GEOSS2S использовала доступный ретроспективный период 2007-2016.

### ***Разложение на высокочастотную и низкочастотную составляющие***

В наших предыдущих исследованиях (Lubkov et al., 2016; 2019; 2020) отмечено, что количество входных индексов ограничено вычислительными возможностями: для оптимальной работы модели рекомендовано использовать не более 25. При этом сложность вычислений увеличивается по закону  $2^x$ , где  $x$  – это количество входных индексов. Следовательно, их уменьшение

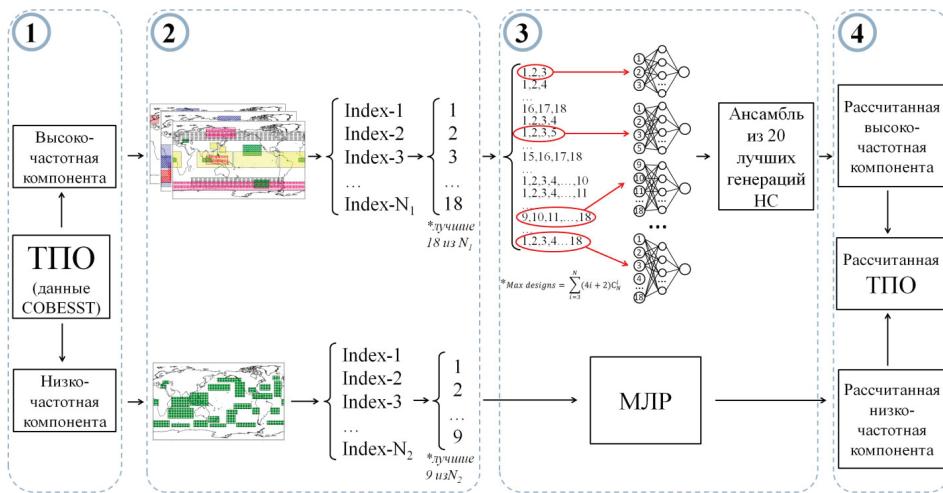
приведет к уменьшению времени расчетов. Разложение исходного ряда на несколько статистически несвязанных компонент и их последующее отдельное моделирование предполагает использование нескольких наборов индексов, подаваемых для моделирования каждой компоненты. Такой подход позволит значительно увеличить количество используемых индексов и, следовательно, улучшить качество моделирования.

Из (Enfield, Mestas-Nunez, 1999) известно, что океанические параметры имеют несколько мод долгопериодной изменчивости, среди которых основными считаются AMO (Knight et al., 2006; Schlesinger, Ramankutty, 1994) с типичным периодом 60-70 лет, ТДО (Mantua et al., 1997; Zhang et al., 1997) с квази-двадцатилетним временным масштабом и межгодовые колебания САК, ЭНЮК и др. (Voskresenskaya, Polonsky, 1993; Trenberth, Caron, 2000) с 2-7-летним периодом чередования экстремальных фаз. Это основные режимы глобальной климатической системы, присущие как океану, так и атмосфере. При этом в атмосферных полях выделяется более десятка режимов с временным масштабом от нескольких месяцев до нескольких лет (Barnston, Livezey, 1987; Wallace, Gutzler, 1981). Стоит также отметить, что в энергетических спектрах ТПО в районах индексов Nino значимые пики обычно отмечаются в диапазоне от 2 до 7 лет (к примеру, (Torrence, Compo, 1998; Voskresenskaya, Polonsky, 1993).

Обычно под декомпозицией подразумевается разложение ряда на несколько компонент, основными из которых являются тренд, сезонная изменчивость, периодическая изменчивость и некоторая неопределенная компонента, чаще называемая «случайной». В нашем исследовании моделирование производится отдельно для каждого месяца, что исключает наличие сезонности. С учетом типичных периодов основных климатических режимов атмосферы и океана, а также с учетом энергетических спектров ТПО в экваториальной зоне Тихого океана мы предлагаем разложить моделируемые индексы Nino на две компоненты: низкочастотную (от 9 лет) и высокочастотную (до 9 лет). При таком разделении высокочастотная компонента будет включать в себя все значимые пики энергетического спектра ТПО экваториальной зоны Тихого океана, которые являются основным источником неопределенности. В низкочастотную компоненту войдут трендовая составляющая и 60-, 20- и 10-летняя изменчивости, свойственные для глобальной климатической системы (Enfield, Mestas-Nunez, 1999). Низкочастотная компонента в этом исследовании имеет вспомогательный характер, а для ее моделирования будет применяться МЛР.

Разложение проводилось с использованием 9-летнего среднего скользящего фильтра. Сглаженный фильтром ряд принимался за низкочастотную компоненту, а ряд разности исходных и сглаженных значений – за высокочастотную. Низкочастотная и высокочастотная компоненты были приведены к климатическим аномалиям (как разница между рядом ТПО и некоторым средним многолетним значением) и нормированы на среднеквадратическое отклонение (СКО), где СКО и среднее многолетние рассчитывались за период 1981-2010. Эти два новых ряда моделировались в текущей работе независимо друг

от друга, а после моделирования выполнялось их сложение. На схеме предложенной модели (рис. 1) этот этап отмечен первым.



**Рисунок 1.** Схема предлагаемой модели: 1) декомпозиция моделируемого ряда; 2) предварительная обработка данных 3) моделирование; 4) результаты моделирования и проверка

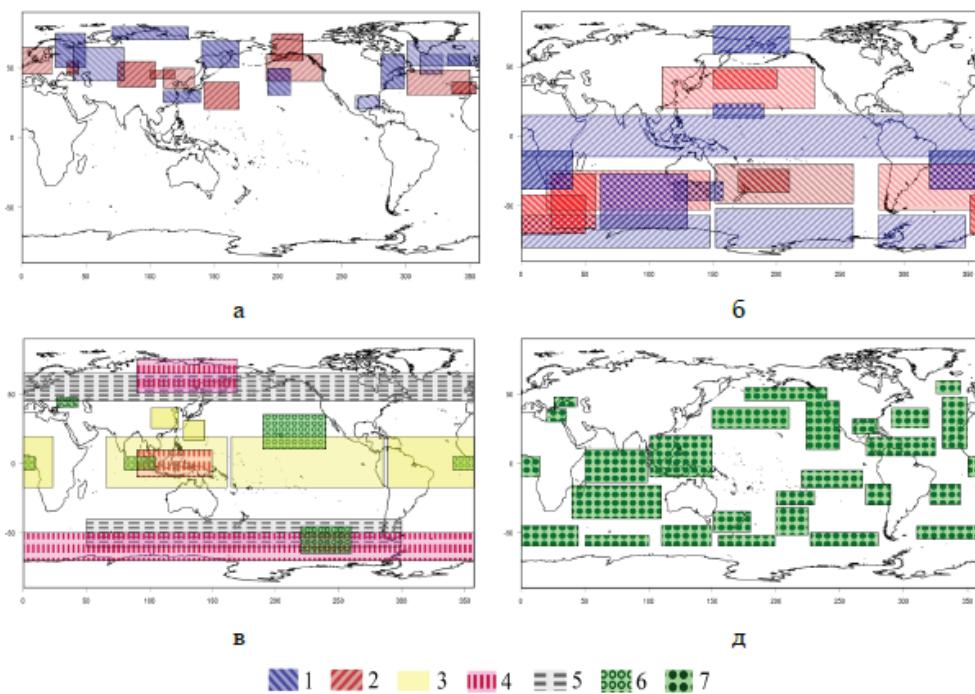
**Figure 1.** Scheme of the proposed model: 1) decomposition of the simulated series; 2) data preprocessing; 3) simulation; 4) model results and verification

### Предикторы модели

Среди большого количества индексов, используемых для моделирования, условно можно выделить индексы известных климатических сигналов и дополнительно рассчитанные в работе индексы.

В работе (Barnston, Livezey, 1987) разложением на ЭОФ выделено и описано 13 сезонных или постоянно действующих атмосферных сигналов. Традиционно индексы этих сигналов вычисляются как взвешенная разность в двух, трех и более центрах действия атмосферы, по данным о геопотенциальной высоте на уровне 500 мб. В нашем исследовании эти индексы были пересчитаны с использованием реанализа NCEP/NCAR. Области, в которых вычислялись индексы, обозначены на рис. 2а. Среди известных климатических сигналов также использовались океанические, такие, как атлантическая мода, подобная ЭНЮК (Voskresenskaya, Polonsky, 1993; Vallès-Casanova et al., 2020), индоокеанский диполь (Saji et al., 1999) и тихоокеанская декадная изменчивость (Maslova et al., 2017), имеющие глобальные климатические проявления (Polonsky, Basharin, 2017; Vallès-Casanova et al., 2020; Maslova et al., 2017). Области, в которых рассчитывались индексы этих климатических сигналов отображены на рис. 2в и рис. 2д.

Дополнительно в работе были рассчитаны атмосферные и океанические индексы Южного полушария и экваториальной области по следующему алгоритму.



**Рисунок 2.** Области, используемые для расчета атмосферных и океанических индексов

Области геопотенциальной высоты на изобарической поверхности 500 мб отмечены как 1 и 2; области геопотенциальной высоты на изобарической поверхности 1000 мб отмечены как 3; области меридиональной и зональной составляющих вектора ветра на изобарической поверхности 500 мб отмечены как 4 и 5, соответственно; области ТПО отмечены как 6; области ТПО, рассчитанной с применением 9-летнего среднего скользящего сглаживания, отмечены как 7

**Figure 2.** Areas used to calculate atmospheric and oceanic indices

The areas of geopotential on the 500 mb are labeled 1 and 2; the areas of geopotential on the 1000 mb are labeled 3; the areas of the meridional and zonal wind components on the 500 mb are labeled 4 and 5, respectively; SST areas are labeled 6; SST areas calculated using 9-year moving average smoothing are labeled 7

Между индексами Nino3, Nino4 и Nino3.4 и гидрометеорологическими полями (ТПО, геопотенциальная высота на изобарическом уровне 500мб и 1000мб, компоненты ветра на уровне 500мб) в каждой узловой точке и с временным сдвигом от 1 месяца до двух лет для высокочастотной составляющей и до 10 лет для низкочастотной были рассчитаны коэффициенты корреляции. Сравнительный анализ индексов Nino и глобальных полей привел к обобщению некоторых областей (рис. 2б,в,г), в которых чаще наблюдались значимые коэффициенты корреляции (при длине ряда, равной 70, и  $\alpha = 0.01$  значимый коэффициент корреляции  $r = 0.195$ ). В пределах этих областей выполнялось осреднение. Далее рассчитывались индексы. В случае нескольких связанных областей в зависимости от их количества индекс рассчитывался как взвешенная разность по формуле (1):

$$\begin{cases} X = H_1 - H_2 \\ X = H_1 - 2H_2 + H_3 \\ X = H_1 - H_2 + H_3 - H_4 \end{cases}, \quad (1)$$

где  $H$  – осредненное значение геопотенциальной высоты в некоторой области,  $X$  – взвешенная разность нескольких областей. Полученное значение пересчитывалось по формуле (2):

$$Index_{i,m} = \frac{X_{i,m} - \bar{X}_m}{\sigma_m}, \quad (2)$$

где  $\bar{X}$  и  $\sigma$  – среднее и стандартное отклонение за период 1981-2010 гг., рассчитанные для каждого месяца отдельно,  $i$  и  $m$  – год и месяц. В случае, когда область не связана с ближайшими областями, индекс рассчитывался только по формуле (2).

Для моделирования низкочастотной составляющей в качестве входных данных использовались только поля ТПО, сглаженные 9-летним фильтром для каждого месяца по отдельности. Выделенные области ТПО, в которых были рассчитаны океанические индексы, представлены на рис. 2г.

В результате было выявлено более 100 регионов, на основе которых было выбрано 58 индексов: 34 для моделирования высокочастотной и 24 для моделирования низкочастотной составляющих.

Последним шагом в выборе предикторов модели была оценка статистической связи выбранных 58 индексов с индексами Nino. Статистическая связь оценивалась с использованием коэффициента корреляции с временным сдвигом от одного месяца до двух лет опережения для высокочастотной составляющей и от одного месяца до десяти лет – для низкочастотной для каждого месяца отдельно. Корреляция считалась за период 1950-2006. Для каждого месяца и каждого индекса Nino в отдельности на основе коэффициента корреляции осуществлялось ранжирование индексов с учетом временного сдвига. Поскольку увеличение числа входных параметров существенно влияет на скорость вычисления, для моделирования высокочастотной и низкочастотной составляющих было использовано 18 и 10 входных индексов соответственно.

## Моделирование

### Высокочастотная составляющая

Моделирование (рис. 1, третий этап) высокочастотной составляющей индексов Nino осуществлялось с помощью МНС, представленной многослойным персептроном с одним скрытым слоем (Haykin, 1994). Выходной слой представлен лишь одним нейроном. Функция активации нейронов МНС – сигмоидальная биполярная  $f(x) = \tanh(\beta x)$  (Осовский, 2002; Haykin, 1994).

Моделирование каждого месяца проводилось независимо друг от друга. Среднемесячные ряды значений моделируемого параметра и использованных входных индексов были разделены на обучающую, тестирующую и контроль-

ную выборки. Длина обучающей выборки составила 38 лет за период 1950-1987 гг. Тестовая выборка равна 19 годам за период 1988-2006 гг. В качестве контрольной выборки рассматривался 14-летний период за 2007-2022 гг.

Обучение модели проводилось на основе алгоритма обратного распространения ошибки (Haykin, 1994) с некоторыми поправками. Обычно максимум обучения определяется целевой функцией, рассчитываемой на каждом шаге обучающей выборки, и формулируется, как правило, в виде квадратичной суммы разностей между фактическими и ожидаемыми значениями выходного сигнала (Осовский, 2002; Haykin, 1994). Если достижение модельных расчетов и заведомо известных значений с некоторой требуемой точностью невозможно, максимум обучения определяется как глобальный минимум целевой функции (Осовский, 2002). В поставленной задаче установить требуемую точность модельных расчетов невозможно ввиду недостаточной изученности моделируемых параметров. При этом обучающая выборка состоит всего из 38 значений, что усложняет определение максимума обучения классическим методом. В этой связи для определения максимума обучения применим метод, описанный в работе (Lubkov et al., 2016). Суть обучения МНС этим методом заключается в следующем. Корректировка весов нейронов МНС осуществляется с помощью классической целевой функции, однако обучающая выборка повторяется многократно (то есть используются ее итерации), при этом значения весов уточняются с каждой итерацией. На каждой итерации рассчитываются коэффициенты корреляции с обучающей ( $r_{\text{обуч}}$ ) и тестовой ( $r_{\text{тест}}$ ) выборками. За максимум обучения принимается итерация, на которой наблюдался глобальный максимум  $r_{\text{обуч}}$ . При этом неравенство  $|r_{\text{тест}} - r_{\text{обуч}}| < 0.15$  должно быть выполнено. В случае, когда условие не выполняется, за максимум обучения принимается ближайшая итерация, для которой неравенство действительно, то есть итерация, которая находится в некоторой близости от глобального максимума обучения. Однако недостаток этого метода состоит в необходимости контрольной проверки моделируемых результатов. Это связано с тем, что в процессе поиска максимума обучения МНС используется тестирующая выборка и, следовательно, возникает необходимость использовать независимую (контрольную) выборку для объективной оценки возможностей модели.

Ранее в работе (Lubkov et al., 2016) было отмечено, что поведение МНС не всегда может быть предсказуемо. На основе всех отобранных на предыдущем этапе предикторов модель демонстрировала неудовлетворительный результат. Это могло быть связано с использованием индексов, не имеющих физической связи с моделируемым параметром и/или с тем, что входные индексы могли иметь тесную статистическую связь между собой. Поэтому моделирование проводилось с перебором всех возможных комбинаций предикторов на входе, выбранных на предварительном этапе. Количество нейронов скрытого слоя также изменялось от 3 до  $4i+2$  (где  $i$  – количество предикторов в текущей выборке). Таким образом, общее число возможных конструкций МНС, имеющих уникальный набор предикторов и различное число нейронов скрытого слоя, можно рассчитать как:

---

$$\text{Max designs} = \sum_{i=3}^N (4i + 2) C_N^i, \quad (3)$$

где  $N$  – общее количество входных предикторов,  $i$  – текущее количество предикторов ( $i = 1, 2, \dots, N$ ). Если учесть, что для высокочастотной составляющей общее количество входных предикторов мы ограничили до 18, то количество уникальных конструкций МНС будет составлять порядка  $10^7$ .

Для каждой уникальной конструкции МНС проводилось обучение. Данные о конструкциях МНС в момент максимума обучения (номера используемых предикторов, количество нейронов скрытого слоя, итерация обучения, корреляционные оценки на тестовой и обучающей выборке) заносились в лог-файл. Далее производилось ранжирование по коэффициенту корреляции на тестовой выборке. По результатам ранжирования отбирались 20 лучших конструкций МНС, которые объединялись в ансамбль путем обычного среднего арифметического.

### *Низкочастотная составляющая*

Моделирование низкочастотной составляющей производилось с использованием простой модели множественной линейной регрессии (МЛР). МЛР имеет стандартный вид  $Y' = a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n$ , где  $X$  – выбранные океанические предикторы, сглаженные 9-летним средним скользящим фильтром,  $a$  – коэффициенты. Смысл МЛР заключается в подборе оптимальных коэффициентов  $a$ , для которого использовалась минимизация с помощью суммы квадратов разностей между модельным расчетом и фактическим значением. Для МЛР применялись 10 предикторов, отобранных на этапе сортировки входных в модель индексов. С применением пошагового алгоритма, предложенного в (Venables, Ripley, 2002), удалось оптимизировать модель МЛР и выделить те предикторы, на основе которых модель МЛР наиболее успешна. Функциональная зависимость предикторов и низкочастотной компоненты индексов Nino была найдена для каждого месяца в отдельности. Все используемые предикторы выбраны с учетом заблаговременности, равной 24 месяцам.

### *Критерии оценки модели*

На заключительном этапе (рис. 1) смоделированные высокочастотная и низкочастотная составляющие приводились обратно к значениям температуры и складывались. Поскольку высокочастотная составляющая представляет собой среднее из 20 прогностических результатов, СКО модельной ТПО в области индексов Nino приводилось к СКО наблюдаемых значений ТПО.

Качество ансамбля оценивалось в сравнении с контрольной выборкой (2007-2022). Для такой оценки использовались следующие инструменты.

1. Корреляция Пирсона:

$$r = \frac{\text{cov}(x_i, y_i)}{\sigma_x \sigma_y}, \quad (4)$$

где  $\sigma_x$  и  $\sigma_y$  – среднеквадратические отклонения выборок  $x$  и  $y$ , которые представляют собой результат моделирования и наблюдаемые значения.

2. Среднеквадратическое отклонение модельных данных от действительных (Root-Mean-Square-Error или RMSE):

$$RMSE = \sqrt{\frac{\sum(x_i - y_i)^2}{n}}, \quad (5)$$

где  $n$  – длина ряда контрольной выборки,  $x_i$  – модель,  $y_i$  – наблюдаемая величина,  $\bar{y}$  – среднее наблюдаемого ряда,  $i$  – год контрольной выборки.

### ***Определение событий ЭНЮК и типизация***

Вокруг вопроса выбора подходящего критерия для выделения событий Эль-Ниньо до сих пор ведутся дискуссии (Webb, Magi, 2022). Зачастую для определения событий ЭНЮК используют скользящее среднее за три месяца индекса Nino3.4. Этот индекс представляет собой аномалии ТПО в районе Nino3.4. Выбор района Nino3.4 обусловлен высокими корреляционными связями между аномалиями ТПО в этом регионе с атмосферным ИЮК (Barnston et al., 1997). Однако существуют и другие точки зрения по выбору региона для выделения фаз ЭНЮК. Например, в работе (Trenberth, Stepaniak, 2001) для определения событий Эль-Ниньо и Ла-Нинья использовался Nino3.4 совместно с введенным авторами Trans-Niño Index (TNI). TNI – это разница между нормированными значениями аномалий ТПО в районе Nino4 и Nino1+2. В статье (Petrosyants, Gushchina, 2002) было предложено выбирать область Nino3 для выделения ЭН и ЛН, так как именно этот район наилучшим образом характеризует крупномасштабные события ЭНЮК. В работах (Serykh, Sonechkin, 2019; Serykh, Sonechkin, 2021) используется так называемый Extended Oceanic Nino index, представляющий собой осредненные аномалии ТПО в районе с координатами 5°с.ш.-5°ю.ш. 170°-80°з.д., включающий в себя экваториальную зону Тихого океана и прилегающую к Панамскому перешейку область. Выбор этого района авторы обосновывают наличием в нём гораздо больших судовых наблюдений, чем в центральных регионах Тихого океана по отдельности, таких, как Nino3.4, Nino3 и Nino4. В классической работе (Yeh et al., 2009) события ЭН выделялись по индексам Nino3 и Nino4 в зимний сезон (декабрь, январь, февраль), в одной из областей отмечалась аномалия более 0.5°C.

В настоящем исследовании мы будем моделировать аномалии ТПО в регионах Nino3.4, Nino3 и Nino4, а затем для каждого рассчитаем трехмесячное среднее скользящее. В разделе «Способность прогнозирования и сравнение с динамическими моделями» для оценки состояния ЭНЮК из-за более высокой способности прогнозирования будем использовать только индексы Nino3 и Nino4. По аналогии с методикой, предложенной в (Qian et al., 2011; Voskresenskaya et al., 2017), будем идентифицировать ЭН и ЛН, если аномалия ТПО в районах Nino3 и Nino4 превышает 0.5°C и продолжается 5 месяцев последовательно:

$$\left\{ \begin{array}{ll} \text{ЭН,} & \frac{(Nino3 + Nino4)}{2} > 0.5^{\circ}\text{C} \text{ и } t \geq 5 \text{ мес.} \\ \text{ЛН,} & \frac{(Nino3 + Nino4)}{2} < -0.5^{\circ}\text{C} \text{ и } t \geq 5 \text{ мес.} \\ \text{нейтральный ЭНЮК,} & -0.5 < \frac{(Nino3 + Nino4)}{2} < 0.5^{\circ}\text{C} \end{array} \right. , \quad (6)$$

Для определения типа будем использовать соотношение, предложенное (Yeh et al., 2009):

$$\left\{ \begin{array}{ll} \text{Восточный,} & Nino3_{зима} > Nino4_{зима} \\ \text{Центральный,} & Nino3_{зима} < Nino4_{зима} \end{array} \right. , \quad (7)$$

## Результаты и обсуждение

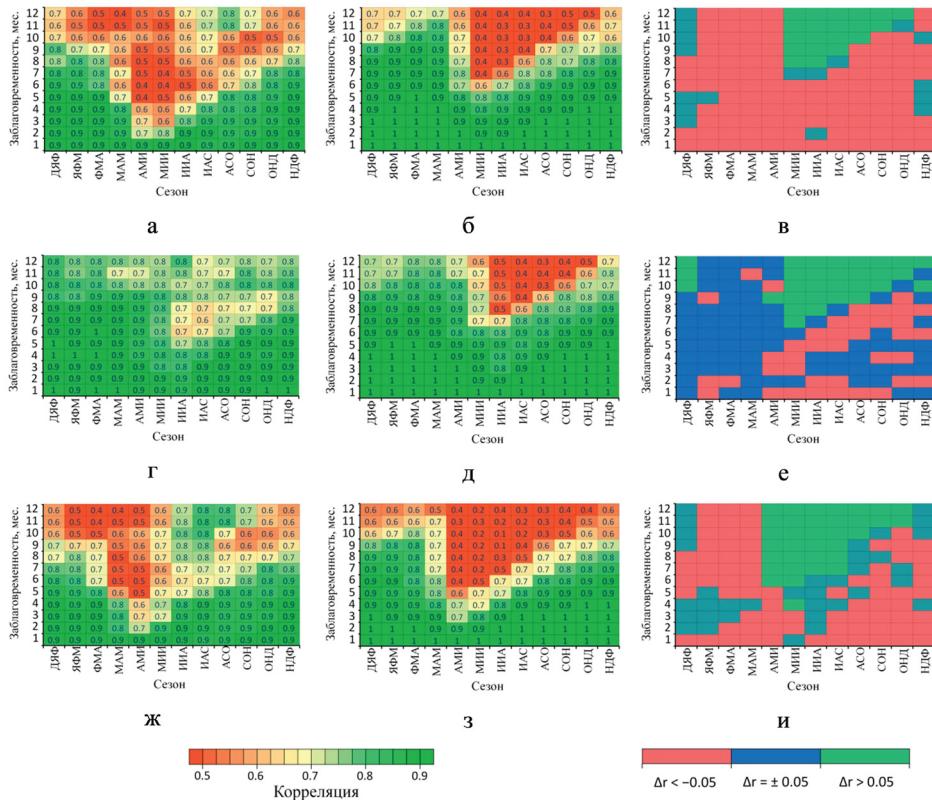
### *Способность прогнозирования и сравнение с динамическими моделями*

В разделе дана оценка сезонной и всесезонной способности прогнозирования модели NNM-ENSOv1 и проведено сравнение с динамическими моделями. Для такой оценки все индексы Nino динамических моделей и NNM-ENSOv1 представлены 3-месячными скользящими средними. Для совместного сравнения был выбран общий временной период 2007-2017 гг.

Для оценки сезонной способности прогнозирования динамических моделей проекта NMME рассматривался ансамбль из 6 моделей. В качестве критерия оценки сезонной способности прогнозирования применялся только корреляционный анализ. Основной особенностью, которой обладают динамические модели – это хорошо выраженное влияние ВПП (рис. 3). Для индекса Nino3.4 в динамических моделях ВПП характерен в сезон май-июнь-июль, начиная с 6 месяцев заблаговременности (рис. 3б). Для индекса Nino4 он смешен в летние месяцы (июнь-июль-август) и его влияние отмечается, начиная с 7 месяцев заблаговременности (рис. 3д). Для индекса Nino3 ВПП характерен в сезон апрель-май-июнь, начиная с 5 месяцев заблаговременности (рис. 3з). За пределами ВПП все прогнозы незначимы.

На диаграммах, изображенных на рис. 3в, е, и, приведено сравнение способностей прогнозирования NNM-ENSOv1 и ансамбля динамических моделей, где  $\Delta t$  представляет собой разницу корреляций. Для всех изображений характерно улучшенное качество моделирования NNM-ENSOv1 за пределами ВПП, при этом коэффициенты корреляции в остальные сезоны ниже или такие же. Индекс Nino3.4 моделируется NNM-ENSOv1 хуже остальных индексов Nino (рис. 3а). Для этого индекса ВПП хотя и значительно смягчен, но ощущается раньше с заблаговременностью 3 месяца и смешен к сезону апрель-май-июнь. Такая же ситуация наблюдается и для индекса Nino3 (рис.

Зг), при этом с заблаговременностью 11 и 12 месяцев модель лучше воспроизводит летние и осенние месяцы. Наилучшим образом модель воспроизводит индекс Nino4 (рис. Зж). ВПП для этого индекса практически отсутствует: корреляции в летний и осенний сезоны незначительно отличаются от корреляций в зимние и весенние сезоны.



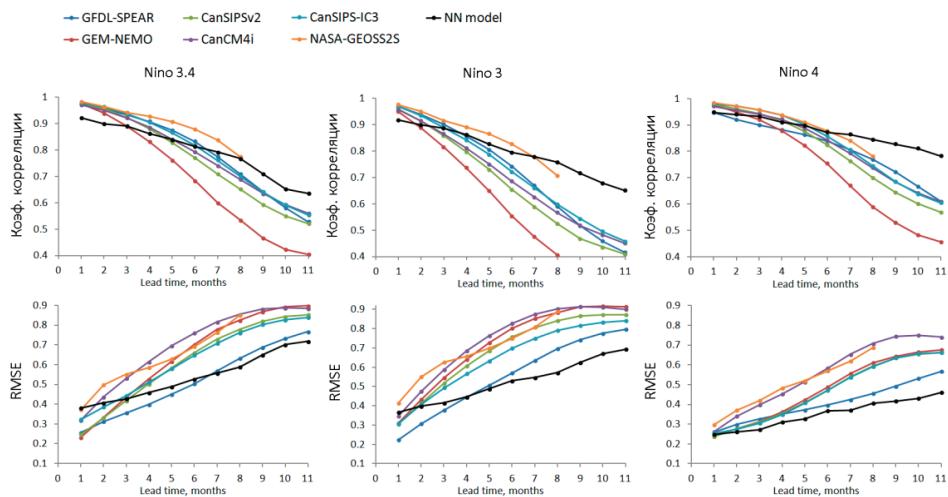
**Рисунок 3.** Корреляционные оценки предложенной модели NNM-ENSOv1 (а,г,ж) и ансамбля динамических моделей NMME (б,д,з) в зависимости от заблаговременности и сезона и их совместное сравнение  $\Delta r = r_{NNM-ENSOv1} - r_{dynamic}$  (в,е,и) для индексов Nino3.4 (а,б,в), Nino4 (г,д,е) и Nino3 (ж,з,и) за контрольный период 2007-2017

**Figure 3.** Seasonal correlation forecast skill of the NNM-ENSOv1 (a,d,g) and an ensemble of dynamic models of the NMME project (b,e,h) depending on the lead times and season and their comparison  $\Delta r = r_{NNM-ENSOv1} - r_{NMME}$  (c,f,i) for Nino3.4 (a,b,c), Nino4 (d,e,f) and Nino3 (g,h,i) indices for the control period 2007-2017

На рис. 4 приведены результаты сравнения всесезонной способности прогнозирования (сравнивались коэффициенты корреляции и RMSE) для индексов Nino3.4, Nino3 и Nino4, слаженных трехмесячным средним скользящим за период 2007-2017. Способность прогнозирования индекса Nino3.4 для большинства динамических моделей проекта NMME превосходит предложенную в работе модель с заблаговременностью до 6 месяцев. При этом с заблаговременностью 8-11 месяцев способность прогнозирования модели NNM-ENSOv1 превосходит способность динамических. Коэффициент корре-

ляции (и RMSE) в случае прогноза с заблаговременностью 11 месяцев с использованием модели NNM-ENSOv1 равен 0.64 (0.72°C) и с использованием динамических моделей – 0.40-0.56 (0.77-0.90°C). Аналогичный результат был получен и для индекса Nino3. При этом с заблаговременностью 8-11 месяцев предложенная модель значительно лучше моделирует индекс Nino3. Для этого индекса коэффициент корреляции (и RMSE) в случае прогноза с 11-месячной заблаговременностью моделью NNM-ENSOv1 равен 0.65 (0.69°C) и динамическими моделями – 0.29-0.46 (0.80-0.91°C). Моделирование индекса Nino4 показало, что предложенная модель превосходит динамические модели в случае сравнения корреляций с заблаговременностью от 6 и больше месяцев, а в случае сравнения по RMSE – с любой заблаговременностью прогноза. Коэффициент корреляции (и RMSE) модели NNM-ENSOv1 для прогноза заблаговременностью 11 месяцев равен 0.78 (0.46°C). При этом для динамических моделей эти значения равны 0.46-0.61 (0.57-0.74°C). Из всех динамических моделей модель NASA-GEOSS2S наиболее успешно описывает динамику состояния ЭНЮК, однако ее заблаговременность прогноза индексов Nino ограничена 8 месяцами, а RMSE заметно выше остальных динамических моделей. По корреляционным оценкам модель NASA-GEOSS2S превосходит предложенную нами в прогнозах с заблаговременностью от 1 до 7 месяцев.

Успехи предложенной модели NNM-ENSOv1 с заблаговременностью прогноза более 7 месяцев являются следствием смягчения ВПП. При этом модель систематически показывает более низкую способность прогнозирования для прогнозов с небольшой заблаговременностью, что особенно выражено для индекса Nino3.4.

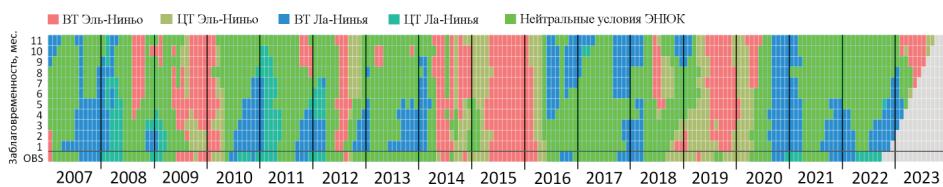


**Рисунок 4.** Всесезонная способность прогнозирования (оценка на основе коэффициентов корреляции и RMSE) трехмесячных скользящих средних индексов Nino3.4, Nino3 и Nino4 для модели NNM-ENSOv1 и ансамбля моделей проекта NMME за период 2007-2017

**Figure 4.** The all-season forecast skill (correlation and RMSE) of the three month moving averaged Nino3.4, Nino3 and Nino4 indices from 2007 to 2017 for NNM-ENSOv1 and NMME ensemble

## Воспроизведимость явлений Эль-Ниньо и Ла-Нинья

Рис. 5 демонстрирует воспроизведение состояния ЭНЮК с учетом типизации Эль-Ниньо и Ла-Нинья в период 2007-2022. Ячейки закрашивались в цвета, соответствующие экстремальным событиям ЭНЮК, если выполнялось условие превышения порога  $\pm 0.5^{\circ}\text{C}$  в соответствии с формулой 6. Типизация производилась с учетом условия из формулы 7 для каждого сезона. На рис. 5 видно, что 4 из 5 явлений ЭН определены верно, включая их тип. Воспроизведение событий ЭН практически не зависит от заблаговременности прогноза. События ЛН воспроизводятся заметно хуже. С увеличением заблаговременности прогнозируемый месяц начала ЛН смещается с запаздыванием. Таким образом, большинство события ЛН воспроизводятся только с небольшой заблаговременностью. Ла-Нинья 2007, 2017 и 2021 являются исключением и хорошо воспроизводятся с заблаговременностью, равной 5 месяцам для ЛН-2007 и 11 месяцев для ЛН-2017 и ЛН-2021.



**Рисунок 5.** Состояние ЭНЮК с учетом типов Эль-Ниньо и Ла-Нинья, по данным COBESST и модельным расчетам, с заблаговременностью до 11 месяцев

**Figure 5.** ENSO events state taking into account the El Niño and La Niña types according to COBESST datasets and model forecasting with lead times of up to 11 months

В табл. 1, полученной на основе рис. 5, приведен процент совпадений прогноза с данными наблюдений. В целом состояние ЭНЮК без учетов типов ЭН и ЛН определяется с вероятностью 60-80%. Если рассматривать только события ЭН и ЛН, вероятность определения варьируется от 82-84% с заблаговременностью прогноза 1-3 месяц до 53-58% с заблаговременностью 8-11 месяцев. Отметим, что вероятность верного определения событий Эль-Ниньо практически не зависит от заблаговременности прогноза и варьируется от 76 до 83%, и если учитывать типизацию, то 65-54%. В то же время события ЛН сильно зависят от заблаговременности прогноза. Вероятность верного определения явления ЛН варьируется от 85 до 31% и с учетом типизации – всего 51-24%. Несмотря на низкий процент определения типов ЭН и ЛН, все события ЭН и 2 события ЛН с заблаговременностью 11 месяцев в сезон декабря-январь-февраль были определены верно.

Далее были проанализированы ошибочные случаи событий ЭН и ЛН. Ошибочные случаи ЛН наблюдаются реже с заблаговременностью до 1-4 месяца (5-9%). С заблаговременностью 7-11 месяцев ошибочные ЛН отмечаются с вероятностью 20-23%. Ошибочные случаи ЭН варьируются от 8 до 28% с минимумом для заблаговременности 6 месяцев. С заблаговременностью 8-11 месяцев вероятность ошибочного прогноза ЭН составляет 11-13%.

**Таблица 1.** Процент совпадений прогноза с данными наблюдений за контрольный период 2007-2022

**Table 1.** The probability of ENSO forecast coincidences with observation in 2007-2022

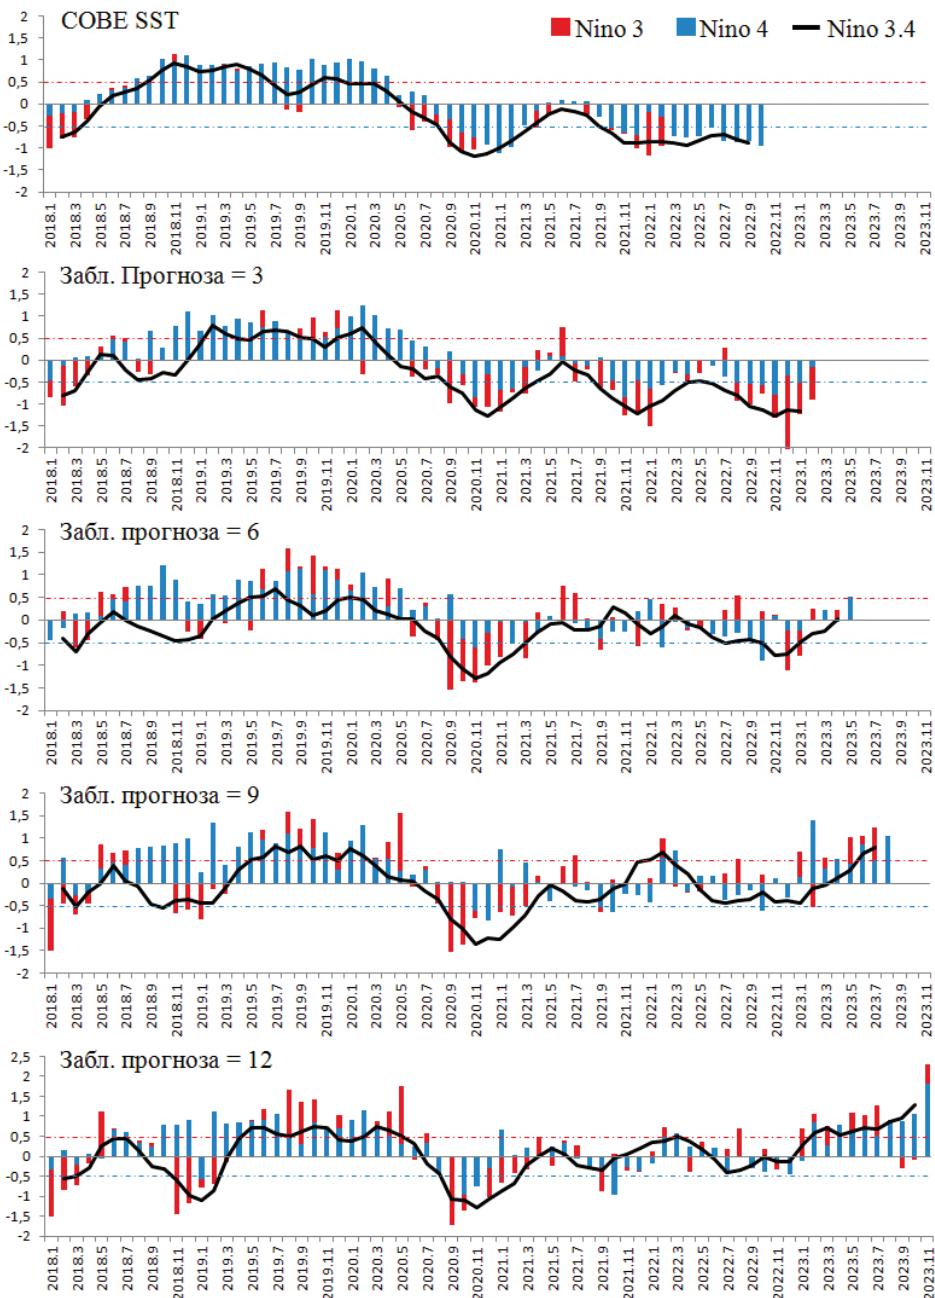
Заблаговременность	1	2	3	4	5	6	7	8	9	10	11
Общие совпадения, % (с учетом типа)	76 (59)	79 (61)	80 (65)	71 (58)	70 (57)	67 (57)	65 (55)	59 (51)	62 (52)	59 (49)	58 (49)
Только события ЭН и ЛН (с учетом типа), %	84 (55)	83 (53)	82 (58)	71 (49)	68 (46)	63 (47)	62 (44)	53 (40)	58 (42)	55 (39)	54 (39)
Только ЭН, % (с учетом типа)	83 (59)	81 (56)	85 (65)	81 (56)	81 (54)	85 (65)	83 (59)	78 (57)	81 (57)	80 (54)	76 (54)
Только ЛН, % (с учетом типа)	85 (51)	85 (51)	80 (51)	61 (42)	56 (39)	42 (31)	42 (31)	31 (24)	37 (27)	32 (25)	34 (25)
Ложные ЭН, %	8	7	5	9	15	19	20	21	23	23	23
Ложные ЛН, %	28	20	17	19	12	8	9	11	11	12	13

Рассмотрим более подробно воспроизводимость событий ЭН и ЛН. На рис. 6 приведены графики рассчитанных, по данным COBESST (до октября 2022 года), трехмесячных средних скользящих индексов Nino3.4, Nino3 и Nino4 и результатов их моделирования с заблаговременностью в 3, 6, 9 и 11 месяцев. Для удобства описания далее будем использовать обозначения LT-3, LT-6, LT-9 и LT-11 (LT – lead time или заблаговременность). Линиями обозначены экстремумы событий по одному из индексов Nino, для которых наблюдалась наибольшая по модулю аномалия ТПО. За период 2007-2022 было отмечено всего 13 событий ЭН и ЛН (рис. 6-верхний). С использованием классификации (Yeh et al., 2009) было выделено 2 ВТ Эль-Ниньо (2009, 2015), 3 ЦТ Эль-Ниньо (2014, 2018, 2019), 2 ВТ Ла-Нинья (2017, 2021, 2022) и 5 ЦТ Ла-Нинья (2007, 2008, 2010, 2011, 2020). Тип Ла-Нинья 2022 на момент подготовки статьи еще не был известен, однако на момент подачи статьи в журнал ЛН-2022 определялся как ВТ. В этом разделе будем рассматривать события ЭН и ЛН исключительно как однолетние.

**ЦТ Ла-Нинья 2007.** Наиболее точно моделирует это событие только LT-3. LT-6 не верно определяет начало, но хорошо воспроизводит экстремальную фазу развития в сезон DJF. LT-3 и LT-6 воспроизводят это событие как ВТ тип. LT-9 и LT-11 это событие практически не воспроизводят.

**ЦТ Ла-Нинья 2008.** LT-3 хорошо воспроизводит это событие. LT-6 это ЛН воспроизводит только по индексу Nino4. LT-9 и LT-11 не воспроизводят ЛН.

**ВТ Эль-Ниньо 2009** воспроизводится по всем приведенным на рис. 6 модельным расчетам. При этом LT-3 занижает значения экстремальной фазы, а LT-6, LT-9 и LT-11 воспроизводят экстремум со смещением в сезон октябрь-ноябрь-декабрь. Также по индексу Nino3.4 начало события определяется неверно и наблюдается в сезон август-сентябрь-октябрь.



**Рисунок 6.** Трехмесячное скользящее среднее индексов Nino3.4, Nino3 и Nino4 в период 2007-2023 гг., рассчитанное по данным COBESST (до ноября 2022 года), и результат их моделирования с заблаговременностью 3, 6, 9 и 11 месяцев до февраля, мая, августа и октября 2023 года соответственно

Оранжевой и голубой линиями обозначены экстремумы событий Эль-Ниньо и Ла-Нинья

**Figure 6.** The three month moving averaged Nino3.4, Nino3 and Nino4 indices calculated by COBE SST data (until November 2022) from 2007 to 2023 and their forecasts for lead times of the 3, 6, 9 and 11 months (until February, May, August and October 2023) respectively  
*The orange and blue lines indicate the extremes of El Niño and La Niña events*

*ЦТ Ла-Нинья 2010.* LT-3 хорошо воспроизводит это событие. LT-6 воспроизводит ЛН, но начало отмечается не весной, а осенью. Максимальная фаза смещена в сезон январь-февраль-март. LT-3 и LT-6 воспроизводят это событие как ВТ тип. LT-9 воспроизводит это ЛН с задержкой на 7 месяцев, а интенсивность события ниже наблюдаемой. LT-11 в целом не воспроизводит явление. *ЦТ Ла-Нинья 2011* воспроизводится только LT-3.

*ЦТ Эль-Ниньо 2014* воспроизводится всеми модельными расчетами. При этом LT-6, LT-9 и LT-11 существенно завышают экстремум (на  $\sim 1^{\circ}\text{C}$ ).

*ВТ Эль-Ниньо 2015* хорошо воспроизводится всеми модельными расчетами. Экстремум совпадает с расчетами LT-6 и LT-9 и несколько занижен для расчета LT-3 и LT-11. После этого Эль-Ниньо наблюдалось два отрицательных экстремума ЭНЮК, первый из которых не был идентифицирован в сезон декабря-январь-февраль как ЛН. Однако, по модельным данным, он был воспроизведен LT-6, LT-9 и LT-11.

*ВТ Ла-Нинья 2017* воспроизводится всеми модельными расчетами, предложенными для анализа на рис. 6. При этом в модельном расчете с заблаговременностью 4 и 5 месяцев событие ЛН не наблюдается (рис. 5). LT-3 занижает значения этого ЛН: индексы чуть превышают порог  $0.5^{\circ}\text{C}$ .

*ЦТ Эль-Ниньо 2018* воспроизводится всеми модельными расчетами только по индексу Nino4. Условия ЭНЮК по индексам Nino3 и Nino3.4 воспроизводятся LT-3 и LT-6 как нейтральные, а LT-9 и LT-11 моделируют условия ЛН.

*ЦТ Эль-Ниньо 2019* не отмечался по индексу Nino3.4, но по методу идентификации, который был использован в этой работе с учетом индексов Nino3 и Nino 4, событие было. Так же, как и предыдущий ЭН, это событие хорошо воспроизводится по индексу Nino4 для всех рассматриваемых расчетов.

*ЦТ Ла-Нинья 2020.* Модель NNM-ENSOv1 успешно спрогнозировала месяц начала ЛН и его интенсивность в независимости от заблаговременности, однако во всех случаях тип был идентифицирован как ВТ тип.

*ВТ Ла-Нинья 2021 и Ла-Нинья 2022.* Эти два года одного двухлетнего Ла-Нинья воспроизводятся только LT-3 и как два отдельных события. Остальные рассматриваемые модельные расчеты показывают нейтральные условия ЭНЮК.

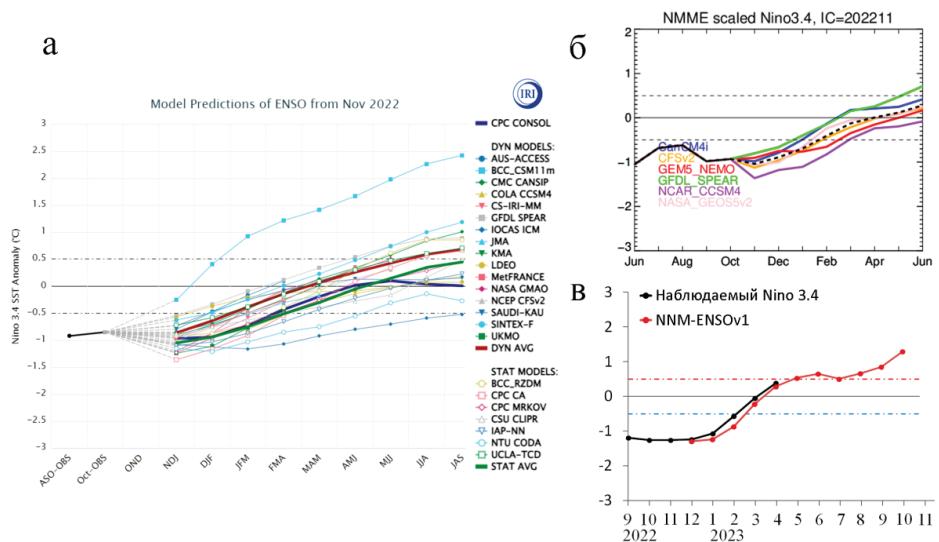
В целом можно отметить, что предложенная модель достаточно хорошо воспроизводит события ЭН. При этом прогнозы с небольшой заблаговременностью более точно определяют сроки начала, но занижают пики максимальной фазы интенсивных событий, а прогнозы с более высокой заблаговременностью менее точно определяют время начала, но более точно пики максимальной фазы интенсивных событий. Все типы ЭН определены верно. События ЛН хорошо воспроизводятся только с небольшой заблаговременностью. С заблаговременностью 11 месяцев время начала и интенсивность только для 2 событий ЛН (2017 и 2021) воспроизвелись верно.

## Эль-Ниньо 2023

На рис. 7 приведены результаты прогноза индекса Nino3.4, опубликованные во второй половине ноября. По результатам, приведенным на сайте Колумбийского университета – IRI ([iri.columbia.edu](http://iri.columbia.edu), обращение 3 декабря

2022), 18 динамических и статистических моделей указывали на нейтральную фазу ЭНЮК и 7 моделей превысили порог  $0.5^{\circ}\text{C}$ , однако в среднем модели показывают нейтральную фазу (рис. 7а). По результатам центра климатических прогнозов США – NOAA (cpc.ncep.noaa.gov, обращение 3 декабря 2022), в ноябре только 1 из 6 моделей прогнозирует начало Эль-Ниньо в 2023 году (рис 7б). Тогда предложенная модель NNM-ENSOv1 предполагала дальнейшую эволюцию ЛН до февраля 2023 г. (рис. 7в), в марте и апреле – нейтральные условия ЭНЮК, а с мая 2023 г. предположительно могло развиться Эль-Ниньо (Лубков, 2022).

На сегодня известно, что прогноз NNM-ENSOv1 подтвердился (рис. 7в). Условия ЛН сменились на нейтральные в феврале. В марте и апреле ЭНЮК находилось в нейтральной фазе. По последним данным Бюро Метеорологии Австралии (bom.gov.au, обращение 2 сентября 2023), в мае, июне, июле и августе наблюдаются условия, характерные для эволюции ЭН. На 2 сентября 2023 года Всемирная метеорологическая организация предсказывает дальнейшее развитие ЭН в 2023 с вероятностью 99-94%. Опираясь на пространственно-временную классификацию Эль-Ниньо (Лубков и др., 2017б), ЭН-2023 будет весеннего восточного типа, что соответствует ВТ по классификации (Yeh et al., 2009).



**Рисунок 7.** Результаты ноябрьского прогноза индекса Nino3.4, склоненного 3-месячным средним скользящим: а – NOAA, б – IRI, в – модель NNM-ENSOv1

**Figure 7.** Results of November 2022 forecast of Nino3.4 index, smoothed by a three-month-moving-average: a – NOAA, b – IRI, c – NNM-ENSOv1

## Заключение и дискуссия

В работе предложена новая модель прогнозирования ЭНЮК, основанная на комбинации методов МНС и МЛР. Основной особенностью модели является детальный отбор входных в модель предикторов и последующее моделирование с проверкой всевозможных комбинаций входного вектора.

Индексы Nino4 и Nino3 воспроизводятся моделью лучше, чем индекс Nino3.4, что повлияло на особенности идентификации событий ЭНЮК в этой работе, которые определялись с учетом Nino4 и Nino3. Вероятность верного определения условий, характерных для событий Эль-Ниньо, достаточно высока и незначительно меняется в пределах от 76 до 83% при изменении заблаговременности прогноза до одиннадцати месяцев. В то же время вероятность верного определения Ла-Нинья с ростом заблаговременности уменьшается от 85 до 31%.

Ложные случаи условий ЛН без учета времени продолжительности события встречаются с вероятностью 8-28% и случаи ЭН – с вероятностью 8-23%.

В целом предложенная модель достаточно хорошо воспроизводит события ЭН. В сезон декабрь-январь-февраль с заблаговременностью 11 месяцев 4 из 5 событий Эль-Ниньо с учетом их типа были определены верно. При этом модель с небольшой заблаговременностью более точно определяет сроки начала, но занижает амплитуду максимальной фазы интенсивных событий, а модель с более высокой заблаговременностью менее точно определяет время начала, но более точно – амплитуду максимальной фазы интенсивных событий. События ЛН хорошо воспроизводятся с небольшой заблаговременностью. В то же время два последних события ЛН (2017 и 2021) с заблаговременностью 11 месяцев в сезон декабрь-январь-февраль были определены верно.

При прогнозе с заблаговременностью 11 месяцев предложенная модель NNM-ENSOv1 имеет более высокое качество прогнозирования в сравнении с существующими динамическими моделями, входящими в NMME, и сопоставимые возможности с современными статистическими моделями, основанными на принципах машинного обучения. Так, для ряда индекса Nino3.4 после трехмесячного скользящего осреднения (или ONI) модель NNM-ENSOv1 за период 2007-2022 имеет коэффициент корреляции 0.64. Сравнить качество нашей модели можно по следующим оценкам: модель СНС, предложенная в (Ham et al., 2019), – 0.67 (за период 1984-2017), модель СДКП, предложенная в (Geng, Wang, 2021), – 0.60 (1994-2010), модель, основанная на графовой нейронной сети, предложенная в (Cachay et al., 2021), – 0.57 (1984-2017 с заблаговременностью 12 месяцев), модель, основанная на разложении на линейные динамические моды, предложенная в (Gavrilov et al., 2019), – ниже 0.4 (2008-2017), модели нейронных сетей гауссовой плотности и квантильной регрессии, предложенные в (Petersik, Dijkstra, 2020), – 0.40-0.45 (2002-2011 и 2012-2017).

Предложенная модель отличается низкой чувствительностью к ВПП, особенно для индекса Nino4. При этом для прогнозов с заблаговременностью до 6 месяцев модель систематически показывает более низкую способность прогнозирования в сравнении с динамическими моделями проекта NMME, что особенно выражено для индекса Nino3.4. Это может быть связано с неучtenными предикторами, имеющими доказанную физическую связь с интенсификацией экстремальных событий ЭНЮК.

В дальнейших исследованиях предполагается добавить в модель NNM-ENSOv1 в качестве предикторов индексы экваториального пассата, предложен-

ные NOAA, и теплосодержание океана 300-метрового слоя, а также уточнить области для расчета экваториальных индексов давления над Тихим океаном, что, с учетом подхода (Ham et al., 2019), вероятно, улучшит способность классифицировать события ЭНЮК и особенно ЛН. Так, область геопотенциала на поверхности 1000мб над экваториальной зоной следует поделить на западно- и восточно-тихоокеанскую. В работе (Ham et al., 2019) были получены ключевые области, которые внесли наибольший вклад в прогноз ЭНЮК с помощью модели СНС. Несмотря на то, что в нашей работе эти области также учтены частично в полях ТПО и геопотенциала на уровне 500мб, стоит обобщить их и привести к двум-трем индексам, а также учесть компоненты ветра.

В работе приведен прогноз состояния ЭНЮК в 2023 году. В ноябре 2022 года предложенная модель верно указывала на условия восточно-тихоокеанского Эль-Ниньо в 2023 году. Модель NNM-ENSOv1 прогнозировала дальнейшую эволюцию Ла-Нинья до февраля 2023 г., в марте и апреле – нейтральные условия ЭНЮК, а с мая 2023 г. предположительно могло развититься Эль-Ниньо. На тот момент только 7 из 25 динамических моделей указывали на возможное начало Эль-Ниньо-2023. В действительности, в мае, июне, июле и августе, сентябре наблюдались условия, характерные для начала и эволюции Эль-Ниньо, что подтверждает успешность прогноза NNM-ENSOv1 с заблаговременностью 11 месяцев. По последним данным Всемирной метеорологической организации, дальнейшее развитие Эль-Ниньо в 2023 предполагается с вероятностью 99-94%.

Все прогнозы модели доступны в режиме реального времени по ссылке на сайт проекта: [neuroclimate.com](http://neuroclimate.com).

*Работа выполнена в рамках государственного задания Института природно-технических систем (№ гос. регистрации 121122300072-3).*

## Список литературы

Лубков, А.С., Воскресенская, Е.Н., Марчукова, О.В. (2017а) Прогнозирование индекса Южного колебания, *Вестник Санкт-Петербургского университета. Науки о земле*, № 4(62), с. 370-388, doi: 10.21638/11701/spbu07.2017.404.

Лубков, А.С., Воскресенская, Е.Н., Марчукова, О.В. (2017б) Объективная классификация явлений Эль-Ниньо, *Использование и охрана природных ресурсов в России*, № 1(149), с. 41-44.

Лубков, А.С. (2022) Научный прогноз: Начнется ли Эль-Ниньо в 2023 году? *Системы контроля окружающей среды*, № 4 (50), с. 143-144.

Марчукова, О.В., Лубков, А.С., Воскресенская, Е.Н. (2020) Качество воспроизведения событий Эль-Ниньо и Ла-Нинья по разным массивам реконструированных данных температуры поверхности океана, *Вестник СПбГУ. Науки о земле*, № 65(1), с. 97-120, doi:10.21638/spbu07.2020.106.

Осовский, С. (2002) *Нейронные сети для обработки информации*, Москва, Финансы и статистика, 344 с.

Петросянц, М.А., Гущина Д.Ю. (2002) Об определении явлений Эль-Ниньо и Ла-Нинья, *Метеорология и гидрология*, № 8, с. 24-35.

An, S.I., Jin, F.F. (2004) Nonlinearity and asymmetry of ENSO, *J. Clim.*, vol. 17(12), pp. 2399-2412, available at: [https://doi.org/10.1175/1520-0442\(2004\)0172.0.co;2](https://doi.org/10.1175/1520-0442(2004)0172.0.co;2).

Ashok, K., Behera, S.K., Rao, S.A., Weng, H., Yamagata, T. (2007) El Niño Modoki and its possible teleconnection, *J. Geophys. Res.: Oceans*, vol. 112(C11), available at: <https://doi.org/10.1029/2006JC003798>.

Bamston, A.G., Chelliah, M., Goldenberg, S.B. (1997) Documentation of a highly ENSO-related SST region in the equatorial Pacific: Research note, *Atmosphere-ocean*, vol. 35(3), pp. 367-383, available at: <https://doi.org/10.1080/07055900.1997.9649597>.

Barnston, A.G., Livezey, R.E. (1987) Classification, seasonality and persistence of low-frequency atmospheric circulation patterns, *Mon. Wea. Rev.*, vol. 115(6), pp. 1083-1126, available at: [https://doi.org/10.1175/1520-0493\(1987\)115<1083:csapol>2.0.co;2](https://doi.org/10.1175/1520-0493(1987)115<1083:csapol>2.0.co;2).

Barnston, A.G., Tippett, M.K., L'Heureux, M.L., Li, S., DeWitt, D.G. (2012) Skill of real-time seasonal ENSO model predictions during 2002-11: Is our capability increasing? *Bull. Am. Meteorol. Soc.*, vol. 93(5), pp. 631-651, available at: <https://doi.org/10.1175/BAMS-D-11-00111.1>.

Cachay, S.R., Erickson, E., Bucker, A.F.C., Pokropek, E., Potosnak, W., Osei, S., Lütjens, B. (2020) Graph Neural Networks for Improved El Niño Forecasting, *arXiv e-prints*, arXiv-2012, available at: <https://doi.org/10.48550/arXiv.2012.01598>.

Deser, C., Alexander, M.A., Xie, S.P., Phillips, A.S. (2010) Sea surface temperature variability: Patterns and mechanisms, *Annu. Rev. Mar. Sci.*, vol. 2, pp. 115-143, available at: <https://doi.org/10.1146/annurev-marine-120408-151453>.

DiNezio, P.N., Deser, C., Karspeck, A., Yeager, S., Okumura, Y., Danabasoglu, G., Meehl, G.A. (2017) A 2 year forecast for a 60-80% chance of La Niña in 2017-2018, *Geophys. Res. Lett.*, vol. 44(22), pp. 11-624, available at: <https://doi.org/10.1002/2017GL074904>.

Enfield, D.B., Mestas-Nuñez, A.M. (1999) Multiscale variabilities in global sea surface temperatures and their relationships with tropospheric climate patterns, *J. Clim.*, vol. 12(9), pp. 2719-2733, available at: [https://doi.org/10.1175/1520-0442\(1999\)012<2719:mvigss>2.0.co;2](https://doi.org/10.1175/1520-0442(1999)012<2719:mvigss>2.0.co;2).

Fang, W., Sha, Y., Sheng, V.S. (2022) Survey on the Application of Artificial Intelligence in ENSO Forecasting, *Mathematics*, vol. 10(20), p. 3793, available at: <https://doi.org/10.3390/math10203793>.

Gavrilov, A., Seleznev, A., Mukhin, D., Loskutov, E., Feigin, A., Kurths, J. (2019) Linear dynamical modes as new variables for data-driven ENSO forecast,

---

*Clim. Dyn.*, vol. 52, pp. 2199-2216, available at: <https://doi.org/10.1007/s00382-018-4255-7>.

Geng, H., Wang, T. (2021) Spatiotemporal model based on deep learning for ENSO forecasts, *Atmosphere*, vol. 12(7), p. 810, available at: <https://doi.org/10.3390/atmos12070810>.

Ham, Y.G., Kim, J.H., Luo, J.J. (2019). Deep learning for multi-year ENSO forecasts, *Nature*, vol. 573(7775), pp. 568-572, available at: <https://doi.org/10.1038/s41586-019-1559-7>.

Haykin, S. (1998) Neural networks: a comprehensive foundation, *Prentice Hall PTR*, available at: <https://dl.acm.org/doi/abs/10.5555/521706>.

Hirahara, S., Ishii, M., Fukuda, Y. (2014) Centennial-scale sea surface temperature analysis and its uncertainty, *J. Clim.*, vol. 27(1), pp. 57-75, available at: <https://doi.org/10.1175/JCLI-D-12-00837.1>.

Hu, Z.Z., Kumar, A., Xue, Y., Jha, B. (2014) Why were some La Niñas followed by another La Niña? *Clim. Dyn.*, vol. 42, pp. 1029-1042, available at: <https://doi.org/10.1007/s00382-013-1917-3>.

Kirtman, B.P., Min, D., Infant, J.M., Kinter, J.L., Paolino, D.A., Zhang, Q. et al. (2014) The North American multimodel ensemble: phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction, *Bull. Am. Meteorol. Soc.*, vol. 95(4), pp. 585-601, available at: <https://doi.org/10.1175/bams-d-12-00050.1>.

Kistler, R., Kalnay, E., Collins, W., Saha, S., White, G., Woollen, J. et al. (2001) The NCEP–NCAR 50-year reanalysis: monthly means CD-ROM and documentation, *Bull. Am. Meteorol. Soc.*, vol. 82(2), pp. 247-268, available at: [https://doi.org/10.1175/1520-0477\(2001\)082<0247:tnnyrm>2.3.co;2](https://doi.org/10.1175/1520-0477(2001)082<0247:tnnyrm>2.3.co;2).

Knight, J.R., Folland, C.K., Scaife, A.A. (2006) Climate impacts of the Atlantic multidecadal oscillation, *Geophys. Res. Lett.*, vol. 33(17), available at: <https://doi.org/10.1029/2006GL026242>.

Kug, J.S., Jin, F.F., An, S.I. (2009) Two types of El Niño events: cold tongue El Niño and warm pool El Niño, *J. Clim.*, vol. 22(6), pp. 1499-1515, available at: <https://doi.org/10.1175/2008JCLI2624.1>.

Larkin, N.K., Harrison, D.E. (2005) Global seasonal temperature and precipitation anomalies during El Niño autumn and winter, *Geophys. Res. Lett.*, vol. 32(16), available at: <https://doi.org/10.1029/2005GL022860>.

Lin, J., Qian, T. (2019) Switch between El Nino and La Nina is caused by subsurface ocean waves likely driven by lunar tidal forcing, *Sci. Rep.*, vol. 9(1), pp. 13106, available at: <https://doi.org/10.1038/s41598-019-49678-w>.

Liu, Z., Alexander, M. (2007) Atmospheric bridge, oceanic tunnel, and global climatic teleconnections, *Rev. Geophys.*, vol. 45(2), available at: <https://doi.org/10.1029/2005RG000172>.

---

Lubkov, A.S., Voskresenskaya, E.N., Kukushkin, A.S. (2016) Method for reconstructing the monthly mean water transparencies for the northwestern part of the Black Sea as an example, *Atmos. Oceanic Opt.*, vol. 29, pp. 457-464, available at: <https://doi.org/10.1134/S1024856016050092>.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2019). Application of a neural network model to forecasting of El Niño and La Niña, *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 386(1), p. 012040, available at: <https://doi.org/10.1088/1755-1315/386/1/012040>.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2020a) Forecasting El Niño/La Niña and their types using neural networks, *Russ. Meteorol. Hydrol.*, vol. 45, pp. 806-813, available at: <https://doi.org/10.3103/S1068373920110084>.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V., Evstigneev, V.P. (2020b, November) European temperature anomalies in the cold period associated with ENSO events, *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 606(1), p. 012031, available at: <https://doi.org/10.1088/1755-1315/606/1/012031>.

Mantua, N.J., Hare, S.R., Zhang, Y., Wallace, J.M., Francis, R.C. (1997) A Pacific interdecadal climate oscillation with impacts on salmon production, *Bull. Am. Meteorol. Soc.*, vol. 78(6), pp. 1069-1080, available at: [https://doi.org/10.1175/1520-0477\(1997\)078<1069:apicow>2.0.co;2](https://doi.org/10.1175/1520-0477(1997)078<1069:apicow>2.0.co;2).

McPhaden, M.J., Zebiak, S.E., Glantz, M.H. (2006) ENSO as an integrating concept in earth science, *Science*, vol. 314(5806), pp. 1740-1745, available at: <https://doi.org/10.1126/science.1132588>.

Messié, M., Chavez, F. (2011) Global modes of sea surface temperature variability in relation to regional climate indices, *J. Clim.*, vol. 24(16), pp. 4314-4331, available at: <https://doi.org/10.1175/2011JCLI3941.1>.

Mokhov, I.I., Smirnov, D.A. (2006) Study of the mutual influence of the El Niño-Southern Oscillation processes and the North Atlantic and Arctic Oscillations, *Izv. Atmos. Oceanic Phys.*, vol. 42(5), pp. 598-614, available at: <https://doi.org/10.1134/S0001433806050069>.

Petersik, P.J., Dijkstra, H.A. (2020) Probabilistic forecasting of El Niño using neural network models, *Geophys. Res. Lett.*, vol. 47(6), p. e2019GL086423, available at: <https://doi.org/10.1029/2019GL086423>.

Philander, S.G. (1989) El Niño, La Niña, and the southern oscillation, *Int. Geophys. Ser.*, vol. 46, p. X-289, available at: <http://pascal-francis.inist.fr/vibad/index.php?action=getrecord&detail&idt=19255649>.

Polonsky, A.B., Basharin, D.V. (2017) How strong is the impact of the Indo-ocean dipole on the surface air temperature/sea level pressure anomalies in the Mediterranean region? *Global Planet. Change*, vol. 151, pp. 101-107, available at: <https://doi.org/10.1016/j.gloplacha.2016.11.007>.

Qian, C., Wu, Z., Fu, C., Wang, D. (2011) On changing El Niño: A view from time-varying annual cycle, interannual variability, and mean state, *J. Clim.*, vol. 24(24), pp. 6486-6500, available at: <https://doi.org/10.1175/jcli-d-10-05012.1>.

Rasmusson, E.M., Carpenter, T.H. (1982) Variations in tropical sea surface temperature and surface wind fields associated with the Southern Oscillation/El Niño, *Mon. Wea. Rev.*, vol. 110(5), pp. 354-384, available at: [https://doi.org/10.1175/1520-0493\(1982\)110<0354:vitsst>2.0.co;2](https://doi.org/10.1175/1520-0493(1982)110<0354:vitsst>2.0.co;2).

Ropelewski, C.F., Jones, P.D. (1987) An Extension of the Tahiti-Darwin Southern Oscillation Index, *Mon. Wea. Rev.*, vol. 115, pp. 2161-2165, available at: [https://doi.org/10.1175/1520-0493\(1987\)1152.0.co;2](https://doi.org/10.1175/1520-0493(1987)1152.0.co;2).

Saji, N.H., Goswami, B.N., Vinayachandran, P.N., Yamagata, T. (1999) A dipole mode in the tropical Indian Ocean, *Nature*, vol. 401(6751), pp. 360-363, available at: <https://doi.org/10.1038/43854>.

Schlesinger, M.E., Ramankutty, N. (1994) An oscillation in the global climate system of period 65-70 years, *Nature*, vol. 367(6465), pp. 723-726, available at: <https://doi.org/10.1038/367723a0>.

Serykh, I.V., Sonechkin, D.M. (2019) Nonchaotic and globally synchronized short-term climatic variations and their origin, *Theor. Appl. Climatol.*, vol. 137, pp. 2639-2656, available at: <https://doi.org/10.1007/s00704-018-02761-0>.

Serykh, I.V., Sonechkin, D.M. (2021) El Niño–Global Atmospheric Oscillation as the main mode of interannual climate variability, *Atmosphere*, vol. 12(11), pp. 1443, available at: <https://doi.org/10.3390/atmos12111443>.

Takahashi, K., Montecinos, A., Goubanova, K., Dewitte, B. (2011) ENSO regimes: Reinterpreting the canonical and Modoki El Niño, *Geophys. Res. Lett.*, vol. 38(10), available at: <https://doi.org/10.1029/2011GL047364>.

Tang, Y., Zhang, R.H., Liu, T., Duan, W., Yang, D., Zheng, F. et al. (2018) Progress in ENSO prediction and predictability study, *Natl. Sci. Rev.*, vol. 5(6), pp. 826-839, available at: <https://doi.org/10.1093/nsr/nwy105>.

Tippett, M.K., Barnston, A.G., Li, S. (2012) Performance of recent multimodel ENSO forecasts, *J. Appl. Meteorol. Climatol.*, vol. 51(3), pp. 637-654, available at: <https://doi.org/10.1175/JAMC-D-11-093.1>.

Trenberth, K.E., Caron, J.M. (2000) The Southern Oscillation revisited: Sea level pressures, surface temperatures, and precipitation, *J. Clim.*, vol. 13(24), pp. 4358-4365, available at: [https://doi.org/10.1175/1520-0442\(2000\)013<4358:tsorsl>2.0.co;2](https://doi.org/10.1175/1520-0442(2000)013<4358:tsorsl>2.0.co;2).

Trenberth, K.E., Stepaniak, D.P. (2001) Indices of El Niño evolution, *J. Clim.*, vol. 14(8), pp. 1697-1701, available at: [https://doi.org/10.1175/1520-0442\(2001\)014<1697:lioeno>2.0.co;2](https://doi.org/10.1175/1520-0442(2001)014<1697:lioeno>2.0.co;2).

Torrence, C., Compo, G.P. (1998) A Practical Guide to Wavelet Analysis, *Bull. Amer. Meteor. Soc.*, vol. 79, pp. 61-78, available at: [https://doi.org/10.1175/1520-0477\(1998\)079<0061:APGTWA>2.0.CO;2](https://doi.org/10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2).

Vallès-Casanova, I., Lee, S.K., Foltz, G.R., Pelegrí, J.L. (2020) On the spatiotemporal diversity of Atlantic Niño and associated rainfall variability over West Africa and South America, *Geophys. Res. Lett.*, vol. 47(8), p. e2020GL087108, available at: <https://doi.org/10.1029/2020GL087108>.

Venables, W.N., Ripley, B.D. (2002) *Modern Applied Statistics with S. Statistics and Computing*, doi:10.1007/978-0-387-21706-2.

Voskresenskaya, E.N., Marchukova, O.V. (2017) Spatial classification of La Niña events, *Izv. Atmos. Oceanic Phys.*, vol. 53(1), pp. 111-119, available at: <https://doi.org/10.1134/S001433817010133>.

Voskresenskaya, E.N., Marchukova, O.V., Maslova, V.N., Lubkov, A.S. (2018) Interannual climate anomalies in the Atlantic-European region associated with La-Nina types, *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 107(1), p. 012043, available at: <https://doi.org/10.1088/1755-1315/107/1/012043>.

Voskresenskaya, E.N., Polonsky, A.B. (1993) Air pressure fluctuations in the North Atlantic and their relationship with El Niño-southern oscillations, *Phys. Oceanogr.*, vol. 4, pp. 275-282, available at: <https://doi.org/10.1007/BF02197626>.

Wallace, J.M., Gutzler, D.S. (1981) Teleconnections in the geopotential height field during the Northern Hemisphere winter, *Mon. Wea. Rev.*, vol. 109(4), pp. 784-812, available at: [https://doi.org/10.1175/1520-0493\(1981\)109<0784:titghf>2.0.co;2](https://doi.org/10.1175/1520-0493(1981)109<0784:titghf>2.0.co;2).

Wallace, J.M., Rasmusson, E.M., Mitchell, T.P., Kousky, V.E., Sarachik, E.S., Von Storch, H. (1998) On the structure and evolution of ENSO-related climate variability in the tropical Pacific: Lessons from TOGA, *J. Geophys. Res.: Oceans*, vol. 103(C7), pp. 14241-14259, available at: <https://doi.org/10.1029/97JC02905>.

Wang, Y., Jiang, J., Zhang, H., Dong, X., Wang, L., Ranjan, R., Zomaya, A.Y. (2017) A scalable parallel algorithm for atmospheric general circulation models on a multi-core cluster, *Future Gener. Comput. Syst.*, vol. 72, pp. 1-10, available at: <https://doi.org/10.1016/j.future.2017.02.008>.

Webb, E.J., Magi, B.I. (2022) The Ensemble Oceanic Niño Index International, *J. Climatol.*, vol. 42(10), pp. 5321-5341, available at: <https://doi.org/10.1002/joc.7535>.

Webster, P.J., Yang, S. (1992) Monsoon and ENSO: Selectively interactive systems, *Q. J. R. Meteorolog. Soc.*, vol. 118(507), pp. 877-926, available at: <https://doi.org/10.1002/qj.49711850705>.

Wu, X., Okumura, Y.M., Deser, C., DiNezio, P.N. (2021) Two-year dynamical predictions of ENSO event duration during 1954-2015, *J. Clim.*, vol. 34(10), pp. 4069-4087, available at: <https://doi.org/10.1175/JCLI-D-20-0619.1>.

Ye, M., Nie, J., Liu, A., Wang, Z., Huang, L., Tian, H. et al. (2021). Multi-year ENSO forecasts using parallel convolutional neural networks with heterogeneous architecture, *Front. Mar. Sci.*, vol. 8, p. 717184, available at: <https://doi.org/10.3389/fmars.2021.717184>.

Yeh, S.W., Kug, J.S., Dewitte, B., Kwon, M.H., Kirtman, B.P., Jin, F.F. (2009) El Niño in a changing climate, *Nature*, vol. 461(7263), pp. 511-514, available at: <https://doi.org/10.1038/nature08316>.

Yuan, Y., Yan, H. (2013) Different types of La Niña events and different responses of the tropical atmosphere, *Chin. Sci. Bull.*, vol. 58, pp. 406-415, available at: <https://doi.org/10.1007/s11434-012-5423-5>.

Zhang, W., Wang, L., Xiang, B., Qi, L., He, J. (2015) Impacts of two types of La Niña on the NAO during boreal winter, *Clim. Dyn.*, vol. 44, pp. 1351-1366, available at: <https://doi.org/10.1007/s00382-014-2155-z>.

Zhang, Y., Wallace, J.M., Battisti, D.S. (1997) ENSO-like interdecadal variability: 1900-93, *J. Clim.*, vol. 10(5), pp. 1004-1020, available at: [https://doi.org/10.1175/1520-0442\(1997\)010<1004:eliv>2.0.co;2](https://doi.org/10.1175/1520-0442(1997)010<1004:eliv>2.0.co;2).

Zheleznova, I.V., Gushchina, D.Y. (2016) Circulation anomalies in the atmospheric centers of action during the Eastern Pacific and Central Pacific El Niño, *Russ. Meteorol. Hydrol.*, vol. 41, pp. 760-769, available at: <https://doi.org/10.3103/S1068373916110030>.

## References

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2017a) Prognozirovaniye indeksa Yuzhnogo kolebaniya [Forecasting the Southern Oscillation Index], *Vestnik Sankt-Peterburgskogo universiteta. Nauki o zemle*, no. 4(62), pp. 370-388, doi: 10.21638/11701/spbu07.2017.404.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2017b) Ob"yektivnaya klassifikatsiya yavleniy El'-Nin'o [Objective classification of El Niño phenomena], *Ispol'zovaniye i okhrana prirodnykh resursov v Rossii*, no. 1(149), pp. 41-44.

Lubkov, A.S. (2022) Nauchnyy prognoz: Nachnetsya li El'-Nin'o v 2023 godu? [Scientific forecast: Will El Niño start in 2023?], *Sistemy kontrolya okruzhayushchey sredy*, no. 4 (50), pp. 143-144.

Marchukova, O.V., Lubkov, A.S., Voskresenskaya, E.N. (2020) Kachestvo vosproizvedeniya sobystiy El'-Nin'o i La-Nin'ya po raznym massivam rekonstruirovannykh dannykh temperatury poverkhnosti okeana [Quality of reproduction of El Niño and La Niña events using different arrays of reconstructed ocean surface temperature data], *Vestnik Sankt-Peterburgskogo universiteta. Nauki o zemle*, no. 65(1), pp. 97-120, doi:10.21638/spbu07.2020.106.

Osovsky, S. (2002) *Neyronnyye seti dlya obrabotki informatsii* [Neural networks for information processing], Finance and Statistics, Moscow, Russia, 344 p.

Petrosyants, M.A., Gushchina D.Yu. (2002) Ob opredelenii yavleniy El'-Nin'o i La-Nin'ya [On the definition of El Niño and La Niña phenomena], *Meteorologiya i gidrologiya*, no. 8, pp. 24-35.

An, S.I., Jin, F.F. (2004) Nonlinearity and asymmetry of ENSO, *J. Clim.*, vol. 17(12), pp. 2399-2412, available at: [https://doi.org/10.1175/1520-0442\(2004\)0172.0.co;2](https://doi.org/10.1175/1520-0442(2004)0172.0.co;2).

Ashok, K., Behera, S.K., Rao, S.A., Weng, H., Yamagata, T. (2007) El Niño Modoki and its possible teleconnection, *J. Geophys. Res.: Oceans*, vol. 112(C11), available at: <https://doi.org/10.1029/2006JC003798>.

Bamston, A.G., Chelliah, M., Goldenberg, S.B. (1997) Documentation of a highly ENSO-related SST region in the equatorial Pacific: Research note, *Atmosphere-ocean*, vol. 35(3), pp. 367-383, available at: <https://doi.org/10.1080/07055900.1997.9649597>.

Barnston, A.G., Livezey, R.E. (1987) Classification, seasonality and persistence of low-frequency atmospheric circulation patterns, *Mon. Wea. Rev.*, vol. 115(6), pp. 1083-1126, available at: [https://doi.org/10.1175/1520-0493\(1987\)115<1083:csapol>2.0.co;2](https://doi.org/10.1175/1520-0493(1987)115<1083:csapol>2.0.co;2).

Barnston, A.G., Tippett, M.K., L'Heureux, M.L., Li, S., DeWitt, D.G. (2012) Skill of real-time seasonal ENSO model predictions during 2002-11: Is our capability increasing? *Bull. Am. Meteorol. Soc.*, vol. 93(5), pp. 631-651, available at: <https://doi.org/10.1175/BAMS-D-11-00111.1>.

Cachay, S.R., Erickson, E., Bucker, A.F.C., Pokropek, E., Potosnak, W., Osei, S., Lütjens, B. (2020) Graph Neural Networks for Improved El Niño Forecasting, *arXiv e-prints*, *arXiv-2012*, available at: <https://doi.org/10.48550/arXiv.2012.01598>.

Deser, C., Alexander, M.A., Xie, S.P., Phillips, A.S. (2010) Sea surface temperature variability: Patterns and mechanisms, *Annu. Rev. Mar. Sci.*, vol. 2, pp. 115-143, available at: <https://doi.org/10.1146/annurev-marine-120408-151453>.

DiNezio, P.N., Deser, C., Karspeck, A., Yeager, S., Okumura, Y., Danabasoglu, G., Meehl, G.A. (2017) A 2 year forecast for a 60-80% chance of La Niña in 2017-2018, *Geophys. Res. Lett.*, vol. 44(22), pp. 11-624, available at: <https://doi.org/10.1002/2017GL074904>.

Enfield, D.B., Mestas-Nuñez, A.M. (1999) Multiscale variabilities in global sea surface temperatures and their relationships with tropospheric climate patterns, *J. Clim.*, vol. 12(9), pp. 2719-2733, available at: [https://doi.org/10.1175/1520-0442\(1999\)012<2719:mvigss>2.0.co;2](https://doi.org/10.1175/1520-0442(1999)012<2719:mvigss>2.0.co;2).

Fang, W., Sha, Y., Sheng, V.S. (2022) Survey on the Application of Artificial Intelligence in ENSO Forecasting, *Mathematics*, vol. 10(20), p. 3793, available at: <https://doi.org/10.3390/math10203793>.

Gavrilov, A., Seleznev, A., Mukhin, D., Loskutov, E., Feigin, A., Kurths, J. (2019) Linear dynamical modes as new variables for data-driven ENSO forecast, *Clim. Dyn.*, vol. 52, pp. 2199-2216, available at: <https://doi.org/10.1007/s00382-018-4255-7>.

Geng, H., Wang, T. (2021) Spatiotemporal model based on deep learning for ENSO forecasts, *Atmosphere*, vol. 12(7), p. 810, available at: <https://doi.org/10.3390/>

Ham, Y.G., Kim, J.H., Luo, J.J. (2019). Deep learning for multi-year ENSO forecasts, *Nature*, vol. 573(7775), pp. 568-572, available at: <https://doi.org/10.1038/s41586-019-1559-7>.

Haykin, S. (1998) Neural networks: a comprehensive foundation, *Prentice Hall PTR*, available at: <https://dl.acm.org/doi/abs/10.5555/521706>.

Hirahara, S., Ishii, M., Fukuda, Y. (2014) Centennial-scale sea surface temperature analysis and its uncertainty, *J. Clim.*, vol. 27(1), pp. 57-75, available at: <https://doi.org/10.1175/JCLI-D-12-00837.1>.

Hu, Z.Z., Kumar, A., Xue, Y., Jha, B. (2014) Why were some La Niñas followed by another La Niña? *Clim. Dyn.*, vol. 42, pp. 1029-1042, available at: <https://doi.org/10.1007/s00382-013-1917-3>.

Kirtman, B.P., Min, D., Infant, J.M., Kinter, J.L., Paolino, D.A., Zhang, Q. et al. (2014) The North American multimodel ensemble: phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction, *Bull. Am. Meteorol. Soc.*, vol. 95(4), pp. 585-601, available at: <https://doi.org/10.1175/bams-d-12-00050.1>.

Kistler, R., Kalnay, E., Collins, W., Saha, S., White, G., Woollen, J. et al. (2001) The NCEP–NCAR 50-year reanalysis: monthly means CD-ROM and documentation, *Bull. Am. Meteorol. Soc.*, vol. 82(2), pp. 247-268, available at: [https://doi.org/10.1175/1520-0477\(2001\)082<0247:tnnyrm>2.3.co;2](https://doi.org/10.1175/1520-0477(2001)082<0247:tnnyrm>2.3.co;2).

Knight, J.R., Folland, C.K., Scaife, A.A. (2006) Climate impacts of the Atlantic multidecadal oscillation, *Geophys. Res. Lett.*, vol. 33(17), available at: <https://doi.org/10.1029/2006GL026242>.

Kug, J.S., Jin, F.F., An, S.I. (2009) Two types of El Niño events: cold tongue El Niño and warm pool El Niño, *J. Clim.*, vol. 22(6), pp. 1499-1515, available at: <https://doi.org/10.1175/2008JCLI2624.1>.

Larkin, N.K., Harrison, D.E. (2005) Global seasonal temperature and precipitation anomalies during El Niño autumn and winter, *Geophys. Res. Lett.*, vol. 32(16), available at: <https://doi.org/10.1029/2005GL022860>.

Lin, J., Qian, T. (2019) Switch between El Nino and La Nina is caused by subsurface ocean waves likely driven by lunar tidal forcing, *Sci. Rep.*, vol. 9(1), pp. 13106, available at: <https://doi.org/10.1038/s41598-019-49678-w>.

Liu, Z., Alexander, M. (2007) Atmospheric bridge, oceanic tunnel, and global climatic teleconnections, *Rev. Geophys.*, vol. 45(2), available at: <https://doi.org/10.1029/2005RG000172>.

Lubkov, A.S., Voskresenskaya, E.N., Kukushkin, A.S. (2016) Method for reconstructing the monthly mean water transparencies for the northwestern part of the Black Sea as an example, *Atmos. Oceanic Opt.*, vol. 29, pp. 457-464, available at: <https://doi.org/10.1134/S1024856016050092>.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2019). Application of a neural network model to forecasting of El Niño and La Niña, *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 386(1), p. 012040, available at: <https://doi.org/10.1088/1755-1315/386/1/012040>.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2020a) Forecasting El Niño/La Niña and their types using neural networks, *Russ. Meteorol. Hydrol.*, vol. 45, pp. 806-813, available at: <https://doi.org/10.3103/S1068373920110084>.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V., Evstigneev, V.P. (2020b, November) European temperature anomalies in the cold period associated with ENSO events, *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 606(1), p. 012031, available at: <https://doi.org/10.1088/1755-1315/606/1/012031>.

Mantua, N.J., Hare, S.R., Zhang, Y., Wallace, J.M., Francis, R.C. (1997) A Pacific interdecadal climate oscillation with impacts on salmon production, *Bull. Am. Meteorol. Soc.*, vol. 78(6), pp. 1069-1080, available at: [https://doi.org/10.1175/1520-0477\(1997\)078<1069:apicow>2.0.co;2](https://doi.org/10.1175/1520-0477(1997)078<1069:apicow>2.0.co;2).

McPhaden, M.J., Zebiak, S.E., Glantz, M.H. (2006) ENSO as an integrating concept in earth science, *Science*, vol. 314(5806), pp. 1740-1745, available at: <https://doi.org/10.1126/science.1132588>.

Messié, M., Chavez, F. (2011) Global modes of sea surface temperature variability in relation to regional climate indices, *J. Clim.*, vol. 24(16), pp. 4314-4331, available at: <https://doi.org/10.1175/2011JCLI3941.1>.

Mokhov, I.I., Smirnov, D.A. (2006) Study of the mutual influence of the El Niño-Southern Oscillation processes and the North Atlantic and Arctic Oscillations, *Izv. Atmos. Oceanic Phys.*, vol. 42(5), pp. 598-614, available at: <https://doi.org/10.1134/S0001433806050069>.

Petersik, P.J., Dijkstra, H.A. (2020) Probabilistic forecasting of El Niño using neural network models, *Geophys. Res. Lett.*, vol. 47(6), p. e2019GL086423, available at: <https://doi.org/10.1029/2019GL086423>.

Philander, S.G. (1989) El Niño, La Niña, and the southern oscillation, *Int. Geophys. Ser.*, vol. 46, p. X-289, available at: <http://pascal-francis.inist.fr/vibad/index.php?action=getrecord&detail&idt=19255649>.

Polonsky, A.B., Basharin, D.V. (2017) How strong is the impact of the Indo-ocean dipole on the surface air temperature/sea level pressure anomalies in the Mediterranean region? *Global Planet. Change*, vol. 151, pp. 101-107, available at: <https://doi.org/10.1016/j.gloplacha.2016.11.007>.

Qian, C., Wu, Z., Fu, C., Wang, D. (2011) On changing El Niño: A view from time-varying annual cycle, interannual variability, and mean state, *J. Clim.*, vol. 24(24), pp. 6486-6500, available at: <https://doi.org/10.1175/jcli-d-10-05012.1>.

Rasmusson, E.M., Carpenter, T.H. (1982) Variations in tropical sea surface temperature and surface wind fields associated with the Southern Oscillation/El

---

Niño, *Mon. Wea. Rev.*, vol. 110(5), pp. 354-384, available at: [https://doi.org/10.1175/1520-0493\(1982\)110<0354:vitsst>2.0.co;2](https://doi.org/10.1175/1520-0493(1982)110<0354:vitsst>2.0.co;2).

Ropelewski, C.F., Jones, P.D. (1987) An Extension of the Tahiti-Darwin Southern Oscillation Index, *Mon. Wea. Rev.*, vol. 115, pp. 2161-2165, available at: [https://doi.org/10.1175/1520-0493\(1987\)1152.0.co;2](https://doi.org/10.1175/1520-0493(1987)1152.0.co;2).

Saji, N.H., Goswami, B.N., Vinayachandran, P.N., Yamagata, T. (1999) A dipole mode in the tropical Indian Ocean, *Nature*, vol. 401(6751), pp. 360-363, available at: <https://doi.org/10.1038/43854>.

Schlesinger, M.E., Ramankutty, N. (1994) An oscillation in the global climate system of period 65-70 years, *Nature*, vol. 367(6465), pp. 723-726, available at: <https://doi.org/10.1038/367723a0>.

Serykh, I.V., Sonechkin, D.M. (2019) Nonchaotic and globally synchronized short-term climatic variations and their origin, *Theor. Appl. Climatol.*, vol. 137, pp. 2639-2656, available at: <https://doi.org/10.1007/s00704-018-02761-0>.

Serykh, I.V., Sonechkin, D.M. (2021) El Niño–Global Atmospheric Oscillation as the main mode of interannual climate variability, *Atmosphere*, vol. 12(11), pp. 1443, available at: <https://doi.org/10.3390/atmos12111443>.

Takahashi, K., Montecinos, A., Goubanova, K., Dewitte, B. (2011) ENSO regimes: Reinterpreting the canonical and Modoki El Niño, *Geophys. Res. Lett.*, vol. 38(10), available at: <https://doi.org/10.1029/2011GL047364>.

Tang, Y., Zhang, R.H., Liu, T., Duan, W., Yang, D., Zheng, F. et al. (2018) Progress in ENSO prediction and predictability study, *Natl. Sci. Rev.*, vol. 5(6), pp. 826-839, available at: <https://doi.org/10.1093/nsr/nwy105>.

Tippett, M.K., Barnston, A.G., Li, S. (2012) Performance of recent multimodel ENSO forecasts, *J. Appl. Meteorol. Climatol.*, vol. 51(3), pp. 637-654, available at: <https://doi.org/10.1175/JAMC-D-11-093.1>.

Trenberth, K.E., Caron, J.M. (2000) The Southern Oscillation revisited: Sea level pressures, surface temperatures, and precipitation, *J. Clim.*, vol. 13(24), pp. 4358-4365, available at: [https://doi.org/10.1175/1520-0442\(2000\)013<4358:tsorsl>2.0.co;2](https://doi.org/10.1175/1520-0442(2000)013<4358:tsorsl>2.0.co;2).

Trenberth, K.E., Stepaniak, D.P. (2001) Indices of El Niño evolution, *J. Clim.*, vol. 14(8), pp. 1697-1701, available at: [https://doi.org/10.1175/1520-0442\(2001\)014<1697:lioeno>2.0.co;2](https://doi.org/10.1175/1520-0442(2001)014<1697:lioeno>2.0.co;2).

Torrence, C., Compo, G.P. (1998) A Practical Guide to Wavelet Analysis, *Bull. Amer. Meteor. Soc.*, vol. 79, pp. 61-78, available at: [https://doi.org/10.1175/1520-0477\(1998\)079<0061:APGTWA>2.0.CO;2](https://doi.org/10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2).

Vallès-Casanova, I., Lee, S.K., Foltz, G.R., Pelegrí, J.L. (2020) On the spatiotemporal diversity of Atlantic Niño and associated rainfall variability over West Africa and South America, *Geophys. Res. Lett.*, vol. 47(8), p. e2020GL087108, available at: <https://doi.org/10.1029/2020GL087108>.

---

Venables, W.N., Ripley, B.D. (2002) *Modern Applied Statistics with S. Statistics and Computing*, doi:10.1007/978-0-387-21706-2.

Voskresenskaya, E.N., Marchukova, O.V. (2017) Spatial classification of La Niña events, *Izv. Atmos. Oceanic Phys.*, vol. 53(1), pp. 111-119, available at: <https://doi.org/10.1134/S0001433817010133>.

Voskresenskaya, E.N., Marchukova, O.V., Maslova, V.N., Lubkov, A.S. (2018) Interannual climate anomalies in the Atlantic-European region associated with La-Niña types, *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 107(1), p. 012043, available at: <https://doi.org/10.1088/1755-1315/107/1/012043>.

Voskresenskaya, E.N., Polonsky, A.B. (1993) Air pressure fluctuations in the North Atlantic and their relationship with El Niño-southern oscillations, *Phys. Oceanogr.*, vol. 4, pp. 275-282, available at: <https://doi.org/10.1007/BF02197626>.

Wallace, J.M., Gutzler, D.S. (1981) Teleconnections in the geopotential height field during the Northern Hemisphere winter, *Mon. Wea. Rev.*, vol. 109(4), pp. 784-812, available at: [https://doi.org/10.1175/1520-0493\(1981\)109<0784:titghf>2.0.co;2](https://doi.org/10.1175/1520-0493(1981)109<0784:titghf>2.0.co;2).

Wallace, J.M., Rasmusson, E.M., Mitchell, T.P., Kousky, V.E., Sarachik, E.S., Von Storch, H. (1998) On the structure and evolution of ENSO-related climate variability in the tropical Pacific: Lessons from TOGA, *J. Geophys. Res.: Oceans*, vol. 103(C7), pp. 14241-14259, available at: <https://doi.org/10.1029/97JC02905>.

Wang, Y., Jiang, J., Zhang, H., Dong, X., Wang, L., Ranjan, R., Zomaya, A.Y. (2017) A scalable parallel algorithm for atmospheric general circulation models on a multi-core cluster, *Future Gener. Comput. Syst.*, vol. 72, pp. 1-10, available at: <https://doi.org/10.1016/j.future.2017.02.008>.

Webb, E.J., Magi, B.I. (2022) The Ensemble Oceanic Niño Index International, *J. Climatol.*, vol. 42(10), pp. 5321-5341, available at: <https://doi.org/10.1002/joc.7535>.

Webster, P.J., Yang, S. (1992) Monsoon and ENSO: Selectively interactive systems, *Q. J. R. Meteorolog. Soc.*, vol. 118(507), pp. 877-926, available at: <https://doi.org/10.1002/qj.49711850705>.

Wu, X., Okumura, Y.M., Deser, C., DiNezio, P.N. (2021) Two-year dynamical predictions of ENSO event duration during 1954-2015, *J. Clim.*, vol. 34(10), pp. 4069-4087, available at: <https://doi.org/10.1175/JCLI-D-20-0619.1>.

Ye, M., Nie, J., Liu, A., Wang, Z., Huang, L., Tian, H. et al. (2021). Multi-year ENSO forecasts using parallel convolutional neural networks with heterogeneous architecture, *Front. Mar. Sci.*, vol. 8, p. 717184, available at: <https://doi.org/10.3389/fmars.2021.717184>.

Yeh, S.W., Kug, J.S., Dewitte, B., Kwon, M.H., Kirtman, B.P., Jin, F.F. (2009) El Niño in a changing climate, *Nature*, vol. 461(7263), pp. 511-514, available at: <https://doi.org/10.1038/nature08316>.

---

Yuan, Y., Yan, H. (2013) Different types of La Niña events and different responses of the tropical atmosphere, *Chin. Sci. Bull.*, vol. 58, pp. 406-415, available at: <https://doi.org/10.1007/s11434-012-5423-5>.

Zhang, W., Wang, L., Xiang, B., Qi, L., He, J. (2015) Impacts of two types of La Niña on the NAO during boreal winter, *Clim. Dyn.*, vol. 44, pp. 1351-1366, available at: <https://doi.org/10.1007/s00382-014-2155-z>.

Zhang, Y., Wallace, J.M., Battisti, D.S. (1997) ENSO-like interdecadal variability: 1900-93, *J. Clim.*, vol. 10(5), pp. 1004-1020, available at: [https://doi.org/10.1175/1520-0442\(1997\)010<1004:eliv>2.0.co;2](https://doi.org/10.1175/1520-0442(1997)010<1004:eliv>2.0.co;2).

Zheleznova, I.V., Gushchina, D.Y. (2016) Circulation anomalies in the atmospheric centers of action during the Eastern Pacific and Central Pacific El Niño, *Russ. Meteorol. Hydrol.*, vol. 41, pp. 760-769, available at: <https://doi.org/10.3103/S1068373916110030>.

Поступила в редакцию: 28.09.2023 г.

Доработана после рецензирования: 13.10.2023 г.

Принята к публикации: 06.11.2023 г.

#### **Для цитирования / For citation:**

Лубков, А.С., Воскресенская, Е.Н., Марчукова, О.В. (2023) Новый подход к использованию нейронных сетей для долгосрочного прогноза Эль-Ниньо и Ла-Нинья, *Фундаментальная и прикладная климатология*, т. 9, № 4, с. 432-466, doi:10.21513/2410-8758-2023-4-432-466.

Lubkov, A.S., Voskresenskaya, E.N., Marchukova, O.V. (2023) An innovative approach to long-term prediction of El Niño and La Niña using neural networks, *Fundamental and Applied Climatology*, vol. 9, no. 4, pp. 432-466, doi:10.21513/2410-8758-2023-4-432-466.