

Проблемы прогнозирования океанографических рядов на примере температуры поверхности Чёрного моря и экмановского индекса для южной части Канарского апвеллинга

А. Н. Серебренников

*Институт природно-технических систем, Севастополь, 299011, Россия
E-mail: swsilv@gmail.com*

Приводится опыт прогнозирования океанических явлений с помощью рекуррентных нейронных сетей и структур долговременной – кратковременной памяти. В частности, проанализированы проблемы, возникающие при прогнозировании температуры поверхности Чёрного моря и экмановского индекса южной части Канарского апвеллинга (13–21° с.ш.) на примере использования одномерной модели для прогноза на 60-месячный период. Показано, что одной из основных проблем прогнозирования океанографических рядов, таких как скорость и направление ветра, температура поверхности моря и т.д., является непредсказуемость вариаций этих параметров на небольших временных масштабах (до года). Эти вариации естественного происхождения не позволяют модели использовать опыт обучения для достоверного прогнозирования. Улучшение качества модели (усложнение) на этапе обучения приводит к переобучению, что отражается при тестировании модели; упрощение модели приводит к сглаживанию прогноза. Кроме этого подтверждается, что точность прогнозирования океанографических параметров в значительной степени зависит от качества и длины исходных данных. Благодаря развитию спутниковых технологий обеспечивается доступ к обширному архиву данных дистанционного зондирования. Однако некоторые данные, как показано в статье, относящиеся, например, к параметрам прибрежных апвеллингов, оказываются всё ещё достаточно зашумлёнными.

Ключевые слова: модель LSTM, рекуррентная модель, градиентный спуск, экмановский индекс апвеллинга, прибрежный апвеллинг, температура поверхности океана

Одобрена к печати: 23.06.2025
DOI: 10.21046/2070-7401-2025-22-4-76-86

Введение

Прибрежные апвеллинги, и в первую очередь система восточных пограничных апвеллингов (*англ.* Eastern Boundary Upwelling System — EBUS), играют важную роль в поддержании продуктивности морских экосистем и влияют на погодные и климатические условия не только в прибрежных районах, но и на климат Земли в целом. Выходящие на поверхность подповерхностные и промежуточные воды несут в себе биологически активные вещества, влияющие на развитие фитопланктона и, как следствие, на жизнедеятельность промысловых рыб. Чёрное море, как региональный морской бассейн, аккумулируя тепло летом и выделяя его в атмосферу зимой, сглаживает температурный контраст между морем и прилегающими районами суши. Поэтому долгосрочный прогноз состояния океанических апвеллингов и региональных морских бассейнов крайне важен для понимания перспектив изменений океанологических процессов и регионального климата (IPCC..., 2021).

Благодаря глобальному охвату спутниковое дистанционное зондирование представляется эффективной технологией для изучения процессов в океане. Объединение методологии машинного обучения (*англ.* machine learning) с преимуществами спутниковых наблюдений открывает новые возможности для долгосрочного прогнозирования состояния морской среды. За последнее десятилетие для построения прогностических моделей стали чаще привлекать методы машинного обучения (Jebri et al., 2022).

Прогнозирование временных рядов может быть реализовано с помощью рекуррентных нейронных сетей и структур долговременной – кратковременной памяти LSTM (*англ.* Long-

Short-Term Memory, долгая краткосрочная память). Одна из идей, сделавшая рекуррентные нейронные сети эффективными, — авторегрессия: созданная переменная добавляется в последовательность в качестве входных данных. Хотя рекуррентная сеть и должна работать со всей последовательностью, к сожалению, присутствует проблема «затухающего градиента» (*англ.* vanishing gradient problem) (<https://habr.com/ru/articles/693562>). Это значит, что вычисленные ранее переменные перестают влиять на текущий прогноз. Для решения этой проблемы была предложена модель LSTM. Алгоритм LSTM, составляющий основу глубокого обучения для прогнозирования временных рядов, был предложен в 1997 г. и с тех пор почти не изменился. Архитектура LSTM при обучении способна схватывать существенные детали прошлого контекста и сохранять их, пока они актуальны.

Для прогнозирования какого-либо параметра, например температуры поверхности моря (ТПМ), можно создать модель на основе одномерных или многомерных временных рядов. Также модель можно настроить на прогнозирование одного значения в будущем или нескольких значений (интервальное прогнозирование). Целевой вектор или прогнозируемые данные для работы как с одномерным, так и многомерным временным рядом будет в данном случае — ТПМ. Целевой вектор прогнозируется на основе одного признака (собственно ТПМ) в случае модели с одномерным временным рядом или нескольких признаков (например, скорость ветра, температура воздуха, поток излучения, ТПМ и др.) для модели с многомерным рядом. Очевидно, что для прогнозирования ТПМ в случае применения многомерной модели, ТПМ будет наиболее релевантным признаком, по которому фактически и будет построен прогноз. Однако для получения более качественного прогноза ТПМ нужно учитывать все доступные релевантные признаки, если их удастся обнаружить.

В настоящей статье показана реализация долгосрочного прогноза, сделанного на основе одномерной модели на 60 месяцев с последующим усреднением. Надо отметить, что все разработанные модели стохастические и при каждом прогоне дают разный результат. Средние значения рассчитывались по 10 прогонам. Прогнозы строились на основе имеющихся исторических данных по принципу продолжения ряда с учётом закономерностей в исторических данных. Для решения этой задачи была выбрана специальная нейронная рекуррентная сеть с двумя слоями LSTM.

Материалы и методика их обработки

Использовались данные о температуре поверхности Чёрного моря с пространственным разрешением $0,05 \times 0,05^\circ$ за 43-летний период (с 1982 по 2024 г.). Набор данных SST_BS_SST_L4_REP_OBSERVATIONS_010_022 был заимствован с сайта открытого доступа CMEMS (*англ.* Copernicus Marine Environment Monitoring Service) (<https://marine.copernicus.eu>).

Для южной части Канарского апвеллинга ($13\text{--}21^\circ$ с.ш.) был рассчитан экмановский индекс апвеллинга EUI (*англ.* Ekman upwelling index), характеризующий интенсивность сгона воды приповерхностным ветром. Индекс EUI рассчитывался по спутниковым данным о приповерхностном ветре CCMP OCW (*англ.* Cross-Calibrated Multi-Platform Ocean Surface Wind) за период с 1993 по 2024 г. версии 3.1. Данные получены из архива PO.DAAC (*англ.* Physical Oceanography Distributed Active Archive Center) NASA (*англ.* National Aeronautics and Space Administration) (<https://www.remss.com>). Пространственное разрешение этих данных составляет $0,25 \times 0,25^\circ$. Апвеллинговая зона была выбрана шириной $1,0^\circ$, примыкающей вплотную к берегу. Методика расчёта EUI — общеизвестная и приводится во многих статьях, например, в работе (Polonsky, Serebrennikov, 2022).

Для разных типов моделей искусственного интеллекта исходные данные должны пройти соответствующую предварительную обработку (Chollet, 2017; Chollet, Watson, 2025; <https://habr.com/ru/articles/800973/>). Исходные массивы данных были разделены на обучающие и проверочные. Обучающий набор использовался для оптимизации модели с помощью обратного распространения ошибки и градиентного спуска с целью минимизации разницы между прогнозируемыми и наблюдаемыми значениями параметров. Проверочный набор применялся для оценки достоверности прогноза модели и предотвращения переобучения.

Весь набор данных (среднемесячные данные с 1982 по 2024 г. для ТПМ и с 1993 по 2024 г. для ЕУИ) был разделён на данные для обучения модели и данные для её проверки в отношении 3:1. Модели глубокого обучения не обрабатывают весь набор данных целиком; они разбивают его на небольшие пакеты, которые часто называют мини-пакетами (*англ.* mini-batch). На каждом шаге, вместо вычисления градиентов на полном обучающем наборе, градиенты рассчитываются на случайно выбранных мини-пакетах. Главное преимущество мини-пакетного градиентного спуска в том, что можно поднять производительность за счёт аппаратной оптимизации матричных операций, особенно при использовании графических процессоров (Géron, 2019). В используемой модели операции над данными выполнялись встроенными методами shuffle и batch из библиотеки TensorFlow (<https://en.wikipedia.org/wiki/TensorFlow>). Метод shuffle перемешивает элементы набора данных в случайном порядке. Это помогает избежать переобучения модели, так как порядок данных не влияет на процесс обучения. Метод batch группирует элементы набора данных в мини-пакеты указанного размера. Это позволяет модели обрабатывать несколько участков временного ряда (примеров) одновременно, что более эффективно, чем обрабатывать один пример за раз. Метод работает с данными в хронологическом порядке, что важно для работы с временными рядами. Рассматриваемая модель стохастическая, так как пакеты выбираются случайным образом.

Для средней кривой прогноза рассчитаны доверительные интервалы с использованием распределения Стьюдента. При вычислении доверительного интервала был выбран уровень значимости 0,05. Доверительные интервалы рассчитывались для каждого прогнозируемого года, т.е. для всех пяти лет. Для получения среднего прогноза модель запускалась 10 раз, таким образом, критическое значение t -распределения Стьюдента при числе степеней свободы, равном 9 (десять запусков минус один), было 2,262 (<https://statpsy.ru/t-student/t-test-tablica/>). В подписях к рисункам даны средние за все годы среднеквадратичные (стандартные) отклонения (СКО). Доверительный интервал для каждого параметра вычислялся по следующей формуле:

$$\mu = \bar{X} \pm t_{\alpha} \frac{\sigma}{\sqrt{n}},$$

где μ — математическое ожидание; $\bar{X}$ — среднее значение (оценка математического ожидания); n — объём выборки; t_{α} — критическое значение t -распределения Стьюдента с уровнем значимости α и числом степеней свободы $n-1$; σ — СКО по выборке, состоящей из n членов.

Описание модели

Нейронная сеть (*англ.* neural network) разрабатывалась на популярной открытой библиотеке машинного обучения TensorFlow и библиотеке высокого уровня Keras (<https://keras.io>), служащей интерфейсом для TensorFlow. Последняя является фреймворком для языка программирования Python и реализует операции с тензорами (обобщение матриц с произвольным количеством измерений). Модель с рекуррентными слоями LSTM выбрана из библиотеки Keras. Для ускорения вычислений (за счёт распараллеливания) использовалась видеокарта от NVIDIA, для которой компания выпустила программный интерфейс CUDA (*англ.* Compute Unified Device Architecture) (<https://developer.nvidia.com/about-cuda>). Расчёт модели на видеокарте делается примерно на порядок быстрее, чем на процессоре. В настоящей работе используется модель Sequential — архитектура сети с линейным стеком слоёв. Модель содержит два слоя LSTM и один слой Dense — полносвязный слой, где все входы связаны со всеми нейронами, находящимися внутри слоя. В качестве функции активизации (задание значений в начале этапа обучения) использовался гиперболический тангенс (tanh), у которого выходное значение находится в диапазоне от -1 до 1 . В модели использовался адаптивный алгоритм оптимизации скорости обучения RMSProp (*англ.* Root Mean Square Propagation) (<https://www.geeksforgeeks.org/rmsprop-optimizer-in-deep-learning/>). Он адаптирует скорость обучения на основе скользящего среднего квадратов градиентов. Такой подход помогает поддерживать баланс между эффективной сходимостью и стабильностью в процессе обучения.

Для оценки эффективности модели и в качестве функции потерь использовалась средне-квадратичная ошибка MSE (англ. Mean Square Error) (https://openforecast.org/ru/etextbook/forecasting_toolbox/estimation-simple-methods/). Она применяется в ситуациях, когда надо выбрать модель, дающую меньше грубых ошибок прогноза. Для расчёта метрики MSE необходимо возвести в квадрат количество обнаруженных ошибок и найти среднее значение:

$$\text{MSE} = \frac{1}{N} \sum_1^N (y_i - f(x_i))^2,$$

где y_i — истинное значение; $f(x_i)$ — прогноз; N — длина ряда на этапе обучения или проверки. Оптимизация модели (функция потерь) показывает, насколько сильно предсказанный моделью результат отличается от фактического.

Используемые модели для расчётов прогноза будут отличаться только входными данными и числом нейронов для двух LSTM-слоёв. Количество эпох будет постоянным и равным 200. Количество эпох — это гиперпараметр, который определяет, сколько раз алгоритм обучения будет обрабатывать весь набор данных, состоящий в нашем случае из мини-пакетов. В конце обработки мини-пакета прогнозы сравниваются с ожидаемыми выходными переменными и вычисляется ошибка, т.е. выполняется алгоритм обучения градиентным спуском.

В настоящее время подробности работы алгоритмов машинного обучения, руководства по созданию моделей и исходные коды для них (в основном на языке программирования Python) можно найти в учебниках по машинному обучению (Chollet, 2017; Chollet, Watson, 2025; Géron, 2019) и во множестве статей, например, в публикации (Wang et al., 2024).

Результаты и их анализ

Далее представлены результаты работы рекуррентной нейронной сети, описанной выше, для прогнозирования температуры поверхности воды в Чёрном море и экмановского индекса для южной части Канарского апвеллинга. Для сравнения прогнозы будут построены для наблюдаемых исходных рядов и для остаточных, полученных из исходных вычитанием тренда и сезонных изменений. Из-за больших естественных вариаций в поле ветра, приводящих к непредсказуемости даже среднемесячных значений температуры и скорости подъёма воды, получить достоверный прогноз на месячном масштабе не удаётся. Модель пытается строить прогнозы по низкочастотным составляющим рядов.

Прогноз температуры поверхности Чёрного моря

По историческим данным о температуре поверхности Чёрного моря за 1982–2024 гг. был построен прогноз на 60 месяцев, который усреднён на пять лет. Модель строит прогнозы по принципу «продолжения временного ряда», в предположении, что основные закономерности выявлены на обучающей выборке. Для двух LSTM-слоёв модели было задано 32 и 16 нейронов. Потери модели на этапах обучения и проверки вычисляются сравнением прогнозируемых выходных данных с фактическими выходными данными с использованием определённой функции потерь, в нашем случае MSE. Модель справилась с задачей прогноза при несущественных потерях на этапах обучения и проверки со средними значениями по метрике MSE: 0,41 и 0,68 % соответственно. Кривая рассчитанного прогноза практически перекрывает тестовую кривую (рисунок не приведён).

На *рис. 1* (см. с. 80) показан средний 5-летний прогноз при 10-кратном прогоне модели. Доверительные интервалы при уровне значимости 0,05 рассчитывались для каждого прогнозируемого года.

Далее показан прогноз временного ряда с *рис. 1*, но с удалённым трендом и сезонным ходом. Исходный ряд был разложен на составляющие с помощью библиотеки statsmodels.

tsa.seasonal.STL (<https://www.statsmodels.org/dev/generated/statsmodels.tsa.seasonal.STL.html>), написанной на Python (рис. 2).




Рис. 1. Межгодовые изменения ТПМ: исторические данные (1982–2024) (синяя кривая) и полученный моделью прогноз на 2025–2029 гг. (красная кривая). Доверительные интервалы показаны полупрозрачным цветом, среднее значение СКО составляет 0,05 °C




Рис. 2. Декомпозиция наблюдаемого ряда ТПМ для Чёрного моря на три составляющие: низкочастотная тенденция (тренд), сезонные колебания и остаточная изменчивость

Временной ряд, содержащий остаточную изменчивость после удаления низкочастотной тенденции и сезонных колебаний, был обработан прогностической моделью с такими же параметрами, что и при предыдущем прогнозировании (см. рис. 1). Потери на этапах обучения и проверки по метрике MSE составили 3,84 и 14,36 % соответственно, что только на этапе обучения на порядок выше, чем в предыдущем примере. Почти в четыре раза большие потери на этапе проверки, чем при обучении, говорят о том, что модель сильно переобучена, т.е. слишком хорошо настроена на обучающих данных и даёт плохие результаты на тестовых. Причина значительных потерь на тестовых данных состоит в том, что среднемесячные температурные флуктуации распределены в исследуемом ряду почти по случайному закону и рассчитанные моделью коэффициенты для обучающей выборки не подходят для тестовой. Упрощение модели для устранения эффекта переобучения приводит к большим потерям на этапе обучения (модель запоминает данные, а не учится на них), что сглаживает прогноз.

Кривая прогноза, построенная моделью для тестовых данных, сильно отличается от последних и имеет значимую периодичность, составляющую 8,6 мес. Колебания с таким периодом также хорошо проявляются на предсказанных моделью значениях температуры (рис. 3). Анализ физических процессов, ответственных за формирование указанного спектрального пика, выходит за рамки настоящей работы.




Рис. 3. Изменения ТПМ за 60 месяцев: исторические данные (2020–2024) (синяя кривая) и предсказанные моделью значения (2025–2029) (зелёная кривая)

На рис. 4 представлен средний 5-летний прогноз при 10-кратном прогоне модели. Доверительные интервалы при уровне значимости 0,05 рассчитывались для каждого прогнозируемого года. Межгодовой 5-летний прогноз, построенный по остаточным данным (без тренда и сезонности), похож на прогноз, полученный по наблюдаемому ряду ТПМ (см. рис. 1), где модель при составлении прогноза в основном ориентировалась по тренду и сезонным изменениям.




Рис. 4. Межгодовые изменения ТПМ: исторические данные (1982–2024) (синяя кривая) и полученный моделью прогноз на 2025–2029 гг. (красная кривая). Доверительные интервалы показаны полупрозрачным цветом, среднее значение СКО составляет 0,02 °C

Очевидно, что модель не может учесть высокочастотную составляющую остаточных данных и строит прогноз по выделенной низкочастотной составляющей (см. рис. 3).

Используя ряд, состоящий из низкочастотной тенденции (см. рис. 2), получаем прогноз, представленный на рис. 5 (см. с. 82). Кривая этого прогноза, как и кривая на рис. 4, предсказывает уменьшение температуры в 2027 г. и увеличение в 2029 г. Во всех представленных вариантах прогноза модель не учитывала высокочастотную составляющую, которая даёт существенный вклад в дисперсию временного ряда (порядка 30 %). Очевидно, что достоверность этих прогнозов низкая.




Рис. 5. Межгодовые изменения ТПМ: исторические данные (1982–2024) (синяя кривая) и полученный моделью прогноз на 2025–2029 гг. (красная кривая). Доверительные интервалы показаны полупрозрачным цветом, среднее значение СКО составляет 0,08 °C

Прогноз экмановского индекса для южной части Канарского апвеллинга

В этом примере для южной части Канарского апвеллинга (13–21° с. ш.) был построен 5-летний прогноз для экмановского индекса. Расчёт EUI выполняется на основе данных приповерхностного вдольберегового ветра, которые всё ещё недостаточно хорошо определяются спутниковой аппаратурой и имеют низкое пространственное разрешение. Непредсказуемые естественные вариации поля ветра не позволили модели, настроенной на этапе обучения, сделать приемлемый прогноз на этапах проверки и предсказания. Потери на этапах обучения и проверки со средними значениями по метрике MSE составили 3,38 и 6,94 % соответственно, что примерно на порядок больше, чем для ряда ТПМ для Чёрного моря (0,41 и 0,68 %). Модель переобучена, т. е. слишком хорошо настроена на обучающих данных (учитывались небольшие флуктуации), и дала плохие результаты на тестовых. Для борьбы с таким явлением обычно упрощают модель, чтобы она не подстраивалась под незначительные изменения на этапе обучения. Упростить модель проще всего за счёт уменьшения числа нейронов в слоях, что обычно приводит к увеличению потерь на этапе обучения и усреднению выходных данных. В настройках рассматриваемого варианта модели число нейронов для LSTM-слоёв составило 32 и 16.

Рисунок 6 иллюстрирует зашумлённость EUI для разных пакетов данных. Обученная на исторических данных модель сделала прогноз на 60 месяцев (красная кривая), который сравнивался с тестовыми данными (синяя кривая), не участвовавшими в обучении.



Рис. 6. Изменения нормализованных значений EUI за 60 месяцев: исторические данные (голубая кривая), тестовые значения (синяя кривая) и значения, построенные моделью (красная кривая)

На рис. 7 (см. с. 83) представлен средний 5-летний прогноз за 10 прогонов модели.




Рис. 7. Межгодовые изменения EUI: исторические данные (1993–2024) (синяя кривая) и полученный моделью прогноз на 2025–2029 гг. (красная кривая). Доверительные интервалы показаны полупрозрачным цветом, среднее СКО составляет 0,012 °C

В следующем примере из временного ряда EUI для южной части Канарского апвеллинга были удалены сезонная изменчивость и тренд (рис. 8).




Рис. 8. Декомпозиция наблюдаемого ряда EUI для южной части Канарского апвеллинга на три составляющие: тенденция (тренд), сезонные колебания и остаток

Временной ряд, содержащий остаточную изменчивость после удаления низкочастотной тенденции и сезонных колебаний, был обработан прогностической моделью с такими же параметрами, как и при прогнозировании по полным историческим данным (см. рис. 7). В результате потери на этапах обучения и проверки по метрике MSE составили 7,99 и 13,49 % соответственно, что примерно в два раза больше, чем для наблюдаемого ряда (3,38 и 6,94 %). Данная модель сильно переобучена. В этом примере не будем упрощать модель, чтобы не сглаживать прогноз. Кривая прогноза, построенная моделью для тестовых данных, не накладывается на тестовую (рисунок не приведён). Предсказанная моделью кривая на рис. 9 (см. с. 84) имеет квазипериодическую составляющую с периодом 7,5 мес. Анализ физических процессов, ответственных за формирование указанного спектрального пика, выходит за рамки настоящей работы.




Рис. 9. Изменения EUI за 60 месяцев: исторические данные (синяя кривая) и предсказанные моделью значения (зелёная кривая)

На рис. 10 представлен средний 5-летний прогноз при 10-кратном прогоне модели. Доверительные интервалы при уровне значимости 0,05 рассчитывались для каждого прогнозируемого года. Кривая межгодового 5-летнего прогноза, построенная по остаточным данным (без тренда и сезонности), напоминает кривую прогноза, полученную по наблюдаемому ряду EUI (см. рис. 7): в 2026 и 2028 гг. EUI увеличится, а в 2027 г. — уменьшится. Надо отметить, что модель в обоих случаях (см. рис. 7 и 10) практически не учитывала высокочастотные колебания и строила прогноз по найденным низкочастотным составляющим, что делает низкой достоверность прогноза.




Рис. 10. Межгодовые изменения EUI: исторические данные (1993–2024) (синяя кривая) и полученный моделью прогноз на 2025–2029 гг. (красная кривая). Доверительные интервалы показаны полупрозрачным цветом, СКО составляет 0,32 °C

Заключение

Построить приемлемые по точности прогнозы (при формальном подходе точность прогнозирования должна быть не ниже 95 %) для океанографических процессов с существенной нестационарностью и большой дисперсией оказалось весьма проблематично. Это хорошо видно на примерах прогнозирования ТПМ Чёрного моря и экмановского индекса для южной части Канарского апвеллинга. Модель делает прогноз по низкочастотным колебаниям, присутствующим во временных рядах (см. рис. 3 и 9), что отражается на достоверности прогноза. Из-за плохо предсказуемых вариаций параметров на временных масштабах меньше года прогнозирование сталкивается с проблемой переобучения нейросетевой модели, т. е. нельзя использовать хорошо обученную для определённого набора данных конфигурацию модели на тестовых данных и, соответственно, сделать прогноз приемлемого качества. Проблема пере-

обучения, решаемая за счёт упрощения модели, приводит к сглаживанию прогноза. Кроме того, прогнозирование океанографических рядов сталкивается с известной проблемой: отсутствие высококачественных и достаточно длинных последовательностей исторических данных.

Для построения качественного прогноза надо использовать многомерную модель, если удастся найти несколько релевантных входных наборов данных (признаков) и обнаружить физические связи. Как известно, некоторые океанографические события однозначно зависят от ряда процессов. Хорошим примером такой зависимости можно отметить следование пика термического индекса апвеллинга после EU1. Из неопубликованных расчётов автора было получено, что для северных широт 24–33° Канарского апвеллинга EU1 опережает термический индекс примерно на два месяца, а для широт 21–24° опережение составляет около пяти месяцев.

Автор выражает благодарность анонимным рецензентам за критические замечания, которые помогли конструктивно доработать статью.

Работа выполнена в рамках темы государственного задания «Фундаментальные исследования процессов в климатической системе, определяющих пространственно-временную изменчивость морской среды и прилегающих территорий в широком диапазоне масштабов (гос. рег. № 124020100120-9)».

Литература

1. Chollet F. Deep learning with Python. Shelter Island, NY: Manning, 2017. 384 p.
2. Chollet F., Watson M. Deep learning with Python. 3rd ed. Shelter Island, NY: Manning, 2025. 600 p.
3. Géron A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. 2nd ed. O'Reilly Media, 2019. 848 p.
4. IPCC, 2021: Summary for policymakers // Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, 2021. P. 1–32.
5. Jebri F., Srokosz M., Jacobs Z. L. et al. Earth observation and machine learning reveal the dynamics of productive upwelling regimes on the Agulhas Bank // Frontiers in Marine Science. 2022. V. 9. Article 872515. DOI: 10.3389/fmars.2022.872515.
6. Polonsky A. B., Serebrennikov A. N. What is the reason for the multiyear trends of variability in the Benguela upwelling? // Izvestiya, Atmospheric and Oceanic Physics. 2022. V. 58. No. 12. P. 1450–1457. DOI: 10.1134/S0001433822120192.
7. Wang S., Fu G., Song Y. et al. Ocean-Mixer: A deep learning approach for multi-step prediction of ocean remote sensing data // J. Marine Science and Engineering. 2024. V. 12. No. 3. Article 446. DOI: 10.3390/jmse12030446.

Problems in forecasting oceanographic series using the example of Black Sea surface temperature and Ekman index for the southern part of Canary Islands upwelling

A. N. Serebrennikov

*Institute of Natural Technical Systems, Sevastopol 299011, Russia
E-mail: swsilv@gmail.com*

The paper presents the experience of forecasting oceanic phenomena using recurrent neural networks and long-term–short-term memory structures. In particular, the problems arising in forecasting Black Sea surface temperature and Ekman index for the southern Canary Islands upwelling (13–21° N) are

analyzed using a one-dimensional model for a 60-month forecast as an example. It is shown that one of the main problems in forecasting oceanographic series, such as wind speed and direction, sea surface temperature, etc., is the unpredictability of variations in these parameters on small time scales (up to a year). These variations of natural origin do not allow the model to use the training experience for reliable forecasting. Improving the quality of the model (complication) at the training stage leads to overfitting, which is reflected in model testing; simplification of the model leads to smoothing of the forecast. In addition, it is confirmed that the accuracy of forecasting oceanographic parameters largely depends on the quality and length of the original data. Due to the development of satellite technologies, access to a vast archive of remote sensing data is provided. However, some data, as shown in the article, related, for example, to parameters of coastal upwellings, are still quite noisy.

Keywords: LSTM model, recurrent model, gradient descent, Ekman upwelling index, coastal upwelling, sea surface temperature

Accepted: 23.06.2025

DOI: 10.21046/2070-7401-2025-22-4-76-86

References

1. Chollet F., *Deep learning with Python*, Shelter Island, NY: Manning, 2017, 384 p.
2. Chollet F., Watson M., *Deep learning with Python*, 3rd ed., Shelter Island, NY: Manning, 2025, 600 p.
3. Géron A., *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*, 2nd ed. O'Reilly Media, 2019, 848 p.
4. IPCC, 2021: Summary for policymakers, In: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge University Press, 2021, pp. 1–32.
5. Jebri F., Srokosz M., Jacobs Z. L. et al., Earth observation and machine learning reveal the dynamics of productive upwelling regimes on the Agulhas Bank, *Frontiers in Marine Science*, 2022, V. 9, Article 872515, DOI: 10.3389/fmars.2022.872515.
6. Polonsky A. B., Serebrennikov A. N., What is the reason for the multiyear trends of variability in the Benguela upwelling?, *Izvestiya, Atmospheric and Oceanic Physics*, 2022, V. 58, No. 12, pp. 1450–1457, DOI: 10.1134/S0001433822120192.
7. Wang S., Fu G., Song Y. et al., Ocean-Mixer: A deep learning approach for multi-step prediction of ocean remote sensing data, 2024, *J. Marine Science and Engineering*, V. 12, No. 3, Article 446, DOI: 10.3390/jmse12030446.