

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ НАУЧНОЕ УЧРЕЖДЕНИЕ
«ИНСТИТУТ ПРИРОДНО-ТЕХНИЧЕСКИХ СИСТЕМ»

На правах рукописи

ЛУБКОВ АНДРЕЙ СЕРГЕЕВИЧ

ДОЛГОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ
ЯВЛЕНИЙ ЭЛЬ-НИНЬО И ЛА-НИНЬЯ
С ИСПОЛЬЗОВАНИЕМ МОДЕЛИ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Специальность 1.6.18 – Науки об атмосфере и климате

Диссертация на соискание ученой степени
кандидата физико-математических наук

Научный руководитель
Воскресенская Елена Николаевна
доктор географических наук, профессор

Севастополь – 2024

ОГЛАВЛЕНИЕ

ГЛАВА 1. ЭЛЬ-НИНЬО – ЮЖНОЕ КОЛЕБАНИЕ: ПРИЧИНЫ ВОЗНИКНОВЕНИЯ, КЛАССИФИКАЦИЯ, КЛИМАТИЧЕСКИЕ ПОСЛЕДСТВИЯ И ПРОБЛЕМЫ ПРОГНОЗИРОВАНИЯ	18
1.1. Эль-Ниньо – Южное колебание	18
1.1.1. Типизация событий Эль-Ниньо и Ла-Нинья.....	25
1.1.2. Воздействие событий Эль-Ниньо и Ла-Нинья и их типов на окружающую среду и климат	31
1.2. Современное состояние моделирования событий Эль-Ниньо и Ла-Нинья..	35
1.2.1. Прогноз пространственного типа явлений Эль-Ниньо и Ла-Нинья.....	39
1.3 Искусственные нейронные сети и мировой опыт их использования для прогноза Эль-Ниньо – Южное колебание	42
1.3.1. Первые простейшие нейронные сети и связанные с ними модели для прогноза ЭНЮК	44
1.3.2. Современные нейросетевые системы прогнозирования ЭНЮК	47
Выводы к Главе 1	55
ГЛАВА 2. ИСПОЛЬЗУЕМЫЕ ДАННЫЕ И ПРОСТРАНСТВЕННО-ВРЕМЕННОЙ АЛГОРИТМ ПОДБОРА ПРЕДИКТОРОВ	57
2.1. Используемые в работе массивы данных и оценка их качества	58
2.1.1. Верификация базы данных поля геопотенциала	59
2.1.2. Верификация реконструированных баз данных ТПО.....	61
2.2. Пространственно-временной алгоритм подбора входных модельных предикторов	69
2.2.1. Предварительная подготовка рядов данных на основе пространственно-временного анализа гидрометеорологических полей	69
2.2.2. Алгоритм выбора ограниченного количества предикторов.....	75

Выводы к Главе 2	76
ГЛАВА 3. НЕЙРОСЕТЕВАЯ ПРОГНОСТИЧЕСКАЯ МОДЕЛЬ.....	79
3.1. Многослойный персептрон	79
3.1.1 Подбор параметров обучения для используемой НС	80
3.1.2 Алгоритм обратного распространения ошибки.....	83
3.1.3 Алгоритм поиска максимума обучения.....	87
3.2. Тестирование модели НС	89
3.2.1 Добавление белого шума к моделируемому параметру	91
3.2.2. Добавление белого шума к входным сигналам	93
3.2.3. Прогноз при отсутствии одного из предикторов.....	95
3.3. Практическое определение оптимального количества нейронов входного и скрытого слоев.....	96
3.4 Комбинации НС и множественный подход	101
3.5. Оптимизация прогностической модели	104
3.6. Декомпозиция исходного сигнала и моделирование низкочастотной компоненты.....	106
3.7. Обобщенная схема модели.....	109
Выводы к Главе 3	111
ГЛАВА 4. ПРИМЕНЕНИЕ РАЗРАБОТАННОЙ МОДЕЛИ ДЛЯ ПРОГНОЗА ЭЛЬ-НИНЬО И ЛА-НИНЬЯ И ИХ ТИПОВ	114
4.1. Воспроизводимость индексов Nino с применением только атмосферных предикторов	114
4.2. Прогностическая модель состояния Эль-Ниньо – Южное колебание	123
4.2.1. Прогноз индексов Nino с применением атмосферных и океанических предикторов	125

4.2.2. Сопоставление способностей модели с современными моделями НС глубокого обучения	132
4.3. Анализ полученных предикторов и их взаимодействие с моделируемым параметром.....	137
4.4. Успешный прогноз Эль-Ниньо 2023г. и предположение о Ла-Нинья в 2024- 2025 гг.....	140
Вывод к Главе 4.....	143
ЗАКЛЮЧЕНИЕ	146
СПИСОК СОКРАЩЕНИЙ.....	148
СПИСОК ЛИТЕРАТУРЫ.....	150
ПРИЛОЖЕНИЕ А. Объективная пространственно-временная классификация явлений Эль-Ниньо	171
ПРИЛОЖЕНИЕ Б. Сравнение предложенной нейросетевой модели с некоторыми моделями глубокого обучения.....	176
ПРИЛОЖЕНИЕ В. Влияние учета теплосодержания океана на глубине до 300м на качество моделирования.....	177

ВВЕДЕНИЕ

Актуальность темы исследования

Эль-Ниньо и Ла-Нинья – важнейшие глобальные климатические явления межгодового масштаба в системе океан-атмосфера экваториальной зоны Тихого океана, которые обуславливают формирование катастрофических аномалий климата и окружающей среды в разных регионах Земного шара в виде засух, наводнений, пожаров, а также приводят к возникновению колоссальных социальных и экономических проблем [Philander, 1989; Voskresenskaya, Polonsky, 1993; Larkin, Harrison, 2005; Ashok et al., 2007; Yuan et al, 2012]. Так засухи, вызванные Эль-Ниньо 2015 года, создали острую нехватку продовольствия в южной части Африки [IPCC, 2022]. Глобальный ущерб от Эль-Ниньо 1982 и 1997 годов составил 4.1 и 5.7 трлн. \$. Ожидаемый суммарный глобальный ущерб от всех событий Эль-Ниньо и Ла-Нинья в XXI веке по оценкам экспертов может составить 84 трлн. \$ [Callahan, Mankin, 2023]. Заблаговременный прогноз этих событий позволит принять превентивные меры для максимально возможного сокращения социально-экономического ущерба. Следовательно, одним из важнейших направлений современных климатических исследований является изучение и прогноз этих событий.

События Эль-Ниньо и Ла-Нинья являются эпизодами климатического процесса Эль-Ниньо – Южное колебание (ЭНЮК). ЭНЮК включает в себя теплую фазу – Эль-Ниньо, холодную фазу – Ла-Нинья, и нейтральную фазу между ними. К настоящему времени получена достаточно подробная характеристика этих событий, проведена классификация каждой фазы ЭНЮК, в результате которой выделено, как минимум, по два пространственных типа, как среди Эль-Ниньо, так и Ла-Нинья. При этом каждый тип имеет свои особенности, которые имеют характерные глобальные проявления. Уже достигнуты определенные успехи в моделировании и прогнозировании событий и их типов. Однако в условиях меняющегося климата чрезвычайно важно продолжение этих исследований и совершенствование прогноза.

Современные динамические и статистические модели многочисленных мировых климатических центров, применяемые для прогноза состояния ЭНЮК в рамках проектов Всемирной метеорологической организации (ВМО), ограничены весенним порогом предсказуемости, а их эффективная заблаговременность равна 6-12 месяцам [Wang B., Fang Z., 1996; Tippet et al., 2012; Qi et al., 2017]. При этом уточнение типа событий ЭНЮК ограничено буквально несколькими месяцами [Ren et al., 2019; Zhang et al., 2021; Gao et al., 2024]. Однако перед мировым сообществом ученых и специалистов сохраняется проблема создания такого прогноза с максимально возможной заблаговременностью и высокой оправдываемостью.

Объект исследования – События Эль-Ниньо и Ла-Нинья.

Предмет исследования – Прогностическое моделирование событий Эль-Ниньо и Ла-Нинья с учетом их пространственных типов.

Цель и задачи исследования

Целью работы является создание модели долгосрочного прогноза событий Эль-Ниньо, Ла-Нинья с учетом их пространственных типов и нейтральной фазы ЭНЮК с заблаговременностью более 12 месяцев на основе искусственных нейронных сетей.

Для достижения цели были поставлены и решены следующие научные задачи:

1. Проанализировать поля гидрометеорологических характеристик и выбрать климатические сигналы в глобальной системе океан-атмосфера для использования их в качестве предикторов Эль-Ниньо/Ла-Нинья.

2. Адаптировать метод искусственных нейронных сетей (ИНС) для создания модели долгосрочных прогнозов Эль-Ниньо, Ла-Нинья и нейтральной фазы ЭНЮК с привлечением климатических сигналов в глобальной системе океан-атмосфера в качестве предикторов.

3. Применить разработанную модель для прогнозирования Эль-Ниньо, Ла-Нинья и нейтральной фазы ЭНЮК с заблаговременностью более 12 мес.

4. Оценить качество прогностических характеристик разработанной модели относительно современных динамических моделей и моделей, основанных на алгоритмах глубокого обучения.

Соответствие диссертации паспорту научной специальности

Диссертация соответствует паспорту научной специальности 1.6.18 – «Науки об атмосфере и климате».

Научная новизна

Созданная модель нейросетевого долгосрочного прогноза событий Эль-Ниньо, Ла-Нинья и нейтральной фазы ЭНЮК впервые обеспечила возможность их эффективного прогноза с заблаговременностью 22 месяца.

На основе сравнения ретроспективных прогнозов показано, что эффективная продолжительность прогноза полученной модели превосходит по качеству классические гидродинамические, статистические модели и модели, основанные на искусственном интеллекте. В 2022 году полученная модель одна из первых в мире указала на приближение Эль-Ниньо восточного типа в 2023 году.

Данные и методы исследования

В работе к анализу привлекался большой объем массивов данных, которые для удобства восприятия представим в виде следующих групп.

Реконструированные массивы среднемесячных данных температуры поверхности океана (ТПО):

- HadISST Метеорологического офиса Гадлея (Великобритания), с пространственным разрешением узлов сетки $1^{\circ} \times 1^{\circ}$ с 1870 по 2023 гг.;
- COBE SST2 Японского метеорологического агентства с пространственным разрешением узлов сетки $1^{\circ} \times 1^{\circ}$ с 1850 по 2023 гг.;

Данные разных типов реанализа:

- среднемесячные поля скорости ветра и геопотенциала на изобарических уровнях из атмосферного реанализа NCEP/NCAR с пространственным разрешением узлов сетки $2.5^{\circ} \times 2.5^{\circ}$ с 1948 по 2023 гг.;

– среднемесячные поля температуры воздуха и геопотенциала на изобарических уровнях из атмосферного реанализа 20 столетия (20th Century Reanalysis V2c) с пространственным разрешением узлов сетки $2^{\circ} \times 2^{\circ}$ с 1870 по 2015 гг.;

Данные наблюдений:

– среднемесячные данные ТПО с буев проекта TOGA-TAO с 1981 по 2019 гг.;

– ежедневные данные аэрологического зондирования Объединенного глобального архива радиозондирования IGRA v2.1 (International Global Radiosound Archive) Национального центра климатических данных США (NCDC).

Спутниковые данные:

– ежемесячные данные ТПО спутника MODIS (Terra Global Level 3) с разрешением 9 км с 2001 по 2019 гг.;

– ежемесячный массив ТПО NOAA IO SST v2 (Optimum Interpolation Sea Surface Temperature v2), полученный путем интерполяции данных сенсора AVHRR (серия спутников NOAA), с пространственным разрешением узлов сетки $1^{\circ} \times 1^{\circ}$ за период 1982-2018 гг.

В работе разработана уникальная методика усвоения данных и применения группы простейших многослойных нейронных сетей для долгосрочных климатических прогнозов, что послужило основой прогностической модели. Разработанная модель использует в качестве предикторов глобальные климатические индексы системы океан-атмосфера, для расчета которых применяются атмосферные и океанические поля.

Научная и практическая значимость результатов

Полученные в работе результаты направлены на решение фундаментальной научной проблемы в области теории климата, связанной с долгосрочным прогнозированием.

Разработанная модель показала высокую способность прогнозирования явлений Эль-Ниньо, Ла-Нинья и нейтральных условий ЭНЮК. Ее эффективная продолжительность прогноза существенно лучше современных динамических и

статистических моделей и достигает 22 месяцев. При этом модель позволяет предупредить не только о начале большинства событий Эль-Ниньо и Ла-Нинья, но и определить их тип, что имеет, несомненно, большое практическое значение для развития климатических прогнозов и минимизации возможных негативных последствий. Поскольку анализ прогнозов предложенной модели показал ее преимущество относительно динамических и современных статистических моделей, в основе которых лежат алгоритмы глубокого обучения, в последующем модель будет предложена для внедрения в Росгидрометцентре.

Кроме этого, результаты работы могут быть использованы для решения многих прикладных задач, в частности, в практической работе учреждений, связанных с выпуском долгосрочных гидрометеорологических прогнозов, а также могут быть включены в образовательные программы ВУЗов географического и гидрометеорологического профиля.

Полученные результаты включены в отчеты по государственным научным темам, а также в отчеты по грантам РФФИ и РГО, что подтверждает их научную и практическую значимость. В частности, результаты работы вошли в отчет тем госзадания Института природно-технических систем по разделу темы (№ 0012-2014-0013): «Исследование закономерностей и механизмов формирования региональных параметров природной среды Черноморского региона под влиянием естественных и региональных факторов», № 0012-2019-0007 «Фундаментальные и прикладные исследования закономерностей и механизмов формирования региональных изменений природной среды и климата под влиянием глобальных процессов в системе океан-атмосфера и антропогенного воздействия», № 0012-2021-0007 (121122300072-3) «Фундаментальные и прикладные исследования закономерностей и механизмов формирования региональных изменений природной среды и климата под влиянием глобальных процессов в системе океан-атмосфера и антропогенного воздействия»; гранта РФФИ № 14-45-01549 «Исследование изменчивости гидрофизических и гидробиологических процессов в севастопольском морском районе»; гранта РФФИ № 16-05-00231 «События Эль-Ниньо и Ла-Нинья: классификация,

особенности и проявления в погодно-климатических аномалиях в Черноморском регионе»; гранта РФФИ № 16-35-00186 «Исследование климатических условий Черноморского побережья России в связи с событиями Эль-Ниньо и Ла-Нинья»; гранта РФФИ № 18-35-00325 «Исследование биоклиматического потенциала курортов Крымского полуострова»; гранта РФФИ № 18-45-920063 «Медико-климатическая характеристика туристско-рекреационного региона Севастополя в условиях наблюдаемых изменений климата»; гранта РФФИ № 18-45-920068 «Закономерности формирования экстремальных штормовых условий в Севастопольском регионе и изменчивости параметров морских экосистем»; гранта РФФИ № 20-45-920015 «Оценка антициклонической активности и сопутствующих гидрометеоусловий для решения проблемы водных ресурсов Севастопольского региона»; гранта РГО «Комплексный анализ природно-климатического потенциала и его будущих изменений на территории Крыма и в прибрежной зоне Черного моря для перспективного планирования устойчивого развития региона».

Положения, выносимые на защиту:

1. Разработана модель долгосрочного прогноза аномалий температуры поверхности океана в экваториальной зоне Тихого океана на основе ИНС, в которой в качестве предикторов используются индексы, характеризующие процессы крупномасштабного взаимодействия в глобальной системе океан-атмосфера.
2. Предложен алгоритм пространственно-временного отбора предикторов, включающих индексы широко известных климатических аномалий, а также индексов, полученных на основе комплексного анализа полей атмосферных реанализов и реконструкций ТПО.
3. Полученная модель обладает минимальной чувствительностью к весеннему порогу предсказуемости, что обеспечивает ее преимущество по сравнению с современными динамическими и статистическими моделями прогноза Эль-Ниньо/Ла-Нинья и позволяет увеличить эффективную заблаговременность прогноза до 22 месяцев, что на 10-16 месяцев превосходит

эту характеристику динамических моделей и на 4 месяца – моделей, основанных на алгоритмах глубокого обучения.

Личный вклад автора

В ходе выполнения диссертационной работы автор активно участвовал в постановке задач, их решении, интерпретации полученных результатов и формулировке выводов. Им самостоятельно были проведены обработка, анализ и верификация всех массивов данных, написаны программные коды для решения поставленных задач, выполнено сопоставление с международным уровнем. Автором лично были подготовлены материалы к научным публикациям в рецензируемых изданиях, представлены результаты на многочисленных всероссийских и международных конференциях.

Степень достоверности и апробация результатов

Достоверность расчетов подтверждается наличием верификационной выборки, обеспечивающей независимую проверку результатов моделирования. Новизна научных результатов подтверждена публикациями в ведущих профильных рецензируемых журналах, размещенных в наукометрических базах РИНЦ, ВАК, SCOPUS и Web of Science.

Результаты диссертационной работы докладывались на семинарах Лаборатории крупномасштабного взаимодействия океана и атмосферы и изменений климата Института природно-технических систем в период 2015 по 2024 гг. и на семинаре в Гидрометцентре России в 2023 году. Кроме этого, полученные результаты были представлены на следующих всероссийских и международных конференциях: Международная научная конференции «Современное состояние и перспективы наращивания морского ресурсного потенциала Юга России» (пгт. Кацивели, 2014); Международная научная конференция студентов и молодых ученых «Современная гидрометеорология: актуальные проблемы и пути их решения» (Одесса, 2014); XX Международный симпозиум «Оптика атмосферы и океана. Физика атмосферы» (Томск, 2014); Научно-практическая молодежная конференция «Экобиологические проблемы Азово-Черноморского региона и комплексное управление биологическими

ресурсами» (Севастополь, Ялта, 2014–2017); «International Geographical Union Regional Conference. Geography, Culture and Society for our Future Earth – IGU» (Москва, 2015); Международной научно-технической конференции «Системы контроля окружающей среды» (Севастополь, 2015–2023); Научная конференция "Мировой океан: модели, данные и оперативная океанология" (Севастополь, 2016); Международная молодежная научно-практическая конференция «Инновации в геологии, геофизике и географии-2016» (Севастополь, 2016); Всероссийская научная конференция молодых учёных «Комплексные исследования Мирового океана» (Севастополь, 2016); I Черноморская научно-практическая конференция МГУ «Проблемы безопасности в современном мире» (Севастополь, Санкт-Петербург, Москва, 2016, 2018, 2019, 2023); Международная научная конференция памяти члена-корреспондента РАН Д. Г. Матишова «Окружающая среда и человек. Современные проблемы генетики, селекции и биотехнологии» (Ростовна-Дону, 2016, 2020); V Международная научно-практическая конференция «Морские исследования и образование – MARESEDU» (Москва, 2016); XXV международная научно-техническая конференция «Прикладные задачи математики» (Севастополь, 2017); Всероссийская конференция "Гидрометеорология и экология: научные и образовательные достижения и перспективы развития" (Санкт-Петербург, 2017); Всероссийская научная конференция «Моря России» (Севастополь, 2017–2019); International Young Scientists School and Conference on Computational Information Technologies for Environmental Sciences (Moscow, 2019); Всероссийская научная конференция молодых ученых «Комплексные исследования Мирового океана» (Москва, Севастополь, Санкт-Петербург, 2018–2020); международная научно-практическая конференция «Здоровье и окружающая среда» (Минск, 2019); V Международная научно-практическая конференция «Фундаментальные и прикладные аспекты геологии, геофизики и геоэкологии с использованием современных информационных технологий» (Майкоп, 2019, 2023); Международная молодежная школа и конференция «по вычислительно-информационным технологиям для наук об окружающей среде» (Томск, 2019);

Международная конференция и школа молодых ученых «по измерениям, моделированию и информационным системам для изучения окружающей среды ENVIROMIS-2020» (Томск, 2020); Международная конференция «Изменения климата: причины, риски, последствия, проблемы адаптации и регулирования. Климат-2023» (Москва, 2023).

Публикации по теме диссертации

Результаты настоящей диссертационной работы опубликованы в 26 научных статьях. Требованиям ВАК при Минобрнауки Российской Федерации соответствует 23 статьи в рецензируемых российских научных изданиях. Из них 12 научных статей входят в наукометрические базы SCOPUS и Web of Science.

Кроме этого, опубликовано 60 тезисов докладов, размещенных в сборниках материалов конференций, входящих в систему РИНЦ, а результаты работы апробированы на 42 всероссийских и международных научных конференциях. По результатам настоящей работы опубликован 1 РИД. Требования к публикациям основных научных результатов диссертации, предусмотренных в п. 11 и 13 «Положения о порядке присуждения ученых степеней», утвержденного Постановлением Правительства Российской Федерации от 24 сентября 2013 г. № 842, соблюдены.

Статьи, входящие в наукометрическую базу Scopus и Web of Science:

1. **Lubkov A.S.**, Voskresenskaya E.N., Kukushkin A.S. Method for reconstructing the monthly mean water transparencies for the northwestern part of the Black Sea as an example // Atmos. Ocean. Opt. 2016. V. 29. P. 457–464. DOI: 10.1134/S1024856016050092.
1. **Lubkov A.S.**, Voskresenskaya E.N., Marchukova O.V. Forecasting Of The Southern Oscillation Index // Vestnik Of Saint Petersburg University. Earth Sciences. 2017. V. 62(4). P. 370–388 DOI: 10.21638/11701/spbu07.2017.404
2. Voskresenskaya E.N., Marchukova O.V., Maslova V.N., **Lubkov A.S.** Interannual climate anomalies in the Atlantic-European region associated with La-Nina types // IOP Conf. Ser.: Earth Environ. Sci. 2018. V. 107. P. 012043. DOI: 10.1088/1755-1315/107/1/012043

3. **Lubkov A.S.**, Voskresenskaya E.N., Marchukova O.V. Application of a neural network model to forecasting of El Niño and La Niña // IOP Conf. Ser.: Earth Environ. Sci. 2019. V. 386. P. 012040. Doi: 10.1088/1755-1315/386/1/012040
4. Marchukova O.V., **Lubkov A.S.**, Voskresenskaya E.N. The quality of the reproduction of El Nino and La Nina events using different reconstructed sea surface temperature data sets // Vestnik Of Saint Petersburg University. Earth Sciences. 2020. V. 65(1). P. 96–120. DOI: 10.21638/spbu07.2020.106
5. Marchukova O.V., Voskresenskaya E.N., **Lubkov A.S.** Diagnostics of the La Niña events in 1900–2018 // IOP Conf. Ser.: Earth Environ. Sci. 2020. V. 606. P. 012036. DOI: 10.1088/1755-1315/606/1/012036
6. **Lubkov A.S.**, Voskresenskaya E.N., Marchukova O.V., Evstigneev V.P. European temperature anomalies in the cold period associated with ENSO events // IOP Conf. Ser.: Earth Environ. Sci. 2020. V. 606 P. 012031. DOI:10.1088/1755-1315/606/1/012031
7. **Lubkov, A.S.**, Voskresenskaya, E.N., Marchukova, O.V. Forecasting El Niño/La Niña and Their Types Using Neural Networks // Russ. Meteorol. Hydrol. 2020. V. 45. P. 806–813. DOI: 10.3103/S1068373920110084
8. Maslova V.N., Voskresenskaya E.N., **Lubkov A.S.**, Yurovsky A.V., Zhuravskiy V.Y., Evstigneev V.P. Intense Cyclones in the Black Sea Region: Change, Variability, Predictability and Manifestations in the Storm Activity // Sustainability. 2020. V. 12(11). P. 4468. DOI:10.3390/su12114468
9. Maslova, V.N., Voskresenskaya, E.N., **Lubkov, A.S.**, Yurovsky, A.V. Temporal Variability and Predictability of Intense Cyclones in the Western and Eastern Mediterranean // Atmosphere. 2021. V. 12. P. 1218. DOI: 10.3390/atmos12091218
10. **Lubkov A.S.**, Voskresenskaya E.N., Sukhonos O. Yu. Forecast of Precipitation in Ai-Petri Area Based on Artificial Neuron Network Model // Water resources. 2022. V. 49(4). P. 671–679. DOI: 10.1134/S0097807822040133
11. **Lubkov A.S.**, Voskresenskaya E.N., Marchukova O.V. A New Approach to Using Neural Networks for Long-Term El Nino and La Nina Forecasting // Izvestiya,

Atmospheric and Oceanic Physics. 2024. V. 60. Suppl. 1. P. S46–S61. DOI: 10.1134/S0001433824700555 WoS Q4

12. **Lubkov A. S.**, Vyshkvarkova E. V., Voskresenskaya E. N., Shchodro A. E. Forecasting Catastrophic Floods in Crimean Territory // Water Resources, 2024. V. 51(6). P. 960–967. DOI: 10.1134/S0097807824701197

Статьи, опубликованные в изданиях из перечня ВАК и РИНЦ:

1. **Лубков А.С.**, Воскресенская Е.Н., Кукушкин А.С. Восстановление климатических данных гидрооптических характеристик на основе моделирования // Системы контроля окружающей среды. 2013. Вып. 19. С. 162–165.

2. Воскресенская Е.Н., **Лубков А. С.**, Марчукова О.В. Пространственная классификация Эль-Ниньо и условия формирования события 2015 года // Системы контроля окружающей среды. 2015. Вып. 2(22). С. 80–90.

3. Марчукова О. В., Воскресенская Е. Н., **Лубков А. С.** Статистический прогноз Эль-ниньо 2015-2016 годов и его верификация // Системы контроля окружающей среды. 2016. Вып. 4(24). С. 80–90.

4. **Лубков А.С.**, Воскресенская Е.Н., Марчукова О.В. Современная классификация Эль-Ниньо и сопоставление соответствующих климатических откликов в Атлантико-Евразийском регионе // Системы контроля окружающей среды. 2017. Вып. 7(27). С.: 94 – 100.

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

6. **Лубков А.С.**, Воскресенская Е.Н., Марчукова О.В., Журавский В.Ю. Проявление событий Эль-Ниньо в Черноморском регионе // Системы контроля окружающей среды. 2018. Вып. 4 (34). С. 94–101. DOI: 10.33075/2220-5861-2018-4-94-101

7. **Лубков А.С.**, Воскресенская Е.Н., Марчукова О.В. Температурные аномалии в Европе в холодный период в связи с ЭНЮК // Системы контроля окружающей среды. 2019. Вып. 2 (36). С. 73–80. doi:10.33075/2220-5861-2019-2-73-80

8. **Лубков А.С.**, Стефанович А.А., Воскресенская Е.Н., Вышкваркова Е.В. Биоклиматические условия на курортах Крыма: состояние и прогноз // Использование и охрана природных ресурсов в России. 2020. № 1(161). С. 60–65
9. **Лубков А.С.**, Воскресенская Е.Н. Метод нейронных сетей для климатического прогнозирования водности Чернореченского водохранилища // Системы контроля окружающей среды. 2021. Вып. 2(44). С. 16–28. DOI: 10.33075/2220-5861-2021-2-16-28
10. **Лубков А.С.**, Воскресенская Е.Н., Марчукова О.В. Новый подход к использованию нейронных сетей для долгосрочного прогноза Эль-Ниньо и Ла-Нинья // Фундаментальная и прикладная климатология. 2023. Т. 9. № 4. С. 432–466. DOI: 10.21513/2410-8758-2023-4-432-466
11. Марчукова О.В., Воскресенская Е.Н., **Лубков А.С.** Явление Ла-Нинья 2020–2021 гг. и его проявления в Европейском регионе // Системы контроля окружающей среды. 2023. Вып. 1 (51). С. 7-14. DOI: 10.33075/2220-5861-2023-1-7-14

Структура и объем работы

Диссертация состоит из введения, четырех глав, заключения, списка использованных источников и трех приложений.

В Главе 1 представлено современное состояние изученности явления ЭНЮК, обсуждены точность прогнозирования эпизодов Эль-Ниньо и Ла-Нинья, включая их типы, и связанные с этими явлениями региональные климатические отклики. На основе литературных источников обобщена информация о существующих моделях, применяемых для прогноза событий ЭНЮК, и приведены результаты их сравнения. Особое внимание уделено моделям, основанным на алгоритмах машинного обучения, в частности, многослойному перцептронному и ИНС глубокого обучения. В Главе 2 описаны используемые массивы данных, приведена оценка их качества. Описан метод отбора климатических индексов для предлагаемой в работе модели и алгоритм предварительной обработки данных. В Главе 3 подробно описывается разработанная модель, основанная на ИНС, рассмотрены тесты модели на основе

искусственно созданных рядов данных, имитирующих климатические колебания, и реальных данных наблюдений на примере стока р. Дунай. Глава 4 представляет основные полученные результаты исследования. В ней даны оценки точности разработанной модели, проведено сравнение с динамическими моделями прогноза ЭНЮК и современными статистическими моделями, основанными на алгоритмах глубокого обучения.

Объем работы составляет 178 страниц. Текст исследования иллюстрирован 36 рисунками. Библиографический список включает в себя 195 наименований, в том числе 168 на английском языке.

Благодарности

Автор искренне благодарит своего научного руководителя, доктора географических наук, профессора Е.Н. Воскресенскую за предоставленную тему и идею диссертации, грамотное руководство и ценные рекомендации. Автор признателен за помощь своему коллеге и соавтору многих публикаций Марчуковой О.В.

ГЛАВА 1. ЭЛЬ-НИНЬО – ЮЖНОЕ КОЛЕБАНИЕ: ПРИЧИНЫ ВОЗНИКНОВЕНИЯ, КЛАССИФИКАЦИЯ, КЛИМАТИЧЕСКИЕ ПОСЛЕДСТВИЯ И ПРОБЛЕМЫ ПРОГНОЗИРОВАНИЯ

1.1. Эль-Ниньо – Южное колебание

Одним из наиболее выраженных климатических явлений, имеющий глобальный отклик в разных районах Земли, является Эль-Ниньо – Южное колебание (ЭНЮК). ЭНЮК – глобальный квазипериодический процесс межгодового масштаба с характерным периодом от двух до семи лет. Он проявляется как первая мода межгодовой изменчивости глобальных аномалий температуры поверхности океана (ТПО), вклад которой составляет 18% от общей дисперсии [Philander, 1989; Deser et al., 2010].

История становления научных знаний об ЭНЮК началась более полутора веков назад. Своим названием оно обязано перуанским рыбакам, которые в период Рождества замечали потепление вод Тихого океана у берегов Южной Америки от Эквадора до северного Перу. Это теплое течение в честь Рождественского праздника получило название Эль-Ниньо, что в переводе с испанского означает «младенец, мальчик». Особенность этого течения заключалось в том, что холодные, обогащенные кислородом воды заглублялись, а на смену им приходили теплые, менее насыщенные питательными элементами воды, в результате чего рыбный улов заметно сокращался.

В начале XX века Гилберт Уокер изучая изменения атмосферного давления на уровне моря в западной и центральной частях Тихого и Индийского океанов [Walker, 1924], заметил: когда атмосферное давление в пункте порт Дарвин в Австралии повышается, то в пункте о. Таити в Тихом океане оно падает, и наоборот. Этот процесс изменения в приземном давлении, подобный «качелям», Уокер назвал Южным Колебанием (ЮК). В конце 1960-х, профессор Я. Бьеркнес, используя данные, собранные за 1957-58 гг., и существовавшие на то время исследования Перуанского прибрежного течения, определил физические

механизмы, связывающие изменения ТПО в восточно-экваториальной части Тихого океана вблизи побережья Перу и Эквадора с изменениями давления над уровнем моря западной части Тихого океана [Bjerknes, 1966]. В начале 1980 г. было определено, что Эль-Ниньо и Южное Колебание являются двумя характеристиками одного большого процесса в системе океан-атмосфера, которое получило название Эль-Ниньо – Южное Колебание [Rasmusson, Carpenter, 1982].

Рассмотрим подробно ЭНЮК и его аномальные состояния, взяв за основу [Артамонов и др., 1991, Полонский, 2008]. В обычные (неаномальные) годы циркуляция вод в тропической зоне Тихого океана характеризуется наличием западных пассатных течений (Северного и Южного), возбуждаемых пассатными ветрами, и системой восточных экваториальных подповерхностных противотечений (Межпассатного противотечения, течения Кромвелла, Южного экваториального противотечения). Северное и Южное пассатные течения нагоняют теплые поверхностные воды в западную часть Тихого океана. Толщина верхнего квазиизотермического слоя, температура которого превышает 29°C , достигает здесь 150 м. У восточного побережья воды верхнего термоклина с температурой 20°C выклиниваются к поверхности. В результате создается градиент давления, направленный на восток, что приводит к формированию в окрестности экватора противотечения (течения Кромвелла). Другие два противотечения, Межпассатное и Южное экваториальное, формируются в районе штилевых зон ВЗК Северного и Южного полушарий, приблизительно между 3 и 5 градусами, соответственно северной и южной широты. Интенсивность северо-восточных пассатов Северного полушария обычно возрастает в зимний период из-за усиления циркуляционной ячейки Хэдли в атмосфере, обусловленной разностью температур между полюсами и экватором. Соответственно юго-восточный пассат Южного полушария интенсифицируется в период усиления циркуляции Хэдли зимой Южного полушария (т.е. летом Северного полушария). Такой сезонный цикл атмосферной циркуляции приводит к внутригодовым вариациям интенсивности и расходов зональных течений, запаздывающих по фазе относительно сезонных вариаций поля ветра. Одновременно изменяется

зональный перепад температуры на поверхности океана. Вместе с тем, значительные климатические зональные градиенты температуры на поверхности океана в экваториальной зоне приводят к формированию в экваториальной атмосфере циркуляционной ячейки Уокера. Она характеризуется восходящими движениями в западной части акватории (возникающими вследствие интенсивной конвекции над областью теплых поверхностных вод), нисходящими в восточной части океана (в области апвеллинга), восточными ветрами в нижней и западными - в верхней тропосфере. Усиление пассатов сопровождается увеличением зонального градиента температуры в верхнем слое океана. Таким образом, между интенсивностью пассатных течений и циркуляцией Уокера существует положительная обратная связь.

Классической и наиболее принимаемой схемой зарождения и эволюции Эль-Ниньо считается схема обратной связи Я.Бьеркнеса [Bjerknes, 1966]. Приведем ее подробное описание. Типичное Эль-Ниньо начинается весной Северного полушария. Происходит резкое ослабление ячейки Уокера, что сопровождается ослаблением пассатных ветров. Ветер в нижней тропосфере может иметь при этом даже незначительную западную компоненту. Индекс ЮК становится, соответственно, отрицательным. Резкое изменение атмосферных условий вызывает быстрый океанический отклик, носящий характер свободных экваториально-захваченных волн. Масса теплой поверхностной воды устремляется из западной в восточную часть акватории и формирует теплую аномалию в центральной и восточной частях экваториальной зоны Тихого океана, достигающую и даже превышающую в отдельные годы 5°C . Время распространения этой аномалии на всю акваторию составляет несколько месяцев и определяется скоростью экваториально захваченных волн. В период развития ЭНЮК усиливается вся система экваториальных противотечений, что приводит к модификации параметров свободных экваториальных волн по сравнению с горизонтально-однородным океаном.

Одновременно с генерацией свободных волн и интенсификацией экваториальных противотечений ослабление пассатной циркуляции в атмосфере

приводит к ослаблению прибрежного апвеллинга. Оно вызывается аномалиями меридиональных ветров пассатной зоны. Поскольку время распространения экваториальных волн от одного берега Тихого океана до другого существенно превышает время релаксации прибрежного апвеллинга к изменениям локальных ветровых условий, происходящих во всей пассатной зоне, теплые аномалии поверхностной температуры вначале отмечаются на береговых станциях Южной Америки, расположенных к югу от 5° ю.ш.. Они возникают почти одновременно со сменой знака индекса ЮК, т.е. весной Северного полушария. В районе экватора потепление поверхности океана обычно происходит на 2-3 месяца позже. В развитии и поддержании высокоамплитудной теплой аномалии в океане принципиальную роль играет положительная обратная связь между аномалиями температуры воды и аномалиями интенсивности ячейки Уокера. Действительно, формирующаяся в начальный период развития ЭНЮК теплая аномалия в прибрежной зоне Южной Америки способствует ослаблению циркуляции в ячейке Уокера или, другими словами, ослаблению пассатных ветров в приводном слое. Это, в свою очередь, приводит к дальнейшему развитию теплой аномалии в восточной и центральной частях экваториальной зоны Тихого океана. Только после того, как сформируется устойчивая аномалия температуры воды на большей части акватории экваториальной зоны Тихого океана, она начинает оказывать прямое влияние на интенсивность циркуляции Хэдли. Атмосферные аномалии обеспечивают формирование глобального отклика гидрометеорологических полей. Обычно это происходит в конце года ЭНЮК (“0-й год”) по терминологии [Rasmusson, Carpenter, 1982], или в первый месяц следующего, (“+1 года”). Аномально теплая вода в экваториальной зоне Тихого океана интенсифицирует циркуляцию Хэдли за счет увеличения (по сравнению с обычными величинами) разности ТПО между полюсами и экватором. Интенсификация ячейки Хэдли приводит к усилению пассатных ветров и к восстановлению обычной климатической ситуации в океане или к возникновению противоположного явления Ла-Нинья.

Существует ряд теоретических схем ЭНЮК [Neelin et al., 1998; Lin, 2009], которые так или иначе подтверждают и дополняют обратную связь Я. Бьеркнеса. Среди них теория стохастического воздействия [McWilliams, Gent, 1978; Lau, 1985], теория осциллятора «загрузки-разгрузки» [Jin, 1997], теория запаздывающего осциллятора [Suarez, Schopf, 1988; Münnich et al., 1991], теория осциллятора адвективного отражения [Picaut et al., 1997] и теория западно-тихоокеанского осциллятора [Weisberg, Wang, 1997].

Однако современные климатические модели, включающие эти схемы, по-прежнему испытывают трудности при моделировании фаз ЭНЮК и весьма чувствительны к различным физическим параметрам [Lin, Qian, 2019]. Теории модуляции ЭНЮК удобны для объяснения обратной связи между атмосферой и океаном в момент, когда интенсифицируется и эволюционирует Эль-Ниньо и после. Они также могут объяснять чередование фаз ЭНЮК, однако эти теории не объясняют причину, по которой происходит интенсификация цикла.

Основным фактором, предшествующим явлению Эль-Ниньо, служит аномально высокий объем теплой воды в экваториальной части Тихого океана. Такая аномалия может оставаться длительное время неподвижной, до момента некоторого высокочастотного возмущения атмосферы [McPhaden, Yu, 1999; Vecchi, Harrison, 2000; Fedorov et al., 2015]. Интенсификация обратной связи Я.Бьеркнеса происходит по причине событий западного ветра (СЗВ) над западно-экваториальным теплым бассейном Тихого океана, которые долгое время считалось стохастическим процессом.

В ранней работе [Zhang, Gottschalck, 2002] было показано влияние колебания Маддена-Джулиана (КМД) на ЭНЮК. Заблаговременность такого воздействия равнялась от 4 до 12 месяцев (корреляция 0.4-0.5). Также обсуждалась взаимосвязь с азиатскими и австралийскими муссонными ветрами, аномалии которых могли приводить к СЗВ, а также регулировать тип Эль-Ниньо [Xu, Chan, 2001]. Несколько позже исследователи связали СЗВ с колебанием КМД [Chiodi et al., 2014; Puy et al., 2016; Liang, Fedorov, 2021]. Так в работе [Chiodi et al., 2014] было показано, что события КМД во второй половине весны, когда

индекс КМД превышал 1, а КМД находилась в 6-7 фазе (конвекция над западной частью Тихого океана), сопровождаемые СВЗ, приводят к интенсификации экваториальной волны Кельвина, тем самым запуская явление Эль-Ниньо. Такое поведение было отмечено для всех наблюдаемых интенсивных Эль-Ниньо за период 1986–2010 гг. Аномалия ТПО, захваченная волной Кельвина, достигает берегов Латинской Америки на 80-100 день. Однако Эль-Ниньо 2014 года, которое должно было стать одним из сильнейших за всю историю наблюдений, интенсифицировалось только весной следующего года, что рассмотрено, например, в [Levine, McPhaden, 2016; Puу et al., 2019; Hu, Fedorov, 2017].

Авторы [Puу et al., 2019] пришли к выводу, что событие 2014 года, прогнозируемое моделями как супер-Эль-Ниньо, не произошло из-за отсутствия поддержки СВЗ в момент эволюции Эль-Ниньо, что привело к наблюдению лишь слабого события. В то время как Эль-Ниньо 2015, самое интенсивное за всю историю наблюдений, поддерживалось регулярными СВЗ. Авторы делают вывод о важности СВЗ в период июнь-июль.

В то же время авторы работы [Liang, Fedorov, 2021] связали проблему Эль-Ниньо-2014 с отсутствием усиления СВЗ с помощью тропических циклонов. Авторы демонстрируют, что поддержка смещенных ближе к экватору тропических циклонов чрезвычайно важна для интенсификации Эль-Ниньо. Так по результатам их исследований 74% аномальных СВЗ в сезон с декабря по апрель связаны с влиянием тропических циклонов.

Несмотря на успехи в понимании спускового механизма Эль-Ниньо, модельное прогнозирование состояния КМД ограничено масштабом, равным 15-20 суткам, что не дает возможности расширить заблаговременность прогноза интенсификации событий Эль-Ниньо и Ла-Нинья на более длительный период.

Межгодовые изменения состояния интенсивности КМД могут регулироваться глобальными механизмами взаимодействия океана-атмосферы. В многочисленных исследованиях, например [Yang, Xu, 1994; Sankar-Rao et al., 1996; Vamzai, Shukla, 1999], показана статистически значимая связь между аномалиями зимнего снежного покрова Евразии с летними индийскими

муссонными осадками. Такая связь может быть обусловлена как результатом наличия некоторой атмосферной связи между высокими субтропическими широтами, так и наличием некоторого глобального колебательного процесса в глобальной системе океан-атмосфера [Bamzai, Shukla, 1999]. Несколько позже было показано, что аномалии снежного покрова также связаны с фазами Арктического колебания (АК). Так в работе [Bamzai, 2003] отмечено, что положительная/отрицательная аномалия АК в январе приводит к отрицательной/положительной аномалии снежного покрова в Северном полушарии в зимний сезон (с января по апрель). Отметим, что АК изначально было определено как Североатлантическое колебание (САК), полученное в результате разложения геопотенциала на изобарической поверхности 500 гПа [Thompson, Wallace, 1998]. САК является колебанием давления в Северной Атлантике между Азорским максимумом и Исландским минимумом. В то же время известно, например, [Полонский и др., 2004; Polyakova et al., 2006], что климат Евразии в значительной степени определяется САК.

Таким образом, на основе анализа литературных источников, можно предположить следующую схему инициации событий ЭНЮК, заблаговременность которой соответствует 6-12 месяцам:

1. Состояние САК в декабре-январе влияет на снежный покров Северного полушария;
2. Аномалии снежного покрова Северного полушария зимой посредством неявного механизма передачи климатического сигнала влияют на муссонные осадки летом, следовательно, и на интенсивность КМД;
3. Интенсификация КМД вызывает СЗВ и, при условии достаточного накопления объема теплой воды в западно-экваториальном бассейне Тихого океана, приводит к запуску Эль-Ниньо. В случае поддержки (отсутствия поддержки) СЗВ тропическими циклонами событие Эль-Ниньо может быть интенсивное (менее интенсивное).
4. Максимальная фаза Эль-Ниньо достигается зимой следующего года.

1.1.1. Типизация событий Эль-Ниньо и Ла-Нинья

Современные исследования показывают, что эволюция событий ЭНЮК носит во многом индивидуальный характер. В первом десятилетии XXI века было обнаружено, что распределение теплых аномалий ТПО в период зрелой фазы событий Эль-Ниньо ведет себя нетипично. После 1990-х годов аномалия ТПО смещается больше к западу относительно центральной части Тихого океана по сравнению с аномалиями событий Эль-Ниньо до 1990 года, что также приводило к значительным изменениям конвекции, вертикального движения воздуха и осадков над тропиками [Ashok et al., 2007; Yuan, Yang, 2012].

Классические события Эль-Ниньо, описанные в работах [Bjerknes, 1966; Rasmusson and Carpenter, 1982], стали называть «типичными», «каноническими» или Восточно-Тихоокеанским типом Эль-Ниньо. Однако, наряду с «типичными» наблюдались события, которые по времени наступления, локализации аномалии ТПО и по продолжительности значительно отличались от них. Этот другой тип Эль-Ниньо имел разные названия: «неявный» (ambiguous) [Kane, 1997], «Транс-Ниньо» (Trans-Nino) [Trenberth, Stepaniak, 2001], «Эль-Ниньо линии перемены дат» (Dateline El Nino), [Larkin, Harrison, 2005], «Эль-Ниньо Модоки» (Modoki) [Ashok et al., 2007], «Теплый бассейн Эль-Ниньо» (Warm Pool El Niño) [Kug et al., 2009], Центрально-тихоокеанский (ЦТ) тип Эль-Ниньо [Yeh et al., 2009]. Характерной особенностью «неканонических» событий Эль-Ниньо является формирование области положительных аномалий ТПО в центре тропиков Тихого океана и области отрицательных или нейтральных аномалий ТПО у Южноамериканского побережья в начальную фазу.

Рассмотрим подробнее пространственные классификации Эль-Ниньо. Их основной отличительной особенностью считается локализация аномалии ТПО. Так в классификации [Kug et al., 2009], в которой новый тип упомянут как Теплый бассейн Эль-Ниньо, на основе ряда ТПО за период 1970-2005 выделено 3 типа: Теплый бассейн, Холодный язык и третий тип, имеющий черты первых двух, также называемый «смешанным». Максимумы двух основных типов наблюдались

в районе Nino 3 (5° с.ш.- 5° ю.ш., 150° з.д.- 90° з.д.) и Nino 3.4 (5° с.ш.- 5° ю.ш. и 170° з.д.- 120° з.д.). Максимум смешанного типа локализован в районе с координатами 5° с.ш.- 5° ю.ш. и 150° з.д.- 120° з.д.

Одна из наиболее признанных, в первую очередь, за свою простоту классификаций принадлежит доктору С. Йеху и группе авторов [Yeh et al., 2009]. Классификация проводилась с использованием индексов Nino3 и Nino4 (5° с.ш.- 5° ю.ш., 160° в.д.- 150° з.д.) в зимний сезон (декабрь, январь, февраль). Если АТПО в области Nino3 превышало по значению АТПО в Nino4, то тип ЭН считался Восточно-Тихоокеанским. При обратной ситуации тип ЭН будет Центрально-Тихоокеанским.

Другой подход пространственных классификаций предложен в работах [Ashok et al., 2007; Takahashi et al., 2011] Этот подход основывается на разложении ТПО в экваториальной и тропической области Тихого океана на эмпирические ортогональные функции (ЭОФ). В работе [Ashok et al., 2007] за 26 летний период 1979-2004гг. Разложение показало, что вторая мода, названная Модоки, объясняет 12% дисперсии. Также авторами был предложен индекс Эль-Ниньо Модоки (ИЭМ), представляющий из себя выражение $ИЭМ=A-B-C$, где А расположено в районе (165° в.д.- 140° з.д, 10° ю.ш.- 10° с.ш.), В – (110° з.д.- 70° з.д., 15° ю.ш.- 5° с.ш.) и С – (125° в.д.- 145° в.д., 10° ю.ш.- 20° с.ш.).

Обобщенную схему всех пространственных классификаций можно почерпнуть, к примеру, из современной работы [Ludescher et al., 2023]. Схема приводится на рис. 1.1.

Method	51	53	57	58	63	65	68	69	72	76	77	79	82	86	87	91	94	97	02	04	06	09	14	15	18
Ashok 2007	E	E	C	C	C	C	C	E	E	E	C		E	E	E	C	C	E	C	C	E	C	E	E	
Feng 2020	E		E		E	E	C		E	E	C		E	E		C	C	E	C	C	E	C	E	E	
Kao 2009	E	C	C	C	C	C	C	C	E	E	C	C	E	C	C	C	C	E	C	C	E	C	C	E	C
Kim 2009	E		E		E	E		C	E	E			E		E	C	C	E	C	C					
Kug 2009	E		E		E	E	C		E	E	C		E	M	M	M	C	E	C	C	E	C	E	E	M
Larkin 2005	E		E		C	E	C	E	E	E	C	C	E	C	E	E	C	E	E						
Ren 2011	E	C	E	C	C	E	C	E	E	E	C		E	E	C	E	C	E	C	C	E	C			
Takahashi 11	E		C		C	C	C		E				E	M	C	C	C	E	C	C	C	C		M	C
Wiedermann 16		C	E	C	C	E	C	C	E	E	C	C	E	C	C	C	C	E	C	C	C	C	C	E	
Yeh 2009	E		E		E	E	C	E	E	E	C	E	E	E	E	E	C	E	C	C	E				M
Yu 2013	M	M	C		C	C	C	C	M	M	C		E	M	C	C	C	E	C	C	M	C			
Consensus	E	C	E	C	C	E	C	M	E	E	C	C	E	M	M	C	C	E	C	C	E	C	E	E	C

Рисунок 1.1 – Обобщенная схема классификации 11 подходов [Ludescher et al., 2023]. Цифры в первом ряду обозначают две последние цифры года начала Эль-Ниньо. Двухлетние Эль-Ниньо представлены как два отдельных года. ВТ Эль-Ниньо отмечены буквой «Е» (оранжевый цвет). ЦТ Эль-Ниньо отмечены буквой «С» (синий цвет). События Эль-Ниньо, отмеченные буквой «М» - смешанные и не идентифицируются как чистые события ВТ или ЦТ типа

Помимо пространственного подхода к классификации Эль-Ниньо отмечены и нетривиальные методы классификации.

Так, распространение получила классификация, основанная на времени начала события. Авторы работы [Ху, Chan, 2001] за момент начала ЭН принимали месяц, когда ТПО в центральном приэкваториальном районе Тихого океана (5° ю.ш.– 5° с.ш., 170° – 120° з.д.) на 0.5°C превышала многолетнюю норму (среднемесячное значение за 1950-1997 гг.). На основании этих данных за период 1950-1997 гг. они выделили 6 весенних (начало в апреле или мае) и 6 летних (начало в июле или августе) событий. Построенные композиты показали, что весенние события более интенсивные (выше АТПО) и более длительные, чем летние. Авторы также подробно описали атмосферные и океанические условия, предшествующие тому или иному типу ЭН.

Часть исследователей для типизации использовала количественные характеристики Эль-Ниньо. В работах [Hanley et al., 2003; Quinn et. al., 1987] и др. авторы считали, что одно событие ЭН от другого отличалось только по своей интенсивности (т.е. по величине аномалии ТПО у Перуанского побережья, либо в центральных районах Тихого океана) и обычно выделяли сильные и слабые события.

Авторы работы [Hori, Hanawa, 2004] на основании исследования АТПО в центре Тихого океана за 1871-2000 гг. также выделили 2 типа событий ЭН: весенний (начало апрель-июнь) и летне-осенний (начало июль-октябрь). Весенние ЭН отличались более высокими величинами АТПО, зрелая фаза наступала зимой северного полушария, и эволюция всех событий этого типа происходила одинаковым образом. Летне-осенние события характеризовались более низкими величинами АТПО и в своем развитии имели нерегулярные особенности. Продолжительность весенних событий в среднем составляла 10-17 месяцев, тогда как летне-осенних 7-28 месяцев. Далее летне-осенние ЭН были разделены на 2 подтипа в зависимости от того, закончилось ли ЭН в течение того года, когда оно началось (короткоживущие) или на следующий год (продолжительные). Продолжительные ЭН эволюционируют в течение 12 и более месяцев и имеют 2-3 максимума, продолжительность короткоживущих ЭН составляет менее 12 месяцев. Т. Хории и К. Ханавы сделали предположение о том, что существование разных типов ЭН связано с характером взаимодействия океана и атмосферы в приэкваториальных районах Тихого океана.

Позже эти же авторы вместе с Т. Хасегава использовали данные о состоянии атмосферы и величине теплосодержания верхнего 300-метрового слоя океана за 1955-2003 гг. и выделили 2 типа ЭН – А и В [Hasegawa et. al., 2006]. События типа А характеризуются резким уменьшением теплосодержания верхнего слоя тропического океана после зрелой фазы, в то время как после событий типа В этого не происходит. Кроме того, Эль-Ниньо типа А сопровождаются большими аномалиями полей в атмосфере и тропическом океане

и отличаются большей продолжительностью. За период 1955-2003 гг. было выделено 12 событий ЭН, из них семь относятся к типу А и пять – к типу В.

Также можно отметить и трехтипные классификации. В работе [Воскресенская, Михайлова, 2010] классификация проводилась на основе длительности события, времени его начала и интенсивности. В результате выделено три типа событий Эль-Ниньо: весенний, летне-осенний короткоживущий и летне-осенний продолжительный. При этом Эль-Ниньо весеннего типа характеризуются большей интенсивностью и существуют около одного года, летне-осенние короткоживущие менее интенсивны и имеют продолжительность около 9 месяцев, а продолжительные события, начинающиеся во второй половине года, характеризуются небольшой амплитудой температурной аномалии и продолжаются не меньше 18 месяцев. Трехтипной можно назвать и описанную выше классификацию авторов работы [Hori, Hanawa, 2004].

Таким образом, все исследователи сходятся во мнении, что события ЭН отличаются друг от друга по целому ряду признаков: времени начала события, его продолжительности, интенсивности, пространственному распределению тепла в верхнем 300-метровом слое, характеру взаимодействия океана и атмосферы, локализации, причинам возникновения. Каждый из указанных признаков использовался в мировой науке в качестве основы для классификации, однако, наиболее перспективным представляется комплексный подход, когда для классификации используется не один признак, а несколько. Так в работе [Лубков, 2017а] предложена пространственно-временная объективная классификация Эль-Ниньо, описанная в этой работе в Приложении А. В классификации удалось статистически обоснованно определить две группы событий Эль-Ниньо, пространственное распределение которых соответствует известным ранее полученным закономерностям из [Kug et al., 2009; Yeh et al, 2009]. При этом восточно-тихоокеанский тип начинается с апреля по июль и отличается сравнительно большей интенсивностью и продолжительностью, а центрально-тихоокеанский тип начинается в сентябре-октябре и является менее интенсивным и менее продолжительным.

Идея о существовании нетипичности событий Ла-Нинья, как и в случае его признания, возникли несколько позже, чем в случае Эль-Ниньо. На фоне идей о классификации Эль-Ниньо в начале 2000-х появились первые работы на основе непродолжительных данных, посвященные классификации холодной фазы ЭНЮК. Стоит отметить, что классификацию Ла-Нинья в первую очередь, рассматривали в ключе локализации минимальной аномалии феномена либо в результате того же разложения на ЭОФ где ЛН представляло собой противоположную ЭН фазу ЭНЮК. Так в работах [Ashok et al., 2007; Као, Yu, 2009], в первую очередь, посвященных классификации Эль-Ниньо, авторы отметили о возможности классификации Ла-Нинья по такой же методике. В работе [Singh et al., 2011] на основе ЭОФ за период 1978-2009гг. было подтверждено наличие двух типов Ла-Нинья. В работе [Shinoda et al., 2013] отмечается, что по спутниковым данным события ЦТ Ла-Нинья можно четко отличить от событий ВТ Ла-Нинья. В то же время многие исследователи высказывались о невозможности пространственной классификации Ла-Нинья [Kug, Nam, 2011; Ren, Jin, 2011].

Несколько позже, с появлением более длинных рядов данных ТПО, имеющих пространственное разрешение 2° и менее, идея о наличии двух типов Ла-Нинья стала закрепляться в научном сообществе. В работах [Yuan, Yan, 2013; Zhang et al., 2014; Ding et al., 2017] использовалась классификация [Yeh et al., 2009], ранее примененная для определения типа Эль-Ниньо. Если аномалия ТПО в районе Nino 3 зимой была меньшей чем в районе Nino 4, то тип Ла-Нинья определялся как Восточно-Тихоокеанский. В обратной же ситуации, когда Nino 4 меньше Nino 3 тип Ла-Нинья определялся как Центрально-Тихоокеанский. Как отмечено в работах [Yuan, Yan, 2013; Zhang et al., 2014], для ВТ характерно зарождение аномалии на западе Экваториальной части Тихого океана и ее последующее смещение на восток, где к зиме отрицательная аномалия ТПО становится меньше в районе Nino 3. Для ЦТ ЛН свойственная зарождение и локализация минимальной аномалии ТПО в районе Nino 4.

В работе [Воскресенская, Марчукова, 2017] наличие пространственных типов было подтверждено с помощью иерархического кластерного анализа, а в более поздних работах выявлены особенности в полях хлорофилла «А» в зависимости от типа ЛН [Марчукова, Воскресенская, 2022], и даже обнаружена закономерность чередования событий Эль-Ниньо и Ла-Нинья и их типов [Marchukova et. al., 2020]. Так, следом за интенсивным ВТ Эль-Ниньо обычно наблюдается два события Ла-Нинья (или, так называемое, двухлетнее Ла-Нинья).

1.1.2. Воздействие событий Эль-Ниньо и Ла-Нинья и их типов на окружающую среду и климат

Экстремальные фазы ЭНЮК и их типы приводят как к тихоокеанским, так и к глобальным климатическим откликам. Однако, если влияние ЭНЮК на тропический климат очевидно, то вопросами глобальных климатических откликов мировое научное сообщество занимается и по сей день. В ранних исследованиях были показаны связанные с ЭНЮК значимые глобальные аномалии температуры воздуха и осадков [Ropelewski, Halpert, 1987; Kiladis, Diaz, 1989; Shabbar, Khandekar, 1996; Livezey et al., 1997; Бышев, 2003], смещение траекторий циклонов в Тихом океане [Fraedrich et al., 1992; Chen, Dool, 1997] и связь с САК [Voskresenskaya, Polonsky, 1993]. В работах [Гущина, Петросянц, 1998; Петросянц, Гущина, 1998] была изучена продолжительность воздействия ЭНЮК на атмосферную циркуляцию, которая составила десять и более месяцев.

В подтверждение возможности обнаруженных значимых глобальных климатических откликов ЭНЮК [Liu, Alexander, 2007] была предложена схема «атмосферного моста», которая на сегодня считается наиболее приемлемой. Схема описывает механизм передачи климатического сигнала из экваториальных районов в средние и высокие широты. Так, например, при событиях Эль-Ниньо интенсификация теплой аномалии ТПО в центральной экваториальной части Тихого океана и у берегов Южной Америки приводит к возникновению атмосферных волн Россби, которые распространяются к полюсам и на восток, и

впоследствии преломляются от полюса к тропикам. Воздействие на глобальную атмосферу в средних и высоких широтах устанавливается в течение 2-6 недель. Атмосферный мост более эффективен в зимний сезон, тогда углубляется Алеутский минимум, усиливаются холодные северо-западные ветры над центральной частью Тихого океана, а более теплые и влажные южным ветры вдоль североамериканского западного побережья [Liu, Alexander, 2007].

Несмотря на противоположный характер аномалий в тропиках, связанный с ЭН и ЛН, возникновение аномалий гидрометеорологических характеристик в годы Эль-Ниньо не являются зеркальным отражением аномалий в годы Ла-Нинья [Hoerling et al., 1997; Нестеров, 2013]. Это связано как с различной продолжительностью Эль-Ниньо и Ла-Нинья [Okumura et al., 2010], так и с различиями во времени начала явлений, их интенсивности и локализации аномалий ТПО. При этом, 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], но иметь разные проявления в глобальной климатической системе в каждый следующий год события, что, вероятно, связано со сменой пространственного типа аномалии ТПО.

Появление глобальных массивов данных, содержащих ретроспективу среднемесячных метеорологических характеристик с середины XIX века, дало возможность изучить на значимом уровне проявления явлений экстремальных фаз ЭНЮК. В последние несколько десятилетий мировое сообщество ученых уделяет особое внимание климатическим откликам явлений ЭН и ЛН, которые зачастую рассматриваются в контексте двух пространственных типов [Larkin, Harrison, 2005; Yuan, Yang, 2012; Yuan, Yan, 2013; Yuan et al., 2012; Tedeschi et al., 2013; Yu, Zou, 2013; Wang, Asefa, 2018; Voskresenskaya et al., 2018; Lubkov et al., 2020].

Климатические отклики на два типа Эль-Ниньо для осени и зимы на примере температуры и осадков выявлены [Larkin, Harrison, 2005]. Осенью в северном полушарии знак аномалии в полях температуры противоположный: для ЦТ типа характерны отрицательные аномалии, а для ВТ Эль-Ниньо – положительные. При этом для зимнего сезона показано наличие значимых ($p=0.2$)

откликов по всему земному шару. В [Yuan et al., 2012; Yuan, Yang, 2012] показаны различия между типами ЭН, которые приводят к значительным изменениям в системе конвекции, вертикального движения воздуха и к изменениям аномалий осадков в тропической зоне Тихого океана. Авторы [Yuan, Yan, 2013] получили отклики на типы ЛН в пределах 40° широты, где показали, что два типа ЛН отличаются по интенсивности аномалий осадков, однако поля аномалий осадков схожи. В работе [Yu, Zou, 2013] показано, что атмосферное струйное течение в северной части Тихого океана при двух типах Эль-Ниньо смещается на юг, при этом ЦТ тип приводит к более южному его расположению в сравнении с ВТ типом. Такие различия обусловили разницу в осадках и стоке рек Северной Америки, исследованную [Wang, Asefa, 2018]. Авторы показали, что два типа ЭН приводят к более влажным зиме и весне во время Эль-Ниньо, однако климатическая аномалия при ВТ Эль-Ниньо интенсивней, чем при ЦТ типе. Они также изучили влияние явлений Ла-Нинья, которые связали с более сухими условиями, однако типы Ла-Нинья отдельно не рассматривали. В работе [Tedeschi et al., 2013] получены значимые отклики в полях аномалий ТПО по всему земному шару, включая северную Атлантику, а также подробно рассмотрены аномалии атмосферных осадков в южной Америке и южной Атлантике, связанные с ЭНЮК. Отклики на два типа ЭН сильно отличались друг от друга, в то время, как для разных типов ЛН различия в полях аномалий были незначительны. В то же время в работах [Zhang et al., 2014; Voskresenskaya et al., 2018] было продемонстрировано существенное влияние двух типов ЛН на САК в зимний период и показано, что ЦТ Ла-Нинья приводят к положительным значениями индекса САК, а ВТ – к отрицательным. Достижение максимальных аномалий ЭНЮК по времени года совпадает с интенсификацией атмосферной циркуляции в Северном полушарии и наблюдается в конце осени и зимой. Следовательно, изучение атмосферных откликов ЭНЮК на Северное полушарие представляет особый интерес.

Рассмотрим изученность климатических откликов в Атлантико-Европейском регионе и северной Азии с акцентом на осенне-весеннее межсезонье

и зиму. В ранних работах, например, [Voskresenskaya, Polonsky, 1993; Нестеров, 2000; Mokhov, Smirnov, 2006], показано, что на Североатлантическое колебание и Арктическую циркуляцию, которые играют ключевую роль в формировании климата Европы и Северной Атлантики, существенно влияют теплая и холодная фазы ЭНЮК. Из [Воскресенская, Михайлова, 2006] известно, что зимой в годы Эль-Ниньо приземное давление уменьшается над Южной и Центральной Европой и увеличивается над Северной Европой, Исландией и Гренландией, что обуславливает аномально холодные зимы в Северной Европе. В работах [Larkin, Harrison, 2005; Graf, Zanchettin, 2012] с учетом двух пространственных типов Эль-Ниньо были получены аномалии осенью и зимой. ЦТ Эль-Ниньо приводит к положительным аномалиям температуры в Северной Азии и Европе осенью и к отрицательным – зимой. Для ВТ Эль-Ниньо наиболее характерны положительные аномалии температуры зимой в Европейском регионе, в особенности в ЕТР. Эти результаты уточнены в [Lubkov et al., 2020], где климатические аномалии были рассмотрены по месяцам и декадам. Было показано, что атмосферные отклики имеют изменчивый характер и климатические аномалии могут меняться на противоположные от месяца к месяцу. [Li et al., 2017] по спутниковым данным за относительно короткий временной период (1982-2015 гг.) была проанализирована весенняя вегетация растительности в Евразии с точки зрения двух типов явления Эль-Ниньо и, так же как и в [Graf, Zanchettin, 2012], были отмечены статистически значимые климатические отклики на центральный Эль-Ниньо.

В работах [Нестеров, 2000; Mokhov, Smirnov, 2006] был сделан акцент на то, что в годы Ла-Нинья происходит большая изменчивость циркуляции атмосферы в Атлантико-европейском регионе, чем в годы Эль-Ниньо. Однако, эти исследования были сделаны без учета пространственных типов Ла-Нинья, что могло сгладить климатический отклик. Позже, [Zhang et al., 2014] показано противоположное влияние типов ЛН на САК. Этот тезис был уточнен в работе [Voskresenskaya et al., 2018]. Помимо противоположных аномалий в поле давления в январе и феврале над северной Атлантикой, было показано смещение

траекторий циклонов севернее при ЦТ Ла-Нинья. Климатический отклик на типы Ла-Нинья в северной Азии практически не изучался. Климатические отклики в северной Азии на события ЭНЮК наиболее полно изучены в вопросе фазового перехода от ЭН к ЛН. В работах [Mokhov, Timazhev, 2017; Mokhov, Timazhev, 2022] рассмотрены возможные климатические отклики в характеристиках температуры воздуха, влагопереноса, количества выпавших осадков для весенних и летних месяцев.

Климатические отклики, связанные с экстремальными состояниями ЭНЮК, зачастую приводят к негативным социально-экономическим последствиям. Так засуха в США во время событий Ла-Нинья 1988 г. привела к ущербу в 40 млрд. \$ [Glantz, 2002] Ущерб сельскохозяйственного сектора США от Эль-Ниньо 1997 года и последующего за ним Ла-Нинья 1998 года был оценен в размере 1.5-1.7 млрд. \$ и 2.2-6.5 млрд. \$ соответственно [Adams et al., 1999]. Современные оценки [Callahan, Mankin, 2023] показывают глобальный ущерб, связанный с событиями Эль-Ниньо 1982 и 1997 годов, в размере 4.1 и 5.7 трлн. \$. При этом ожидается, что в 21 столетии в связи с глобальным потеплением повторяемость экстремальных фаз ЭНЮК увеличится, а суммарный глобальный ущерб от всех событий Эль-Ниньо и Ла-Нинья достигнет 84 трлн. \$. Во время Эль-Ниньо 2015 года Индонезия, Австралия, Эфиопия, регионы Амазонки, юг Африки и Европа сильно пострадали от засух [IPCC, 2021]. Засухи, вызванные этим Эль-Ниньо, создали острую нехватку продовольствия в южной части Африки [IPCC, 2022] и гибель тропических лесов в Центральной Америке [Erfanian et al., 2017; Aragão et al., 2018]. Вопрос социально-экономического ущерба, связанного с ЭНЮК, указывает на острую необходимость прогноза и заблаговременного определения пространственного типа аномалии ТПО.

1.2. Современное состояние моделирования событий Эль-Ниньо и Ла-Нинья

На сегодняшний день для долгосрочного прогнозирования ЭНЮК используют два основных подхода: 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]. Среди динамических моделей выделяют простые [Hirst, 1986], модели с промежуточной связью [Zebiak, Cane, 1987], гибридные модели [Barnett et al., 1993] и совместные модели океана и атмосферы [Luo et al., 2016]. Большинство современных динамических моделей представляют собой совместные модели, то есть такие, в которых отдельные модели океана и атмосферы объединены в единую прогностическую систему со сложными алгоритмами усвоения данных. В табл. 1.1 приведен современный перечень динамических моделей, входящих в прогностический ансамбль Международного исследовательского института климата и общества Колумбийского университета (IRI). Все модели из этой таблицы кроме модели LDEO5 – совместные. Обычно на основе этих моделей и суждений группы синоптиков Климатического центра прогнозов США (Climate Prediction Center - National Oceanic and Atmospheric Administration – CPC/NOAA) дается прогноз состояния ЭНЮК, на который опирается ВМО. Следовательно, высокий интерес представляет Североамериканский мультимодельный ансамбль (The North American Multi-Model Ensemble – NMME), представляющий собой ядро моделей прогноза ЭНЮК.

Сейчас в NMME входят 7 совместных моделей: GFDL-Spear, GEM5-NEMO, CanCM4i, NCEP-CFSv2, COLA-CCSM4, NCAR-CCSM1 и NASA-GEOSS2S. Все модели, входящие в NMME, доступны в открытом доступе с разрешением 1° с возможностью ретроспективного анализа результатов моделирования. В [Barnston et al., 2019] сравнивались способности моделей ансамбля NMME по отдельности за ретроспективный период 1982-2016 гг. Авторы исследования выделили модель NCEP-CFSv2 как наиболее успешную. Модель NCEP-CFSv2 значительно лучше прогнозирует состояние ЭНЮК с заблаговременностью от 6 месяцев в летне-осенний сезоны в сравнении с другими моделями ансамбля.

Статистический подход подразумевает прогнозирование ЭНЮК некоторым математическим методом анализа исторических данных. Статистические модели могут быть линейными и нелинейными. Линейная статистическая модель строится с использованием методов множественной линейной регрессии [Tseng et al., 2017], канонической корреляции [Barnston, Ropelewski, 1992], цепей Маркова [Хуе et al., 2000] и т.д. Нелинейный же подход, чаще всего основан на методах машинного обучения, таких как «байесовские» и «нейронные» сети [Fang et al., 2022]. В табл. 1.2 приведен современный список статистических моделей, используемых для прогноза ЭНЮК IRI. Из этого списка только отечественная модель IAP-NN, предложенная в исследовании [Gavrilov et al., 2019], является нелинейной и представляет собой симбиоз двух методов: разложение на линейные динамические моды и искусственные нейронные сети. Также интерес представляет физико-статистическая модель NTU CODA [Chen et al., 2020], использующая внетропические индексы для прогноза состояния ЭНЮК с годовым опережением последнего. Авторы модели утверждают, что им удалось существенно улучшить воспроизводимость ЭНЮК в весенние и летние месяцы.

Таким образом, в настоящее время существует, по меньшей мере, 18 динамических (табл. 1.1) и 9 статистических (табл. 1.2) моделей, представленных на сайте IRI, которые применяются для прогнозирования ЭНЮК. При этом в работах [Tippett et al., 2012; Barnston et al., 2012; Tang et al., 2018] отмечено, что динамические модели справляются с прогнозом ЭНЮК на порядок лучше, чем статистические. Несмотря на это, динамические модели имеют ряд проблем, связанных как с неточными исходными данными, приводящими к ошибке начальных условий, так и с самой физикой и параметрами модели [Gao et al., 2024; Qi et al., 2017; Тао, Duan, 2019]. Начальные ошибки приводят к неопределенности начальных состояний и неизбежно увеличиваются по мере интеграции модели, что снижает способность к прогнозированию [Mu et al., 2015; Chen et al., 2023]. Более явной проблемой является стохастическое описание в моделях спускового механизма Эль-Ниньо, что вносит значительную

неопределенность в прогнозы весеннего и летнего сезонов [Vecchi, Harrison, 2000; Fedorov et al., 2015].

Таблица 1.1 – Динамические модели, используемые для прогноза состояния ЭНЮК

Модель	Институт	Страна	Разрешение	
			Атмосферный блок	Морской блок*
AUS-ACCESS	CSIRO Australian Community Climate and Earth System Simulator	Австралия	T216, 85	0.25°, 75
BCC_CSM11m	Beijing Climate Center	Китай	T106, 26	1°×1/3-1°, 40
CMC CANSIP	Government of Canada	Канада	T63, 35	1°×1/3-1°, 50
COLA CCSM4	University of Miami	США	288×200 (1.25°×0.9°), 26	1.11°×0.27-0.54°, 60
DWD	German Weather Service – Deutscher Wetterdienst	Германия	T127, 95	0.4°, 40
ECMWF SEAS5	European Centre for Medium-Range Weather Forecasts	Европа	T319, 91	0.25°, 75
GFDL Spear	NOAA	США	0.5°, 33	1°, 75
JMA	Tokyo Climate Center	Япония	T319, 100	0.25°, 60
KMA SNU	Korean Met Agency	Южная Корея	T106, 21	T512, 70
LDEO5	Lamont-Doherty Earth Observatory, Columbia University	США	5.625°×2°	2°×0.5°
MetFRANCE	Meteo France Seasonal Forecast	Франция	T359, 137	0.25°, 75
NCEP CFSv2	NOAA Climate Prediction Center NCEP	США	T128, 64	0.5°×0.25-0.5°, 40
SAUDI KAU	Saudi King Abdulaziz University Climate Center	Саудовская Аравия	T213,L44	0.25°, 51
SINTEX-F	Japanese Agency for Marine-Earth Science and Technology	Япония	T106, 31	0.5°, 31
UKMO	UK Met Office	Великобритания	T216, 85	0.25°, 75

Способности прогнозирования динамических и статистических моделей имеют выраженную сезонную изменчивость [Yu et al., 2009; Tippet et al., 2012; Qi et al., 2017], что, очевидно, связано с недостаточным пониманием спускового механизма, в первую очередь, явлений Эль-Ниньо [McPhaden, Yu, 1999; Vecchi,

Harrison, 2000; Fedorov et al., 2015]. 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 во второй половине весны и летом, когда обычно происходит интенсификация явлений Эль-Ниньо и Ла-Нинья, резко ухудшаются. Такое ограничение прогностических способностей модели получило название «весеннего порога предсказуемости» (ВПП) [Webster, Yang, 1992]. Проблемы спускового механизма мы обсуждали выше.

Таблица 1.2 – Статистические модели, используемые для прогноза состояния ЭНЮК

Модель	Институт	Страна	Краткое описание
CPC CA	NOAA CPC Canonical Correlation Analysis	США	Канонический корреляционный анализ
CPCMRKOV	NOAA CPC MARKOV	США	Цепь Маркова
CSU CLIPR	Colorado State University	США	Модель множественной линейной регрессии
IAP-NN	Институт прикладной физики имени А. В. Гапонова-Грехова РАН	Россия	Разложение на линейные динамические моды, использование ИНС
NTU CODA	Taiwan Computational Oceanography and Dynamics of Air-Sea Interaction Lab	Тайвань	Модель статистического прогнозирования на физической основе, представляющая некоторую функцию климатических индексов
UCLA TCD	UCLA Theoretical Climate Dynamics	США	Сингулярный спектральный анализ
UW PSL-CSLIM	University of Wisconsin	США	Циклостационарная линейная инверсивная модель
UW PSL-LIM	University of Wisconsin	США	линейная инверсивная модель

1.2.1. Прогноз пространственного типа явлений Эль-Ниньо и Ла-Нинья

Заблаговременное определение типа явлений Эль-Ниньо и Ла-Нинья является более сложной задачей, чем прогноз наступления самих событий. Особенно это относится к определению типа Эль-Ниньо, точность которого заметно уменьшилась последние 30 лет [Zhang et al., 2021; Gao et al., 2024]. Многие авторы заметили [Latif et al., 1997; Larkin, Harrison, 2005; Achok et al.,

2007; Kao, Yu, 2009], что, начиная с 1990-х годов, повторяемость ЦТ Эль-Ниньо значительно возросла. По результатам анализа будущих климатических проекций моделей проекта CMIP3 авторы работы [Yeh et al., 2009] получили пятикратное увеличение соотношения количества ЦТ к ВТ типу Эль-Ниньо в 21 веке. Последние исследования этого вопроса подтвердили, что изменение климата привело к увеличению частоты явлений ЦТ Эль-Ниньо с 1990-х годов [Ren et al., 2019; Dieppeis et al., 2021]. К тому же, низкая эффективность прогнозирования явлений ЦТ Эль-Ниньо серьезно снизила эффективность прогнозирования ЭНЮК в целом [Ren et al., 2019; Tao et al., 2020; Zhang et al., 2021].

В работе [Ren et al., 2019] показано, что только 2-3 из 6 отобранных в исследовании модели способны определить тип с заблаговременностью всего в 1 месяц. Что касается только Эль-Ниньо, зачастую ВТ тип более интенсивен, чем ЦТ, при этом оценить интенсивность предстоящего ЭН возможно на основе ансамбля динамических и статистических моделей заблаговременно за 6 месяцев. Так, Национальное управление океанических и атмосферных исследований США полагается на субъективные экспертные прогнозы, которые объективно переводятся в вероятности того, что сила Эль-Ниньо (по индексу Nino3.4) превысит заданные пороговые значения [L'Neureux et al., 2019]. Превышение заданного порогового значения будет указывать на ВТ тип.

Среди последних исследований, посвященных улучшению способности моделей прогнозировать типы ЭНЮК, можно выделить работы [Железнова, Гущина, 2020; Tseng et al., 2022; Ludescher et al., 2023], использующих физико-статистический подход к прогнозу ЭНЮК, заключающейся в создании некоторого физически обоснованного предикативного индекса. Авторы работы [Железнова, Гущина, 2020] предложили физико-статистическую модель на основе модели прогноза Эль-Ниньо Государственного университета Флориды [Clarke, Van Gorder, 2003]. В качестве предикторов модели авторы работы [Железнова, Гущина, 2020] использовали аномалии ТПО и теплосодержания океана (ТСО) в экваториальной части Тихого океана, индексы интенсивности колебания Маддена-Джулиана и волн Россби. Авторы отметили, что предложенная модель

несколько лучше способна прогнозировать ЦТ тип, в сравнении с ВТ. Коэффициент корреляции прогностической модели с заблаговременностью 12 месяцев в сравнении с действительными значениями для индекса ЦТ типа составил 0.55, а для индекса ВТ типа – 0.34.

В работе [Tseng et al., 2022] отмечена важность учета внетропического воздействия на экваториальную часть Тихого океана. Разработанный авторами индекс оказался значительно лучше для прогнозов ЦТ Эль-Ниньо, чем результаты динамического моделирования. Прогноз АТПО в области Nino 4 (где обычно наблюдается максимум ЦТ Эль-Ниньо) с заблаговременностью 12 месяцев можно отметить как значимый, а его корреляция с действительным индексом за период 1980-2020 гг. составила около 0.6.

В [Ludescher et al., 2023] предложен метод определения типа предстоящего ЭН на основе разности ТПО между центральной и восточной частями экваториальной зоны Тихого океана в декабре предшествующего года. Когда разность ТПО положительна, ожидается ВТ тип, когда отрицательна – ЦТ. Метод показал весьма значимый результат: 18 типов ЭН из 21 было предсказано верно, что указывает на важность учета предложенного предиктора. Физически суть метода заключается в создании системы оценки состояния теплого бассейна экваториального Тихого океана и обязано своему происхождению теории осциллятора «загрузки-разгрузки» [Jin, 1997]. В то же время авторы для своих расчетов использовали массив данных ERSSTv5. В работе [Марчукова и др, 2020] показано, что этот массив данных является наиболее неудачным выбором для определения событий ЭН и ЛН и их пространственных типов. Кроме того, в районе теплого бассейна экваториальной части Тихого океана отмечается выраженная несогласованность между массивами данных ТПО ERSSTv5, COBESST2 и HadISST: коэффициенты корреляции при сопоставлении массивов реконструкций лежат в пределах 0.4-0.6, а RMSE составляет 0.2-0.5°C. Учитывая, что для 10 из 18 удачных попыток определения типа Эль-Ниньо модуль разницы ТПО в центральной и восточной части был меньше 0.5°, использование

альтернативного массива данных может привести к несогласованности результатов.

Выше особое внимание было уделено описанию климатических откликов на разные типы ЭН и ЛН, из чего можно сделать вывод о важности заблаговременного прогнозирования этих типов. Особенно это важно для регионов Северной Азии и европейской части России, поскольку в этих районах Евразии теплая зима обычно является следствием ВТ Эль-Ниньо, а холодная – ЦТ Эль-Ниньо [Larkin, Harrison, 2005; Graf, Zanchettin, 2012; Lubkov, et. al., 2020]. Следовательно, заблаговременный прогноз типов Эль-Ниньо и Ла-Нинья очевидно является приоритетной задачей моделирования.

Важность этого тезиса в очередной раз подтвердилась зимой 2023-2024 года. Большинство прогностических центров ожидало положительную аномалию температуры в декабре и январе в Северо-западных и центральных регионах России, связывая ее с ВТ Эль-Ниньо. Однако температура была ниже многолетней нормы. Неоправдавшийся прогноз может быть связан со смещением положительной аномалии ТПО тропиков Тихого океана от берегов Южной Америки в западном направлении в эти месяцы, что привело к смене пространственного типа Эль-Ниньо с ВТ на смешанный.

1.3 Искусственные нейронные сети и мировой опыт их использования для прогноза Эль-Ниньо – Южное колебание

Принцип работы искусственных нейронных сетей (НС) базируется на аналогии с процессом обработки сигналов в нейронах живых существ. Идея создания искусственной нейронной сети сформировалась еще в середине XX столетия. Одной из первых моделей нейрона была бинарная модель Мак Каллока-Питса, предложенная в 1943 году [McCulloch, Pitts, 1943]. Несколько позже, в 1956 году на Дартмутской конференции, посвященной компьютерным наукам, была сформулирована концепция искусственного интеллекта. Ее суть заключалась в надежде, что машины смогут думать и реагировать так же, как

человеческий мозг [Fang et al., 2022]. Это дало толчок для дальнейших исследований, и уже в 1958 году Фрэнком Розенблаттом была предложена математическая модель персептрона, успешно реализованная в виде первого нейрокомпьютера «Марк-1» [Rosenblatt, 1962]. С выходом в свет книги «Perceptrons» [Minsky, Papert, 1969], в которой помимо положительных сторон персептрона также было много критики, внимание к ИИ несколько уменьшилось.

Одновременно с P.J.Werbos, в 1974 году советским ученым А. И. Галушкиным [Галушкин, 1974] был разработан алгоритм обратного распространения ошибки, в иностранной литературе называемый «Backpropagation». Однако интерес к НС вернулся лишь в 1986 году, когда алгоритм был вновь опубликован D. E. Rumelhart и соавторами [Rumelhart et al., 1986] и параллельно советскими учеными С.И. Барцевом и В.А. Охониным [Барцев, Охонин, 1986]. Популяризация дискуссий вокруг возобновления идеи создания ИИ и параллельное развитие компьютерных технологий вернуло интерес к изучению данной области наук. Важной чертой этого алгоритма была возможность обучения многослойных персептронов. Предложенный алгоритм и сегодня используется для обучения нейронных сетей.

Стоит отметить, что в 1970-х и 1980-х годах многослойный персептрон и алгоритм обратного распространения ошибки были вновь и вновь разработаны несколько раз разными учеными. Это связано с тем, что каждая группа авторов называла эти термины по-своему. К примеру, А. И. Галушкин многослойный персептрон называл многослойной системой распознавания образов, а алгоритм обратного распространения ошибки – вторичной функцией оптимизации.

В 2006 году [Hinton et al., 2006] была предложена концепция глубокого обучения, которая относится к процессу машинного обучения для получения глубокой сетевой структуры. Под глубокими нейронными сетями подразумевается многослойность. При этом предполагается, что увеличение числа скрытых слоев должно уменьшить количество нейронов в этих слоях. Это исследование открыло эпоху глубокого обучения. На рис. 1.2 показана иерархическая связь между искусственным интеллектом, машинным обучением,

искусственными нейронными сетями и глубоким обучением. В отличие от машинного обучения, процесс извлечения признаков глубокого обучения выполняется автоматически. Функции нейронной сети получаются путем обучения. В отличие от неглубоких нейронных сетей (к примеру, однослойный персептрон), в которых извлеченные объекты представляются для исходных данных менее репрезентативными, когда количество сетевых слоев велико, функции, извлеченные моделью, будут более репрезентативными [Fang et al., 2022]. Глубокое обучение применяется для комплексных сложных задач, а основным условием успешного моделирования считается достаточно длинная выборка данных (тысячи, десятки тысяч синхронных наблюдений).

Ниже будет уделено внимание моделям и системам прогнозирования ЭНЮК, основанным на методах ИНС. Все результаты оценок моделей и систем были компактно собраны в табл. 1.3.



Рисунок 1.2 – Схема, иллюстрирующая иерархическую связь между искусственным интеллектом, машинным обучением, искусственными нейронными сетями и глубоким обучением, из [Fang et al., 2022]

1.3.1. Первые простейшие нейронные сети и связанные с ними модели для прогноза ЭНЮК

Одна из первых успешных попыток применения методов НС к моделированию ЭНЮК была сделана в 1997 году в работе [Tangang et al., 1997].

За основу модели взят однослойный персептрон. Модель обучалась за период 1952-1981гг., а период 1982-1993 гг. выбран как тестовый. В качестве предикторов были использованы эмпирические ортогональные функции (ЭОФ) поля ТПО экваториальной части Тихого океана. На тестовом периоде авторы показали достаточно высокий уровень корреляции, 0.64 для заблаговременности 12 месяцев. Разложение на ЭОФ проводилось в период 1952-1993гг., что говорит о зависимости тестового периода от методики моделирования, с чем соглашаются и сами авторы в своей следующей работе [Tangang et al., 1998]. Стоит отметить, что в этих работах временной интервал тестовой выборки лежит в период до климатического «сдвига», когда частота ЦТ Эль-Ниньо значительно увеличилась, что было изучено в более поздних исследованиях [Latif et al., 1997; Larkin, Harrison, 2005; Achok et al., 2007; Kao, Yu, 2009; Ren et al., 2019; Dieppois et al., 2021]. Гораздо позже в работе [Gavrilov et al., 2019] был применен похожий подход, где на тестовом периоде 2008-2017 гг. оценки модели были значительно ниже. В работе [Wu et al., 2006] также использовался комбинированный подход, включающий разложение на ЭОФ и модель МСП. Входными данными были ДУМ и ТПО. В модели не использовался определенный конкретный период для проверки. Вместо этого проводилась перекрестная проверка: модель обучалась на 9/10 временного ряда, а 1/10 служила тестовой выборкой, десятые части менялись местами и модель обучались заново. Таким образом, весь ряд 1948-2005 гг. можно считать тестовой выборкой. Для этого периода прогностическая модель с заблаговременностью 12 месяцев показала невысокий уровень корреляции – 0.54 для индекса Nino3.4.

В работе [Aguilar-Martinez, Hsieh, 2009] проводилось сравнение эффективности линейной регрессии, байесовской нейронной сети (БНС) и регрессии опорных векторов (РОВ) для прогнозов ЭНЮК. В качестве предикторов использовались данные ДУМ и ТПО в тропической части Тихого океана. Авторы показали, что способности моделей на основе использованной ИНС и линейной регрессии не сильно отличались, при этом метод регрессии опорных векторов оказался заметно хуже. В работе [Nooteboom et al., 2018] был

предложен объединенный метод авторегрессии и ИНС для прогноза ЭНЮК. Результат показал преимущество по сравнению с одной из наиболее успешных динамических моделей NCEP-CFSv2.

В работе [Лубков и др., 2017] предложен МСП для прогноза индекса Южного колебания (ИЮК), как основной характеристики состояния ЭНЮК. Особенность работы заключается в том, что в качестве предикторов модели использовались лишь внетропические индексы дальнедействующих связей системы океан-атмосфера. Для северного полушария использовались широко известные индексы, полученные в работе [Barnston, Livezey, 1987]. Для Южного полушария использовались барические структуры из работы [Mo, White, 1985], пересчитанные в климатические индексы. Несмотря на уникальность подхода при выборе входных признаков, авторам удалось получить значимый прогноз ИЮК с заблаговременностью 5 месяцев. Также в работе были проанализированы отдельные повторяющиеся индексы и отмечена важность их учета в прогнозах ИЮК (а следовательно и ЭНЮК).

Авторы работы [Gavrilov et al., 2019] предложили математическую модель, основанную на разложении на линейные динамические моды (ЛДМ) и нейросетевых методах. Для обучения модели использовались данные ТПО за период 1960-2007 гг., ограниченные 30 широтой с севера и юга. На выбранном контрольном периоде 2008-2017 гг. с заблаговременностью более 7 месяцев коэффициент корреляции был ниже 0.5. Тем не менее, со слов авторов модель показала сопоставимое качество моделирования в сравнении с моделями, применяемыми на сегодня для прогнозов ЭНЮК.

В работе [Lubkov et al., 2019] для прогноза ЭНЮК была использована модель, в основе которой лежит МСП, разработанная ранее в [Лубков и др., 2016] и применена для прогноза ИЮК с невысокой заблаговременностью [Лубков и др., 2017]. Особенностью предлагаемого метода является использование в качестве предикторов не пространственных полей климатических баз данных, а конкретных климатических индексов, характеризующих глобальное состояние атмосферной циркуляции и океанических энергоактивных центров. Несколько

десятков климатических индексов отбираются на основе корреляционного анализа в качестве признаков модели. При этом моделирование осуществляется путем множественного перебора комбинаций входных индексов, в результате которого формируется вектор решений с разными конструкциями МСП. Несмотря на хорошую способность модели с заблаговременностью прогноза 9 мес. в контрольный период 1950-1957 гг. ($r=0.79$), в дополнительный проверочный период 1870-1947 с такой же заблаговременностью корреляция была равна всего 0.4.

1.3.2. Современные нейросетевые системы прогнозирования ЭНЮК

В 2019 году была опубликована статья [Nam et al., 2019], положившая начало применению глубокого обучения для прогнозов ЭНЮК. Это стало возможным за счет использования авторами рядов климатических моделей проекта CMIP5. В исследовании применялась сверточная нейронная сеть (СНС), обученная с использованием полей ТПО и ТСО, включавших внетропические широты (0° – 360° в.д. и 55° ю.ш.– 60° с.ш.). ТСО рассчитывался для глубины до 300м. Всего для предобучения было использовано 42 запуска 21 климатической модели за период 1861-2004 гг. и поля реанализа SODA для трансферного обучения за период 1871-1973. Таким образом, для первичного обучения одного месяца использовалось 6006 среднемесячных значений данных климатических моделей и 102 значения реанализа SODA для трансфертного обучения. Модель превзошла существующие динамические модели: с годовой заблаговременностью на контрольной выборке 1984-2017 корреляция равна 0.65, а так называемая эффективная продолжительность прогноза (ЭПП), выраженная в достижении коэффициента корреляции 0.5, наблюдается с заблаговременностью на 17 месяцев. В работе также проверены способности прогноза типа Эль-Ниньо с годовой заблаговременностью. В контрольный период для 8 Эль-Ниньо из 12 тип был предсказан верно.

Подход к использованию данных SMIP5 в работе [Ham et al., 2019], позволяющий применить методы глубокого обучения, и связанный с ним успех вызвали интерес у исследователей. Он был применен в более поздних работах [Hu et al., 2021; Cachay et al., 2021; Geng, Wang, 2021; Zhou, Zhang, 2022; Wang et al., 2023].

В работе [Cachay et al., 2021] предложена модель, основанная на графовых нейронных сетях (ГНС). Все входные данные и периоды обучения/контроля для объективного сравнения были выбраны как в работе [Ham et al., 2019]. Несмотря на то, что в работе также используются данные моделей SMIP5, авторы не применяли трансферное обучение. Модель показала себя лучше СНС с заблаговременностью до 6 месяцев. Однако с годовой заблаговременностью уступила СНС, коэффициент корреляции равен 0.58.

В работе [Hu et al., 2021] проведен анализ прогностических способностей оригинальной модели остаточной сверточной нейронной сети (ОСНС) в разные интервалы времени. Все данные для обучения были аналогичны работе [Ham et al., 2019]. Контрольный период был на 2 года больше с 1982 по 2017 гг. В сравнении с обычной СНС, ОСНС оказалась незначительно лучше по параметру эффективного времени прогноза ($r > \approx 0.5$), равного 20 месяцам.

В работе [Geng, Wang, 2021] моделирование осуществлялось с помощью архитектуры сверточной нейронной сети с длинной цепью элементов краткосрочной памяти (СНС-ДЦКП) (Dense Convolution-Long Short-Term Memory – DC-LSTM), обладающей свойствами рекуррентных и сверточных нейросетей. Результаты моделирования оказались лучше, чем в работе [Ham et al., 2019], однако объективно сравнить их затруднительно, так как в этой работе для проверки модели был выбран более короткий ряд 1994-2017 гг. Тем не менее, в работе приведено свое сравнение на примере прогноза зимнего сезона, где предложенная архитектура модели оказалась лучше в сравнении с СНС.

В [Zhou, Zhang, 2022] предложено использовать модель, названную POP-Net, объединившую анализ основных колебательных структур (ОКС) (Principal Oscillation Pattern - POP), СНС и ДЦКП. В отличие от ЭОФ, анализ ОКС ищет

простейшую динамическую систему, которая может объяснить основные особенности пространственно-временных данных. Результаты моделирования были незначительно хуже в сравнении с работами [Ham et al., 2019; Geng, Wang, 2021], что можно снова же объяснить различными периодами проверки модели. Также в работе [Zhou, Zhang, 2022] вместо CMIP5 использовались 23 отобранные модели проекта CMIP6.

В [Wang et al., 2023] предложена модель пространственно-временного извлечения и объединения информации – STIEF (The spatio-temporal information extraction and fusion), которая содержит два ключевых компонента: блоки пространственно-временного извлечения признаков и блоки слияния. Первые блоки используют временные СНС для извлечения соответствующих признаков входных переменных. Блоки слияния признаков полностью объединяют временные и пространственные характеристики посредством многослойной свертки и понижающей дискретизации. На контрольном периоде 1982-2020 гг. модель STIEF показала себя несколько лучше модели, предложенной [Ham et al., 2019]. С годовой заблаговременностью прогноза корреляция равна 0.69, а ЭПП равна 23 месяцам. Авторы оценили прогностические способности модели STIEF, используя разные комбинации источников предикторов (рис. 1.3). Стоит отметить, что внетропические предикторы имеют большое значение для способностей прогнозирования (рис. 1.3 D и B). Модель с использованием только внетропических широт северного и южного полушария с заблаговременностью от 5 до 18 месяцев имеет корреляцию, большую чем 0.4, а разница корреляций между моделью с использованием предикторов по всему земному шару и только в тропиках в этот же период заблаговременности прогноза равна около 0.1. Также стоит обратить внимание на важность Индийского и Атлантического океанов, особенно при прогнозах с заблаговременностью 7-11 месяцев (рис. 1.3 A и C). Другим не менее важным результатом является успешное моделирование только на основе ТПО. Авторы показали, что моделирование с учетом ТПО+ТСО и без ТСО имеют несущественные различия, при этом использование только ТПО позволяет оперативно обновлять прогнозы.

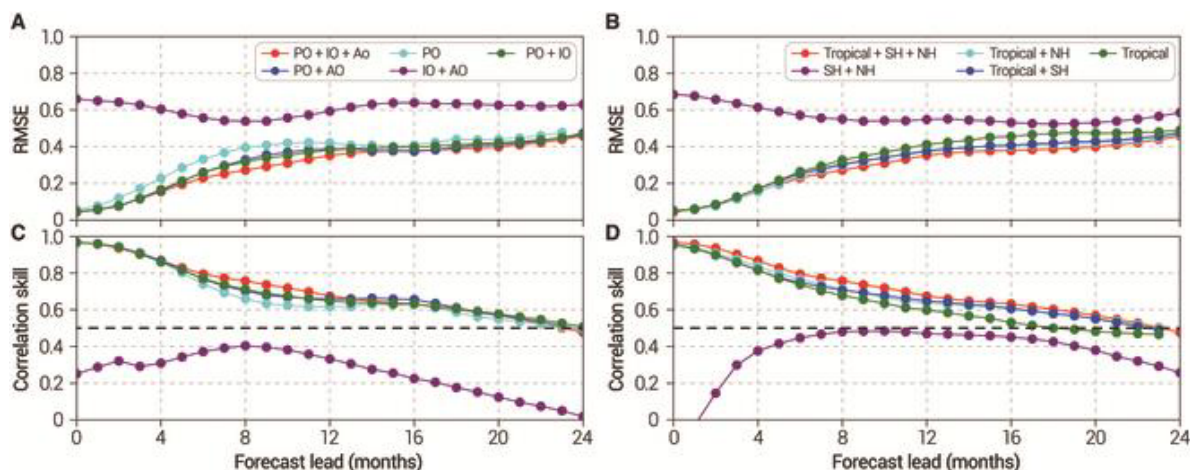


Рисунок 1.3 – Навыки прогнозирования STIEF на основе данных из различных регионов. (A) RMSE с различными комбинациями входных океанских бассейнов. PO — Тихий океан; АО — Атлантический океан; IO, Индийский океан. (B) RMSE с различными комбинациями широтных входных диапазонов. Tropical – Тропические широты океаны; NH — внетропические океаны Северного полушария; SH – внетропический океан Южного полушария. (C) и (D) то же, что и (A) и (B), только для корреляции. Источник: [Wang et al., 2023]

Несмотря на сравнительно хорошие результаты прогнозирования ЭНЮК моделью ГНС, моделями глубокого обучения ДЦКП, СНС и ОСНС, и гибридными системами глубокого обучения STIEF и POP-Net, их существенным ограничением является использование данных климатических моделей, которые, как известно, не достаточно точны в воспроизведении процессов системы океан-атмосфера. Следовательно, у такого подхода есть ограничение по входным данным, которое, судя по всему, выражается в достижении некоторого предела точности, и его не удастся преодолеть, не заменив данные моделей на оригинальные массивы данных или основанные на таких данных массивы реанализов.

Далее рассмотрим успехи современных нейросетевых моделей и систем прогноза ЭНЮК, в которых не применялись данные климатических моделей для обучения.

В работе [Petersik, Dijkstra, 2020] проведен анализ прогностических способностей двух моделей нейронных сетей квантильной регрессии и Гауссовой плотности (НСКР и НСГП) в разные интервалы времени. В качестве предикторов были выбраны Океанический индекс Nino, объем теплой воды выше изотермы 20°C в тропической части Тихого океана (5°ю.ш.–5°с.ш., 120–80°з.д.), Индоокеанский диполь (ИОД), среднее по площади значение, пропорциональное зональной аномалии напряжения ветра в западной части Тихого океана (2.5°с.ш.–2,5°ю.ш., 120°в.д.–160°з.д.), аномалии высоты морской поверхности (ВМП). Для обучения и проверки модели использовались перекрестные периоды промежутка времени 1963-2017 гг. Прогноз с годовой заблаговременностью моделями в периоды 1963-1981 гг. и 2002-2017 гг. имеет сравнительно низкие корреляционные оценки (около 0.4-0.5) в сравнении с периодом 1982-2001 гг. (около 0.75-0.8), что проиллюстрировано на рис. 1.4. Авторы работы [Petersik, Dijkstra, 2020] также сравнили модель НСГП с моделью СНС из работы [Nam et al., 2019] на одинаковом периоде 1984-2017 гг. Несмотря на сравнительно небольшую обучающую выборку модели НСГП, эффективная продолжительность прогноза, как и для СНС, равна 17 месяцам. При этом с меньшей заблаговременностью прогноза модель СНС имеет более высокие прогностические способности. С годовой заблаговременностью прогноза модель НСГП показала корреляцию 0.58.

Результаты авторов работы [Petersik, Dijkstra, 2020] сравнивались с ОСНС в работе [Hu et al., 2021] на 4-х 10-летних промежутках времени. Навыки прогнозирования с годовой заблаговременностью на промежутках 1982-1991, 1992-2001 и 2002-2011 у всех трех моделей (НСКР, НСГП и ОСНС) были примерно одинаковы, однако модели показывали высокие корреляции на промежутках времени 1982-1991 и 1992-2001, равные около 0.78, и сравнительно низкие корреляции на промежутке 2002-2011 (≈ 0.4). Для последнего временного интервала 2012-2017 гг. ОСНС оказалась заметно лучше НСКР и НСГП: коэффициенты корреляции равны 0.72, 0.45 и 0.41, соответственно. Из результатов сравнения можно подчеркнуть, что временной промежуток,

выбранный для проверки моделей, существенно влияет на объективный контроль и, по сути, предопределяет оценку успешности. Исключением оказался только последний временной период 2012-2017 гг. где прогностические способности ОСНС оказалась выше, чем у более простых НС.




Рисунок 1.4. Прогностические способности (коэффициент корреляции) моделей НСГП (a) и НСКР (b) в различные временные сроки. Источник изображения [Petersik, Dijkstra, 2020]

Стоит отметить, что существуют два основных подхода в прогнозировании ЭНЮК: прямой многоэтапный и повторяющийся многоэтапный [Chevillon, 2007]. Первый означает непосредственное прогнозирование будущего месяца с определенной заблаговременностью, а второй означает использование выходного результата прогноза в качестве входных данных для будущих месяцев прогноза.

В работе [Mu et al., 2021] предложена система прогнозирования ENSO-ASC, в которой использовался повторяющийся многоэтапный подход для всей выборки данных в независимости от сезона, в отличие от СНС из работы [Ham et al., 2019], где каждый сезон прогнозировался отдельно. ENSO-ASC устроена как кодировка-моделирование-декодирование данных. В системе используются методы глубокого обучения ГНС, СНС и ДЦКП. В качестве предикторов использованы ТПО, осадки, компоненты ветра, испарение и облачность в области с границами

40° с.ш.–40° ю.ш. и 160° в.д.–90° з.д. Для предобучения модели используются данные реанализа NOAA/CIRES 1850-2015 гг., для трансферного обучения используется массив данных наблюдений REMSS 1997-2012 гг. Поскольку прогноз осуществляется повторным многоэтапным методом, длина обучающих выборок баз данных равна 1992 и 192 поля каждого параметра. Авторы показали преимущество системы ENSO-ASC в сравнении со стандартными нейросетевыми методами глубокого обучения (CHC, ДЦКП, DC-LSTM), использующими тот же набор данных, что и ENSO-ASC. Однако сравнить систему ENSO-ASC с ранее описанными системами и модели не представляется возможным в виду короткого контрольного периода 2014-2020 гг., длина которого связана с ограниченным количеством данных. Для этого контрольного периода прогностические способности с годовой заблаговременностью равны 0.65, а ЭПП соответствует 17 месяцам. Также можно отметить, что исключение зональной компоненты ветра привело к наибольшему снижению оценочных показателей модели, что подтверждает важность этого параметра как триггера явлений Эль-Ниньо.

В работе [Patil et al., 2023] была использована CHC, входными данными которой были поля ТПО реконструкций COBE и OISSTv2 и TCO реанализов SODA и GODAS. Регион, которым ограничивались поля предикторов, соответствовал работе [Nam et al., 2019] (0–360° в.д. и 55° ю.ш.–60° с.ш.). В работе проверялись только прогнозы с высокой заблаговременностью от 12 до 36 месяцев. Проверка модели проводилась в период 1984-2021 гг. Несмотря на то, что корреляция с годовой заблаговременностью прогноза была ниже, чем у [Nam et al., 2019], и равнялась 0.57, а ЭПП оказалась на 5 месяцев дольше и равна 22 месяцам.

В работе [Лубков и др., 2023] была доработана модель прогноза ЭНЮК, основанная на МСП [Lubkov et al., 2019; Лубков и др., 2020]. Признаками модели были геопотенциал и компоненты ветра на 500 изобарической поверхности и поля ТПО. Алгоритм работы блоков подготовки данных и моделирования описан ниже. В контрольный период 2007-2023 гг. с годовой заблаговременностью прогноза корреляция модели составила 0.64. ЭПП в работе не проверялась.

Таблица 1.3 – Модели прогнозирования ЭНЮК, основанные на ИНС

Источник	Метод	Входные данные	Обучение	Тест	Коррел. (r) Забл. = 1 год	ЭПП r≈0.5
Tangang et al., 1997	МСП+ЭОФ	ТПО	1952-1981	1982-1993	0.64	-
Wu et al., 2006	МСП+ЭОФ	ДУМ, ТПО	Перекрестная:	1948-2005	0.54	15
Aguilar-Martinez, Hsieh, 2009	РОВ+ЭОФ/ БНС+ЭОФ	ДУМ, ТПО	1948-1979	1980-2005	0.60/0.64	>15
Gavrilov et al., 2019	ЛДМ+ИНС	ТПО	1960-2007	2008-2017	-	8
Lubkov et al., 2019	МСП	Н500 Обуч.: NCEP/NCAR Тест: 1. 20CR; 2. NCEP/NCAR	1958-2019	1.1870-1947 2.1950-1957	0.4* 0.79* *Забл. = 9мес.	7 >9
Ham et al., 2019	СНС	ТПО, ТСО Обучение: 1. CMIP5; 2. SODA (t) Тест: GODAS	1. 1861-2004 2. 1871-1973	1984-2017	0.65	17
Petersik, Dijkstra, 2020	НСГП / НСКР	ONI, ВМП, ИОД, объем теплой воды, Зональное напряжение ветра	Перекрестная 1963-2017	1963-2017 1984-2017 1963-1971 1972-1981 1982-1991 1992-2001 2002-2011 2012-2017	0.56 / 0.56 0.58 / - 0.51 / 0.51 0.48 / 0.46 0.82 / 0.78 0.75 / 0.77 0.38 / 0.44 0.39 / 0.42	<15 17 12 <6 >21 18 9 9
Hu et al., 2021	ОСНС	ТПО, ТСО Обучение: 1. CMIP5 2. SODA (t) Тест: GODAS	1. 1861-2004 2. 1871-1973	1982-2017 1982-1991 1992-2001 2002-2011 2012-2017	0.67 0.78 0.79 0.4 0.72	18 >22 19 11 19
Cachay et al., 2021	ГНС	ТПО, ТСО Обучение: 1. CMIP5; 2. SODA Тест: GODAS	1. 1861-2004 2. 1871-1973	1984-2017	0.58	-
Geng, Wang, 2021	DC-LSTM	ТПО, ТСО, компоненты ветра Обучение: 1. CMIP5; 2. SODA (t) Тест: GODAS	1. 1861-2004 2. 1871-1973	1994-2017	0.6	20
Mu et al., 2021	ENSO-ASC	ТПО, осадки, компоненты ветра, испарение, облачность 1. NOAA/CIRES 2. REMSS (t)	1. 1850-2015 2. 1997-2012	2014-2020	0.65	17
Zhou, Zhang, 2022	POP-Net	ТПО, ТСО Обучение: 1. CMIP6; 2. SODA (t) Тест: GODAS	1. 1850-1980 2. 1871-1980	1994-2020	0.57	15
Patil et al., 2023	СНС	ТПО, ТСО Обучение: COBE, SODA Тест: OISSTv2, GODAS	1871-1980	1984-2021	0.57	20
Wang et al., 2023	STIEF	ТПО, ТСО Обучение: 1. CMIP5/6; 2. SODA (t) Тест: 1. Argo; 2. GODAS	1. 1861-2012 2. 1871-1973	1982-2020 Объединен из: 1.1982-2004 2.2005-2020	0.69	23
Лубков и др., 2023	NNM-ENSO	Н500, ТПО, компоненты ветра	1948-2006	2007-2023	0.64	-

Модели, использующие действительные данные наблюдений или основанные на этих данных реанализы и реконструкции, в целом показали конкурентный результат в сравнении с моделями, в которых использовались данные климатических моделей. ЭПП и первых и вторых моделей сопоставима. При этом коэффициент корреляции для прогнозов с годовой заблаговременностью несколько ниже (на 0.1-0.05, где выбранные авторами временные интервалы позволяли провести сравнения контрольных выборок) был отмечен у моделей, использующих действительные данные.

Подводя итог, следует отметить, как для динамических моделей, так и для статистических моделей используемые входные данные и ядро модели играют важную роль в успешности прогнозов ЭНЮК. За последние 30 лет были предложены разнообразные алгоритмы НС, однако основные прорывы в способностях моделей НС были связаны не столько с усложнением моделей, сколько с пространственно-временным расширением разнообразия массивов входных данных этих моделей.

Выводы к Главе 1

Анализ литературных источников, посвященных разнообразию ЭНЮК и его прогнозам, привел к следующему заключению.

1. Механизм интенсификации ЭНЮК, в особенности событий Эль-Ниньо, до сих пор дискусионен, однако последние десятилетия было проведено множество исследований, способствующих его пониманию.

2. Прогнозы, предлагаемые набором динамических и статистических моделей, используемых ВМО, ограничены весенним порогом предсказуемости, а их эффективная заблаговременность не превышает 6-9 месяцев.

3. Заблаговременность определения типа событий ЭНЮК ограничена несколькими месяцами, однако совместное использование динамических моделей и статистических методов позволяет увеличить эту заблаговременность. При

этом, некоторые исследования утверждают значительное увеличение заблаговременности определения типа при использовании ИНС.

4. Своевременный и более точный прогноз состояния ЭНЮК на сегодня позволяет применение ИНС.

5. Применение данных климатических моделей дает возможность использовать алгоритмы глубокого обучения сверточных и рекурсивных нейронных сетей. И хотя такой подход помогает увеличить способности моделей прогноза ЭНЮК, остается опасение, связанное с достижением некоторого предела точности, который не удастся преодолеть, не заменив входные данные моделей на оригинальные данные.

Таким образом, ограниченность применяемых на сегодня динамических и статистических моделей не позволяет с достаточной заблаговременностью предупредить наступление явлений Эль-Ниньо и Ла-Нинья и их тип. В то же время, региональные климатические отклики на разные типы этих явлений могут значительно отличаться. Применение ИНС может существенно расширить пределы предсказуемости ЭНЮК и его типов.

ГЛАВА 2. ИСПОЛЬЗУЕМЫЕ ДАННЫЕ И ПРОСТРАНСТВЕННО-ВРЕМЕННОЙ АЛГОРИТМ ПОДБОРА ПРЕДИКТОРОВ

Основу исследования составляют массивы данных, которые используются для поиска и расчета входных предикторов в предлагаемую в настоящей работе нейросетевую модель. Основными критериями, которыми должна обладать такая база данных являются достаточная продолжительность, однородность и оперативное обновление актуальных данных.

Под достаточной продолжительностью массивов данных подразумевается наличие минимум двух климатических периодов. При этом исходим из определения ВМО о том, что климатический период составляет 30 лет. Таким образом, ряд данных должен составлять не менее 60 лет. Поэтому массивы данных спутниковых наблюдений (к примеру, NCEP/DOE, MERRA-2), охватывающие только 40 летний временной период, не подходят для решения поставленной задачи. Под однородностью подразумевается достаточно однородные по пространству и времени данные систем наблюдений, из которых составляются массивы реконструкций и реанализов. Под оперативным обновлением понимается наименьший временной отрезок, за который может обновиться массив данных. Обычно таким свойством обладают массивы с относительно грубым пространственным разрешением. Таким образом, массивы с высоким пространственно-временным разрешением, требующие дополнительного времени для обновления актуальных данных (к примеру, ERA5, время обновления которого занимает 10-15 суток), не подходят для решения поставленной задачи. Следовательно, одна из задач этой главы – проверить качество существующих массивов данных, удовлетворяющих этим трем критериям.

Другая важная задача, которая решается в этой главе – это реализация пространственно-временного алгоритма подготовки данных для разработанной в диссертационной работе модели.

2.1. Используемые в работе массивы данных и оценка их качества

Для решения сформулированных задач в настоящей работе привлекались различные массивы данных реанализов, реконструкции ТПО и стационарные данные наблюдений. При этом на каждом этапе исследования применялись определенные массивы данных.

Основными массивами данных, которые использовались для моделирования, были:

- массив реконструированных данных ТПО HadISST Метеорологического офиса Гадлея (Великобритания), с разрешением сетки $1^{\circ} \times 1^{\circ}$ с 1870 по 2023 гг.;

- массив реконструированных данных ТПО COBE SST2 Японского метеорологического агентства в узлах пространственной сетки $1^{\circ} \times 1^{\circ}$ доступный с 1850 по 2023 гг.;

- среднемесячные поля скорости ветра и геопотенциала на изобарических уровнях из атмосферного реанализа NCEP/NCAR с шагом сетки в $2.5^{\circ} \times 2.5^{\circ}$ с 1948 по 2023 гг.;

Для дополнительной проверки воспроизводимости моделью периода 1872-1947 гг. вместо NCEP/NCAR применялся атмосферный реанализ 20 столетия (20th Century Reanalysis V2c) с шагом сетки в $2^{\circ} \times 2^{\circ}$, доступный за период 1870 по 2015 гг.;

Для верификации указанных массивов использовались:

- среднемесячные данные ТПО с буев проекта TOGA-TAO с 1981 по 2019 гг.;

- ежемесячные данные ТПО спутника MODIS (Terra Global Level 3) с разрешением 9 км с 2001 по 2019 гг.;

- ежемесячный массив ТПО NOAA IO SST v2 (Optimum Interpolation Sea Surface Temperature v2), полученный путем интерполяции данных сенсора AVHRR (серия спутников NOAA), с разрешением $1^{\circ} \times 1^{\circ}$ за период 1982-2018 гг.;

– данные аэрологического зондирования Объединенного глобального архива радиозондирования IGRA v2.1 (International Global Radiosound Archive) Национального центра климатических данных США (NCDC).

2.1.1. Верификация базы данных поля геопотенциала

Для проверки качества данных реанализов NCEP/NCAR и 20CR использовался Объединенный глобальный архив радиозондирования IGRA v2.1. Проверка проводилась для Атлантико-Европейского региона. Дополнительно, для сравнения были взяты данные реанализа ERA-Interim. Для надежного сравнения данные реанализов были интерполированы методом сплайн-интерполяции в координаты 119 аэрологических станций выбранного региона. На рис. 2.1 изображены профили корреляции, RMSE и средней ошибки для геопотенциала на изобарических уровнях от 925 до 200 гПа. Профили получены путем осреднения критериев оценивания, рассчитанных в точке каждой станции, на каждом изобарическом уровне.

На основе сравнения корреляций (рис. 2.1а) в более низких слоях атмосферы обнаружены незначительные различия, при этом NCEP/NCAR оказался несколько хуже ERA-Interim на 0.01-0.02 единицы. На барическом уровне 500 гПа и выше различия практически отсутствуют, а корреляции реанализов с данными наблюдений больше 0.99. Если рассматривать среднюю ошибку, то NCEP/NCAR показал себя лучше ERA-Interim. Отклонения от данных наблюдений реанализа NCEP/NCAR практически отсутствуют (рис. 2.1б), в то время как реанализ ERA-Interim систематически занижает показатели геопотенциала. Сравнение RMSE указывает на то, что реанализ ERA-Interim лучше в низких слоях атмосферы, а после 500 гПа лучшим оказался NCEP/NCAR (рис. 2.1в). На изобарическом уровне 500 гПа RMSE реанализов NCEP/NCAR и ERA-Interim равно 18м и 17м, соответственно.

Очевидно, что реанализ 20CR заметно хуже NCEP/NCAR и ERA-Interim. Профили корреляции 20CR указывают на более низкий уровень согласованности

в сравнении с другими реанализами, 0.97-0.98, средняя ошибка указывает на систематическое завышение геопотенциала, а RMSE растет по мере уменьшения давления от 20м на барическом уровне 850 гПа до 75м на барическом уровне 200 гПа.

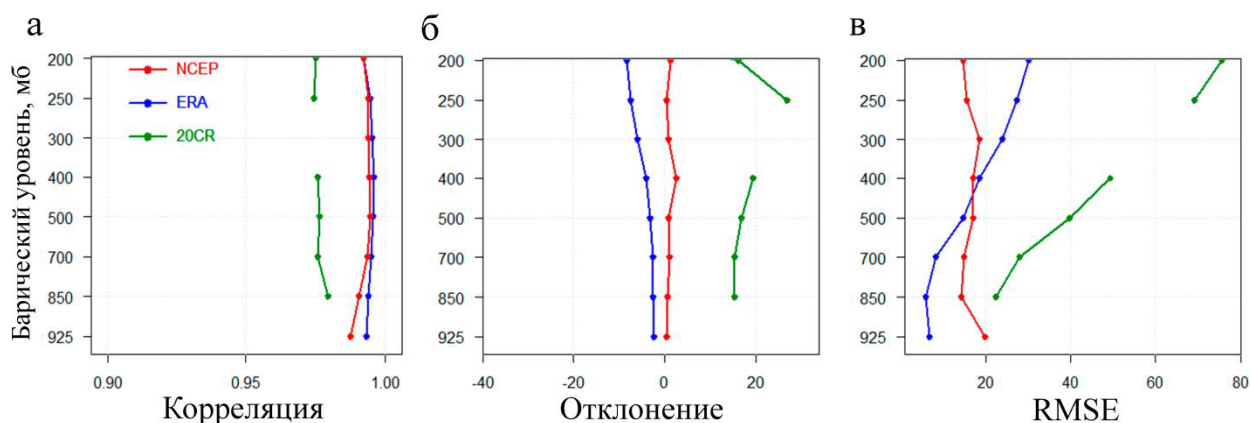


Рисунок 2.1 – Профили (а) – коэффициентов корреляции, (б) – средней ошибки и (в) – RMSE геопотенциала для реанализов NCEP/NCAR, ERA-Interim и 20CR в сравнении с данными аэрологического зондирования массива IGRA v2.1

Геопотенциал на изобарическом уровне 500 гПа является ключевым параметром данной работы. Большинство предикторов модели, описанной в Главе 3, рассчитываются именно на основе этого поля. Поэтому рассмотрим подробнее распределение разницы расчетных и наблюдаемых величин геопотенциала на 500 гПа. На рис.2.2. изображена гистограмма распределения **средней** ошибки для реанализов ERA-Interim и NCEP/NCAR и поля средней-ошибки геопотенциала. Из гистограммы на рис.2.2а очевидно, что ERA-Interim занижает геопотенциальную высоту, а NCEP/NCAR хоть и имеет моду около нуля, но при этом распределение более сглаженное, что говорит о более высокой RMSE. Распределение поля средней ошибки реанализа NCEP/NCAR говорит о неравномерности ее распределения. В Средиземноморском регионе отмечается занижение значений геопотенциала, а в Восточной Европе – завышение.

А

б

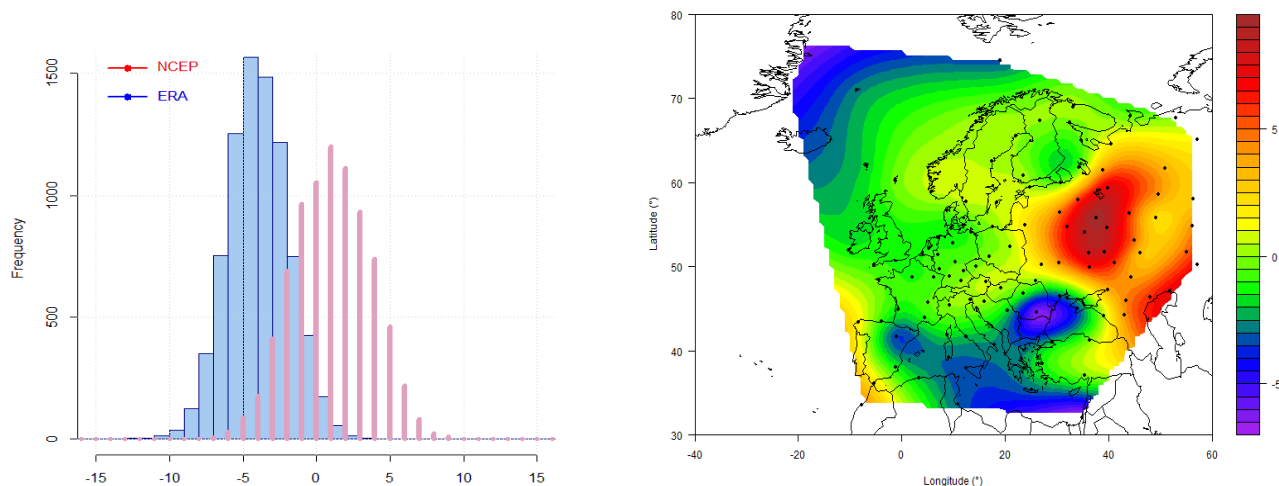


Рисунок 2.2 – (а) – средняя ошибка геопотенциала на 500 гПа реанализов NCEP/NCAR (красный) и ERA-Interim (синий); (б) – поле распределения средней ошибки геопотенциала на 500 гПа реанализа NCEP/NCAR

2.1.2. Верификация реконструированных баз данных ТПО

В настоящем исследовании для расчета индексов Niño и океанических предикторов использовались реконструированные данные ТПО HadISST и COBESST. Опишем эти массивы данных и проведем их верификацию на примере тропической зоны Тихого океана. Помимо этих двух баз данных ТПО, дополнительно для сравнения использовалась база данных ERSSTv5 с пространственным разрешением узлов сетки $2^{\circ} \times 2^{\circ}$.

Данные ТПО в массиве HadISST охватывают период с 1870 по 2018 гг. Они состоят из Морского банка данных Метеорологической службы Великобритании (MDB – Marine Data Bank) в узлах пространственной сетки $1^{\circ} \times 1^{\circ}$, которые, начиная с 1982 г., включают данные Глобальной системы телекоммуникаций (GTS – Global Telecommunications System). Для расширения объема информации MDB привлекались среднемесячные данные о ТПО за период с 1871 по 1995 гг. из Всеобъемлющего массива данных об океане и атмосфере (COADS –

Comprehensive Ocean-Atmosphere Data Set). Кроме этого, в массиве были использованы спутниковые данные NOAA (сенсор – AVHRR), наблюдаемые только в ночное время суток, и разработан свой алгоритм ассимиляции этих данных (Rayner et al., 2003). При этом их алгоритм имеет значительные отличия от алгоритма, применяемого в массиве NOAA IO SST v2 [Reynolds et al., 2002]. ТПО в массиве HadISST восстанавливается с использованием интерполяционной процедуры с оптимальным уменьшением по пространству в два этапа, с последующим наложением качественно-улучшенных данных наблюдений с привязкой к сетке, что позволяет восстановить более локальные детали [Rayner et al., 2003]. В самой математической модели использовано разложение на эмпирические ортогональные функции (ЭОФ) данных ТПО «in situ» и данных, полученных с помощью дистанционного зондирования Земли [Rayner et al., 2003]. Данные HadISST имеют более высокое пространственное разрешение, по сравнению с ERSSTv5, но период восстановленных данных меньше (с 1870 г.), чем у массивов ERSSTv5 (с 1854 г.) и COBE SST2 (с 1850 г.).

COBE SST2 – это массив среднемесячных данных ТПО Японского метеорологического агентства в узлах пространственной сетки $1^{\circ} \times 1^{\circ}$ за период с 1850 по 2018 гг. (Hirahara et al., 2014). COBE SST2 включает в себя ТПО из Международного комплексного набора данных об океане и атмосфере (ICOADS – International Comprehensive Ocean-Atmosphere Data Set) версии 2.5, данные японской коллекции Kobe [Ishii et al., 2005] и данные наблюдений с морских судов и разных типов буев [Hirahara et al., 2014]. Также в массиве использовались данные спутников NOAA (сенсор AVHRR), применяемые для разложения на ЭОФ [Hirahara et al., 2014]. Однако в конечном продукте COBE SST2 спутниковые данные не ассимилируются. Это связано с тем, что они увеличивают изменчивость ТПО на 10–20% по пространственной сетке, тем самым искажая реальную картину [Hirahara et al., 2014]. Как и в HadISST, данные до 1941 г. скорректированы с использованием метода С. К. Фолланда и Д. И. Паркера [Folland, Parker, 1995]. Этот эмпирический метод основан на сравнении результатов специально проведенных измерений ТПО, выполненных на торговых

и других попутных судах ручным термометром при измерении температуры заборной воды в выставленных на палубе ведрах с учетом тепло- и влагообмена. В результате в данные внесены географические и сезонные поправки для периода с 1856 по 1941 гг. Восстановленные скорректированные данные и данные, прошедшие контроль качества, накладывались на сетку с использованием оптимальной интерполяции [Hirahara et al., 2014].

Сравнительный анализ выполнялся в несколько этапов. Вначале проводилось сравнение массивов HadISST, ERSSTv5 и COBE SST2 между собой. Затем эти же массивы сравнивались со спутниковыми и натурными наблюдениями.

На первом этапе с помощью корреляционного анализа было проведено сравнение массивов HadISST, ERSSTv5 и COBE SST2.

Поскольку массив данных ERSSTv5 имеет отличную от HadISST и COBE SST2 регулярную сетку координат, для него было выполнено уменьшение размерности в единую одноградусную сетку с помощью сплайн-интерполяции, обеспечив пространственную сопоставимость массивов.

Результаты рассчитанных полей корреляции и RMSE между сравниваемыми в работе массивами приведены на рис. 2.3. Можно отметить, что корреляция между COBE SST2 и HadISST (рис. 2.3в) в экваториальной зоне несколько выше, чем в случае корреляций между HadISST–ERSSTv5 (рис. 2.3а) и COBE SST2–ERSSTv5 (рис. 2.3д). Этот же вывод подтверждается при оценке корреляционной связи в районе Nino3.4: за весь период сравнений коэффициент корреляции для COBE SST2–HadISST равен 0,93, в то время как для HadISST–ERSSTv5 и COBE SST2–ERSSTv5 – 0,90 и 0,89 соответственно. RMSE массивов HadISST и COBE SST2 относительно друг друга не превышают $0,4^{\circ}\text{C}$. Их сходство частично можно объяснить использованием некоторых аналогичных методов при реконструкции данных до 1941г. [Hirahara et al., 2014]. В отличие от тесной связи между HadISST и COBE SST2, ERSSTv5 отличается от них больше и RMSE в среднем равняется $0,3-0,5^{\circ}\text{C}$, при этом RMSE в районах Nino3 и Nino4 достигают $0,7^{\circ}\text{C}$.

Следует обратить внимание на теплый бассейн экваториальных вод, который под действием пассатных ветров смещен на запад тропической зоны Тихого океана. В этом районе наблюдается невысокая согласованность между всеми тремя массивами, корреляции равны 0.5-0.7, а RMSE – 0.5-0.9°C. При этом исходя из теории осциллятора «загрузки-разгрузки» [Jin, 1997] эта область является ключевой в образовании ЭНЮК.




Рисунок 2.3 – Коэффициенты корреляции между массивами ERSSTv5 и HadISST (а), COBE SST2 и HadISST (в), ERSSTv5 и COBE SST2 (д), и RMSE массивов ERSSTv5 и HadISST (б), COBE SST2 и HadISST (г), ERSSTv5 и COBE SST2 (е)

Далее в работе рассмотрено изменение корреляции и RMSE между тремя массивами во времени. Для этого были рассчитаны коэффициенты корреляций и RMSE для скользящего 30-летнего периода с 1870 по 2018 гг. в районе Nino3.4 (рис. 2.4). Получено, что пара COBE SST2–HadISST с 1885 по 1960 гг. имеет коэффициенты корреляции 30-летнего скользящего периода выше, чем остальные корреляционные пары (рис. 2.4а), а RMSE – ниже (рис. 2.4б). При этом с 1905 г.

коэффициенты корреляции для всех 3 пар уменьшаются синхронно, а RMSE повышаются. Для всех 3 пар в период с 1900 по 1970 гг. данные менее согласованы (корреляции уменьшаются, RMSE растет), чем в период с 1986 по 1900 гг.. Начиная с 1970-х годов наблюдается заметное уменьшение различий между реконструкциями, что может быть связано с увеличением обеспеченности банка данных.




Рисунок 2.4 – Коэффициенты корреляции (а) и RMSE (б), рассчитанные для скользящего 30-летнего периода в районе Nino 3.4 между массивами данных ERSSTv5 и HadISST (красная линия), COBE SST2 и HadISST (зеленая), ERSSTv5 и COBE SST2 (синяя)

По результатам проведенного выше сравнительного анализа для используемых в работе реконструированных данных можно сделать вывод о том, что наиболее идентичны друг к другу массивы HadISST и COBE SST2. Это можно объяснить тем, что методы их реконструкции достаточно схожи [Hirahara et al., 2014]. Особенно это касается реконструкции данных до 1941 г., которые корректировались на основе метода С. К. Фолланда и Д. И. Паркера [Folland, Parker, 1995].

На втором этапе проведено сопоставление реконструированных массивов со спутниковыми данными и натурными наблюдениями. В таблице 2.1 приведены

результаты сравнения массивов HadISST, ERSSTv5 и COBE SST2 с данными датчика AVHRR (спутники NOAA), скорректированными на основе измерений «in situ» в проекте NOAA OI SSTv2, датчика MODIS (спутник Terra) и измерениями «in situ», полученными с буев проекта TAO, расположенных на экваторе. Следует отметить, что для сравнения массивов рассматривались только периоды, в течение которых в каждом из массивов присутствовали данные. Поэтому временные отрезки анализируемых массивов различаются. Так, для NOAA OI SSTv2 период равен 1982-2018, для спутника Terra – 2001-2018 и буев TAO – 1981-2018, при этом данные буев имеют пропуски. В качестве областей, по которым проводилось сравнение рядов данных, для NOAA OI SSTv2 и MODIS-Terra были выбраны регионы Nino3, Nino4 и Nino3.4, а для буев проекта TAO была выполнена сплайн-интерполяция реконструированных массивов в координаты локализации буев (0°ш, 95°з.д., 125°з.д. и 140°з.д.). Из используемых рядов данных исключен тренд и сезонная изменчивость.

По результатам коррекционной оценки из таблицы 2.1 видно, что коэффициенты корреляции с данными NOAA OI SSTv2 для различных реконструированных массивов практически не отличаются и равны 0.99-0.98. Такая высокая корреляция может быть связана с тем, что массив NOAA OI SSTv2 корректировался с помощью судовых наблюдений и наблюдений с буев [Reynolds et al., 2002], которые также учитывались во всех трех используемых реконструкциях. При этом массив NOAA OI SSTv2 содержит данные с сенсора AVHRR, который использовался в каждом из массивов на различных этапах корректировки. Анализируя взаимосвязь с остальными базами данных, отметим, что наиболее точно отображает динамику изменения температуры массив COBE SST2. Самые низкие коэффициенты корреляции с выбранными базами данных были получены при сравнении с массивом ERSSTv5.

По результатам оценки RMSE в сравнении с буями TAO самое меньшее отклонение наблюдается у массива COBE SST2. В сравнении с данными MODIS-Terra и NOAA OI SSTv2 наиболее низкие отклонения имеет массив HadISST. Только в районе Nino3.4 в сравнении с данными MODIS-Terra сравнительно

низкое RMSE приурочено массиву COBE SST2. Массив ERSSTv5 показывает относительно максимальные показатели RMSE.

Таким образом, можно сделать вывод, что реконструкция COBE SST2 лучше остальных массивов усваивает данные буев проекта ТАО, при этом имеет высокую корреляционную связь со спутниковыми данными MODIS-Terra, которые не усваивались в данной реконструкции. В тоже время, коэффициенты корреляции массива HadISST несколько ниже в сравнении с данными MODIS-Terra, однако, в районах Nino3 и Nino4 массив получил сравнительно низкие оценки RMSE. Массив ERSSTv5, несмотря на то, что обучение его модели реконструкции проводилось в период 1982-2011 [Huang et al., 2017], хуже остальных массивов описывает температурные изменения в выбранных регионах, имея сравнительно низкие коэффициенты корреляции и высокие RMSE.

Таблица 2.1 – Сравнение массивов реконструкций COBESST2, HadISST и ERSSTv5 с данными спутника Terra (сенсор MODIS) за период 2000-2015, спутников NOAA (сенсор AVHRR) за период 1982-2015 и буев проекта ТАО за период 1981-2015 на основе корреляции и RMSE

массив	район	r			RMSE, °C		
		HadISST	COBESST2	ERSSTv5	HadISST	COBESST2	ERSSTv5
NOAA OISST2	Nino 3	0,99	0,99	0,99	0,24	0,34	0,41
	Nino 3.4	0,99	0,99	0,99	0,18	0,27	0,34
	Nino 4	0,98	0,99	0,98	0,19	0,31	0,39
Сенсор MODIS	Nino 3	0,94	0,94	0,94	0,32	0,45	0,46
	Nino 3.4	0,91	0,98	0,89	0,47	0,34	0,65
	Nino 4	0,92	0,98	0,98	0,44	0,59	0,68
Буи ТАО*	95 з.д.	0,88	0,90	0,89	0,67	0,62	0,66
	125 з.д.	0,94	0,95	0,93	0,51	0,47	0,53
	140 з.д.	0,96	0,96	0,94	0,41	0,37	0,47

* буи проекта ТАО, привязанные к определенной локации, в связи с чем в координаты буев выполнялась сплайн-интерполяция массивов реконструкционных данных.

В итоге, рассмотрев профили корреляции, средней ошибки и RMSE и детально изучив ошибки геопотенциала на изобарической поверхности 500 гПа реанализов NCEP/NCAR, ERA-Interim и 20CR, можно сделать вывод, что реанализ NCEP/NCAR вполне пригоден для расчета индексов атмосферной

циркуляции. Геопотенциал на 500 гПа реанализа NCEP/NCAR имеет незначительные отклонения от базы данных натуральных наблюдений, корреляция равна 0.99, средняя ошибка около 0, а среднеквадратичная ошибка равна 18м.

В результате проведенного сравнительного анализа было показано, что линейная связь между массивами ERSSTv5, HadISST и COBE SST2 среднемесячных значений ТПО с 1870 по 2018 гг. для районов тропической зоны Тихого океана – высокая (коэффициенты корреляции (r) равны от 0,7 до 0,95) и для района тепло бассейна в западной тропической части Тихого океана – удовлетворительная ($r = 0.5-0.7$). Среднеквадратические отклонения массивов HadISST и COBE SST2 относительно друг друга не превышают $0,4^{\circ}\text{C}$: это частично объясняется использованием при реконструкции данных некоторых аналогичных методов [Hirahara et al., 2014]. В отличие от тесной связи между HadISST и COBE SST2, ERSSTv5 связан с этими реконструкциями в меньшей степени. Среднеквадратические отклонения массива ERSSTv5 от HadISST и COBE SST2 в районах Nino3 и Nino4 в среднем равны до $0,7^{\circ}\text{C}$.

По результатам верификации массивов показано, что в COBE SST2 были незначительно лучше усвоены данные буев проекта TOGA-TAO. Сравнивая анализируемые массивы со спутниковыми данными Terra (MODIS), которые не усваивались ни в одной из реконструкций, COBE SST2 показал несколько лучшую воспроизводимость изменчивости аномалий ТПО за период 2001–2018, в сравнении с другими массивами. Однако массив HadISST имеет наименьшие среднеквадратические отклонения от спутниковых данных Terra (MODIS) и данных проекта NOAA IO SST v2. Наибольшие значения RMSE и наименьшие корреляции, особенности в области Nino 3.4, наблюдались для массива данных ERSSTv5. Таким образом, отметим, что массивы HadISST и COBE SST более предпочтительны для расчетов индексов Nino и предикторов модели, описанной ниже, чем массив данных ERSSTv5.

2.2. Пространственно-временной алгоритм подбора входных модельных предикторов

Рассмотрим алгоритм выбора входных сигналов для модели НС. Он состоит из двух основных этапов: предварительная подготовка рядов данных на основе пространственно-временного анализа полей гидрометеорологических характеристик и выбор ограниченного количества предикторов, используемых в модели. Основная задача первого этапа состоит в формировании массива климатических индексов, имеющих отношение к моделируемому параметру. Задача второго этапа заключается в отборе ограниченного числа климатических индексов, имеющих некоторое временное опережение по отношению к прогностическому параметру.

2.2.1. Предварительная подготовка рядов данных на основе пространственно-временного анализа гидрометеорологических полей

Наборы климатических индексов, отбираемые на первом этапе, включают в себя как известные индексы, которые были пересчитаны на основе анализа литературных источников, так и дополнительно рассчитанные.

Для начала рассмотрим общеизвестные климатические индексы, описывающие состояние атмосферы и океана.

Индекс североатлантического колебания (САК или NAO) рассчитывается как разность аномалий геопотенциала между Азорским максимумом и Исландским минимумом на изобарической поверхности 500 гПа [Wallace, Gutzler, 1981; Barnston, Livezey, 1987]. Барическая структура САК наиболее устойчива и наблюдается на протяжении всего года. Из работ [Voskresenskaya, Polonsky, 1993; Нестеров, 2000; Мохов, Смирнов, 2006] известно о влиянии ЭНЮК на Североатлантическое колебание. При этом в работе [Полонский и др., 2004] отмечена гипотеза обратной связи САК-ЭНЮК.

Индекс Восточно-атлантического колебания (ВАК или EA) рассчитывается как разность аномалий геопотенциала в трех центрах действия атмосферы над Канарскими островами, Великобританией и Черноморским регионом на изобарической поверхности 500 гПа [Wallace, Gutzler, 1981]. В работе [Нестеров, 2000; Voskresenskaya et al., 2018] отмечено взаимодействие Эль-Ниньо и Ла-Нинья с Восточноатлантическим колебанием.

Индекс Скандинавского колебания (СКАНД, SCAND или EU-1), также известный как Евразийское-1 [Barnston, Livezey, 1987], комплексно рассчитывается на основе полей геопотенциала над Скандинавией, Монголией и Восточной Россией на изобарической поверхности 500 гПа.

Индекс Полярного или Североазиатского колебания (ПК - POL) вычисляется как разность поля геопотенциала на изобарической поверхности 500 гПа между Полярным регионом Северного полушария и Центральной Азией.

Западно-тихоокеанское колебание (ЗТК или WP) – устойчивое колебание, также как и САК наблюдаемое на протяжении всего года. Его индекс рассчитывается как разность геопотенциала на изобарической поверхности 500 гПа между Камчаткой и западными субтропиками Тихого океана [Wallace, Gutzler, 1981; Barnston, Livezey, 1987]. Известно о взаимосвязи ЗТК и ЭНЮК во время развития Эль-Ниньо или Ла-Нинья, например из [Wang, 1999]

Индекс колебания между восточной Атлантикой и западной частью России (ВА/ЗР, EA/WR или EU-2), также известного как Евразийское-2 [Barnston, Livezey, 1987], рассчитывается в 4-х центрах действия атмосферы: над Европой, Каспийским морем, центром Северной Америки и севером Китая на основе геопотенциала на изобарической поверхности 500 гПа.

Индекс колебания между Тихим океаном и Северной Америкой (ТСА или PNA) вычисляется как разность геопотенциала изобарической поверхности 500 гПа над северо-восточным районом Тихого океана (район между о. Гавайи и межгорьем Северной Америки), и западом Северной Америки (район между Алеутскими островами и юго-восточными штатами США) [Barnston, Livezey, 1987].

Перечисленные атмосферные индексы Северного полушария связаны с Арктической осцилляцией, которая, как было описано ранее, может неявно влиять на интенсификацию ЭНЮК, чем и обосновано их использование. Все атмосферные индексы Северного полушария были пересчитаны на основе литературных источников, а их области пересчета представлены на рис. 2.6а.

Наборы известных океанических индексов, ответственных за основные механизмы взаимодействия системы океан-атмосфера, рассчитывались с использованием реконструированных массивов данных о ТПО. В их число вошли индексы состояния ЭНЮК: Nino 3, Nino 4 и Nino 1+2, индекс «Atlantic Nino», известный как аналог индексов Nino в Атлантическом океане [Vallès-Casanova et al, 2020], индоокеанский диполь [Saji et al, 1999] и тихоокеанская декадная осцилляция (ТДО) [Maslova et al, 2017]. Известно, что все перечисленные индексы, характеризующие основные климатообразующие области океана, имеют глобальные проявления [Polonsky, Basharin, 2017; Vallès-Casanova et al, 2020; Maslova et al, 2017]. Упомянутые океанические индексы были пересчитаны на основе литературных источников, а их области пересчета представлены на рис. 2.6в (ТДО представлена на рис. 2.6г. среди других рассчитанных в работе индексов).

Остальные климатические индексы были получены с использованием пространственно-временного анализа полей гидрометеорологических характеристик. Опишем последовательно этапы процедуры этого анализа.

На первом этапе была изучена возможная статистическая взаимосвязь между моделируемым параметром (то есть индексами Nino 3, Nino 4, Nino 3.4) и глобальными метеорологическими (геопотенциал на изобарических уровнях 500 гПа и 1000 гПа, зональная и меридиональная составляющие скорости ветра на изобарическом уровне 500 гПа) и океанологическими (ТПО) полями. Статистическая связь оценивалась с помощью коэффициентов корреляции, которые рассчитывались в каждой узловой точке поля отдельно для каждого месяца. Глобальные метеорологические и океанологические поля сравнивались с прогнозируемыми индексами Nino с временным сдвигом от 1 мес. до 2 лет. Таким

образом, мы получили 288 полей корреляционных оценок для каждого гидрометеорологического параметра. В случае наличия значимого коэффициента корреляции (при длине ряда, равной 70, и $\alpha = 0.01$ коэффициент корреляции, $r = 0.195$) в узловой точке реанализа производилось суммирование. На рис. 2.5 приведены поля повторяемости значимых коэффициентов корреляции для четырех 6-месячных периодов заблаговременности: 1-6, 7-12, 13-18 месяцев и 19-24 месяца.

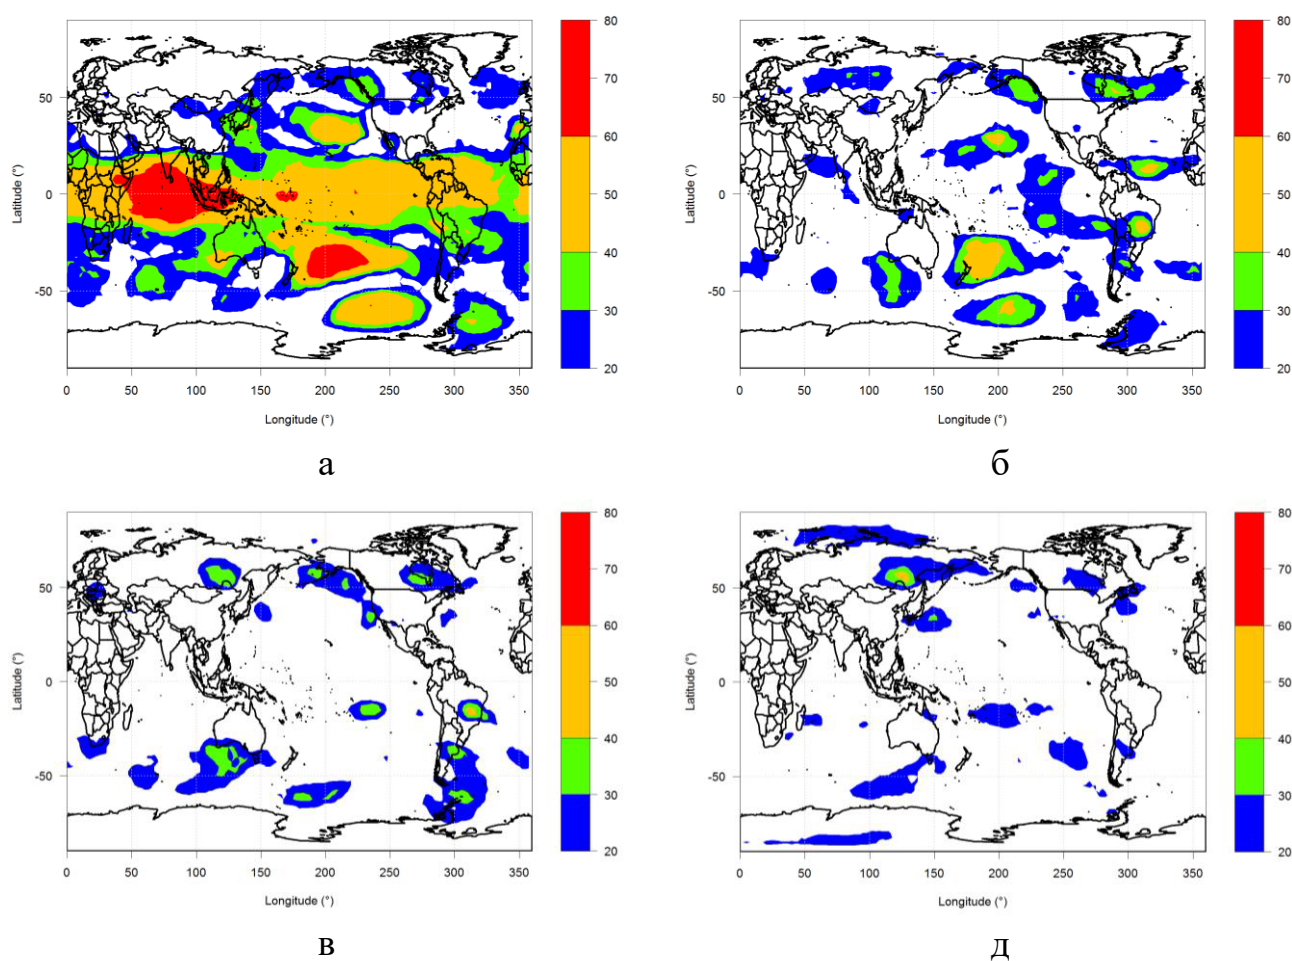


Рисунок 2.5 – Повторяемость значимых коэффициентов корреляции, обобщенная на картах с опережением атмосферы на (а) – 1-6 мес.; (б) – 7-12 мес.; (в) – 13-18 мес.; (г) – 19-24 мес.

На следующем этапе экспертным путем (то есть с участием специалиста) определялись прямоугольные широтно-долготные области, в которых значимые коэффициенты корреляции повторялись чаще или имеется факт наличия

сравнительно высокого коэффициента корреляции (больше 0.45), который повторялся хотя бы 3 раза.

На заключительном этапе проводился анализ предположительной взаимосвязи соседних областей (только для полей геопотенциала), и рассчитывались климатические индексы. Если области отрицательной и положительной корреляций располагались в непосредственной близости, а изменение знака корреляции для нескольких шагов временного сдвига происходило синхронно, то такие области объединялись в один индекс, представляющий собой разность средних значений в этих областях. В случае нескольких связанных областей в зависимости от их количества индекс рассчитывался как разность по формуле (2.1):

$$\begin{cases} X = H_1 - H_2 \\ X = H_1 - 2H_2 + H_3 \\ X = H_1 - H_2 + H_3 - H_4 \end{cases}, \quad (2.1)$$

где H – осредненное значение геопотенциальной высоты в некоторой области, X – разность нескольких областей.

Такое объединение областей помогает избавиться от дублирующихся предикторов, что в перспективе улучшит качество моделирования.

Объединенные области (X) и «одиочные» области, которые не нуждались в объединении, были пересчитаны в нормированные климатические индексы по формуле (2.2):

$$Index_{i,m} = \frac{X_{i,m} - \bar{X}_m}{\sigma_m}, \quad (2.2)$$

где \bar{X} и σ – среднее и стандартное отклонение за период 1981–2010 гг., рассчитанные для каждого месяца отдельно, i и m – год и месяц. В случае «одиочной» области X представлял собой осредненный ряд значений в некоторой области.

В результате было определено более 100 регионов, на основе которых получено 58 индексов: 34 для моделирования высокочастотной и 24 для моделирования низкочастотной составляющих (о декомпозиции моделируемых

рядов будет изложено ниже, в параграф 3.6). Обобщим полученные группы индексов.

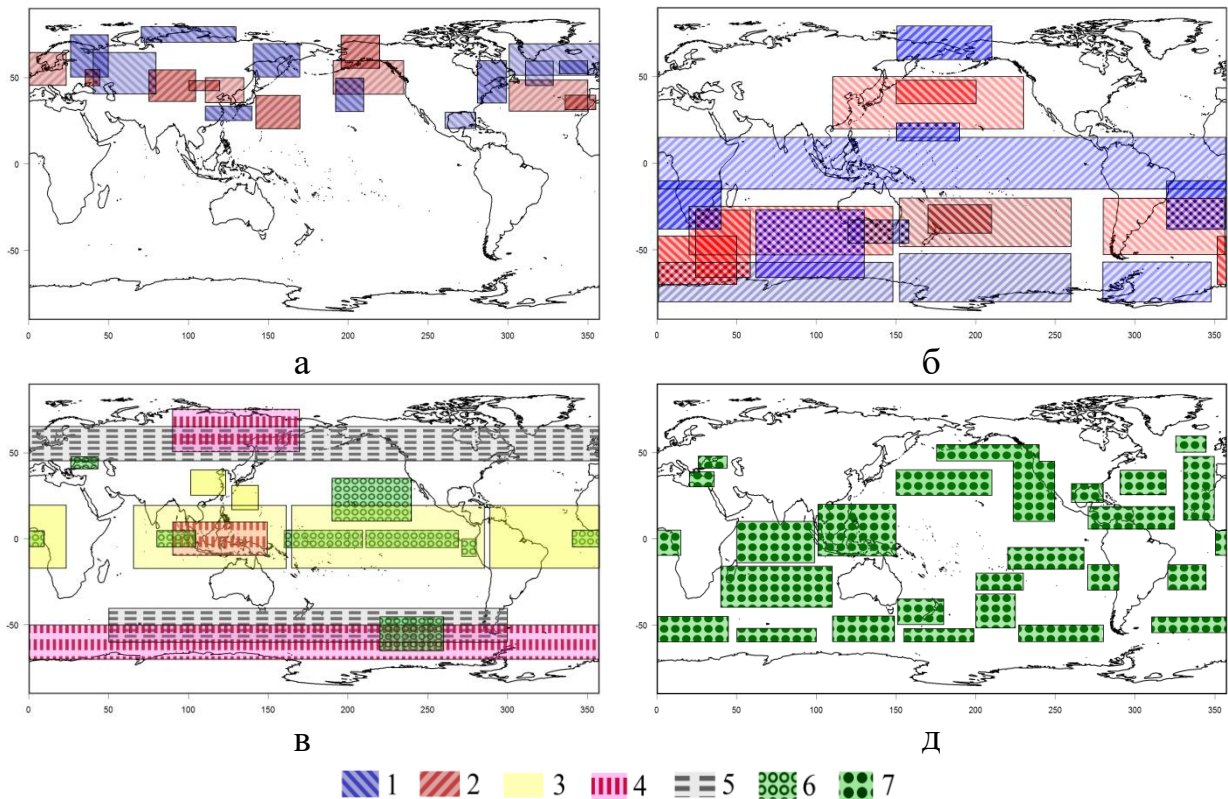


Рисунок 2.6 – Области, используемые для расчета атмосферных и океанических индексов. Области геопотенциальной высоты на изобарической поверхности 500 гПа отмечены как 1 и 2; области геопотенциальной высоты на изобарической поверхности 1000 гПа отмечены как 3; области меридиональной и зональной составляющих вектора ветра на изобарической поверхности 500 гПа отмечены как 4 и 5, соответственно; области ТПО отмечены как 6; области ТПО, рассчитанной с применением 9-летнего среднего скользящего сглаживания, отмечены как 7

На рис. 2.6а, 2.6б (штриховка "1" и "2") и 2.6в (штриховка "3") представлены области полей геопотенциала на изобарической поверхности 500 гПа и 1000 гПа, полученные как с использованием литературных источников, так и выбранные в работе на основе анализа статистической связи.

На рис. 2.5в (штриховки “4” и “5”) представлены области, выбранные на основе полей меридиональной и зональной компонент скорости ветра. При этом меридиональная компонента взята по модулю. Рассчитанный на основе областей в высоких широтах индекс может характеризовать тип атмосферной циркуляции: положительные значения индекса будут соответствовать меридиональному типу, а отрицательные – зональному.

Штриховкой “6” на рис. 2.5в представлены области расположения индексов, полученных по аномалиям ТПО.

Для моделирования низкочастотной составляющей в качестве входных данных использовались только поля ТПО, сглаженные 9-летним фильтром отдельно для каждого месяца. Выделенные области ТПО представлены на рис. 2.5г (штриховка “7”).

2.2.2. Алгоритм выбора ограниченного количества предикторов

Рассмотрим этап отбора предикторов модели. Поскольку увеличение числа входных параметров существенно влияет на скорость вычисления, для моделирования высокочастотной и низкочастотной составляющих было использовано ограниченное число предикторов, равное 18 и 10, соответственно. Предикторы выбирались из полученных на предыдущем этапе климатических индексов. Статистическая связь оценивалась с использованием коэффициента корреляции. Вектор предикторов отбирался для каждого месяца отдельно с учетом заданного моделью порога заблаговременности.

Опишем алгоритм выбора предикторов. Для каждого месяца моделируемой величины (то есть индексов Nino) за период 1950-2006 гг. были оценены коэффициенты корреляции с климатическими индексами с учетом заданного моделью предела заблаговременности. Временной сдвиг индексов варьировался от 1 месяца до 2 лет и до 10 лет для высокочастотной и низкочастотной компоненты, соответственно. К примеру, для моделирования высокочастотной составляющей индекса Nino 3.4 с заблаговременностью прогноза 12 месяцев были

рассчитаны 408 коэффициентов корреляции (сочетание 34 климатических индексов и 12 временных смещений).

Все полученные оценки статистической связи ранжировались на основе коэффициента корреляции. Для каждого климатического индекса был установлен порог, ограничивающий возможность выбора индекса до двух (до одного) раз в случае высокочастотной (низкочастотной) компоненты. Поскольку моделируемые индексы Niño имеют некоторую автокорреляцию, связанную с особенностями интенсификации и эволюции фаз ЭНЮК, для каждого климатического индекса во внимание принимался только коэффициент корреляции, представляющий локальный максимум/минимум.

В итоге было отобрано 18 (10) рядов климатических индексов, получившие наивысшую оценку статистической связи, которые использовались на следующем этапе моделирования.

Таким образом, в работе предложен алгоритм пространственно-временной подготовки данных. Алгоритм анализирует глобальные поля геопотенциала и компонент ветра на изобарической поверхности 500 гПа и 1000 гПа и ТПО. В результате работы алгоритма выбрано ограниченное число предикторов, далее используемых в нейросетевой модели.

Выводы к Главе 2

Для обеспечения достоверности результатов климатических расчетов и моделирования, проводимых в диссертационной работе выбраны массивы гидрометеорологических данных и проведена проверка их качества. Показано, что выбранные ряды данных обладают необходимыми свойствами для успешной работы модели: достаточная продолжительность, однородность и оперативное обновление актуальных данных. В итоге, показано следующее.

1. Анализ качества массивов геопотенциала на изобарической поверхности 500 гПа реанализов NCEP/NCAR, ERA-Interim и 20CR показал, что реанализ NCEP/NCAR пригоден для расчета индексов атмосферной циркуляции.

2. Результаты верификации массивов ТПО показали, что массивы HadISST и COBE SST предпочтительны для расчетов индексов Nino и других океанических индексов, используемых в качестве предикторов нейросетевой модели.

3. Предложенный в работе алгоритм пространственно-временной подготовки данных анализирует глобальные поля геопотенциала, компонент ветра и ТПО и обеспечивает выбор ограниченного числа наиболее подходящих предикторов, используемых далее нейросетевой модели.

Результаты Главы 2 опубликованы в шести научно-исследовательских журналах, четыре из которых входят в базы данных Web of Science и SCOPUS [Луков, 2017; Лубков, 2022; Марчукова и др., 2020; Lubkov, Voskresenskaya, et al., 2024] и два в РИНЦ [Лубков, 2021; Луков, 2023]. На основе алгоритма ассимиляции данных было получено свидетельство результата интеллектуальной деятельности № 2021668360 [Свидетельство 2021668360, 2021]. Результаты этой Главы были изложены на 7 международных и всероссийских научно-исследовательских и научно-практических конференциях.

Расшифровка опубликованных работ.

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

Лубков А.С., Воскресенская Е.Н., Сухонос О.Ю. Прогноз выпадения осадков в районе Ай-Петри на основе модели искусственной нейронной сети // Водные ресурсы, 2022. Том 49. № 4. С. 517–526. DOI: 10.31857/S0321059622040137

Марчукова О.В., Лубков А.С., Воскресенская Е.Н. Качество воспроизведения событий Эль-Ниньо и Ла-Нинья по разным массивам реконструированных данных температуры поверхности океана // Вестник СПбГУ. Науки о Земле. 2020. Т. 1. Вып. 1. С. 97–120. DOI: 10.21638/spbu07.2020.106

Лубков А.С., Воскресенская Е.Н. Метод нейронных сетей для климатического прогнозирования водности Чернореченского водохранилища // Системы контроля окружающей среды. 2021. Вып. 2 (44). С. 16–28. DOI: 10.33075/2220-5861-2021-2-16-28

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

Lubkov A.S., Voskresenskaya E.N., Marchukova O.V. A New Approach to Using Neural Networks for Long-Term El Nino and La Nina Forecasting // *Izvestiya, Atmospheric and Oceanic Physics*, 2024. V.60. Suppl. 1. P. S46–S61. DOI: 10.1134/S0001433824700555

Свидетельство 2021668360. Программа поиска статистических связей «NeuroClim-Correlation» системы комплексного климатического прогнозирования: программа для ЭВМ / А.С. Лубков (RU); правообладатель ФГБНУ ИПТС. № 2021667541 ; заявл. 02.11.2021 ; опубл. 15.11.2021, Бюл. № 11. 10 Кб.

ГЛАВА 3. НЕЙРОСЕТЕВАЯ ПРОГНОСТИЧЕСКАЯ МОДЕЛЬ

В предыдущей главе были выбраны массивы данных и подготовлен алгоритм отбора входных в модель предикторов. В данной главе представлена модель на основе ИНС. Для подтверждения базовых свойств НС и тестирования вычислительного блока модели было выполнено имитационное моделирование с использованием искусственных рядов.

3.1. Многослойный персептрон

Анализ успехов современных нейросетевых моделей и систем прогноза ЭНЮК показал хорошую перспективу их развития для долгосрочного прогнозирования различных метеорологических характеристик.

Как было отмечено ранее, использование алгоритма глубокого обучения и связанных с ним нейронных сетей требуют весьма длинно ряда данных для обучения (тысячи и десятки тысяч шагов обучения). При этом использование данных климатических моделей вместо действительных данных наблюдений вызывает опасение, связанные с достижением некоторого предела точности. В то же время, статистически обеспеченные и надежные ряды наблюдений доступны лишь со второй половины XX столетия. Ряд такой длины вводит некоторые ограничения по применению большинства современных сетей глубокого обучения, в связи с чем, в работе предлагается разработать многоуровневую систему моделирования на основе более простой структуры сети, а именно – многослойного персептрона.

Многослойный персептрон представляет собой однонаправленную гетероассоциативную многослойную НС с одним скрытым слоем [Rosenblatt, 1962; Hecht-Nielsen, 1991; Haykin, 1994]. Передача сигнала в таких НС осуществляется только в одном направлении от входа к выходу. Обучение такой НС обычно происходит с учителем методом обратного распространения ошибки. Результат обучения НС может быть выражен в виде строгой функциональной

зависимости. За счет прозрачности математического алгоритма многослойного персептрона у исследователя есть возможность рассмотреть различные комбинации предикторов и получить четкое представление о том, какие из используемых предикторов привели к успешному прогнозу.

Схема алгоритма работы используемой НС проиллюстрирована на рис. 3.1. Алгоритм делится на несколько последовательных шагов.

1. Обработка входного сигнала функцией активации.
2. Расчет активности нейронов *скрытого* слоя путем суммирования входных сигналов, поступающих от нейронов *входного* слоя, умноженных на текущие веса связей между этими слоями и последующая их активация.
3. Расчет активности нейронов *выходного* слоя путем суммирования сигналов нейронов *скрытого* слоя, умноженных на текущие веса связей и последующая их активация.
4. Деактивация сигнала. На этом шаге полученные значения проходят через функцию, обратную функции активации и сравниваются с обучающим вектором. В результате формируется целевая функция, которая и формирует изменение весов связей.
5. Формирование вектора ошибки весов для скрытого слоя на основе сравнения выходных сигналов скрытого слоя и входных выходного слоя и соответственно изменение весов связей между входным и скрытым слоем.

3.1.1 Подбор параметров обучения для используемой НС

Для начала следует определить стартовые параметры модели НС. Основными регулируемыми элементами выбранной конфигурации НС являются: стартовые веса связи между нейронами разных слоев, поляризация, функция активации нейронов и коэффициент обучения.

Единичный сигнал поляризации [Осовский, 2002] в данном исследовании отсутствует.

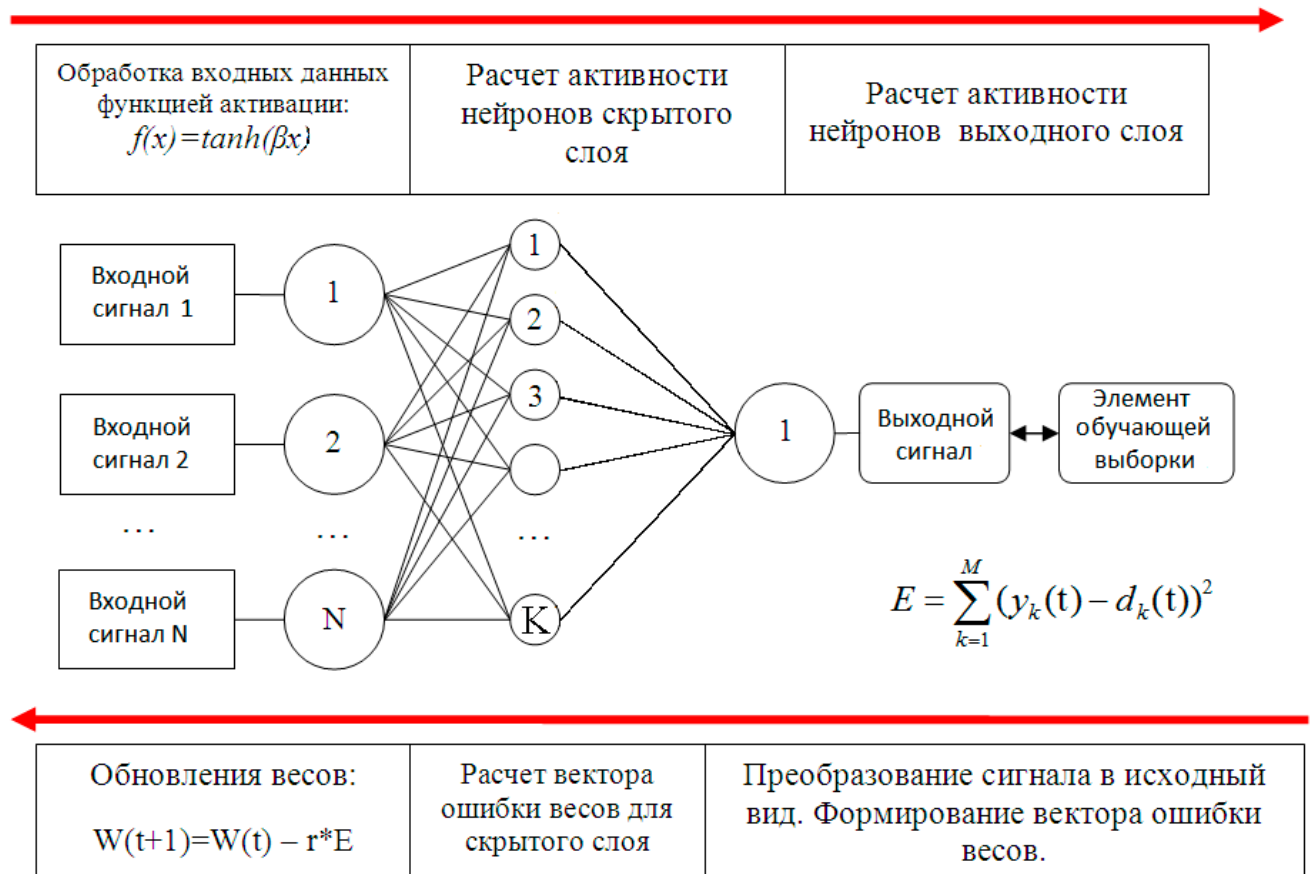


Рисунок 3.1 – Краткая схема обучения нейронной сети. W – веса активности нейронов (на схеме также обозначены линиями между нейронами), t – временной шаг, r – коэффициент скорости обучения, E – целевая функция, y_k – множество выходных сигналов, d_k – множество элементов обучающей выборки. N – общее количество нейронов во входном слое, K – общее количество нейронов в скрытом слое, k – номер нейрона скрытого слоя (в случае выходного $k = 1$)

Все нейроны НС представлены сигмоидальной биполярной функцией: $f(x) = \tanh(\beta x)$ от -1 до 1. Такое представление удобно с точки зрения входных рядов данных, представляющих из себя климатические аномалии, нормированные на СКО.

Стартовые веса связи приравнены к 0.25. Определение стартовых весов практически не влияют на скорость обучения, однако для корректного сравнения разных конструкций НС, которые будут упомянуты ниже, удобно использовать постоянные стартовые коэффициенты весов.

Коэффициент обучения определяет скорость обучения НС, а также разрешает детализацию максимума обучения. При малом коэффициенте обучение может существенно замедлиться, особенно в точках локальных минимумов целевой функции. В обратном же случае, глобальный минимум может “провалиться” под шаг и останется просто незамеченным. Существует множество различных методов подбора оптимального коэффициента обучения, r [Осовский, 2002]. Величина r , как правило, подбирается для каждого слоя отдельно. В работе [Klimauskas, 1992] приведено следующее ограничение: $r \leq 1/N$, где N – количество входов для нейрона i -ого слоя. Также r может быть динамическим, то есть изменяться в процессе обучения НС [Demuth, Beale, 1992]. В данном исследовании мы применим отношение $r=1/N$, то есть для каждой НС будут задействованы минимум 2 коэффициента скорости обучения, для скрытого и выходного слоя НС.

Как известно, НС обычно обучаются на высоко статистически обеспеченных данных [Haykin, 1994; Осовский, 2002], ряды которых представляют выборку порядка 10000 значений. Учитывая среднемесячный масштаб поставленной задачи, достичь такого количества значений не представляется возможным в силу короткого ряда климатических наблюдений, составляющих от 40 до 120 среднемесячных значений в разных базах данных. В таких случаях можно использовать два подхода к обучению: увеличение коэффициента скорости обучения в 10-100 раз или увеличение обучающей выборки путем повторного ее использования. Поскольку увеличение коэффициента обучения на 2 порядка приведет к очень грубому поиску локального минимума целевой функции минимизации [Haykin, 1994; Klimauskas, 1992], в работе использовались итерации обучения некоторой короткой обучающей выборки. Стоит отметить, что такой подход к обучению многослойного персептрона вполне уместен и известна практика такого применения [Осовский, 2002].

В ходе обучения НС на каждом шаге итераций оценивались средняя ошибка и коэффициенты корреляции между данными наблюдений и продуктом модели.

После завершения цикла определялся максимум обучения модели. Подробное описание алгоритма его определения приведено ниже. Параметры обученной НС сохранялись в лог-файл. Интуитивная блок-схема использования итераций и поиска максимума обучения проиллюстрирована на рис. 3.2.

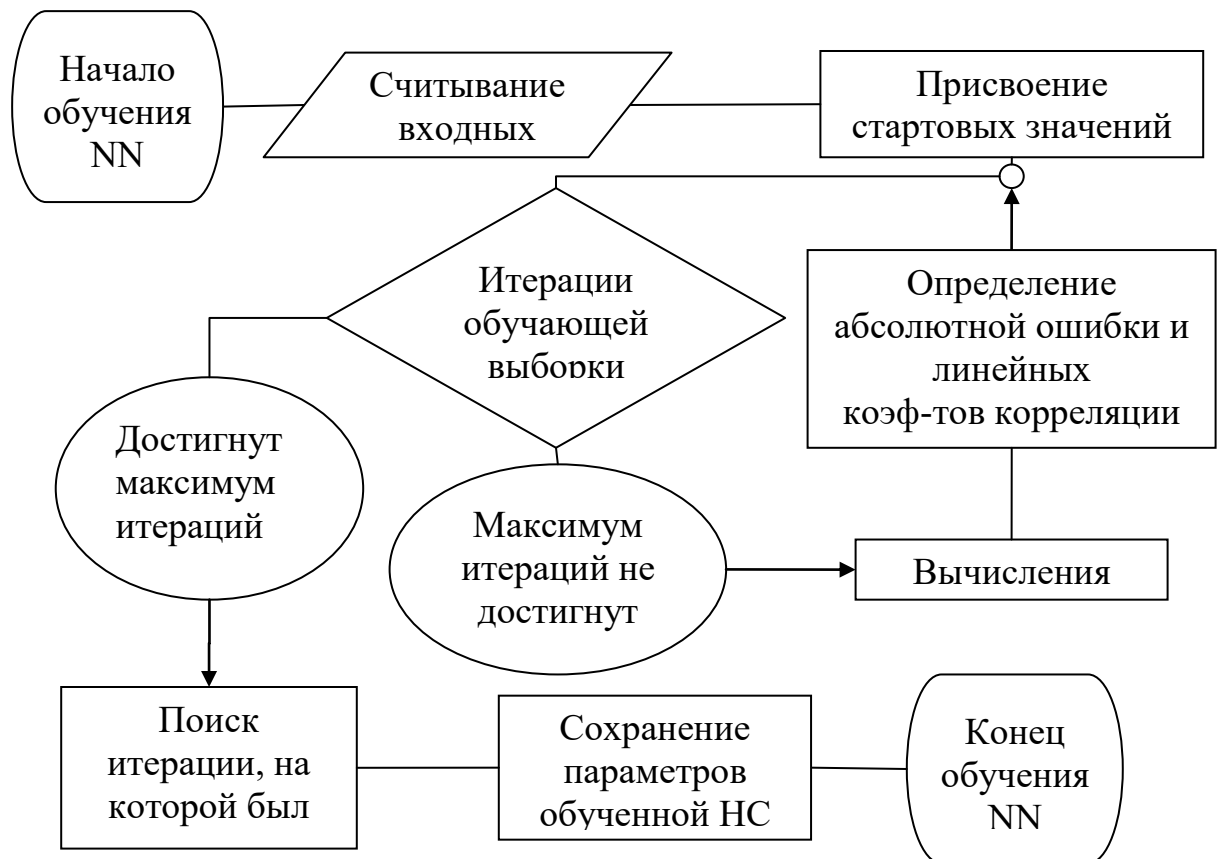


Рисунок 3.2 – Схема использования итераций в процессе обучения НС

3.1.2 Алгоритм обратного распространения ошибки

Алгоритм обратного распространения ошибки, схематически проиллюстрированный на рис. 3.1, определяет стратегию подбора весов многослойной сети с применением градиентных методов оптимизации [Осовский, 2002]. В настоящее время он считается одним из наиболее эффективных алгоритмов обучения многослойного персептрона. В основе этого алгоритма лежит целевая функция, формулируемая в виде квадратичной суммы разностей между фактическими и ожидаемыми значениями выходных сигналов. В случае

единичной обучающей выборки (x, d) целевая функция определяется в виде

$$E(w) = \frac{1}{2} \sum_{k=1}^K (y_k - d_k)^2, \quad (3.1)$$

где y_k – результат моделирования, d_k – моделируемый параметр, k ($k = 1, 2 \dots K$) – номер входящего в нейрон сигнала, K – общее количество нейронов в скрытом слое.

Уточнение весов может проводиться после предъявления каждой обучающей выборки либо однократно после предъявления всех выборок, составляющих цикл обучения. В нашем исследовании используется целевая функция вида (3.1), которая соответствует актуализации весов после предъявления каждой выборки.

Классически цель обучения состоит в таком определении значений весов нейронов каждого слоя сети, чтобы при заданном входном векторе получить на выходе значения сигналов y , совпадающие с требуемой точностью с ожидаемыми значениями d .

Обучение сети с использованием алгоритма обратного распространения ошибки проводится в несколько этапов. На первом из них предъявляется обучающая выборка x и рассчитываются значения сигналов соответствующих нейронов сети. При заданном входном векторе x определяются вначале значения нейронов выходных сигналов v_j скрытого слоя, а затем значения y_i нейронов выходного слоя. Расчет v_j и y_i осуществляется по следующим формулам.

$$v_j = f \left(\sum_{i=0}^N w_{ij}^{(1)} x_i \right), \quad (3.3)$$

где $w_{ij}^{(1)}$ – веса скрытого слоя, x_i – сигналы нейронов входного слоя, $i = 1, 2, \dots, N$. Причем значения v_0 и x_0 могут быть равны как 1, так и 0, в зависимости от выбранной поляризации нейронной сети. В нашем исследовании поляризация нулевая.

В выходном слое i -тый нейрон рассчитывает выходной сигнал, определяемый как

$$y_k = f\left(\sum_{i=0}^K w_{ki}^{(2)} v_i\right) = f\left(\sum_{i=0}^K w_{ki}^{(2)} f\left(\sum_{j=0}^N w_{ij}^{(1)} x_j\right)\right) \quad (3.4)$$

где $w_{ki}^{(2)}$ – веса выходного слоя.

После получения значений выходных сигналов y_i можно рассчитать фактическое значение целевой функции $E(w)$, заданной выражением (3.1).

Второй этап алгоритма призван минимизировать значения функции $E(w)$. Если принять, что целевая функция непрерывна, то наиболее эффективными способами обучения оказываются градиентные методы оптимизации, согласно которым уточнение вектора весов (то есть обучение) производится по формуле:

$$w(t + 1) = w(t) + \Delta w, \quad (3.5)$$

где

$$\Delta w = rp(w), \quad (3.6)$$

t – номер подаваемого на вход набора, а в нашем случае временной шаг, r – коэффициент обучения, $p(w)$ – направление в многомерном пространстве w .

Обучение многослойной сети с применением градиентных методов требует определения вектора градиента относительно весов всех слоев сети, что необходимо для правильного выбора направления $p(w)$. Эта задача имеет очевидное решение только для весов выходного слоя. Для других слоев создана специальная стратегия, которая в теории НС называется алгоритмом обратного распространения ошибки (англ.: backpropagation) [Klimauskas, 1993; Demuth, Beale, 1992], отождествляемым, как правило, с процедурой обучения сети. В соответствии с этим алгоритмом в каждом цикле обучения следует выделить следующие этапы [Hertz et al., 1995].

1. Анализ нейронной сети в прямом направлении передачи информации при генерации с помощью функции активации входных сигналов, составляющих вектор x . В результате такого анализа рассчитываются значения выходных сигналов нейронов скрытых слоев и выходного слоя, а также соответствующие

производные $\frac{df(u_i^{(1)})}{du_i^{(1)}}$, $\frac{df(u_i^{(2)})}{du_i^{(2)}}$, ..., $\frac{df(u_i^{(m)})}{du_i^{(m)}}$ функций активации каждого слоя (m – количество слоев в сети)

2. Создание набора обратного распространения ошибок путем изменения направлений передачи сигналов, замена функции активации ее производными и подача сигналов на бывший выход (а в настоящий момент - вход) сети возбуждения в виде разности между фактическим и ожидаемым значением. Для определенной таким образом сети необходимо рассчитать значения требуемых обратных разностей.

3. Уточнение весов (то есть обучение сети), выполняемое по предложенной выше формуле 3.6.

4. Описанный в пунктах 1, 2 и 3 процесс следует повторить для всех обучающих выборок, продолжая его вплоть до выполнения условия остановки алгоритма.

Базовые формулы считаются классическими для теории нейронных сетей. Рассмотрим условия, относящиеся к сети с одним скрытым слоем.

Как и ранее, количество входных узлов обозначим буквой N , количество нейронов в скрытом слое K , а количество нейронов в выходном слое M . Будем использовать сигмоидальную биполярную функцию активации этих нейронов. Основу алгоритма составляет расчет значения целевой функции как квадратичной суммы разностей между фактическими и ожидаемыми значениями выходных сигналов сети. В случае единичной обучающей выборки (x, d) целевая функция задается формулой (3.1). Эта функция определяется выражением

$$E = \frac{1}{2} \sum_{k=1}^M \left[f \left(\sum_{i=0}^K w_{ki}^{(2)} v_i \right) - d_k \right]^2 = \frac{1}{2} \sum_{k=1}^M \left[f \left(\sum_{i=0}^K w_{ki}^{(2)} f \left(\sum_{j=0}^N w_{ij}^{(1)} x_j \right) \right) - d_k \right]^2. \quad (3.7)$$

Конкретные компоненты градиента рассчитываются дифференцированием зависимости (3.8). В первую очередь подбираются веса нейронов выходного слоя. Для выходных весов получаем:

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = (y_i - d_i) \frac{df(u_i^{(2)})}{du_i^{(2)}} v_j, \quad (3.8)$$

Если ввести обозначение $\delta_i^{(2)} = (y_i - d_i) \frac{df(u_i^{(2)})}{du_i^{(2)}}$, то соответствующий компонент градиента относительно весов нейронов выходного слоя можно

представить в виде:

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = \delta_i^{(2)} v_j. \quad (3.9)$$

Компоненты градиента относительно нейронов скрытого слоя определяются по тому же принципу, однако они описываются другой, более сложной зависимостью, следующей из существования функции, заданной в виде

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = (y_k - d_k) \frac{dy_k}{dv_i} \frac{dv_i}{dw_{ij}^{(1)}} \quad (3.10)$$

После конкретизации отдельных составляющих этого выражения получаем:

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \sum_{k=1}^M (y_k - d_k) \frac{df(u_k^{(2)})}{du_k^{(2)}} w_{ki}^{(2)} \frac{df(u_k^{(1)})}{dw_{ij}^{(1)}} x_j. \quad (3.11)$$

Если ввести обозначение

$$\delta_i^{(1)} = \sum_{k=1}^M (y_k - d_k) \frac{df(u_k^{(2)})}{du_k^{(2)}} w_{ki}^{(2)} \frac{df(u_k^{(1)})}{dw_{ij}^{(1)}}. \quad (3.12)$$

То получим выражение, определяющее компоненты градиента относительно весов нейронов скрытого слоя в виде

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \delta_i^{(1)} x_j. \quad (3.13)$$

В обоих случаях (формулы (3.9) и (3.13)) описание градиента имеет аналогичную структуру и представляется произведением двух сигналов: первый соответствует начальному узлу данной взвешенной связи, а второй - величине погрешности, перенесенной на узел, с которым эта связь установлена. Определение вектора градиента очень важно для последующего процесса уточнения весов. В классическом алгоритме обратного распространения ошибки фактор $p(w)$, учитываемый в выражении (3.5), задает направление отрицательного градиента, поэтому

$$\Delta w = -\eta \nabla E(w) \quad (3.14)$$

3.1.3 Алгоритм поиска максимума обучения

В настоящей работе веса связей обновляются после предъявления итерации обучающей выборки, следовательно, для каждой итерации проверяется условие достижения максимума обучения. Обычно максимум обучения определяется целевой функцией по формуле (1). Во многих задачах ставится пороговое условие, при достижении которого НС считается обученной. Однако 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 30-38 значений, что усложняет определение максимума обучения классическим методом. В этой связи для определения максимума обучения был предложен альтернативный подход. На каждом шаге обучающая выборка повторяется многократно, 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 — необходимость контрольной проверки моделируемых результатов. Это связано с тем, что в процессе поиска максимума обучения НС используется тестирующая выборка и, следовательно, возникает необходимость использовать независимую (контрольную) выборку для объективной оценки возможностей модели.

Из предложенного метода определения максимума обучения следует, что количество итераций может быть ограничено лишь специалистом. Если предположить, что любой максимум обучения является лишь локальным, то задача затребует миллионы итераций для поиска глобального максимума

обучения. Однако в таком случае вычисления бы занимали много времени. Экспериментальным путем было получено, что при выбранном коэффициенте обучения оптимальный порог количества итераций равняется 1000, который и будет использоваться в этой работе.

3.2. Тестирование модели НС

Для тестирования нейросетевой модели были созданы несколько массивов данных, представляющих собой гармонические функции (\cos и \sin) с различными частотами и амплитудами (рис. 3.3). Эти функции использовались в качестве входных сигналов (предикторов), как аналоги реальных климатических сигналов, оказывающих влияние на прогнозируемую величину:

- $\cos(X \cdot 0,2)$ – период в 320 шагов;
- $\sin(X \cdot 1,05)$ – период в 60 шагов;
- $0,7 \cdot \cos(X \cdot 9)$ – период в 7 шагов;
- $0,3 \cdot \sin(X \cdot 22)$ – период в 3-4 шага.

Частоты и амплитуды выбранных функций были подобраны в соответствии с [Хотон, 1987]. При этом период 320 лет был предположен гипотетически.

Количество нейронов входного слоя соответствует количеству входных сигналов и равно 4. Согласно теореме Колмогорова–Арнольда [Колмогоров, 1957] о представлении непрерывных функций нескольких переменных суперпозицией непрерывных функций одного переменного и сложения, которая в 1987 году была использована Хечт-Нильсеном для нейронных сетей, оптимальное количество нейронов в скрытом слое должно равняться $2i+1$ (i – количество входных сигналов) [Наукин, 1994; Hecht-Nielsen, 1991]. Следовательно, количество нейронов скрытого слоя для этой подзадачи было равно 9. Начальные значения весов остались без изменений и равны 0.25. Поскольку искусственно созданная выборка представляет собой сумму заведомо известных функций, то для

обеспечения достижения более точного максимума обучения НС следует взять более низкий коэффициент скорости обучения НС. r в этом случае равнялся 0.05. Для моделирования были использованы 160 шагов суммы гармонических функций, из которых для обучения использовались первые 60, а для тестирования модели – с 61 по 160.

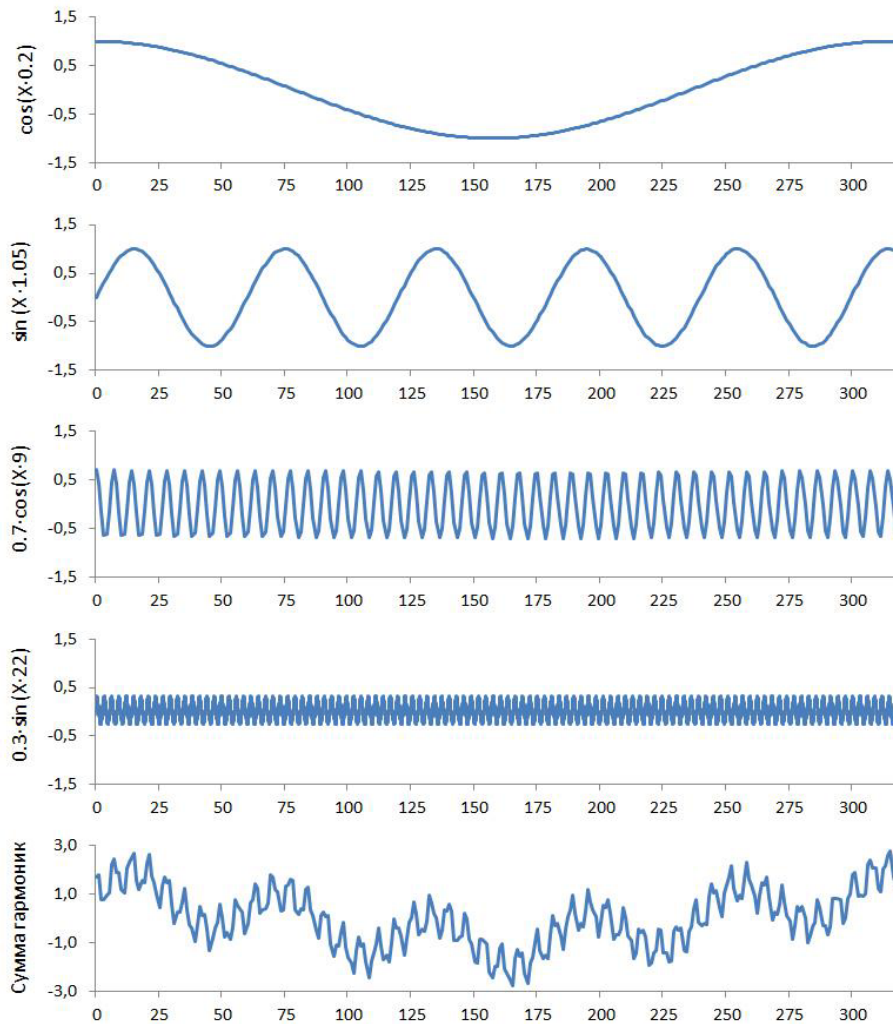


Рисунок 3.3 – Гармонические функции, характеризующие 3-4-летний, 7-летний, 60-летний и 320-летний период и их сумма.

В силу того, что начальные условия определяются случайным образом, были выполнены 100 запусков, а после этого определены значения коэффициента линейной корреляции (r), САП на тестовой выборке и итерация максимума обучения (10 случайных результатов приведено в таблице 1.1). В среднем для 100 запусков модели был получен следующий результат: $r = 0.998$; САП = 0.063.

Таблица. 3. 1 – случайно выбранных результатов тестирования модели на основе искусственно созданных закономерностей

итерация	15399	1642	5995	18044	4070	19375	7552	2345	15	9206
r	0.9985	0.9982	0.9983	0.9979	0.9979	0.9986	0.9974	0.9977	0.9977	0.9980
САП	0.0581	0.0678	0.0576	0.0682	0.0652	0.0596	0.0734	0.0696	0.0704	0.0639

На рис. 3.4 приведен график обучения одного из сценариев. На графике четко выделен момент максимума обучения. На 600 итерации коэффициенты корреляции модельных данных с моделируемым параметром на тестовой и обучающей выборках расположены максимально близко, в то время как САП достигает своего минимума. Под “целевой функцией” здесь подразумевается максимум разности между моделируемой и полученной моделью величиной. Рис. 3.4 демонстрирует процесс обучения, соответствующий иллюстрации на рис 3.5.

3.2.1 Добавление белого шума к моделируемому параметру

Для оценки способности модели НС справляться с зашумленными выборками к моделируемой сумме гармоник добавлялся шум.

Было проведено два эксперимента. В первом диапазон разброса значений шума выбран от 1 до -1, определяемый случайно. Для удобства анализа влияния шума на обучение зафиксируем все начальные значения весов, приравняв их к 0.25. Были получены следующие результаты. При достижении минимума функции обучения коэффициент корреляции составил 0.91, САП = 0.49 с зашумленными данными и 0.995 (MAE=0.17) с моделируемой функцией без шума. Результат предоставлен на рис. 3.6а.

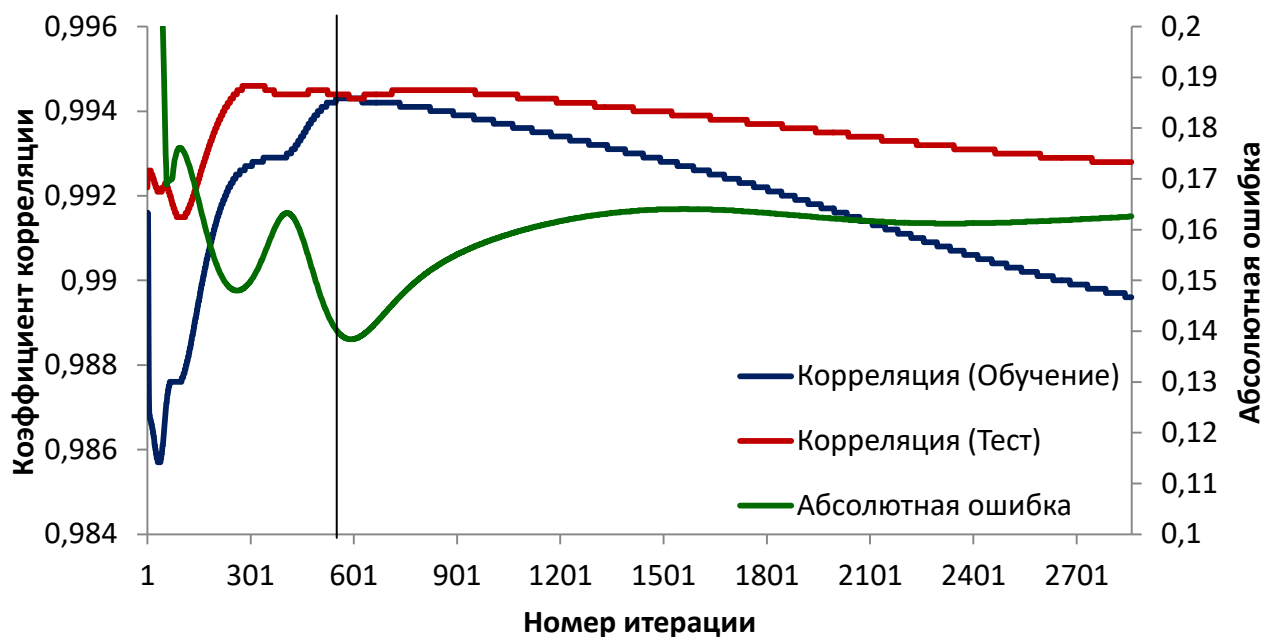


Рисунок 3.4 – Обучение и переобучение нейронной сети на примере искусственно созданных закономерностей. Вертикальная линия обозначает момент максимума обучения.




Рисунок 3.5 – Моделирование искусственно созданного ряда

Однако, если шум значительно превышает амплитуду высокочастотной периодики то САП растет (0,38), в то время как корреляция изменяется не существенно (0,95), а результат моделирования представляет собой модельную функцию с менее выраженной амплитудой как на низкочастотных, так и на высокочастотных колебаниях (рис 3.6б).




Рисунок 3.6 – Обучение с добавлением шума (а) – в диапазоне от -1 до 1 и (б) – в диапазоне от -3 до 3 в моделируемую величину.

Таким образом, при использовании нейронной сети в целях восстановления данных и/или формирования климатических прогнозов в качестве моделируемого параметра допускается использование данных, имеющих случайную погрешность измерений. Следовательно, нейронные сети можно использовать в целях отчистки от шума моделируемого сигнала.

3.2.2. Добавление белого шума к входным сигналам

Для оценки способности модели НС справляться с зашумленными входными данными был проведен ряд экспериментов. Сначала шум добавлялся только к одному из входных сигналов, на следующем эксперименте уже к двум, и так далее, пока каждый из 4 сигналов не подавался на вход с определенным уровнем шума. Шум варьировался от 15% от разброса данных, до 60%. Под разбросом следует понимать разницу между максимальным и минимальным значениями ряда за 160 шагов периода обучения. Было реализовано 100 прогонов для каждого варианта с добавлением шума к входным сигналам. Для каждого прогона модели НС запоминались максимумы обучения и их проверка на тестовой выборке, после – рассчитывалось среднее. Результаты представлены в таблице 2.

Таблица 3.2 – Добавление шумов во входящие сигналы, осредненные по результатам 100 прогонов для каждого варианта добавления шума к входным сигналам

Количество зашумленных сигналов	1		2		3		4	
	correl	САП	correl	САП	correl	САП	correl	САП
Шум от -0,5 до 0,5 (15%)	0,96	0,29	0,96	0,31	0,94	0,37	0,91	0,43
Шум от -1 до 1 (30%)	0,91	0,45	0,84	0,58	0,78	0,67	0,73	0,76
Шум от -1,5 до 1,5 (45%)	0,86	0,56	0,74	0,78	0,63	0,86	0,56	0,9
Шум от -2 до 2 (60%)	0,84	0,60	0,67	0,82	0,47	1,04	0,41	1,03

Из результатов видно, что шум, добавляемый к входному сигналу, не фильтруется и в зависимости от его интенсивности меняется качество моделирования. Также отмечено, чем больше зашумленных сигналов на входе, тем хуже будет моделироваться параметр. Пример моделирования в случае, если ко всем входным сигналам был добавлен шум в промежутке от -1 до 1, приведен на рис. 3.7




Рисунок 3.7 – Результат моделирования с зашумленными входными сигналами случайным шумом от -1 до 1.

Таким образом, при использовании НС с учителем следует помнить, что зашумленность входных параметров может сильно сказаться на качестве моделирования в отличие от зашумленности моделируемой величины. Если доля

шума составляет более 60% – моделирование в таком случае не даст положительных результатов – коэффициенты корреляции в приведенной симуляции приближаются к незначимым.

3.2.3. Прогноз при отсутствии одного из предикторов

Попробуем дать предварительную оценку значимости мод, исключая поочередно из входных сигналов каждую из них. Начнем с низкочастотной моды. При исключении низкочастотной моды модель не смогла определить низкочастотную составляющую процесса. Аналогичная картина наблюдалась при исключении каждой мод поочередно (рис 3.8). Из-за отсутствия предиктора модель не могла моделировать процесс с точностью, сравнимой с обучением при участии всех предикторов. В табл.3 приведены результаты эксперимента.

Таблица 3.3 – Прогноз при отсутствие одного из предикторов

Исключенная мода	Корреляция	Средняя абсолютная погрешность
$COS(0,2*X) - 320лет$	0.79	0.68
$SIN(1,05*X) - 60лет$	0.80	0.67
$0,7*COS(9*X) - 7лет$	0.90	0.46
$0,3*SIN(22*X) - 3-4лет$	0,98	0,19
Все включено (для сравнения)	0,99	0,06

Таким образом, исключая какой либо параметр из системы, которую мы моделируем, НС получает не полную информацию и не способна смоделировать процесс. Наибольшую значимость на достаточно длинных рядах имеют низкочастотные характеристики, наименьшую – высокочастотные.

Таким образом, можем заключить, что реализация модели НС работает корректно. НС способна фильтровать шум, присутствующий в моделируемой характеристике, однако при высокой зашумленности амплитуда ослабевает. В то же время, шум, добавленный к входным в НС сигналам, не фильтруется. Если доля шума для каждого параметра составляет более 30% то моделирование

возможно только качественное. Если более 60% – моделирование в таком случае не даст положительных результатов. Этот тезис в очередной раз подчеркивает важность выбора надежных статистически обеспеченных данных. При отсутствии одного из входных сигналов качество моделирования уменьшается. Отсутствующий сигнал не восполняется.

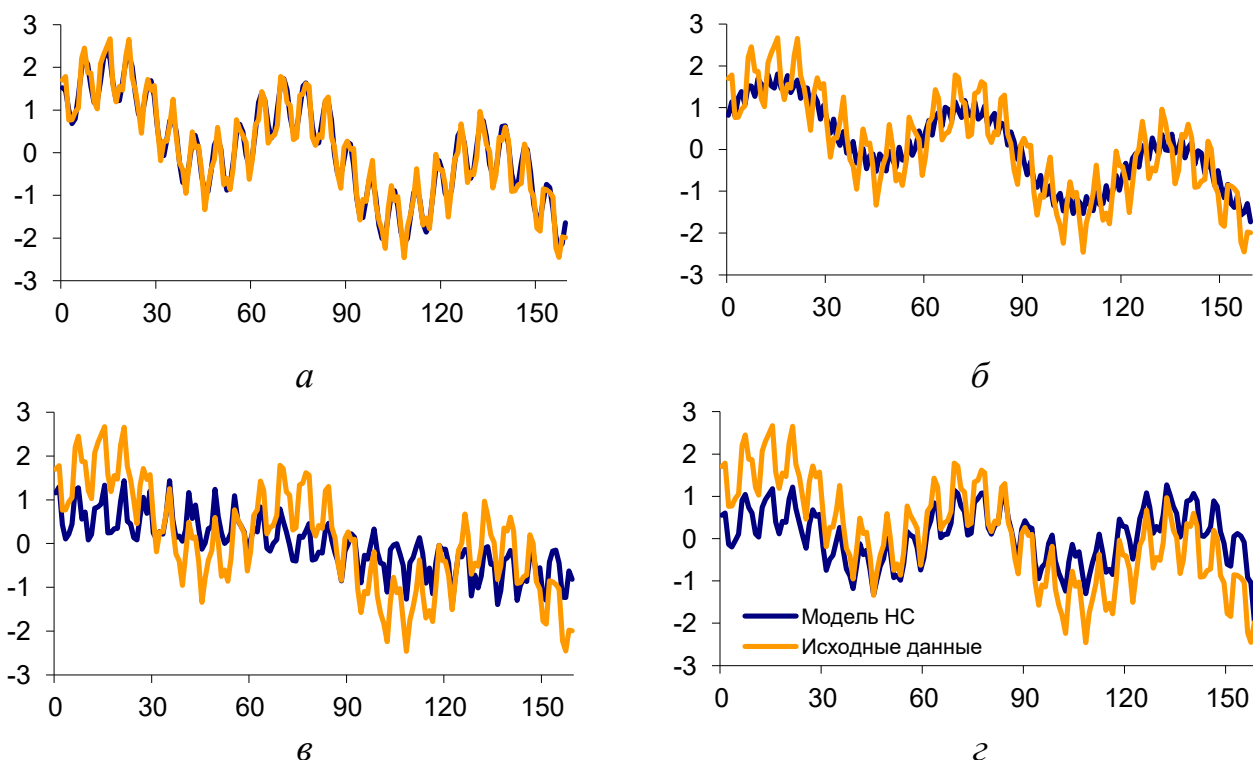


Рисунок 3.8 – Моделирование при отсутствии (а) – 3-4 летнего, (б) – 10-летнего, (в) – 60-летнего и (г) – 320-летнего входного индекса

3.3. Практическое определение оптимального количества нейронов входного и скрытого слоев

Для выявления оптимального количества нейронов входного и скрытого слоев проведем ряд экспериментов. Для этого были использованы среднемесячные данные об объеме расхода стока р. Дунай (станция Измаил) за период 1950-2012 гг. в августе. В качестве предикторов, которые использовались для этого эксперимента, были взяты индексы Г. Барстона и Р. Ливизи из работы [Barnston, Livezey, 1987]. Входные сигналы в НС определялись по алгоритму ранжирования,

описанному в параграфе 2.2. Их количество варьировалось от 2 до 10 в зависимости от условий эксперимента. Диапазон количества нейронов скрытого слоя выбран от 1 до $i*3+10$, где i – количество нейронов во входном слое. Тестовая и обучающая выборки выбраны равными относительно друг друга и составляли 31 значение. Коэффициент скорости обучения постоянный и равен 0.05. Начальные весовые коэффициенты равнялись 0.25. Максимум обучения определялся предложенным в работе методом (см. подпараграф 3.1.3).

Все результаты прогона для каждой конструкции модели с $i=2..10$ входами нейронами и $1..i*3+10$ нейронами скрытого слоя были занесены в лог-файл. Их количество составило 1015.

Для анализа результатов прогона 1015 различных конструкций НС следует отфильтровать конструкции, явным образом не удовлетворяющие условию предпочтительной точности модели. Фильтрация проводилась на основе уже обученной НС в контрольный период. Предполагалось, что пороговое значение будет определено с использованием критического Т-критерия Стьюдента. Для начала следует определить эффективное количество степеней свободы.

$$n_{эфф} = n \frac{1 - r_1 r_2}{1 + r_1 r_2}, \quad (3.15)$$

где r_1 – автокорреляция с предыдущим временным шагом результата модели, r_2 – автокорреляция с предыдущим временным шагом используемых данных. Для расхода стока р. Дунай в августе $r_2 = 0.38$, а r_1 лежит в пределах от 0.25 до 0.4 для разных конструкций НС. Из этого следует, что эффективная степень свободы лежит в диапазоне от 22 до 25 значений.

Для уровня значимости $\alpha = 0.05$ и ряда, имеющего 22 степени свободы, $T_{кр} = 2.0739$. Для расчета критической корреляции воспользуемся функцией связи $T_{эмп}$ (эмпирический критерий Стьюдента) и корреляции:

$$T_{эмп} = r \frac{\sqrt{n}}{\sqrt{1 - r^2}}. \quad (3.16)$$

Заменим $T_{эмп}$ на $T_{кр}$ и рассчитаем $r_{кр}$. При известном $T_{кр}$ и $n_{эфф}$, $r_{кр} = 0.404$. Таким образом для фильтрации конструкций НС на основе критического Т-

критерия Стьюдента получен следующий порог: $r_{мест} > 0.404$, где $r_{мест}$ – корреляция модели с моделируемой величиной на тестовой выборке.

На практике практически все модельные результаты конструкций НС превышали $r_{кр}$, однако не отображали поведение моделируемой величины в целом. Объективно полагать, что коэффициент корреляции, равный всего 0.404, недостаточен для индикации близкой статистической связи моделируемого значения и результатов модели. Поэтому был введен условный порог, равный 0.7.

Ниже приведен анализ как оптимального количества нейронов входного и скрытого слоев. Для этого использовался перебор всех возможных комбинаций предикторов на входе, использованных для моделирования расхода р. Дунай, начиная с комбинаций из 2 индексов. Количество комбинаций НС можно представить следующим образом:

$$M = \sum_{i=2}^N C_N^i, \quad (3.17)$$

где N – общее количество входных предикторов, i – текущее количество предикторов ($i = 1, 2, \dots, N$), C_N^i – сочетание i элементов по множеству N .

Для каждой комбинации входных нейронов мы отбирали конструкцию НС с максимальной корреляцией на тестовой выборке и соответствующему ей количеству нейронов скрытого слоя, которое менялось от 3 до 30. Ни одна конструкция модели, использовавшая комбинацию из двух различных входных сигналов, не превысила выбранный предел. Максимальное количество комбинаций НС, преодолевших порог 0.7, соответствует 6 нейронам во входном слое. При этом максимальное количество комбинаций НС возможно при 5 входных нейронах. В то же время отношения между количеством преодолевших предел и возможных комбинаций растет с ростом количества используемых на входе сигналов (см. табл. 4 и рис 3.9).

Далее проведем анализ по количеству нейронов в скрытом слое. Рассмотрим распределение конструкций НС, преодолевших предел, по количеству нейронов в скрытом слое в случае использования комбинаций из 5, 6

и 7 нейронов на входе (рис. 3.10). Так же, как и на предыдущем этапе, использовались только результаты моделирования, преодолевшие порог $r = 0.7$.

Таблица. 3.4 – Распределение комбинаций по количеству нейронов во входном слое, превысивших заданный предел: $r = 0.7$

Количество нейронов во входном слое	Количество всевозможных комбинаций с определенным количеством нейронов во входном слое	Количество комбинаций, преодолевших установленный предел	Отношения преодолевших предел к общему
2	44	0	0
3	120	3	0,025
4	210	16	0,076
5	252	50	0,2
6	212	69	0,327
7	120	45	0,375
8	45	25	0,556
9	10	6	0,6
10	1	1	1




Рисунок 3.9 – Распределение соотношения преодолевших корреляционный порог (0.7) к общему числу комбинаций НС в зависимости от количества нейронов во входном слое

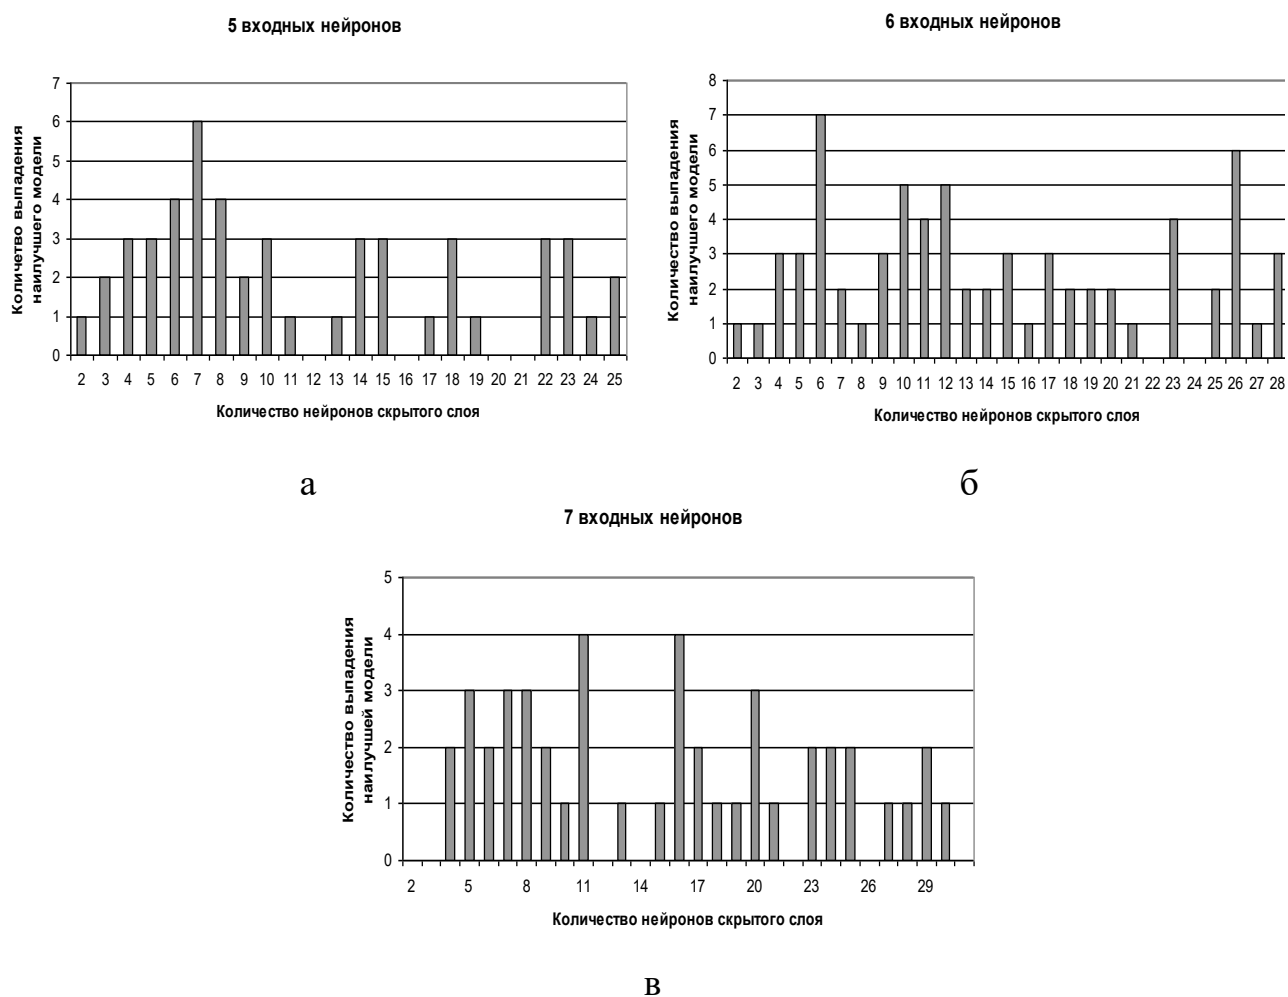


Рисунок 3.10 – Гистограммы количества комбинаций выпадающих на количество нейронов скрытого слоя для пяти (а), шести (б) и семи (в) входных нейронов

Ожидалось, что мы получим нормальное ли близкое к нормальному распределение, мода и математическое ожидания которого совпадет и будет равняться упомянутому ранее оптимальному количеству нейронов скрытого слоя $i*2+1$ (где i – количество нейронов входного слоя) в соответствии с модификацией Р. Хечт-Нильсеном [Hecht-Nielsen, 1991] известной теоремы Колмогорова–Арнольда [Колмогоров, 1957]. Математическое ожидание полученного нами количества нейронов скрытого слоя действительно оказалось близко к теоретическим расчетам Р. Хечт-Нильсена и равнялось 12 в случае 5 нейронов во входном слое, 14 в случае 6 и 15 в случае 7. Однако мода и разброс, очевидно, указывают на то, что распределение близко к равномерному (рис. 3.10).

Следовательно, используемое отношение $i \cdot 2 + 1$ не применимо в качестве оптимального количества нейронов скрытого слоя в подобных практических задачах. Поэтому в текущей работе будут рассчитаны все конструкции НС с количеством нейронов в скрытом слое, которое будет меняться от 3 до удвоенного условия Р. Хечт-Нильсена – $4 \cdot i + 2$.

3.4 Комбинации НС и множественный подход

Поскольку в качестве входных сигналов в работе были использованы климатические индексы с доказанной значимой статистической связью, что в свою очередь не является доказательством наличия физической связи между предиктором и предикатом, не все входные сигналы неизбежно приведут к положительному результату моделирования. Использование выбранного входного сигнала, физически несвязанного с предикатом, приведет к ошибочному обучению НС, что станет очевидно на тестовой выборке. Помимо этого, климатические индексы могут быть связаны с прогнозируемой характеристикой через один и тот же физический механизм, проявляющийся с разным запаздыванием в океане и атмосфере. Такая мультиколлинеарность приведет к использованию «индексов-дублеров», в результате чего именно их связанный физический механизм получит гораздо больший вес внутри НС. Предполагая, что на климатическую аномалию может влиять несколько не пересекающихся физических механизмов, такая нейронная сеть заведомо может упускать некоторый объем информации, а ее функциональная зависимость будет неустойчивой.

Этот тезис подтвердился на практике. На основе всех отобранных индексов модель продемонстрировала неудовлетворительный результат. Поэтому моделирование проводилось с перебором всех возможных комбинаций предикторов на входе, выбранных на предварительном этапе, начиная с комбинаций из 3 индексов. Схематически алгоритм ядра модели представлен на рис 3.11а. Количество нейронов скрытого слоя на основании выводов, сделанных

из предыдущего параграфа, изменялось от 3 до $4i+2$ (где i – количество предикторов в текущей выборке). Таким образом, общее число возможных конструкций НС, имеющих уникальный набор предикторов и различное число нейронов скрытого слоя, можно рассчитать как

$$\text{Max designs} = \sum_{i=3}^N (4i + 2) C_N^i, \quad (3.18)$$

где N – общее количество входных предикторов, i – текущее количество предикторов ($i = 1, 2, \dots, N$), C_N^i – сочетание i элементов по множеству N .

На рис. 3.11б проиллюстрирован рост комбинаций входного слоя НС в зависимости от количества используемых индексов N . Если построить функцию

$$F = \frac{\text{Max}(N+1)}{\text{Max}(N)}, \quad (3.19)$$

проиллюстрированную на рис 3.11в, можно заметить, что эта функция с ростом N будет стремиться к 2. Таким образом, рост сложности можно сформулировать, используя предел:

$$\lim_{N \rightarrow \infty} \sum_{i=3}^N C_N^i = 2^N, \quad (3.20)$$

Стоит отметить, что полученная закономерность вполне справедлива и связана с известной теоремой $\sum_{i=0}^n C_n^i = 2^n$, выполняющейся при положительных n . Таким образом, количество используемых для моделирования индексов существенно влияет на скорость поиска функциональной зависимости, которая будет использована для составления прогноза. Следовательно отбор предикторов, описанный в параграфах 2.2 и 2.3, является важнейшей задачей.

Для каждой уникальной конструкции НС проводилось обучение. Данные о конструкциях НС в момент максимума обучения (номера используемых предикторов, количество нейронов скрытого слоя, итерация обучения,

корреляционные оценки на тестовой и обучающей выборке) заносились в лог-файл (рис. 3.11а). По окончании расчета функциональных зависимостей всех конструкций НС производилось ранжирование с использованием коэффициента корреляции на тестовой выборке в момент максимума обучения. По результатам ранжирования отбирались 20 лучших конструкций НС. Используя информацию из лог-файла, успешные НС воспроизводились вновь и объединялись в ансамбль путем обычного среднего арифметического. На общей схеме модели (рис. 3.14) этот этап указан как третий.

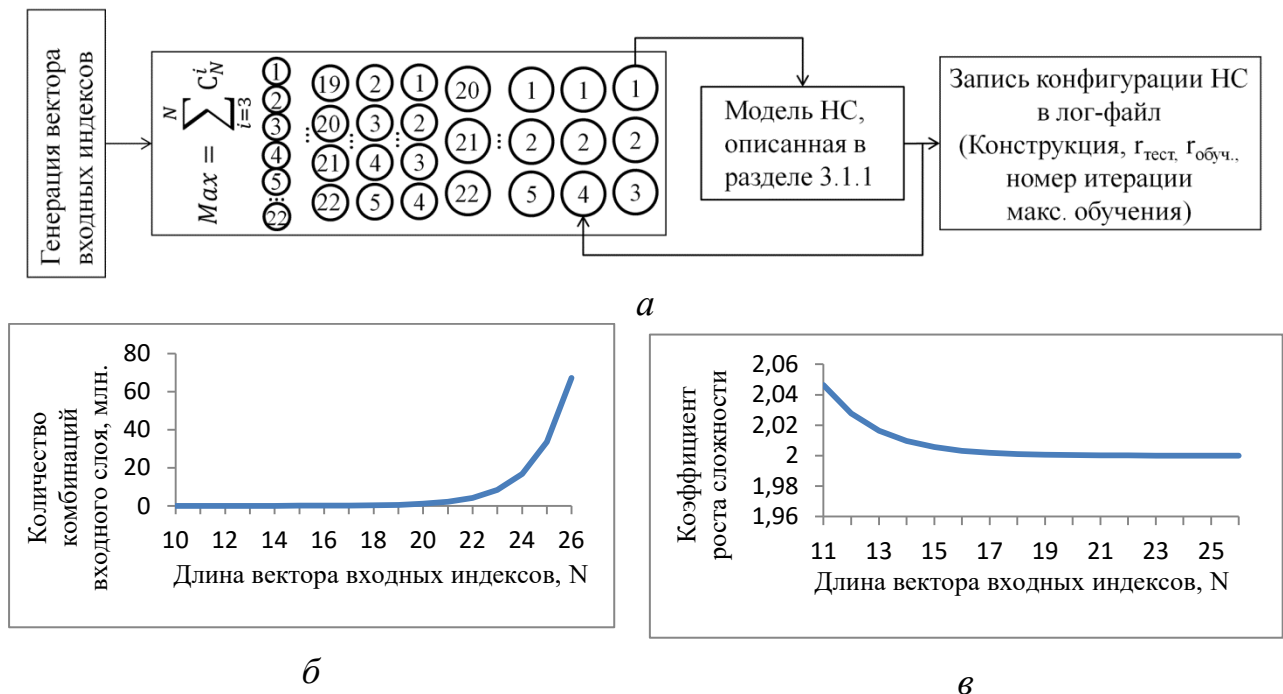


Рисунок 3.11 – *а* – алгоритм работы модели, иллюстрирующий запуск множества НС с различными комбинациями входного слоя, *б* – рост количества комбинаций в зависимости от количества используемых индексов для генерации входных векторов, *в* – коэффициент роста сложности в зависимости от *N*.

Следует отметить, что использование тестовой выборки для отбора 20 лучших моделей и ее косвенное использование для отбора максимума обучения (алгоритм описан в параграфе 3.1.3) привело к необходимости дополнительной независимой проверки модели. Для этого была добавлена контрольная выборка.

Таким образом, моделирование каждого месяца проводилось независимо друг от друга. Среднемесячные ряды значений индексов Nino 3.4, Nino 3, Nino 4 и входных климатических индексов были разделены на обучающую, тестирующую и контрольную 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. (рис. 3.12).




Рисунок 3.12 – Обучающая (1950–1987 гг.), тестовая (1988–2006 гг.) и контрольная (2007–2022 гг.) выборки на примере индекса Nino 3.4 для января

3.5. Оптимизация прогностической модели

Необходимость рассматривать множество комбинаций НС привела к потребности в оптимизации этих расчетов. Одним из способов оптимизации можно считать сокращение вектора входных в модель индексов в процессе расчета.

Ранее приведенный алгоритм на основе искусственных нейронных сетей показал приемлемое качество моделирования, однако время работы такого алгоритма значительно варьировалось в зависимости от количества входных сигналов [Лубков и др., 2016, Лубков и др., 2017]. В случае, если входных сигналов было больше 20, расчет производился по времени от недели и более. При этом практически всегда существовали нейроны, которые не входили ни в одну из 20 лучших конструкций НС (см. параграф 3.4). В связи с этим, алгоритм

модели был доработан в сторону оценки "важности" нейрона входного слоя и увеличения скорости производимых расчетов.

Для определения "важности" индексов, подаваемых на вход НС, был разработан алгоритм накопительной оценки. Как было отмечено в предыдущем параграфе, модель в процессе работы перебирала все возможные комбинации входных сигналов с различным количеством нейронов скрытого слоя от 3 до 18. В процесс перебора этих комбинаций был добавлен некий пороговый коэффициент корреляции. В начале работы модели всем входным индексам присваивалось 0 баллов. В случае, если текущая генерация после обучения коррелировала с тестовой выборкой с коэффициентом, превышающим выбранную пороговую величину, – каждому индексу, входящему в генерацию, присваивался 1 балл. Таким образом, для каждого индекса накапливались баллы "важности". Когда длина вектора входных нейронов i увеличивалась на единицу, индекс, который набрал меньше всего баллов, исключался из числа входящих в модель индексов и больше не входил в генерации входного вектора предикторов НС. В результате сложность модели понижалась, а с ней и уменьшалось время расчета прогноза.

Каждый раз, когда длина вектора входных нейронов i увеличивалась на единицу, выполнялся алгоритм исключения индекса с минимальным количеством баллов, до тех пор, пока число анализируемых индексов, из которых составляются генерации входных нейронов НС, не составило заранее заданное количество. Оптимально – это 15 индексов (задается по желанию). Прimitивная схема алгоритма исключения "незначимых" индексов из модели представлена на рис. 3.13

Такой подход дает возможность не только выявить атмосферные и океанические сигналы, которые не оказывают существенного влияния на качество моделирования, но и обратить внимание на сигналы, набравшие наибольшее количество баллов "важности".

Предложенный алгоритм был протестирован на основе повторного моделирования ранее смоделированных величин стока реки Дунай, опубликованных в работе [Лубков и др., 2016]. Оказалось, что удаленные индексы

действительно не влияют на результат моделирования: на этапе сортировки по коэффициенту корреляции на обучающей выборке в лучшие 20 конструкций НС попали те же самые конструкции модели, что и без применения предложенного алгоритма.

Таким образом, если количество индексов, при которых алгоритм перестанет исключать "незначимые", равно 15, то сложность модели в случае использования 22 входных индексов (столько было выбрано в работе [Лубков и др., 2016]) сократится в 34.1 раза, и в случае 18 индексов – в 7.3 раза.

Помимо реализации изложенного выше алгоритма, код модели был оптимизирован, а также скомпилирован в 64-битном компиляторе, что сократило время расчетов еще примерно в 2 раза.

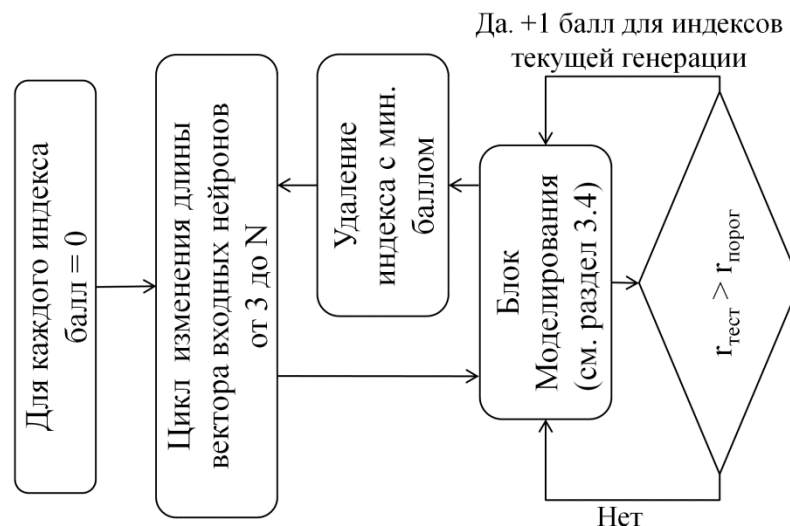


Рисунок 3.13 – Схема работы алгоритма исключения входных в модель индексов.

$\gamma_{\text{тест}}$ – коэффициент корреляции текущей генерации на тестовой выборке, $\gamma_{\text{порог}}$ – коэффициент корреляции порогового значения (задается исследователем).

3.6. Декомпозиция исходного сигнала и моделирование низкочастотной компоненты

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 АМО [Knight at al., 2006; Schlesinger, Ramankutty, 1994] с типичным периодом 60–70 лет, ТДО [Mantua at al., 1997; Zhang at al., 1997, Maslova at al., 2017] 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].

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.

Дисперсионный вклад низкочастотной компоненты индексов Nino относительно не велик и варьируется от 2% в январе до 13% в весенний сезон, но в среднем равен 7%. Применение описанной в этой главе модели на основе НС не целесообразно в виду больших затрат времени на расчеты при сравнительно низком дисперсионном вкладе. Для моделирования низкочастотной компоненты будет применяться простейшая и быстрая модель, а именно, множественная линейная регрессия (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 использовалось минимизация с помощью суммы квадратов разностей между модельным расчетом и фактическим значением. Для МЛР применялись 22 предиктора, отобранных на этапе сортировки входных в модель индексов. С применением пошагового алгоритма, предложенного в [Venables, 2002], удалось оптимизировать модель и выделить те предикторы, на основе которых модель 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.

3.7. Обобщенная схема модели

Таким образом, разработанные выше алгоритмы можно обобщить в общую схему модели, схематически проиллюстрированную на рис 3.14.

На первом этапе производилась декомпозиция исходных индексов Nino3, Nino4 и Nino3.4 на низкочастотную (более 9 лет) и высокочастотную (до 9 лет) компоненты. Эти компоненты были приведены к климатическим аномалиям и нормированы на СКО, после чего компоненты моделировались различными методами, а после моделирования выполнялось их сложение. Высокочастотная компонента моделировалась с использованием МНС, а низкочастотная – МЛР. Такой подход обусловлен необходимостью расширить количество используемых моделью индексов и сократить время расчета.

Моделирование высокочастотной составляющей индексов Nino осуществлялось (рис. 3.14, этап 3) с помощью МНС представленной многослойным персептроном с одним скрытым слоем. Выходной слой представлен лишь одним нейроном. Функция активации нейронов МНС – сигмоидальная биполярная $f(x) = \tanh(\beta x)$. Выбранная архитектура нейронной сети была параметризована: выбраны скорость обучения, поляризация и значения стартовых весов связей нейронов. Для корректного решения поставленной в работе задачи, а именно, моделирования коротких рядов, были использованы итерации обучающей выборки и разработан специфический алгоритм обучения для такого подхода.

Проведено множество тестов разработанного ядра модели, в ходе которых показано, что НС способна фильтровать шум, присутствующий в моделируемой характеристике. В то же время, шум, добавленный к входным сигналам НС, не фильтруется. При отсутствии одного из входных сигналов качество моделирования уменьшается, а отсутствующий сигнал не восполняется. В связи с этим важно очень внимательно подойти к вопросу выбора предикторов (рис. 3.14, этап 2), чему и посвящены параграфы 2.2 и 2.3.

Особенностью предложенной модели является использование на входе климатических индексов, которые связаны статистически с моделируемым параметром с некоторым временным сдвигом от 1 месяца. В ходе тестирования ядра модели на примере моделирования расхода стока р. Дунай была показана необходимость проверки комбинаций НС с различным числом нейронов скрытого слоя. В виду мультиколлинеарности входных в НС индексов был применен множественный подход к поиску наилучших 20 комбинаций НС, среднее значение которых являлось результатом моделирования высокочастотной составляющей.

Низкочастотная составляющая моделировалась с помощью МЛР, где предикторами служили сглаженные 9-летним фильтром индексы ТПО, имеющие статистическую связь с моделируемым параметром со сдвигом от 1 месяца до 10 лет. Результаты моделирования двух компонент складывались и рассчитывались прогностические индексы Nino (рис. 3.14, этап 4).

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

1. Корреляция Пирсона:

$$r = \frac{\text{cov}(x_i y_i)}{\sigma_x \sigma_y}, \quad (3.21)$$

где σ_x и σ_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):

$$\text{RMSE} = \sqrt{\frac{\sum(x_i - y_i)^2}{n}}, \quad (3.22)$$

где n – длина ряда контрольной выборки, x_i – модель, y_i – наблюдаемая величина, i – год контрольной выборки.

3. Отношение RMSE к среднеквадратическому отклонению наблюдаемого ряда (СКО или σ):

$$RMSE/\sigma = \sqrt{\frac{(n-1) \cdot \sum (x_i - y_i)^2}{n \cdot \sum (y_i - \bar{y})^2}}, \quad (3.23)$$

где \bar{y} – среднее наблюдаемого ряда. Значимый результат определяется, если $RMSE/\sigma$ меньше 1 (то есть $RMSE > \sigma$).

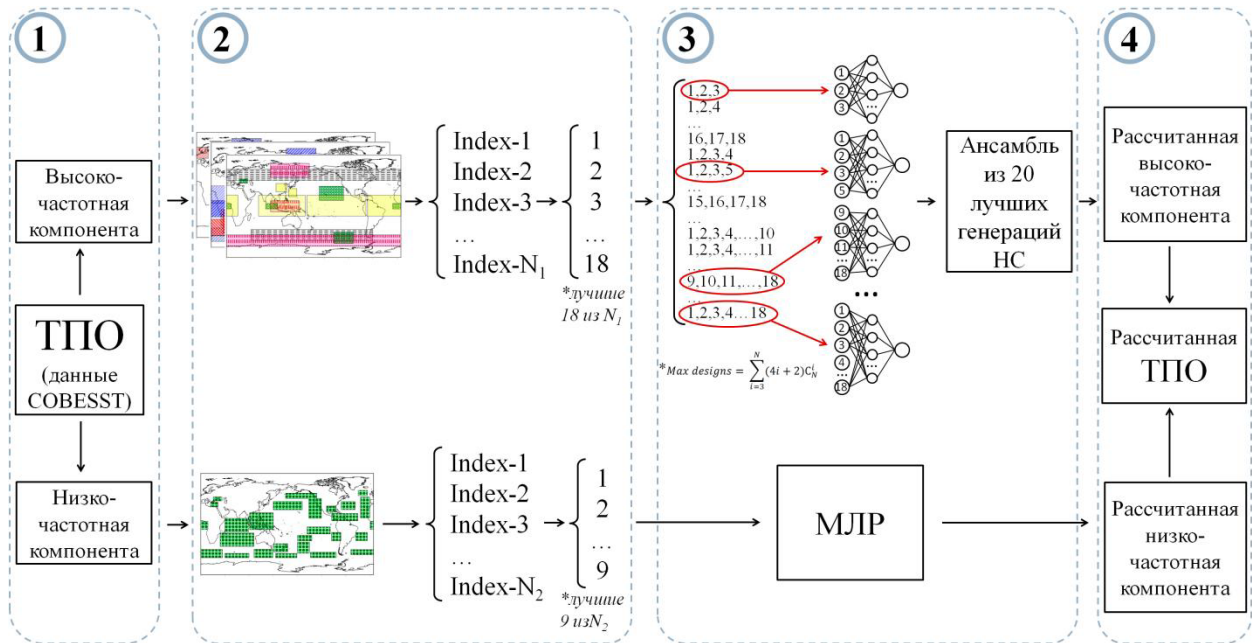


Рисунок 3.14 – Схема предлагаемой модели: 1) декомпозиция моделируемого ряда; 2) предварительная обработка данных; 3) моделирование; 4) Результаты моделирования и проверка

Выводы к Главе 3

В Главе 3 подробно описаны алгоритмы и параметры предлагаемой прогностической модели, в основе которой лежит многослойный персептрон. Основной ряд выводов можно подытожить следующими положениями.

1. Тесты на искусственно созданных рядах данных указали на верную сборку математического алгоритма модели, а также подтвердили известные особенности нейронных сетей.

2. Моделирование реальных данных, а именно, стока реки Дунай, помогло выявить проблемы с количеством и качеством нейронов входного и скрыто слоев. В результате предложено использовать множественный перебор конструкций

нейронных сетей для достижения наилучшего модельного результата и три ключевых выборки данных: обучающую, тестовую и контрольную.

3. Оптимизация модели позволила ускорить ее как минимум на порядок.

Результаты Главы 3 опубликованы в 11 научно-исследовательских журналах, семь из которых входят в базы данных Web of Science и SCOPUS [Луков, 2016; Луков, 2017; Lubkov, 2019; Lubkov, 2020; Лубков, 2022; Lubkov, Vyshkvarkova, et al., 2024; Lubkov, Voskresenskaya, et al., 2024] и три в РИНЦ [Лубков, 2013; Луков, 2021; Лубков, 2022]. Результаты этой Главы были изложены на 14 международных и всероссийских научно-исследовательских и научно-практических конференциях.

Расшифровка опубликованных работ.

Лубков А.С., Воскресенская Е.Н., Кукушкин А.С. Метод восстановления среднемесячных значений прозрачности воды на примере северо-западной части Черного моря. // Оптика атмосферы и океана. 2016. Т. 29. № 04. С. 343–350.

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

Lubkov A.S., Voskresenskaya E.N., Marchukova O.V. Application of a neural network model to forecasting of El Niño and La Niña // IOP Conf. Ser.: Earth Environ. Sci., 2019, V.386, 012040. doi:10.1088/1755-1315/386/1/012040

Lubkov, A.S., Voskresenskaya, E.N. & Marchukova, O.V. Forecasting El Niño/La Niña and Their Types Using Neural Networks. Russ. Meteorol. Hydrol. 45, 806–813 (2020). doi: 10.3103/S1068373920110084

Лубков А.С., Воскресенская Е.Н., Сухонос О.Ю. Прогноз выпадения осадков в районе Ай-Петри на основе модели искусственной нейронной сети // Водные ресурсы, 2022. Том 49. № 4. С. 517–526. DOI: 10.31857/S0321059622040137

Лубков А.С., Воскресенская Е.Н., Кукушкин А.С. Восстановление климатических данных гидрооптических характеристик на основе моделирования

// Системы контроля окружающей среды. Севастополь: МГИ НАНУ, 2013. № 19. 162–165.

Лубков А.С., Воскресенская Е.Н. Метод нейронных сетей для климатического прогнозирования водности Чернореченского водохранилища // Системы контроля окружающей среды. 2021. Вып. 2 (44). С. 16–28. DOI: 10.33075/2220-5861-2021-2-16-28

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

Lubkov A.S., Voskresenskaya E.N., Marchukova O.V. A New Approach to Using Neural Networks for Long-Term El Nino and La Nina Forecasting // *Izvestiya, Atmospheric and Oceanic Physics*, 2024. V.60. Suppl. 1. P. S46–S61. DOI: 10.1134/S0001433824700555 WoS Q4

Lubkov A. S., Vyshkvarkova E. V., Voskresenskaya E. N., Shchodro A. E. Forecasting Catastrophic Floods in Crimean Territory // *Water Resources*, 2024. V. 51(6). P. 960–967. DOI: 10.1134/S0097807824701197

ГЛАВА 4. ПРИМЕНЕНИЕ РАЗРАБОТАННОЙ МОДЕЛИ ДЛЯ ПРОГНОЗА ЭЛЬ-НИНЬО И ЛА-НИНЬЯ И ИХ ТИПОВ

В этой главе последовательно рассмотрены эксперименты моделирования ЭНЮК, оценена воспроизводимость явлений Эль-Ниньо и Ла-Нинья и их типов, выполнено сравнение ретроспективных прогнозов разработанной модели с моделями ведущих климатических центров и передовыми моделями искусственного интеллекта и дан успешный прогноз последнего Эль-Ниньо 2023 года. Рассмотрено промежуточное исследование о моделировании индексов Nino с использованием только атмосферных предикторов и финальная прогностическая модель состояния ЭНЮК с использованием как глобальных атмосферных, так и океанических предикторов. Затем в этой главе приводится анализ предикторов успешных конструкций НС, на основе которого выдвигаются предположения о влиянии Северного полушария на интенсификацию экстремальных фаз ЭНЮК.

4.1. Воспроизводимость индексов Nino с применением только атмосферных предикторов

Для начала рассмотрим возможность моделирования ЭНЮК и их типов с использованием атмосферных предикторов по всему земному шару. В этом эксперименте предикторы выбирались только на основе атмосферного реанализа NCEP/NCAR. Области, в которых рассчитывались климатические индексы, приведены на рис. 2.6а и б ранее. Наборы данных были разделены на 3 выборки: обучающую (1950-1979 гг.), тестовую (1980-2009 гг.) и контрольную (2010-2019 гг.). В этом эксперименте не производилась декомпозиция моделируемого индекса, а для моделирования применялись те же алгоритмы, что и для высокочастотной составляющей из схемы на рис.3.14.

Возможность прогнозирования индекса *Nino 3.4* проверялась для каждого месяца в отдельности с различной заблаговременностью от 3 до 9 месяцев. Для

контрольного периода были рассчитаны коэффициенты корреляции, RMSE и отношение $RMSE/\sigma$. СКО (σ) рассчитывалось за период 1950-2019гг. На рис. 4.1 приведены диаграммы, иллюстрирующие зависимость месяца прогноза и его заблаговременности от RMSE (рис. 4.1а) $RMSE/\sigma$ (рис. 4.1б) и r (рис. 4.1в). Для удобства описания далее будем использовать обозначения НС-3, НС-5, НС-7 и НС-9, что соответствует модельным расчетам с возможностью прогноза заблаговременно за 3, 5, 7 и 9 месяцев соответственно. На рис. 4.1 видно, что НС-3 показывает высокое качество моделирования индекса *Nino 3.4* с августа по май (коэффициент корреляции r находится в пределах от 0.83 до 0.98, $RMSE/\sigma$ – 0.51-0.68), в то время как для двух летних месяцев – июня и июля – качество ниже (r – 0.56 и 0.63, $RMSE/\sigma$ – 0.75 и 0.81, соответственно). При увеличении заблаговременности прогноза на два месяца (НС-5), качество модели существенно не изменилось для месяцев с октября по апрель (r – 0.78 - 0.95, $RMSE/\sigma$ – 0.54 – 0.75). По сравнению с НС-3 хуже стали воспроизводиться август и сентябрь: для этих месяцев, а также июня и июля коэффициенты корреляции составляют 0.57-0.63, а $RMSE/\sigma$ – 0.81-0.94. НС-7 хорошо воспроизводит пять месяцев с декабря по апрель (r – 0.88-0.94, $RMSE/\sigma$ – 0.57-0.77). Месяцы с июня по ноябрь воспроизводятся несколько хуже (r – 0.76-0.59, $RMSE/\sigma$ – 0.91-0.78). При этом хуже остальных месяцев воспроизводится июнь: величина корреляционной связи для него равна 0.51. Рассматривая возможность заблаговременности прогноза на 9 месяцев, получилось, что только два месяца – март и апрель, моделируются так же хорошо, как в предыдущих описанных прогностических вариантах с меньшей заблаговременностью. Для них коэффициенты корреляции равны 0.93 и 0.92, $RMSE/\sigma$ – 0.77 и 0.69. Модель хуже воспроизводит месяцы май и с августа по февраль (r – 0.77-0.55, $RMSE/\sigma$ – 0.70-0.94). Самые низкие корреляции свойственны для июня и июля и равны 0.45 и 0.43 соответственно, а $RMSE/\sigma$ – 0.91 и 0.98.

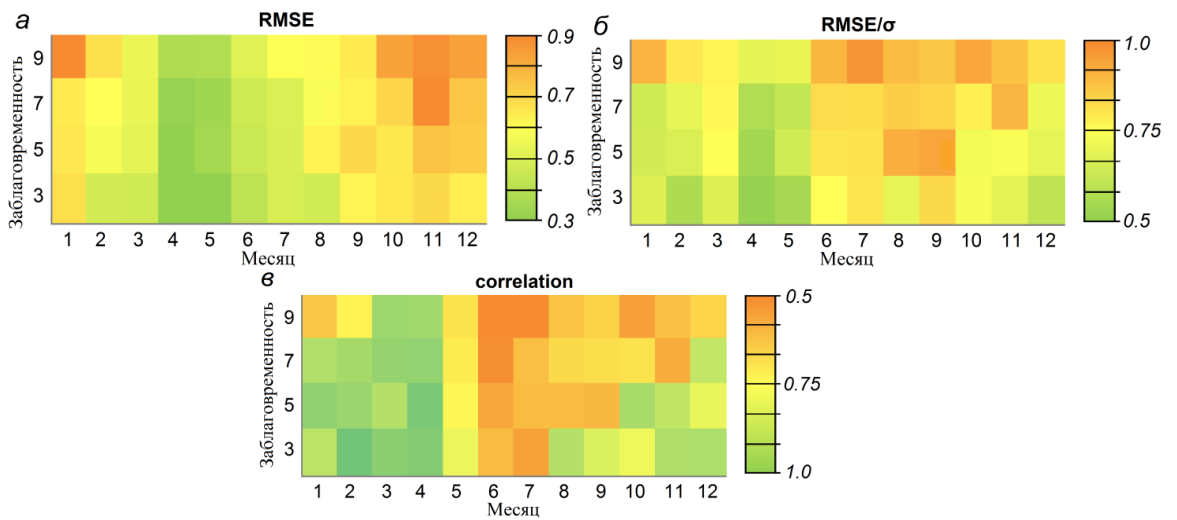


Рисунок 4.1 – Диаграммы зависимости RMSE (а), $RMSE/\sigma$ (б) и коэффициента корреляции (в) от прогнозируемого месяца и заблаговременности прогноза индекса Niño 3.4

На втором этапе по полученным с помощью нейросетевого моделирования индексам *Niño 3.4*, *Niño 3* и *Niño 4* были выделены и типизированы события ЭН и ЛН с 1950 по 2019 гг. с возможностью заблаговременного прогноза моделью за 3, 5, 7 и 9 месяцев (таблица 4.1). Полученное количество ЭН и ЛН ВТ и ЦТ типов было посчитано для обучающего, тестового и контрольного периодов и проведено сравнение с этими событиями и типами, полученными уже по реальным данным массива HadISST. Рассмотрим отдельно каждый период.

Первый, обучающий, период. В этот отрезок времени модель выделяет лишние события ЭНЮК. Для всех прогностических рядов с заблаговременностью 3, 5, 7 и 9 месяцев выделяется только одно лишнее событие ЭН 1979-1980 гг., которое определено как ВТ тип для НС-3, НС-5, НС-7, и как ЦТ тип для НС-9. Однако выделяется и много несуществующих событий Ла-Нинья (таблица 4.1). Это можно связать с тем, что в модели продолжительные события ЛН (к примеру, 1970-1972 и 1950-1951) идентифицируются как два отдельных явления. Помимо того, выделенные моделью ЛН 1961-1962 (НС-3, -5, -7, -9) и 1967-1968 (НС-3, -5) не определяются по реальному индексу Niño3.4.

Тестовый период. Для этого периода в целом количество событий, выделенных по модельным данным, достаточно близко, однако более половины

ЭН ВТ моделью определены как ЦТ (таблица 4.1). Событие ЭН ВТ типа 1997-1998 гг., известное как одно из самых интенсивных, по всем четырем полученным модельным рядам идеально воспроизводится, включая тип, месяц начала события, его интенсивность и продолжительность. По рядам НС-3 не идентифицируется событие ЭН ЦТ типа 2006-2007гг. С увеличением заблаговременности прогноза до 7 месяцев и выше не выделяется событие ЭН 2004г. В случае с ЛН выделяется лишнее событие 1996-1997 гг. (по моделям с любой заблаговременностью) и событие 1981 г. (для НС-3, -5, -7). Для НС-7 отмечено слияние двух ЛН 1983-1984 и 1984-1985 гг. в одно. По рядам НС-5 и НС-9 также выделяется несуществующее событие ЛН 2008-2009 гг.

Контрольный период. В контрольный период (2010–2019 гг.) вошли 3 события ЛН и 2 ЭН (таблица 4.1). Результаты воспроизводимости индекса *Nino 3.4* для этого отрезка времени продемонстрированы на рис. 4.2. По модельным данным НС-7 и НС-9 выделяется несуществующее событие ЭН 2012 г. ВТ типа. По всем четырем модельным расчетам хорошо прогнозируется событие Эль-Ниньо 2014-2016 гг. ВТ типа (рис. 4.2). Также хорошо воспроизводится последнее событие ЭН ЦТ типа 2018-2019 гг. в случаях НС-3, -5 и -7, однако с заблаговременностью в 9 месяцев это событие уже не прогнозируется. По модельным расчетам идентифицируется несколько событий ЛН, которые не были выделены по реальному индексу *Nino 3.4*. По рядам НС- 3, -5 и -7 выделяется лишнее ЛН ВТ типа 2013-2014 гг. При этом, по рядам НС-5, -7 и -9 выделяется событие ЛН 2016-2017 гг., которое не идентифицируется по массиву HadISST, однако это событие было зарегистрировано по спутниковым данным и по реконструкционному массиву COBE SST [Марчукова и др., 2016], а также представлено на официальном сайте NOAA (Национальное управление океанических и атмосферных исследований, США). ЛН 2010-2011гг. НС-3, -5 и -7 воспроизводят как ВТ тип, а даты начала этого ЛН не совпадают с действительными: в модельных расчетах наблюдается запаздывание события. Также ЛН 2011-2012 не выделяется в прогностических расчетах НС-5 и НС-7 как отдельное явление.

Таблица 4.1 – Количество событий Ла-Нинья и Эль-Ниньо ЦТ и ВТ типов по массиву HadISST и нейросетевой модели с заблаговременностью 3 (НС-3), 5 (НС-5), 7 (НС-7) и 9 (НС-9) месяцев для периодов 1950-1979, 1980-2009, 2010-2019 гг.

	период	ЭН ВТ	ЭН ЦТ	ЛН ВТ	ЛН ЦТ
HadISST	1950 - 1979	7	2	3	3
	1980-2009	4	5	3	5
	2010-2019	1	1	1	2
НС-3	1950 - 1979	8	2	6	3
	1980-2009	5	3	5	4
	2010-2019	1	1	2	1
НС-5	1950 - 1979	8	2	7	4
	1980-2009	7	2	4	6
	2010-2019	1	1	4	0
НС-7	1950 - 1979	8	2	4	3
	1980-2009	6	2	3	4
	2010-2019	2	1	4	0
НС-9	1950 - 1979	6	2	4	4
	1980-2009	6	1	5	6
	2010-2019	2	0	2	2

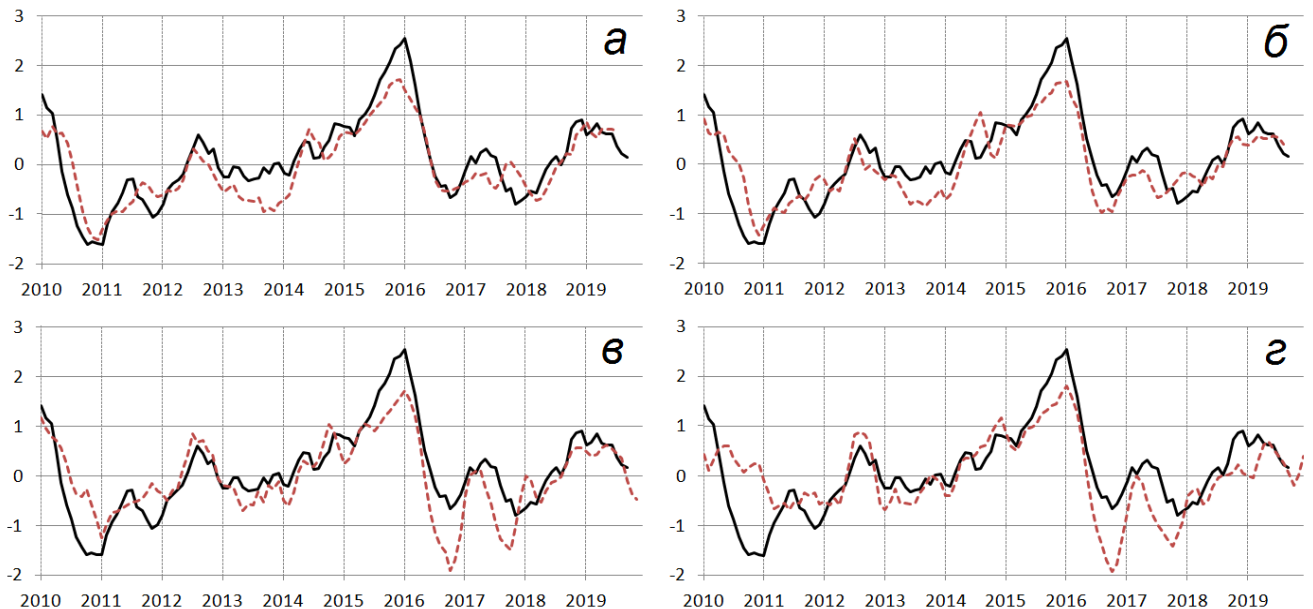


Рисунок 4.2 – Модельный индекс Niño 3.4 с заблаговременностью прогноза 3 (а), 5 (б), 7 (в) и 9 (г) месяцев (красный пунктир), и наблюдаемый Niño 3.4 (черная сплошная линия) за контрольный период 2010-2019

Далее было проведено ретроспективное прогнозирование за период 1872-1947 гг. Для этого привлекались данные атмосферного реанализа 20CR следующим образом. Климатические индексы, подаваемые на вход модели, пересчитывались по данным реанализа 20CR, при этом описанный выше расчет модели не пересчитывался заново. Таким образом, период 1872-1947 гг. является дополнительной независимой выборкой. Стоит отметить, что статистическая обеспеченность данных, на основе которых создавался реанализ 20CR, в этот период значительно меньше, чем в современный. Следовательно, качество воспроизведения гидрометеорологических полей реанализом этих двух периодов заведомо отличаются. Помимо этого, алгоритмы усвоения данных реанализов 20CR и NCEP/NCAR отличаются, что приводит к некоторым различиям в полях геопотенциала [Xu, Powell, 2012], на основании которых в работе рассчитываются индексы. Поэтому при анализе результатов моделирования с использованием массивов 20CR делался упор больше на качественную оценку.

Для начала оценим некоторые статистические характеристики. Из рис. 4.3 очевидно, что наилучшее сходство с реальным индексом наблюдается при прогнозе с заблаговременностью 3 месяца. Корреляция такой модели равна 0.75, RMSE – 0.56°C. Ретроспективный прогноз с заблаговременностью 5 и 7 месяцев сравнительно хуже воспроизводит индекс Nino 3.4. Корреляция этих модельных прогнозов с индексом Nino 3.4 равна 0.61 и 0.46, а RMSE – 0.67°C и 0.77°C соответственно. На рис. 4.4 отображен временной ход индекса Nino 3.4 и модельных расчетов с заблаговременностью прогноза 3, 5 и 7 месяцев. Все графики сглажены 3-месячным средним скользящим фильтром. Видно, что модель с заблаговременностью прогноза 3 месяца действительно лучше описывает индекс Nino 3.4.




Рисунок 4.3 – Отношение наблюдаемого и рассчитанного индекса Niño 3.4 с заблаговременностью моделирования 3 (а), 5 (б) и 7 (в) месяцев для периода 1872-1947 гг.

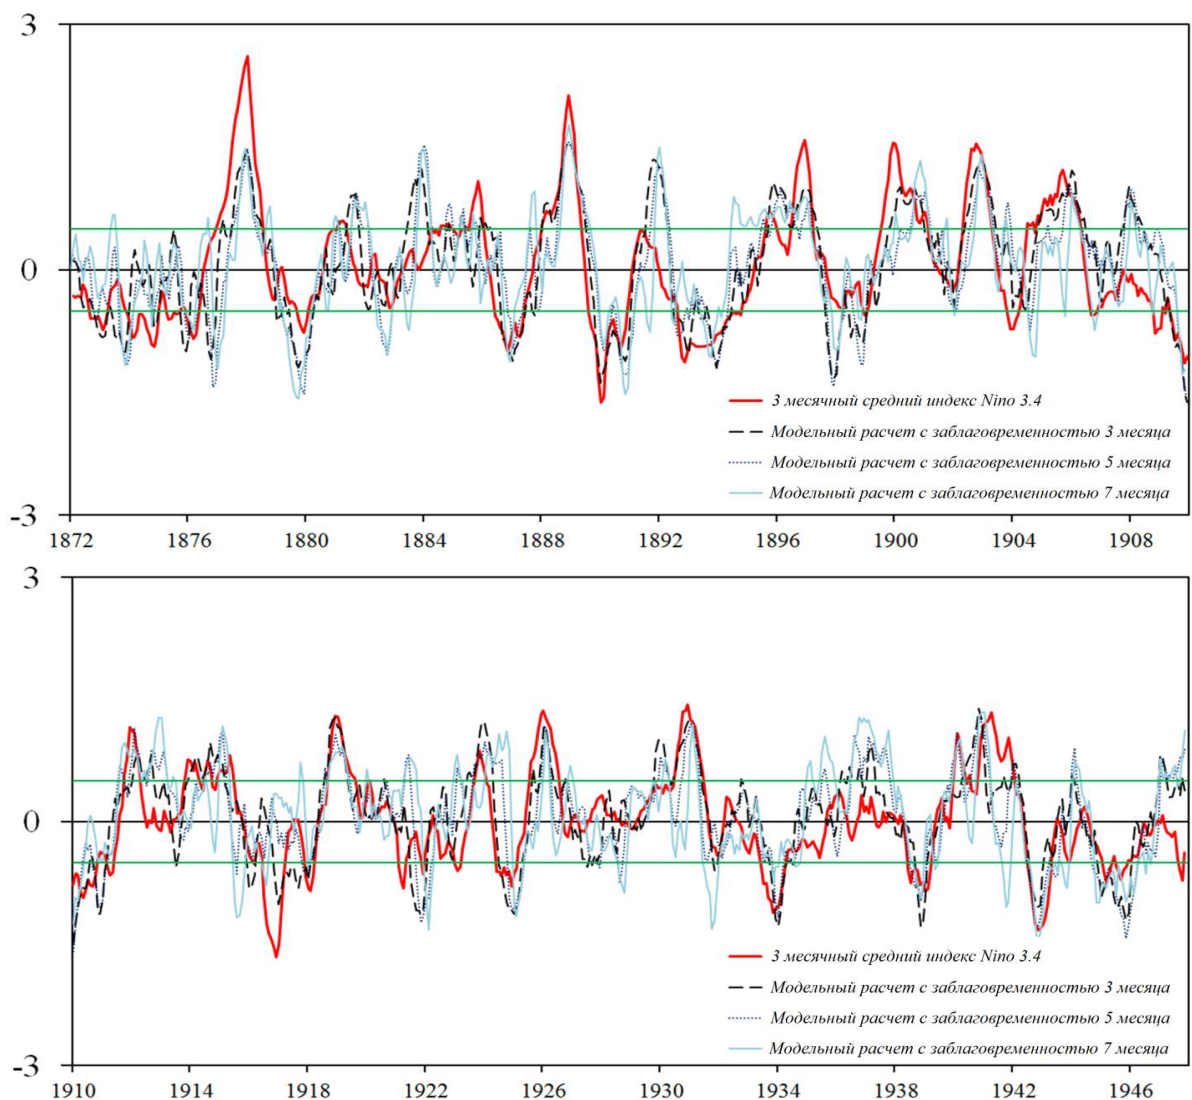


Рисунок 4.4 – Среднее трехмесячное значение Niño 3.4 (красная линия), прогнозируемое значение Niño 3.4 с 3 (пунктирная линия), 5 (пунктирная линия) и 7 (синяя линия) -месячной заблаговременностью за 1872-1909 гг.) и 1910-1947 гг. Порог для выбора Эль-Ниньо и Ла-Нинья отмечен зеленой линией (0.5°C)

Проанализируем возможность модели прогнозировать заранее приближающиеся события Эль-Ниньо и Ла-Нинья за период с 1872 по 1947. В табл. 4.2 приведены все зафиксированные экстремальные фазы ЭНЮК за этот период. В качестве критерия принималось, что индекс Nino 3.4 должен быть больше/меньше чем $0.5/-0.5^{\circ}\text{C}$, а продолжительность аномалии должна превышать 5 месяцев. Если начало явления определялось моделью с опозданием, большим, чем заблаговременность прогноза, то считалось, что модель не отображает его начало. Таким образом, модель с заблаговременностью прогноза 3 месяца из 27 экстремальных событий воспроизводит 20, что составляет чуть больше 74%. При этом отметим, что из 7 событий, начало которых смоделировать не удалось, 5 – это Ла-Нинья. Модель с заблаговременностью прогноза 5 месяцев из 27 экстремальных событий воспроизводит 18, что составляет чуть больше 66%, а с заблаговременностью 7 – 14, т.е. почти 52%. В случае прогноза с заблаговременностью 9 месяцев только 9 из 27 событий было идентифицировано заранее.

Очевидно, что прогностическая способность модели на этом временном промежутке значительно ниже в сравнении с прогнозом на контрольной выборке. Причин этому может быть несколько: использование при обучении и проверке на этом периоде разных массивов данных, низкая обеспеченность оперативными данными реанализа 20CR в период 1872-1947, а также нестационарность модели, которая могла быть обнаружена на более длительных проверочных периодах.

Таким образом, с использованием предложенной модели и климатических атмосферных индексов, используемых в качестве входных данных, показана возможность успешного моделирования индексов Nino 3.4, Nino 3 и Nino 4 с заблаговременностью прогноза от 3 до 9 месяцев и получена оценка качества моделирования.

Результаты верификации модели для каждого месяца, полученные по контрольной выборке за период 2010–2019 гг., показали, что с увеличением заблаговременности прогноза качество моделирования ухудшается, однако, в целом остается на удовлетворительном уровне. Коэффициенты корреляций с

индексом Nino 3.4 лежат в среднем в пределах от 0.5 до 0.9. Моделирование с возможностью заблаговременного прогноза за 3 месяца до начала события показывает самое высокое качество воспроизведения индекса Nino 3.4 для большей части года, кроме летних месяцев – для июня и июля качество сравнительно ниже. При заблаговременности прогноза 5 месяцев качество модели существенно не меняется для большего периода года с октября по апрель, но для июня-сентября качество воспроизведения Nino 3.4 несколько хуже. При заблаговременности 7 месяцев хорошо воспроизводится пять месяцев, с декабря по апрель и сравнительно хуже остальные – с мая по ноябрь. При заблаговременности прогноза 9 месяцев только март и апрель воспроизводятся так же хорошо, как в предыдущих прогностических случаях с меньшей заблаговременностью.

Оценка воспроизводимости событий Эль-Ниньо и Ла-Нинья с учетом их классификации на Центрально- и Восточно-Тихоокеанский типы показала, что модель лучше воспроизводит события Эль-Ниньо. События Ла-Нинья моделируются хуже, при этом систематическое завышение количества Ла-Нинья частично связано с тем, что в случаях длительного события, в прогностическом расчете модель идентифицирует его как два отдельных коротких события, что является методическим, а не практическим вопросом.

По результатам дополнительной проверки с привлечением данных реанализа 20CR за период 1872-1947, показано, что на качественном уровне возможно прогнозировать до 75% событий Эль-Ниньо и Ла-Нинья с заблаговременностью 3 месяца, до 66% с заблаговременностью 5 месяцев, а с заблаговременностью 7 месяцев – всего до 52%. При этом события Ла-Нинья воспроизводятся заметно хуже событий Эль-Ниньо. Коэффициент корреляции индекса Nino 3.4 и модельных прогнозов также понижается с увеличением заблаговременности и равен 0,75, 0,61 и 0,46 при прогнозе на 3, 5 и 7 месяцев соответственно.

Таблица 4.2 – Оценка возможности прогнозирования начала и максимальной фазы событий Эль-Ниньо (ЭН) и Ла-Нинья (ЛН) заранее за 3, 5, 7 и 9 месяцев (НС -3, -5, -7, -9) за период 1872-1947; r - коэффициент корреляции Пирсона. Значения столбиков указывают на опережение/отставание модельных расчетов от данных реанализа CR20 в момент начала ЭН/ЛН и в их максимальную фазу развития

ENSO	Years	макс(мин) Nino3.4 / продол-сть (мес)	Сдвиг начала событий ENSO и их макс. фазы							
			НС-3 $r=.75$		НС-5 $r=.61$		НС-7 $r=.46$		НС-9 $r=.40$	
			старт	макс. фаза	старт	макс. фаза	старт	макс. фаза	старт	макс. фаза
ЛН	1872	-0.97/8	-3	0	—	—	—	—	—	—
ЛН	1873	-1.06/15	—	—	—	—	—	—	—	—
ЛН	1875	-0.89/14	—	—	—	—	—	—	—	—
ЭН	1877	2.71/17	0	-1	-5	-1	—	-1	-8	0
ЭН	1885	1.03/5	—	—	—	—	—	—	—	—
ЛН	1886	-1.16/13	-3	0	—	-2	-7	0	-7	-2
ЭН	1888	2.37/16	0	0	-5	+2	—	+1	-7	-1
ЛН	1889	-2.12/16	-3	-1	-5	-1	-6	-2	—	—
ЛН	1892	-1.30/22	+3	-1	+1	-3	—	—	—	—
ЭН	1895	0.75/5	-2	-2	-3	-5	0	-1	—	—
ЭН	1896	1.64/9	-1	-1	+1	+4	+1	-2	—	—
ЭН	1899	1.59/15	-3	-2	—	—	—	—	—	—
ЭН	1902	1.61/12	0	-1	-2	-1	-7	-1	-6	-1
ЛН	1903	-0.94/5	—	—	—	—	—	—	—	—
ЭН	1904	1.46/17	0	-4	—	-2	—	-4	—	—
ЛН	1909	-1.32/17	0	-1	-2	-1	-3	-1	-5	-1
ЭН	1911	1.51/6	-3	-2	-2	-1	+1	-2	—	—
ЛН	1916	-1.69/9	—	—	—	—	—	—	—	—
ЭН	1918	1.36/10	0	+2	0	+2	0	+2	-2	0
ЛН	1924	-0.98/9	-1	+1	-5	+1	—	—	—	—
ЭН	1925	1.50/13	—	-1	-5	-3	—	—	—	—
ЭН	1931	1.75/12	0	-1	-3	-2	-6	-2	-6	-2
ЛН	1933	-1.22/10	-2	-1	-5	0	-5	0	—	—
ЛН	1938	-1.00/10	—	+3	-1	+2	-1	+3	—	—
ЭН	1940	1.15/8	-3	-6	0	-1	0	0	0	0
ЭН	1941	1.39/14	0	+5	+3	+4	+1	+4	—	—
LN	1942	-1.44/9	0	0	0	+1	-1	+1	-1	0

4.2. Прогностическая модель состояния Эль-Ниньо – Южное колебание

В этом параграфе приведены результаты моделирования состояния ЭНЮК с использованием как атмосферных, так и океанических массивов данных. Входные данные модели были выбраны с использованием пространственно-временного

корреляционного алгоритма. Области, с использованием которых рассчитывались входные индексы, иллюстрированы на рис. 2.6. Наборы данных были разделены на 3 выборки: обучающую (1950–1987 гг.), тестовую (1988–2006 гг.) и контрольную (2007–2022 гг.) – которые отличались от периодов выборок предыдущего эксперимента. Результатам моделирования дана оценка на основе ретроспективного прогнозирования на контрольном периоде 2007-2022 гг. Проведен сравнительный анализ с динамическими моделями и нейросетевыми моделями глубокого обучения. Для объективного сравнения все индексы Nino динамических моделей и нашей модели представлены 3-месячными скользящими средними значениями.

Также в параграфе выполняется анализ воспроизводимости условий Эль-Ниньо/Ла-Нинья, с учетом пространственных типов, и нейтральной фазы ЭНЮК. Ввиду более высокой способности прогнозирования индексов Nino3 и Nino4 (о чем будет сказано ниже), будем использовать эти индексы для оценки состояния ЭНЮК. По аналогии с методикой, предложенной в [Qian et al., 2011; Воскресенская, Марчукова, 2017], ЭН и ЛН выделялись при условии, если аномалия ТПО в районах Nino3 и Nino4 превышает 0.5°C и продолжается 5 месяцев последовательно:

$$\left\{ \begin{array}{l} \text{ЭН, } \frac{(Nino3 + Nino4)}{2} > 0.5^{\circ}\text{C} \cup t \geq 5 \text{ мес.} \\ \text{ЛН, } \frac{(Nino3 + Nino4)}{2} < -0.5^{\circ}\text{C} \cup t \geq 5 \text{ мес.} \\ \text{нейтральный ЭНЮК, } -0.5 < \frac{(Nino3 + Nino4)}{2} < 0.5^{\circ}\text{C} \end{array} \right. , \quad (4.1)$$

Для определения типа будем использовать соотношение, предложенное [Yeh et al., 2009]:

$$\left\{ \begin{array}{l} \text{Восточный, } Nino3_{\text{зима}} > Nino4_{\text{зима}} \\ \text{Центральный, } Nino3_{\text{зима}} < Nino4_{\text{зима}} \end{array} \right. , \quad (4.2)$$

4.2.1. Прогноз индексов Nino с применением атмосферных и океанических предикторов

Успешность ретроспективных прогнозов 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 взяты модели NMME, которые включали ретроспективный период 2007-2017 гг.: GFDL-SPEAR, GEM-NEMO, CanSIPsv2, CanCM4i, CanSIPS-IC3. Также была выбрана модель NASA-GEOSS2S с более коротким доступным периодом ретроспективного прогноза – 2007-2016 гг.

В качестве критерия оценки сезонной способности прогнозирования применялся только корреляционный анализ. Основным недостатком, которым обладают динамические модели – это хорошо выраженное влияние ВПП (рис. 4.5). Для индекса Nino 3.4 в динамических моделях ВПП характерен в сезон май-июнь-июль начиная с 6 месяцев заблаговременности (рис. 4.5б). Для индекса Nino 4 он смещен в летние месяцы (июнь-июль-август) и его влияние отмечается, начиная с 7 месяцев заблаговременности (рис. 4.5д). Для индекса Nino 3 ВПП характерен в сезон апрель-май-июнь, начиная с 5 месяцев заблаговременности (рис. 4.5з). За пределами ВПП все прогнозы незначимы.

На диаграммах, изображенных на рис. 4.5в, е, и, приведено сравнение способностей прогнозирования предложенной модели и ансамбля динамических моделей, где Δr представляет собой разницу корреляций. Для всех изображений характерно улучшенное качество моделирования нейросетевой модели за пределами ВПП, при этом коэффициенты корреляции в остальные сезоны ниже или такие же. Индекс Nino 3.4 моделируется хуже остальных индексов Nino (рис. 4.5а). Для этого индекса ВПП, хотя и значительно смягчен в сравнении с динамическими моделями, но начинает проявляться с заблаговременностью 3 месяца и смещен к сезону апрель-май-июнь. Такая же ситуация наблюдается и для индекса Nino 3 (рис. 4.5ж), при этом с заблаговременностью 11 и 12 месяцев

модель лучше воспроизводит летние и осенние месяцы. Наилучшим образом модель воспроизводит индекс Nino 4 (рис. 4.5г). ВПП для этого индекса практически отсутствует: корреляции в летний и осенний сезоны незначительно отличается от корреляций в зимние и весенние сезоны.

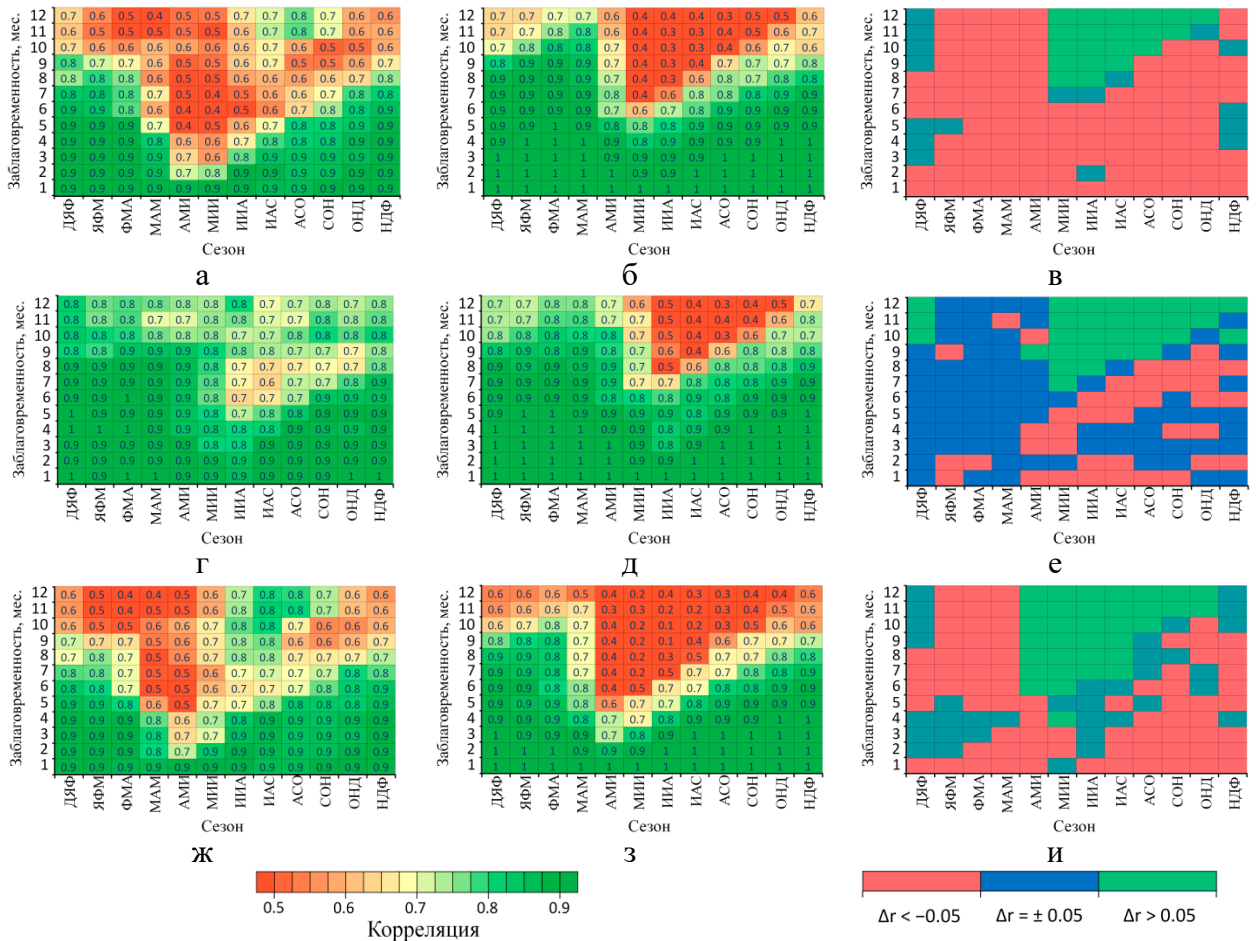


Рисунок 4.5 – Корреляционные оценки предложенной модели (а, г, ж) и ансамбля динамических моделей NMME (б, д, з) в зависимости от заблаговременности и сезона и их совместное сравнение $\Delta r = r_{nc} - r_{dynamic}$ (в, е, и) для индексов Nino 3.4 (а, б, в), Nino 4 (г, д, е) и Nino 3 (ж, з, и) за контрольный период 2007–2017 гг.

На рис. 4.6 приведено сопоставление предлагаемой модели и моделей проекта NMME для индексов Nino3.4, Nino3 и Nino4, сглаженных трехмесячным скользящим средним за период 2007-2017 гг. Способность прогнозирования индекса Nino 3.4 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 HC превосходит способность динамических. Коэффициент корреляции (и RMSE) в случае прогноза с заблаговременностью 11 месяцев с использованием предлагаемой модели равен 0.64 (0.72°C) и с использованием динамических моделей – 0.40-0.56 ($0.77-0.90^{\circ}\text{C}$). Аналогичный результат был получен и для индекса Nino 3. При этом с заблаговременностью 8-11 месяцев предложенная модель значительно лучше моделирует индекс Nino 3. Для этого индекса коэффициент корреляции (и RMSE) в случае прогноза с 11-месячной заблаговременностью моделью HC равен 0.65 (0.69°C) и динамическими моделями – 0.29-0.46 ($0.80-0.91^{\circ}\text{C}$). Моделирование индекса Nino 4 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 HC для прогноза заблаговременностью 11 месяцев равен 0.78 (0.46°C). При этом для динамических моделей эти значения равны 0.46-0.61 ($0.57-0.74^{\circ}\text{C}$). 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. Однако в ретроспективный период этой модели не входит Ла-Нинья 2017 года, воспроизведение которого было затруднительно: в январе-мае 2016 года статистические и динамические модели IRI, включая модель NASA-GEOSS2S, указывали на условия Эль-Ниньо или нейтральную фазу ЭНЮК.

Успехи предложенной модели 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 Nino 3.4.

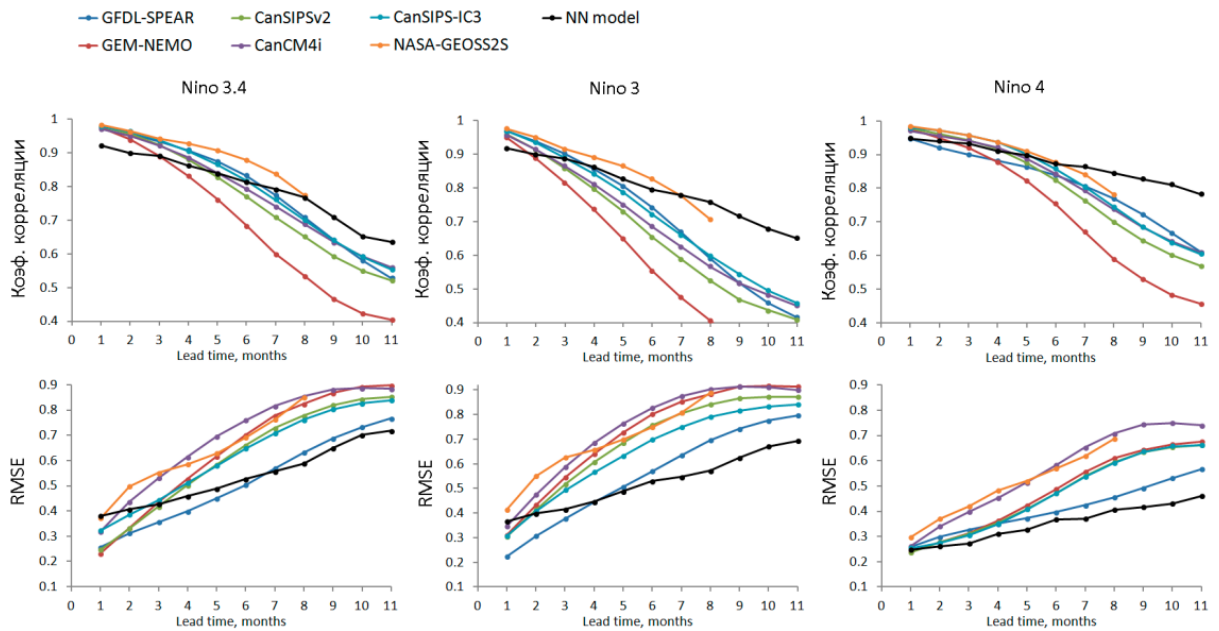


Рисунок 4.6 – Зависимость коэффициента корреляции и среднеквадратической ошибки прогнозов трехмесячных скользящих средних индексов Nino3.4, Nino3 и Nino4 для предлагаемой модели и ансамбля моделей проекта NMME за период 2007-2017.

Рис. 4.7 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 4.1. Типизация производилась с учетом условия из формулы 4.2. На Рис. 4.7 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 в 5 месяцев для ЛН-2007 и 11 месяцев для ЛН-2017 и ЛН-2021.

В табл. 4.3, полученной на основе Рис. 4.7, приведен процент совпадений прогноза с данными наблюдений. В целом состояние ЭНЮК без учета 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 декабрь-январь-февраль были определены верно.




Рисунок 4.7 – Состояние ЭНЮК с учетом типов Эль-Ниньо и Ла-Нинья по данным COBESST (на диаграмме ряд "OBS") и модельным расчетам с заблаговременностью до 11 месяцев.

Таблица 4.3 – Процент совпадений прогноза с данными наблюдений за контрольный период 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

Далее были проанализированы ошибочные **ретроспективные прогнозы** событий ЭН и ЛН. Ошибочные 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 заблаговременности 6 месяцев. С заблаговременностью 8-11 месяцев вероятность ошибочного прогноза ЭН составляет 11-13%.

Рассмотрим более подробно воспроизводимость **индивидуальных** событий ЭН и ЛН. На рис. 4.8 приведены графики рассчитанных по данным COBESST (до октября 2022 года) трехмесячных средних скользящих индексов Nino3.4, Nino3 и Nino4 и результатов их **ретроспективного прогнозирования** с заблаговременностью в 3, 6, 9 и 11 месяцев. Для удобства описания далее будем использовать обозначения НС-3, НС-6, НС-9 и НС-11, где число соответствует заблаговременности. 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. 4.8-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). Продолжительные ЛН будем рассматривать как два отдельных события.

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 зимний сезон. 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 Nino 4. LT-9 и LT-11 не воспроизводят ЛН.

ВТ Эль-Ниньо 2009 воспроизводится по всем приведенным на рис. 4.8 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. По индексу Nino 3.4 начало события определяется неверно и наблюдается в сезон август-сентябрь-октябрь.

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 завывают 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 декабрь-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. При этом в модельном расчете с заблаговременностью 4 и 5 месяцев событие ЛН не наблюдается (рис. 4.7). LT-3 занижает значения этого ЛН: индексы чуть превышают порог 0.5°C .

ЦТ Эль-Ниньо 2018 воспроизводится всеми модельными расчетами только по индексу Nino 4. Условия ЭНЮК по индексам Nino 3 и Nino 3.4 воспроизводятся LT-3 и LT-6 как нейтральные, а LT-9 и LT-11 моделируют условия ЛН.

ЦТ Эль-Ниньо 2019 не отмечалось по индексу Nino 3.4, но по методу идентификации, который был использован в этой работе с учетом индексов Nino 3 и Nino 4, событие было. Так же, как и предыдущий ЭН, это событие хорошо воспроизводится по индексу Nino 4 для всех рассматриваемых расчетов.

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

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 **прогнозирует** 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 определяет 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 двух событий ЛН (2017 и 2021) **из восьми** воспроизводились верно.

4.2.2. Сопоставление способностей модели с современными моделями НС глубокого обучения

Сравним разработанную в исследовании модель с современными моделями глубокого обучения. Для надежного сравнения требуется выполнить условие однородности сопоставляемых временных промежутков. Выбранный нами период проверки модели 2007-2023гг. не сопоставим с периодами проверки других исследователей, и перекрывает лишь интервал 2014-2020гг., используемый для проверки авторами исследования [Mu et al., 2021]. Так в работах [Ham et al., 2019; Petersik, Dijkstra, 2020; Cachay et al., 2021] проверка проводилось для периода 1984-2017гг., в работе [Hu et al., 2021] – 1982-2017гг., в работе [Zhou, Zhang, 2022] – 1994–2020гг., в работе [Geng, Wang, 2021] – 1994–2017гг., в работе [Patil et al., 2023] – 1984-2021гг., в работе [Wang et al., 2023] – 1982-2020гг. Таким образом, для всестороннего полноценного сравнения со всеми современными моделями глубокого обучения необходимо перекрыть период 1982-2021гг.

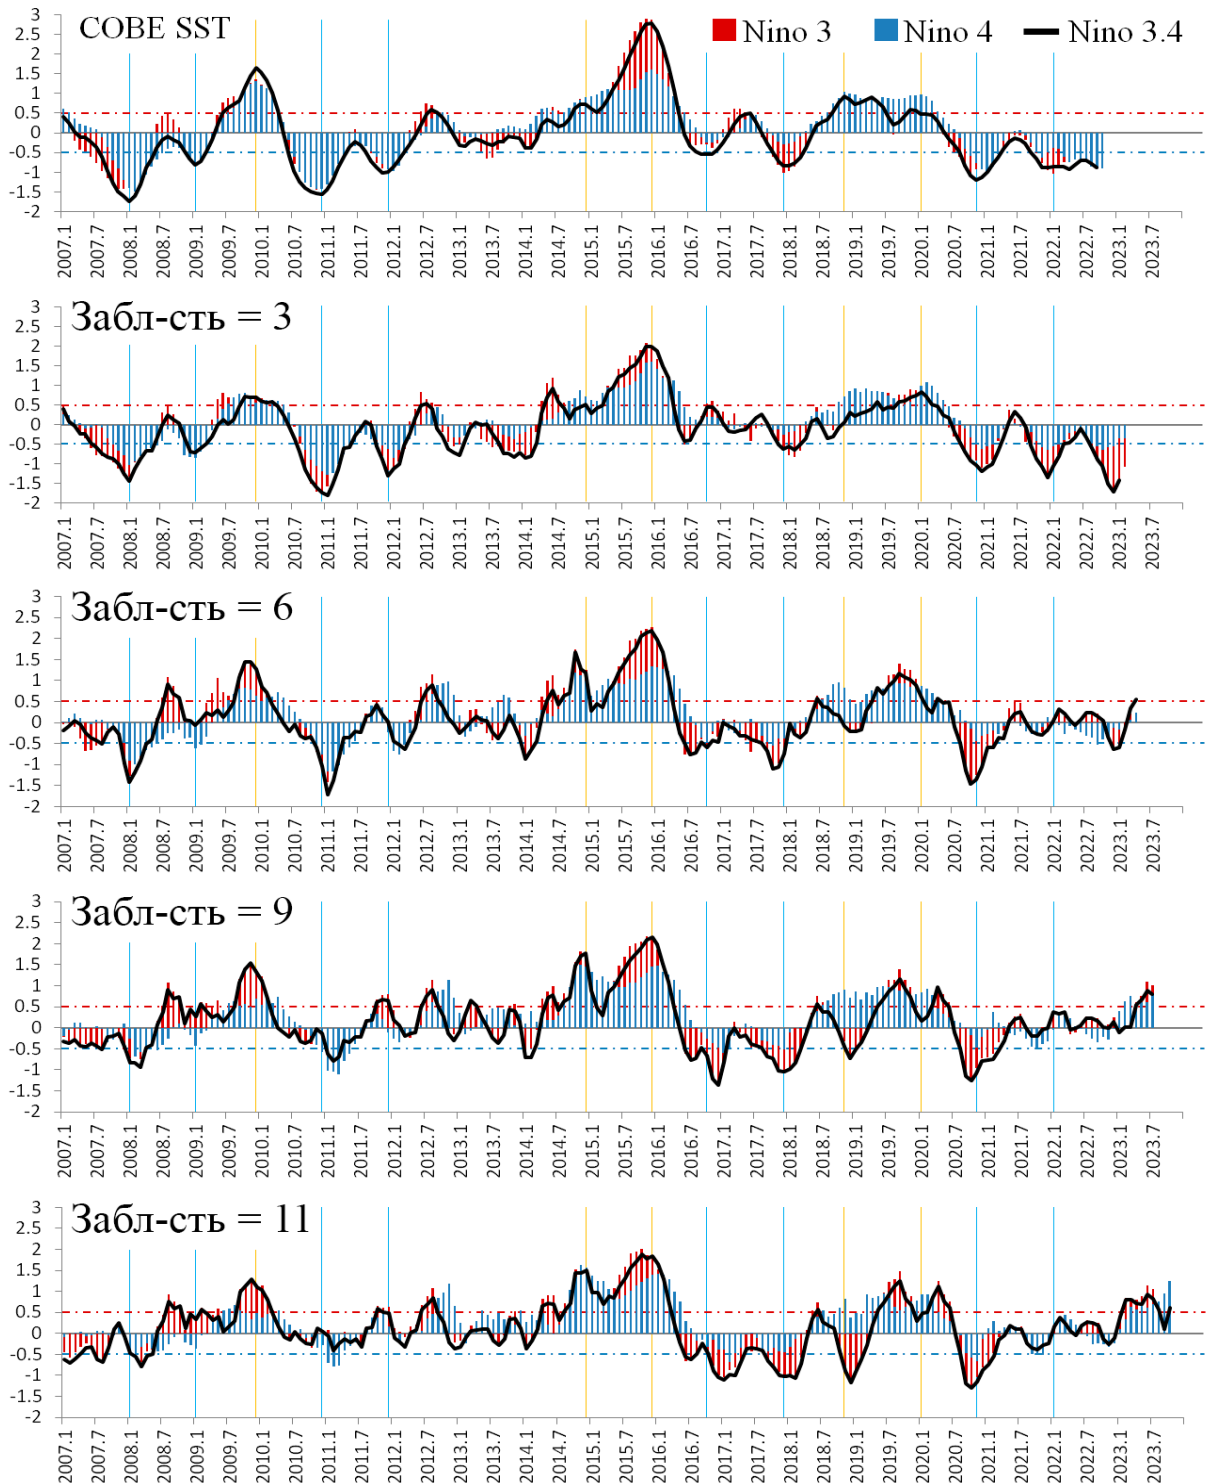


Рисунок 4.8 – Трехмесячное скользящее среднее индексов Nino3.4, Nino3 и Nino4 в период 2007-2023гг., рассчитанные по данным COBESST (до ноября 2022 года) и результат их ретроспективного прогнозирования с заблаговременностью 3, 6, 9 и 11 месяцев до февраля, мая, августа и октября 2023 года соответственно. Оранжевой и голубой линиями обозначены экстремумы событий Эль-Ниньо и Ла-Нинья

Для этого предложено выполнить модельные расчеты несколько раз, последовательно смещая контрольную выборку, по аналогии с перекрестным смещением тестовой выборки из работ [Wu et al., 2006; Petersik, Dijkstra, 2020]. В результате было выполнено 6 полных расчетов модели с контрольной выборкой, равной 14 годам. Обучающая и тестовая выборки были 40 и 19 лет соответственно. Контрольная выборка смещалась следующим образом. В первом расчете был выбран период 1951-1964гг, в следующем 1963-1976гг, и так далее. Выборки выбраны с двухлетним пересечением не случайно. Известно, что ТПО имеет некоторую инерционную память (например [Mu et al., 2021]), поэтому крайний "левый" и "правый" годы не могут быть объективными для проверки прогностических способностей модели. Поскольку в работах, посвященных моделям глубокого обучения, рассматривались ретроспективные прогнозы с заблаговременностью до 24 месяцев, пересчет нашей модели следует производить с такой же максимальной заблаговременностью прогноза. В этой связи моделируемый индекс Nino 3.4 был выбран за период с 1951 года, а в пространственно-временном алгоритме отбора модельных предикторов для высокочастотной компоненты было расширено окно поиска предикторов с 2 до 3 лет.

На рис. 4.9 приведено сопоставление коэффициентов корреляции модельных расчетов и наблюдаемого трехмесячного скользящего среднего индекса Nino 3.4 на контрольных выборках из разных исследований [Ham et al., 2019; Petersik, Dijkstra, 2020; Cachay et al., 2021; Mu et al., 2021; Hu et al., 2021; Wang et al., 2023]. Сравнение с результатами работ [Geng, Wang, 2021; Zhou, Zhang, 2022; Patil et al., 2023] приведено в Приложении Б. Предложенная модель заметно лучше воспроизводит индекс Nino 3.4 в сравнении со всеми современными моделями глубокого обучения. С заблаговременностью **более 5** месяцев навыки предложенной модели заметно выше моделей глубокого обучения, а время эффективного прогноза равно 21-22 месяца, что на 2-4 месяца лучше аналогов. Исключение составляет только модель STIEF [Wang et al., 2023]: с заблаговременностью прогноза от 5 до 20 месяцев способности моделей

одинаковы, однако с заблаговременностью до 5 месяцев и более 20-и воспроизводимость ЭНЮК моделью STIEF выше.

Стоит отметить, что с заблаговременностью до 5 месяцев наша модель, в целом, показывает себя хуже большинства моделей глубокого обучения. Можно предположить, что это связано с отсутствием в качестве предикторов теплосодержания океана (ТСО) в верхнем 300м слое. Как показал эксперимент (см. Приложение В) с включением в ряд предикторов среднемесячного поля ТСО, качество моделирования с заблаговременностью до 5 месяцев действительно выше. Однако из-за уменьшенной обучающей выборки, что связано, в первую очередь, с коротким рядом данных ТСО, который начинается с 1958 года, для прогноза с заблаговременностью более 5 месяцев наблюдается заметное уменьшение прогностических способностей модели.

Можно также обратить внимание на высокую способность модели к воспроизведению состояния ЭНЮК в период 2014-2020гг. (рис. 4.9г). Этот период не типичен для ЭНЮК. В каждый год этого периода наблюдалось по одному экстремальному состоянию ЭНЮК: три ЦТ Эль-Ниньо, одно сильное ВТ Эль-Ниньо, два ЦТ Ла-Нинья и одно ВТ Ла-Нинья, описанные выше. Тем не менее, модель показала сравнительно высокую способность к прогнозу этой череды экстремальных фаз ЭНЮК даже с заблаговременностью 2 года.

В этом параграфе показано, что индексы Nino 4 и Nino 3 воспроизводятся моделью лучше, чем индекс Nino 3.4, что повлияло на особенности идентификации событий ЭНЮК, которые определялись с учетом Nino 4 и Nino 3. Вероятность верного определения условий, характерных для событий Эль-Ниньо, практически не зависит от заблаговременности прогноза и варьируется от 76 до 83%. Воспроизведение событий Ла-Нинья сильно зависят от заблаговременности прогноза. Вероятность верного определения явления Ла-Нинья варьируется от 31% (большая заблаговременность) до 85% (небольшая заблаговременность). Ложные случаи условий ЛН без учета времени продолжительности события встречаются с вероятностью 8-28%, и случаи ЭН – с вероятностью 8-23%.

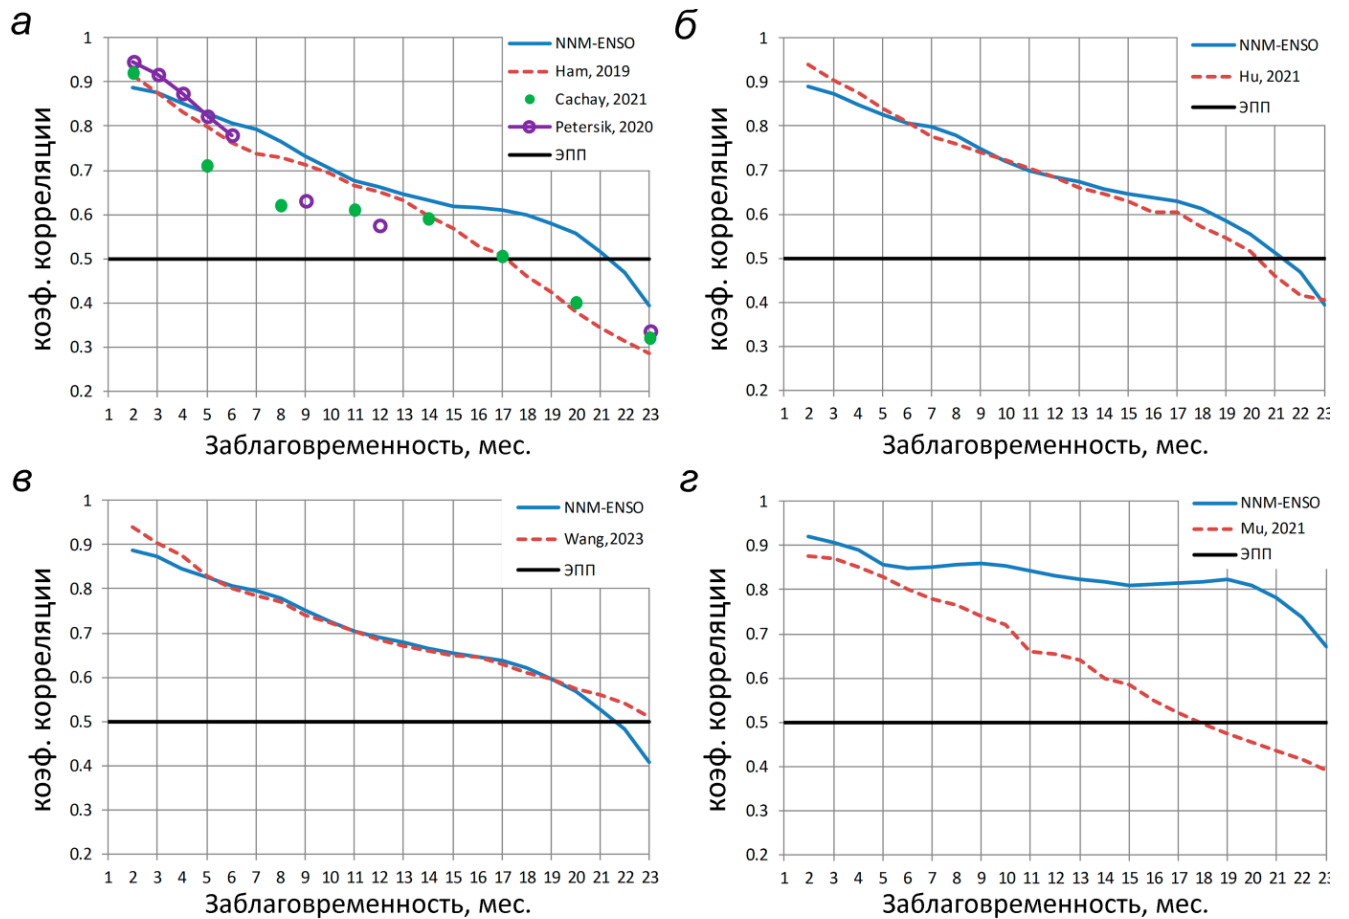


Рисунок 4.9 – Зависимость коэффициента корреляции моделей от заблаговременности ретроспективного прогноза для нейросетевых моделей глубокого обучения и предложенной в работе модели (синяя кривая) за временные периоды: *а* – 1984-2017гг., *б* – 1982 – 2017гг., *в* – 1982-2020гг., *г* – 2014-2020гг.

В целом можно отметить, что предложенная **прогностическая** 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 занижают 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. Два события ЛН (2017 и 2021) с заблаговременностью 11 месяцев в сезон декабрь-январь-февраль были определены верно.

Предложенная модель отличается низкой чувствительностью к ВПП, особенно для индекса Nino 4. При этом для прогнозов с заблаговременностью до 6 месяцев модель систематически показывает более низкие навыки прогнозирования в сравнении с динамическими моделями проекта NMME, что особенно выражено для индекса Nino 3.4. Это может быть связано с неучтенными предикторами, имеющими доказанную физическую связь с интенсификацией экстремальных событий ЭНЮК.

В сравнении с современными моделями искусственного интеллекта, основанными на алгоритмах глубокого обучения, предложенная модель также продемонстрировала лучшее воспроизведение индекса Nino 3.4. С заблаговременностью **более** 5 месяцев навыки предложенной модели заметно выше моделей глубокого обучения, а время эффективного прогноза составляет 21-22 месяца, что на 2-4 месяца лучше аналогов.

4.3. Анализ полученных предикторов и их взаимодействие с моделируемым параметром

Проанализируем выбранные моделью индексы в последнем модельном эксперименте, когда учитывались геопотенциал на 500 гПа и 1000 гПа изобарических уровнях, компоненты ветра на 500 гПа и ТПО. Основное внимание будет посвящено предикторам высокочастотной изменчивости, так как ее дисперсионный вклад равен около 93%. На этом этапе для нескольких ключевых сезонов были проанализированы используемые лучшими конструкциями НС предикторы. Как было указано выше, в Главе 3, для каждого месяца и каждой заблаговременности выбирались 20 наилучших конструкций НС. Ради удобства обобщим повторяемость различных предикторов этих конструкций для трех сезонов: май-июль, осень и зима; и для 4 групп заблаговременности прогноза: за 1-3 месяца, 4-6, 7-9 и 10-12 месяцев. Далее визуализируем полученные группы

предикторов (рис. 4.10). Поскольку предикторы являются климатическими индексами, расчет которых производился в определенных областях, на рис. 4.10 изображены именно широтно-долготные области, глубина **окраски** которых говорит о повторяемости выбора конкретного предиктора от 0 до максимально-возможного значения (180 значений для 3 месяцев сезона и 3 обобщенных месяцев заблаговременности прогноза). Такой подход является непрямым аналогом «тепловых карт», используемых в СНС для анализа предикторов модели, например, в работах [Ham et al., 2019; Patil et al., 2023].

Сезон май-июль совпадает с ВПП и является самым сложным для прогнозирования динамическими моделями. В этот сезон происходит интенсификация большинства событий ЭНЮК. При этом, как было отмечено ранее, статистически значимый ретроспективный прогноз сезона май-июль группа динамических моделей способна давать с заблаговременностью менее 6 месяцев. Уделим особое внимание анализу предикторов этого сезона. С заблаговременностью до 3 месяцев отмечена высокая повторяемость предикторов в тропических широтах, что, вероятно, связано интенсификаций совместного влияния СЗВ и КМД [Chiodi et al., 2014; Puy et al., 2016; Liang, Fedorov, 2021] и аномалиями в объеме накопленной теплой воды в экваториальной части Тихого океана [McPhaden, Yu, 1999; Vecchi, Harrison, 2000; Fedorov et al., 2015]. Также отмечена сравнительно менее частая повторяемость предикторов в Тихом океане и в средних и высоких широтах. С заблаговременностью 4-6 месяцев наблюдается увеличение повторяемости индексов Северного полушария и, в частности, индекса меридионального ветра, который, по сути, является индикатором типа атмосферной циркуляции (меридиональный или зональный). Такое поведение предикторов согласуется с описанной в Главе 1 схемой взаимодействия Северного полушария с ЭНЮК [Yang, Xu, 1994; Sankar-Rao et al., 1996; Bamzai, Shukla, 1999]. Особое внимание следует уделить САК. С заблаговременностью 3-6 и 7-9 месяцев этот предиктор выбирался моделями довольно часто, что подтверждает высказанный ранее тезис, о возможном влиянии Северной Атлантики на ЭНЮК посредством передачи климатического сигнала через

Евразию [Полонский и др., 2004]. Стоит отметить заметное увеличение повторяемости областей, характеризующих Южноатлантическое колебание (ЮАК), с заблаговременностью 10-12 месяцев. Роль ЮАК в схеме интенсификации ЭНЮК на сегодня еще не определена, однако можно предположить наличие связи САК и ЮАК с задержкой в несколько месяцев.

Для осени с заблаговременностью прогноза до 3 месяцев наблюдается высокая повторяемость тропических и тихоокеанских предикторов, что может быть связано с эволюцией событий Эль-Ниньо/Ла-Нинья. Для заблаговременности прогноза от 4 до 6 месяцев в тропиках все также наблюдается высокая повторяемость предикторов, однако предикторы средних широт Тихого океана повторяются реже. Для заблаговременности от 9 месяцев повторяемость предикторов по всему земному шару, в целом, одинакова, без акцентов на какой-либо регион. Зимой Тропические предикторы выбираются моделью часто при любой заблаговременности прогноза. Предикторы Тихого и «Южного» океанов чаще выбираются для заблаговременности прогноза до 10 месяцев. С заблаговременностью от 10 месяцев отмечается интенсификация предикторов северного полушария.

Авторы модели STIEF [Wang et al., 2023], анализ ретроспективного прогноза которой показал сопоставимое качество с предлагаемой нами моделью, показали, что предикторы Северного и Южного полушарий существенно улучшают качество прогноза с заблаговременностью от 5 до 18 месяцев. Этот тезис согласуется с выполненным нами анализом повторяемости предикторов.

В целом, проведенный анализ предикторов подтвердил предложенную в Главе 1 теоретическую схему влияния Северной Атлантики на ЭНЮК через северную часть Евразии. Интерес также представляет неявное влияние Южной Атлантики на ЭНЮК с заблаговременностью более года. Предполагается, что Южноатлантическое колебание может быть связано с Североатлантическим с некоторым опережением.

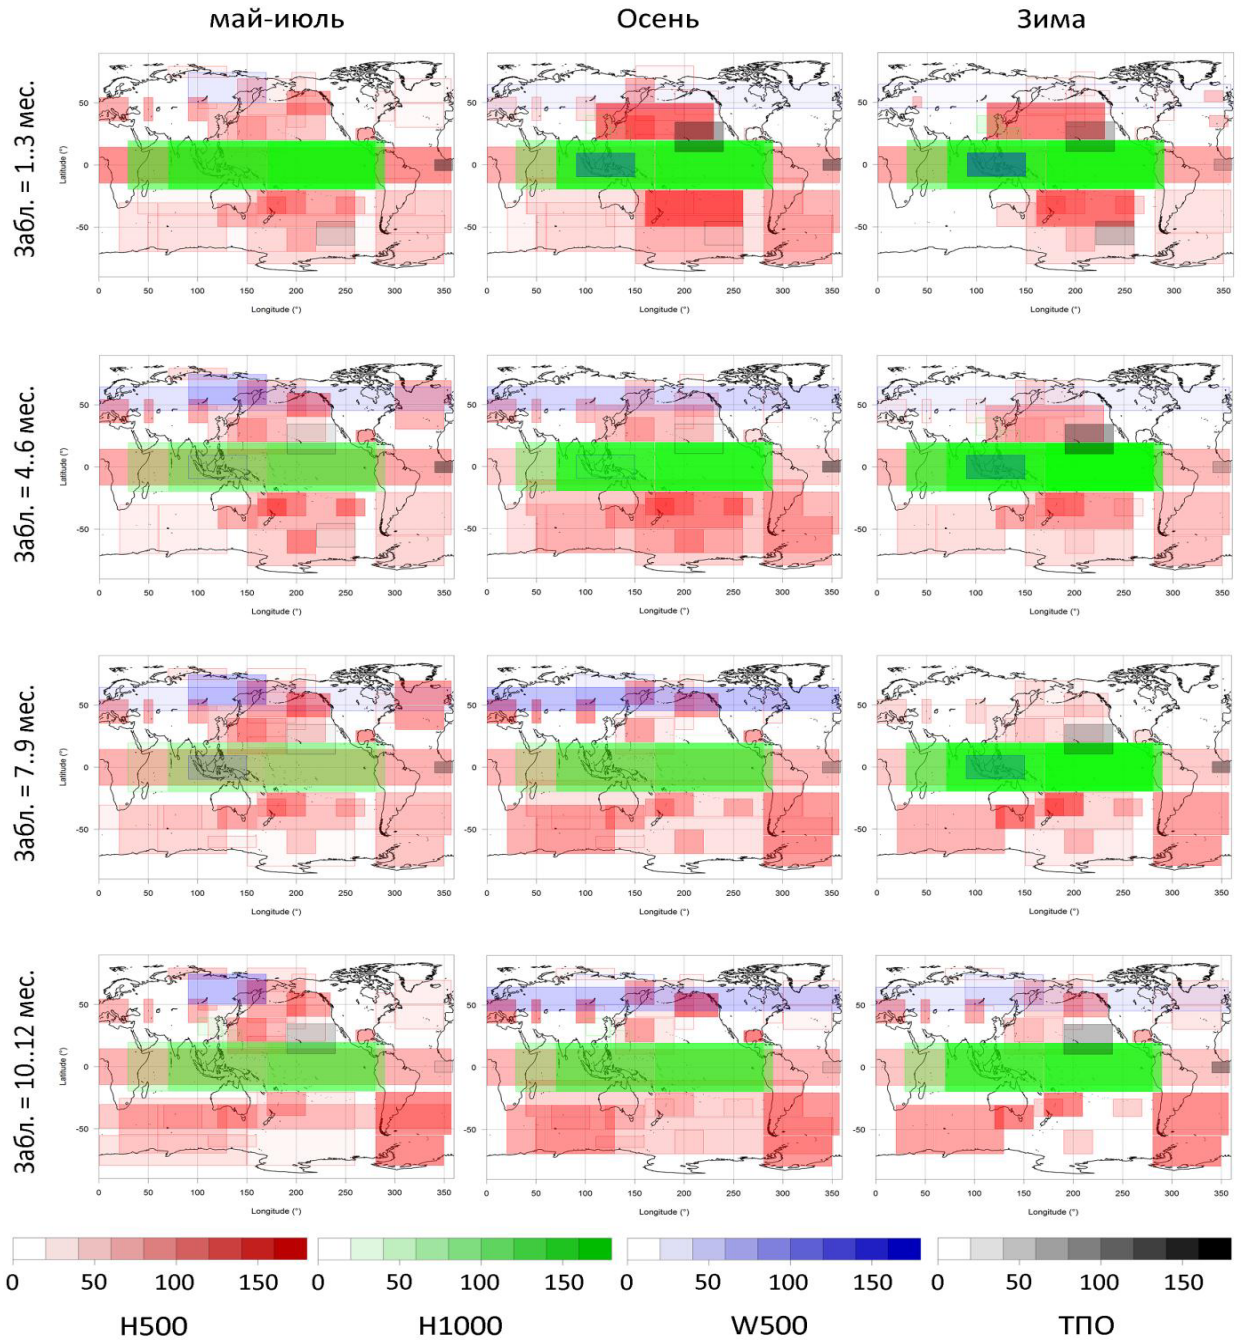


Рисунок 4.10 – Повторяемость предикторов, входящих в 20 наилучших конструкций МНС и рассчитанных на основе полей геопотенциала, компонент ветра и ТПО за 3 ключевых периода с заблаговременностью прогноза до 12 месяцев.

4.4. Успешный прогноз Эль-Ниньо 2023г. и предположение о Ла-Нинья в 2024-2025 гг.

В завершение описания качества предложенной в работе модели приведем на рис. 4.11 результаты прогноза индекса Nino 3.4, полученные в ноябре 2022 г. [Лубков, 2022]. Наша модель предполагала дальнейшую эволюцию Ла-Нинья до февраля 2023 г. (рис. 4.11в), в марте и апреле – нейтральные условия ЭНЮК, а с мая 2023 г. – начало развития Эль-Ниньо. Опираясь на пространственно-временную классификацию Эль-Ниньо [Лубков и др., 2017b], предполагалось, что ЭН-2023 будет весеннего восточного типа, что соответствует восточно-тихоокеанскому по классификации [Yeh et al., 2009]. При этом по результатам, приведенным на сайте Колумбийского университета – IRI (iri.columbia.edu, обращение 3 декабря 2022), вероятность возникновения Эль-Ниньо в мае была всего лишь 12%. К августу 2023г. эта вероятность выросла до 44% (рис. 4.11а). По результатам центра климатических прогнозов США – NOAA (src.ncer.noaa.gov, обращение 3 декабря 2022) в ноябре 2022г. только 1 из 6 моделей прогнозировала начало Эль-Ниньо в 2023 году (рис. 4.11б).

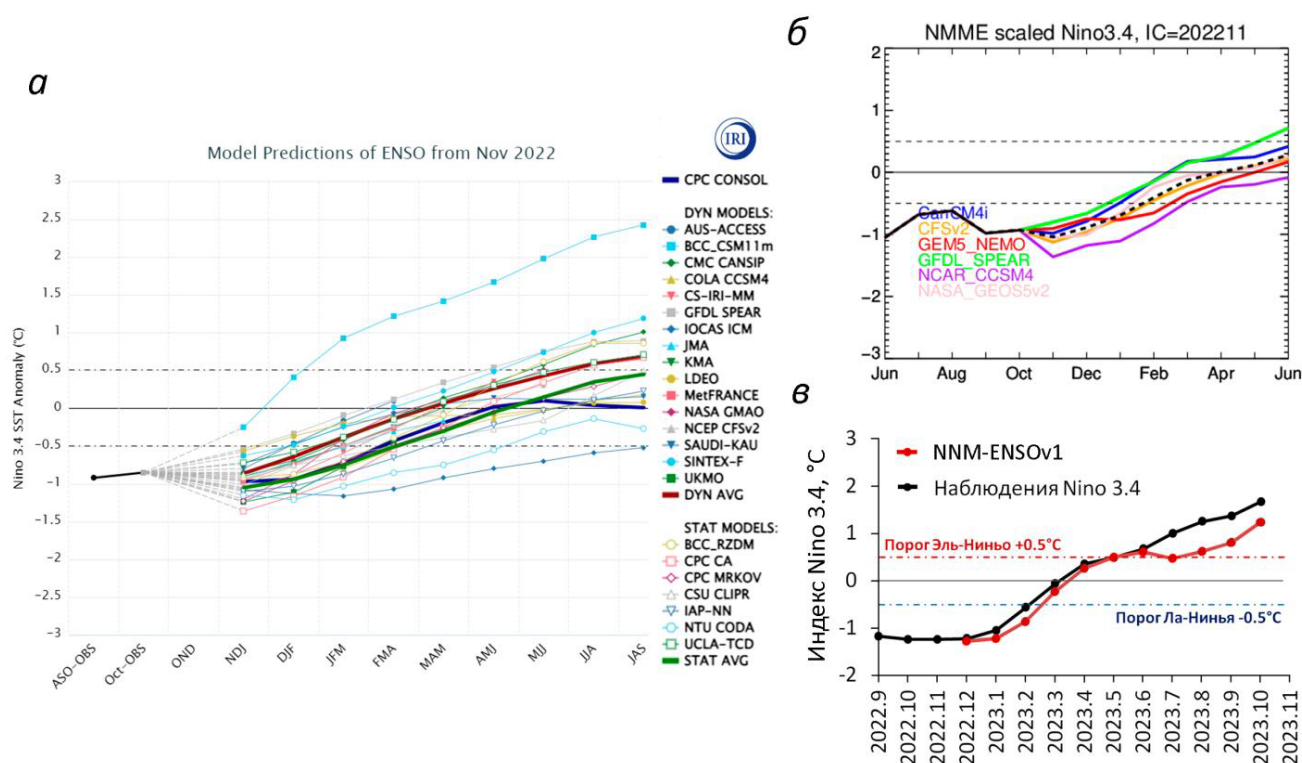


Рисунок 4.11 – Результаты ноябрьского прогноза индекса Nino 3.4, сглаженного 3-месячным средним скользящим: а – IRI, б – NOAA, в – разработанная в исследовании модель

По факту известно, что прогноз предлагаемой в исследовании модели подтвердился (рис. 4.11в). Условия Ла-Нинья сменились на нейтральные в феврале. В марте и апреле ЭНЮК находилось в нейтральной фазе. С мая наблюдались условия, характерные для эволюции Эль-Ниньо. Зимой 2023-2024 года — это Эль-Ниньо было охарактеризовано как восточно-тихоокеанский тип. Следовательно, наша модель одна из первых в мире указала на приближающийся Эль-Ниньо, а пространственно-временной анализ помог с заблаговременностью более чем за год определить тип события.




Рисунок 4.12 – Результат прогноза индекса Nino 3.4, полученный 3 июня 2024г. График представлен в виде межквартильных диаграмм, построенных на основе 20 лучших конструкций НС. Цвет межквартильных диаграмм соответствует диапазону корреляций (r), полученных на контрольной выборке, красная и синяя линии это пороговое значение условий Эль-Ниньо/Ла-Нинья, равное $+0.5/-0.5^{\circ}\text{C}$.

Последний актуальный прогноз состояния ЭНЮК (составлен в июне 2024г.) указывает на приближающееся событие Ла-Нинья (рис. 4.12). Результаты нашей модели согласуются с прогнозами Центра климатических прогнозов США, ВМО и Североамериканским мультимодельным ансамблем. По данным NOAA 6 из 7 моделей проекта NMME указывают на Ла-Нинья. По версии IRI вероятность наступления Ла-Нинья в октябре равна 55%, в то время как Центр климатических прогнозов США оценивает вероятность возникновения такой аномалии в 82%.

Вывод к Главе 4

Модель, описанная в Главе 3, успешно адаптирована для прогноза явлений Эль-Ниньо и Ла-Нинья и их типов.

1. Вероятность верного определения условий в период до одного года, характерных для событий Эль-Ниньо, практически не зависит от заблаговременности прогноза и варьируется от 76 до 83%. В то же время успешность воспроизведения событий Ла-Нинья сильно зависит от заблаговременности прогноза. Вероятность верного определения явления Ла-Нинья уменьшается с ростом заблаговременности прогноза от 31 до 85%. Ложные случаи условий Ла-Нинья встречаются с вероятностью 8-28%, и случаи Эль-Ниньо – с вероятностью 8-23%.

2. Предложенная **прогностическая** модель достаточно хорошо воспроизводит события Эль-Ниньо и их тип. С годовой заблаговременностью прогноза для четырех событий Эль-Ниньо из пяти тип был определен верно. При этом модель с небольшой заблаговременностью более точно определяет сроки начала, но занижают амплитуду максимальной фазы интенсивных событий, а с более высокой заблаговременностью менее точно определяет время начала, но более точно – амплитуду максимальной фазы интенсивных событий. События Ла-Нинья хорошо воспроизводятся с небольшой заблаговременностью, при этом, только два события Ла-Нинья (2017 и 2020) из восьми с годовой

заблаговременностью были определены верно, включая их пространственный тип.

3. Индексы Nino 3 и Nino 4 воспроизводятся моделью лучше, чем индекс Nino 3.4. При этом предложенная модель отличается низкой чувствительностью к весеннему порогу предсказуемости, а для прогноза индекса Nino 4 ВПП вовсе отсутствует.

4. Сравнение с динамическими моделями проекта NMME показало преимущество предложенной модели для прогнозов с заблаговременностью от 5 до 12 месяцев.

5. В сравнении с современными моделями искусственного интеллекта, основанными на алгоритмах глубокого обучения, предложенная модель также продемонстрировала лучшее воспроизведение индекса Nino 3.4. С заблаговременностью от 5 месяцев навыки предложенной модели заметно выше моделей глубокого обучения, а время эффективного прогноза равно 20-21 месяц, что на 4-2 месяца лучше аналогов.

6. Анализ предикторов успешных конструкций НС не противоречит схеме влияния Северной Атлантики на ЭНЮК через северную Евразию и тропики Индийского океана. Интерес также представляет неявное влияние Южной Атлантики на ЭНЮК с заблаговременностью более года. Предполагается, что Южноатлантическое колебание может быть связано с Североатлантическим с некоторым опережением.

7. Прогноз состояния ЭНЮК на 2023 г., рассчитанный в ноябре 2022 г., одним из первых в мире показал начало Эль-Ниньо с точностью до месяца. Таким образом, наш прогноз опередил на 4 месяца официальное сообщение ВМО о вероятности наступления этого события.

В целом, всесторонняя оценка предложенной модели показала свое высокое практическое значение для прогнозов состояния ЭНЮК. При этом воспроизводимость моделью **эпизодов** ЭНЮК оказалась заметно лучше в сравнении с динамическими моделями и современными моделями, основанными

на алгоритмах глубоко обучения, ее заблаговременность прогноза лучше на 5-6 месяцев.

Результаты Главы 4 опубликованы в шести научно-исследовательских журналах, четыре из которых входят в базы данных Web of Science и SCOPUS [Луков, 2017; Lubkov, 2019; Lubkov, 2020] и два в РИНЦ [Лубков, 2022; Луков, 2023]. Результаты этой Главы были представлены на 9 международных и всероссийских научно-исследовательских и научно-практических конференциях.

Расшифровка опубликованных работ.

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

Lubkov A.S., Voskresenskaya E.N., Marchukova O.V. Application of a neural network model to forecasting of El Niño and La Niña // IOP Conf. Ser.: Earth Environ. Sci., 2019, V.386, 012040. doi:10.1088/1755-1315/386/1/012040

Lubkov, A.S., Voskresenskaya, E.N. & Marchukova, O.V. Forecasting El Niño/La Niña and Their Types Using Neural Networks. Russ. Meteorol. Hydrol. 45, 806–813 (2020). doi: 10.3103/S1068373920110084

Лубков А.С. Научный прогноз: Начнется ли Эль-Ниньо в 2023 году? // Системы контроля окружающей среды. 2022. Вып. 4 (50). С. 143-144.

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

Lubkov A.S., Voskresenskaya E.N., Marchukova O.V. A New Approach to Using Neural Networks for Long-Term El Nino and La Nina Forecasting // Izvestiya, Atmospheric and Oceanic Physics, 2024. V.60. Suppl. 1. P. S46–S61. DOI: 10.1134/S0001433824700555

ЗАКЛЮЧЕНИЕ

1. Комплексный анализ глобальных полей из современных массивов гидрометеорологических характеристик позволил выбрать набор индексов, характеризующих процессы в системе океан-атмосфера, которые, наряду с известными климатическими индексами, использовались в качестве предикторов при прогностическом моделировании Эль-Ниньо/Ла-Нинья.

2. Разработана модель заблаговременного прогноза среднемесячных аномалий климатических характеристик на основе искусственных нейронных сетей, которая была успешно адаптирована для прогноза явлений Эль-Ниньо и Ла-Нинья и их типов. Модель осуществляет последовательный перебор множества конструкций нейронных сетей и выбор 20 наилучших. Ансамбль из отобранных ею 20 конструкций нейронных сетей соответствует прогностической функции модели, которая позволяет обеспечить расчеты с заблаговременностью более 12 месяцев.

3. Предложенная модель позволяет успешно прогнозировать события Эль-Ниньо и их тип и, с меньшей заблаговременностью – события Ла-Нинья. Вероятность верного определения условий, характерных для событий Эль-Ниньо, в период до одного года существенно не зависит от количества месяцев заблаговременности прогноза и варьируется от 76 до 83%. В то же время, успешность воспроизведения событий Ла-Нинья уменьшается с ростом заблаговременности прогноза от 85 до 31%.

4. Разработанная модель отличается низкой чувствительностью к весеннему порогу предсказуемости при прогнозе аномалии ТПО в районе Nino 3.4 и Nino 3, а при прогнозе аномалии ТПО в районе Nino 4 весенний порог предсказуемости вовсе отсутствует. Это обеспечивает ее преимущество по сравнению с современными динамическими и статистическими моделями прогноза Эль-Ниньо/Ла-Нинья и позволяет увеличить эффективную заблаговременность прогноза до 22 месяцев, что на 10-16 месяцев превосходит эту характеристику динамических моделей и на 4 месяца – моделей, основанных на алгоритмах

глубокого обучения. Прогноз состояния ЭНЮК на 2023 г., рассчитанный в ноябре 2022 г., одним из первых в мире с точностью до месяца показал начало Эль-Ниньо.

СПИСОК СОКРАЩЕНИЙ

БНС – байесовская нейронная сеть

ВМО – Всемирная метеорологическая организация

ВМП – высота морской поверхности

ВПП – весенний порог предсказуемости

ГНС – графовая нейронная сеть

ДУМ – давление на уровне моря

ДЦКП – длинная цепь элементов краткосрочной памяти

ИНС (также НС) – искусственные нейронные сети (нейронные сети)

ИОД – Индоокеанский диполь

ИЮК – индекс южного колебания

КМД – Колебания Маддена – Джулиана

ЛДМ – линейные динамические моды

МСП – многослойный персептрон

НСГП – нейронная сеть Гауссовой плотности

НСКР – нейронная сеть квантильной регрессии

ОСНС – остаточная свёрточная нейронная сеть

РОВ – регрессия опорных векторов

САК – Североатлантическое колебание

СНС – свёрточная нейронная сеть

ТПО – температура поверхности океана

ТСО – теплосодержание океана

ЭНЮК – Эль-Ниньо – Южное колебание

ЭОФ – эмпирические ортогональные функции

ЭПП – эффективная продолжительность прогноза (когда коэффициент корреляции больше 0.5)

20CR – Twentieth Century Reanalysis / Реанализ двадцатого столетия

AVHRR – Advanced Very-High-Resolution Radiometer (Усовершенствованный радиометр очень высокого разрешения)

CPC – Climate Prediction Center / Центр прогнозирования климата

E-OBS – Ensembles daily gridded observational dataset in Europe / Ансамбли данных ежедневных наблюдений в Европе, привязанных к сетке координат

H500 – геопотенциал на изобарическом уровне 500мб

IGRA v2.1 – International Global Radiosound Archive / Интернациональный Глобальный архив данных радиозондирования, Национального центра климатических данных США (NCDC)

MODIS – Moderate Imaging Spectrometer / спектрометр умеренной визуализации

NCDC – National Climatic Data Center / Национальный центр климатических данных США

NCEP – National Centers for Environmental Prediction / Национальный центр прогнозов состояния окружающей среды

NCEP/NCAR – National Centers for Environmental Prediction / National Center for Atmospheric Research (Национальный центр прогнозов состояния окружающей среды / Национальный центр атмосферных исследований США)

NMME – The North American Multi-Model Ensemble (Североамериканский мультимодельный ансамбль),

NOAA – National Oceanic and Atmospheric Administration (Национальное управление океанических и атмосферных исследований, США)

RMSE – Root Mean Square Error / Среднеквадратическая ошибка

TOGA-TAO – Tropical Ocean-Global Atmosphere and Tropical Atmosphere Ocean projects (Всемирный исследовательский проект «Тропический океан – Глобальная атмосфера» с 1985 по 1994 гг., и «Тропическая атмосфера и океан» с 1994 г. по настоящее время)

СПИСОК ЛИТЕРАТУРЫ

1. Артамонов Ю.В., Воскресенская Е.Н., Джиганшин Г.Ф., и др. Низкочастотная изменчивость гидрометеорологических и гидрофизических характеристик Тропической и Субтропической Атлантики в связи с глобальными вариациями типа Эль-Ниньо – Южные Осцилляции / Под ред. АБ Полонского, АА Сизова // Депон. рукопись N., 1991. Т. 4560.
2. Барцев С.И., Охонин В.А. Адаптивные сети обработки информации. Препринт ИФ СО АН СССР, Красноярск, 1986, №59Б, 20 с.
3. Бышев В.И. Синоптическая и крупномасштабная изменчивость океана и атмосферы. М.: Наука. 2003. 343 с.
4. Воскресенская Е.Н., Марчукова О.В. Пространственная классификация событий Ла-Нинья // Известия РАН. Физика атмосферы и океана, 2017. Т. 53. № 1. С. 125–134 DOI: 10.7868/S0002351517010138
5. Воскресенская Е.Н., Михайлова Н.В. Классификация событий Эль-Ниньо и погодно-климатические аномалии в Черноморском регионе // Доп. НАН України. 2010. № 3. С. 124–130.
6. Воскресенская Е.Н., Михайлова Н.В. Эль-Ниньо разных типов и особенности их проявления в Атлантико-Европейском регионе // Системы контроля окружающей среды. 2006. Т. 2. С. 307–310
7. Галушкин А.И. Синтез многослойных систем распознавания образов. М.: Энергия, 1974. 367 с.
8. Галушкин А.И. Синтез многослойных схем распознавания образов. - М.: Энергия, 1974. 367 с.
9. Гущина Д.Ю., Петросянц М.А. О связи температуры поверхности экваториальной части Тихого океана с циркуляцией скорости ветра в центрах действия атмосферы // Метеорология и гидрология. 1998. № 12. С. 5–22.
10. Железнова И.В., Гущина Д.Ю., Коленникова М.А. Оценка Изменения Вклада Основных Предикторов В Прогноз Эль-Ниньо В Последние Десятилетия

На Основе Простой Статистической Модели // *Фундаментальная и прикладная климатология*. 2020. №1. С. 42–64. DOI: 10.21513/2410-8758-2020-1-42-64

11. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиций непрерывных функций одного переменного и сложения // *Доклады АН СССР*. 1957. Т. 114. С. 953–956.

12. Лубков А.С. Научный прогноз: Начнется ли Эль-Ниньо в 2023 году? // *Системы контроля окружающей среды*. 2022. Вып. 4 (50). С. 143-144.

13. Лубков А.С., Воскресенская Е.Н., Кукушкин А.С. Метод восстановления среднемесячных значений прозрачности воды на примере северо-западной части Черного моря. // *Оптика атмосферы и океана*. 2016. Т. 29. № 04. С. 343–350. DOI: 10.1134/S1024856016050092.

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

15. Лубков А.С., Воскресенская Е.Н., Марчукова О.В. Применение нейронных сетей для модельного прогноза Эль-Ниньо и Ла-Нинья, включая их типы // *Метеорология и гидрология*. 2020. №11 С. 111–121. DOI: 10.3103/S1068373920110084

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

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

18. Марчукова О.В., Воскресенская Е.Н. Особенности формирования Центрально- и Восточно-Тихоокеанского типов Ла-Нинья. *Вестник Санкт-Петербургского университета. Науки о Земле*. 2022. Т. 67 №. 2. С. 299–317. DOI: 10.21638/spbu07.2022.205

19. Марчукова О.В., Лубков А.С., Воскресенская Е.Н. Качество воспроизведения событий Эль-Ниньо и Ла-Нинья по разным массивам реконструированных данных температуры поверхности океана // Вестник СПбГУ. Науки о Земле. 2020. Т. 1. №. 1. С. 97–120. DOI: 10.21638/spbu07.2020.106
20. Мохов И.И., Смирнов Д.А. Исследование взаимного влияния процессов Эль-Ниньо – Южное колебание и Северо-Атлантического и Арктического колебаний // Известия РАН. Физика атмосферы и океана. 2006. Т. 42. №. 5. С. 650–667.
21. Нестеров Е.С. Изменчивость характеристик атмосферы и океана в атлантико-европейском регионе в годы событий Эль-Ниньо и Ла-Нинья // Метеорология и гидрология. 2000. № 8. С. 74–83.
22. Нестеров Е.С. Североатлантическое колебание: атмосфера и океан. М.:Триада, лтд. 2013. 144 с.
23. Осовский С. Нейронные сети для обработки информации – М.: Финансы и статистика. 2002. 344 с.
24. Петросянц М.А., Гущина Д.Ю. Крупномасштабное взаимодействие глобальной циркуляции атмосферы с температурой поверхности экваториальной части Тихого океана // Метеорология и гидрология. 1998. Т. 5. С. 5–24
25. Полонский А.Б. Роль океана в изменениях климата. Киев. Изд. «Наукова Думка». 2008. 184 с.
26. Полонский А.Б., Башарин Д.В., Воскресенская Е.Н., Ворли С., Североатлантическое колебание: описание, механизмы и влияние на климат Евразии // Морской гидрофизический журнал. 2004. № 2. С. 42–59.
27. Хотон Дж. Глобальный климат. -Л.: Гидрометеиздат, 1987. 502 с.
28. Adams R.M., Chen C.C., McCarl B.A., Weiher R.F. The economic consequences of ENSO events for agriculture // Climate Research. 1999. V. 13(3). P. 165–172. DOI: 10.3354/cr013165
29. Aguilar-Martinez S., Hsieh W.W. Forecasts of tropical Pacific sea surface temperatures by neural networks and support vector regression // International Journal of Oceanography. 2009. P. 167239. DOI: 10.1155/2009/167239

30. Aragão L.E.O.C., Anderson L.O., Fonseca M.G. et al. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions // *Nat Commun.* 2018. V. 9. P. 536 DOI: 10.1038/s41467-017-02771-y
31. Ashok K., Behera S.K., Rao S.A., Weng H., Yamagata T. El Nino Modoki and its possible teleconnection // *Journal of Geophysical Research.* 2007. V. 112. P. C11007. DOI: 10.1029/2006JC003798
32. Bamzai A.S. Relationship between snow cover variability and arctic oscillation index on a hierarchy of time scale // *Int. J. of Climatology.* 2003. V. 23(2). P. 131–142. DOI: 10.1002/joc.854
33. Bamzai A.S., Shukla J. Relation between Eurasian Snow Cover, Snow Depth, and the Indian Summer Monsoon: An Observational Study // *J. Climate.* 1999. V. 12. P. 3117–3132. DOI: 10.1175/1520-0442(1999)012<3117:RBESCS>2.0.CO;2.
34. Barnett T.P., Graham N., Pazan S. ENSO and ENSO-related predictability. Part I: Prediction of equatorial Pacific sea surface temperature with a hybrid coupled ocean-atmosphere model // *J. Clim.* 1993. V. 6. P. 1545–1566. DOI: 10.1175/1520-0442(1993)006<1545:EAERPP>2.0.CO;2
35. Barnston A.G., Livezey R.E. Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns // *Monthly Weather Review.* 1987. V. 115(6). P. 1083 – 1126. DOI: 10.1175/1520-0493(1987)115<1083:CSAPOL>2.0.CO;2
36. Barnston A.G., Ropelewski C.F. Prediction of ENSO Episodes Using Canonical Correlation Analysis // *J. Climate.* 1992. V. 5. P. 1316–1345. DOI: 10.1175/1520-0442(1992)005<1316:POEEUC>2.0.CO;2.
37. Barnston A.G., Tippett M.K., L'Heureux M.L., Li S., DeWitt D.G. Skill of real-time seasonal ENSO model predictions during 2002–11: Is our capability increasing? // *Bull. Am. Meteorol. Soc.* 2012. V. 93(5). P. 631–651. DOI: 10.1175/BAMS-D-11-00111.1
38. Barnston A.G., Tippett M.K., Ranganathan M., et al. Deterministic skill of ENSO predictions from the North American Multimodel Ensemble // *Clim. Dyn.* 2019. V. 53. P. 7215–7234. DOI: 10.1007/s00382-017-3603-3

39. Bjerknes J. A possible response of the atmospheric Hadley circulation to equatorial anomalies of Ocean temperature // *Tellus*. 1966. V. 18(4). P. 820–829. DOI: 10.1111/j.2153-3490.1966.tb00303.x
40. Bjerknes J. Atmospheric teleconnections from the equatorial Pacific // *Mon. Weather Rev.* 1969. V. 97. P. 163172
41. Cachay S.R., Erickson E., Bucker A.F.C. The World as a Graph: Improving El Nino Forecasts with Graph Neural Networks // *arXiv*. 2021. arXiv:2104.05089
42. Callahan C.W., Mankin J.S. Persistent effect of El Niño on global economic growth // *Science*. 2023. V. 380(6649). P. 1064–1069. DOI:10.1126/science.adf2983
43. Chen H., Wang Q., Zhang R.-H. Sensitivity of El Niño diversity prediction to parameters in an intermediate coupled model // *Clim. Dynam.* 2023. V. 61. P. 2485–2502. DOI: 10.1007/s00382-023-06695-w
44. Chen H.C., Tseng Y.H., Hu Z.Z., Ding R. Enhancing the ENSO Predictability beyond the Spring Barrier // *Sci Rep.* 2020. V. 10. P. 984. DOI: 10.1038/s41598-020-57853-7
45. Chen W.Y., van den Dool H.M. Asymmetric impact of tropical SST anomalies on atmospheric internal variability over the North Pacific // *J. Atmos. Sci.* 1997. V. 54(6). P. 725–740. DOI: 10.1175/1520-0469(1997)054<0725:AIOTSA>2.0.CO;2
46. Chevillon G. Direct multi-step estimation and forecasting // *J. Econ. Surv.* 2007. V. 21. P. 746–785. DOI: 10.1111/j.1467-6419.2007.00518.x
47. Chiodi A. M., Harrison D. E., Vecchi G. A. Subseasonal Atmospheric Variability and El Niño Waveguide Warming: Observed Effects of the Madden–Julian Oscillation and Westerly Wind Events // *J. Climate*. 2014. V. 27. P. 3619–3642. DOI: 10.1175/JCLI-D-13-00547.1
48. Clarke A. J., Van Gorder S. Improving El Niño Prediction Using a Space-Time Integration of Indo-Pacific Winds and Equatorial Pacific Upper Ocean Heat Content // *Geophysical Research Letters*. 2003. V. 30(7). P. 2-5. DOI: 10.1029/2002GL016673

49. Demuth H., Beale M. Neural Network Toolbox for use with Matlab. // Natick: The MathWorks. 1992
50. Deser C., Alexander M.A., Xie S.P., Phillips A.S. Sea surface temperature variability: Patterns and mechanisms // *Annu. Rev. Mar. Sci.* 2010. V. 2. P. 115–143. DOI: 10.1146/annurev-marine-120408-151453
51. Dieppois B., Capotondi A., Pohl B., Chun K.P., Monerie P., Eden J. ENSO diversity shows robust decadal variations that must be captured for accurate future projections // *Commun. Earth Environ.* 2021. V. 2(1). DOI: 10.1038/s43247-021-00285-6
52. DiNezio P.N., Deser C., Karspeck A., Yeager S., Okumura Y., Danabasoglu G., Rosenbloom N., Caron J., Meehl G. A. A 2 year forecast for a 60–80% chance of La Niña in 2017–2018 // *Geophys. Res. Lett.* 2017. V. 44(22). P. 11624–11635. DOI:10.1002/2017GL074904
53. Ding S., Chen W., Feng J., Graf H-F. Combined Impacts of PDO and Two Types of La Niña on Climate Anomalies in Europe // *Journal of Climate.* 2017. V. 30. P. 3253–3278. DOI: 10.1175/JCLI-D-16-0376.1
54. Enfield D.B., Mestas-Nuñez A.M. Multiscale variabilities in global sea surface temperatures and their relationships with tropospheric climate patterns // *J. Clim.* 1999. V. 12(9). P. 2719-2733. DOI: 10.1175/1520-0442(1999)012<2719:mvigss>2.0.co;2
55. Erfanian A., Wang G., Fomenko L. Unprecedented drought over tropical South America in 2016: significantly under-predicted by tropical SST // *Scientific Reports.* 2017. V. 7(1). P. 5811. DOI:10.1038/s41598-017-05373-2.
56. Fang W., Sha Y., Sheng V.S. Survey on the Application of Artificial Intelligence in ENSO Forecasting // *Mathematics.* 2022. V. 10. P. 3793. DOI: 10.3390/math10203793
57. Fedorov A.V., Hu S., Lengaigne M., Guilyardi E. The impact of westerly wind bursts and ocean initial state on the development, and diversity of El Niño events // *Clim. Dyn.* 2015. V. 44(5–6). P. 1381–1401. DOI: 10.1007/s00382-014-2126-4

58. Folland C.K., Parker E. Correction of instrumental biases in historical sea surface temperature data // *Quarterly Journal of the Royal Meteorological Society*. 1995. V. 121. P. 319–367. DOI: 10.1002/qj.49712152206
59. Fraedrich K., Muller K., Kuglin R. Northern Hemisphere circulation regimes during the extremes of the El Niño/ Southern Oscillation // *Tellus*. 1992. V. 44a(1). P. 33–40. DOI: 10.3402/tellusa.v44i1.14941
60. Gao Y., Zhang J., Liu K., Chen H., Xu M. Improvement of an extended ensemble coupled data Assimilation–Forecast system and its application in El Niño diversity predictions // *Ocean & Coastal Management*. 2024. V. 247. P. 106917. DOI: 10.1016/j.ocecoaman.2023.106917.
61. Gavrilov A., Seleznev A., Mukhin D., Loskutov E., Feigin A., Kurths J. Linear dynamical modes as new variables for data-driven ENSO forecast // *Climate Dynamics*. 2019. v. 52. P. 2199–2216 DOI: 10.1007/s00382-018-4255-7
62. Geng H., Wang T. Spatiotemporal Model Based on Deep Learning for ENSO Forecasts // *Atmosphere*. 2021. V. 12. P. 810. DOI: 10.3390/atmos12070810
63. Glantz M.H. La Nina and its impacts: facts and speculation / M. H. Glantz. New York: The United Nations University. 2002. p. 271.
64. Graf H.-F., Zanchettin D. Central Pacific El Niño, the “subtropical bridge,” and Eurasian climate // *J. Geophys.* 2012. V. 117. P. D01102. DOI: 10.1029/2011JD016493.
65. Ham Y.G., Kim J.H. Luo J.J. Deep learning for multi-year ENSO forecasts // *Nature*. 2019. V. 573. P. 568–572. DOI: 10.1038/s41586-019-1559-7
66. Hanley D.E., Bourassa M.A., O'Brien J.J., Smith S.R., Spade E.R. Quantitative Evaluation of ENSO Indices // *J. of Clim.* 2003. V. 16. P. 1249–1258. DOI: 10.1175/1520-0442(2003)16<1249:AQEOEI>2.0.CO;2.
67. Hasegawa T, Horii T, Hanawa K. Two different features of discharge of equatorial upper ocean heat content related to El Niño events // *Geophys. Res. Lett.* 2006. V. 33. P. L02609. DOI: 10.1029/2005GL024832
68. Haykin S. *Neural networks, a comprehensive foundation*. N.Y.: Macmillan College Publishing Company. 1994. 823 c.

69. Hecht-Nielsen R. Neurocomputing. Amsterdam: Addison Wesley. 1991. 433 c.
70. Hertz J., Krogh A., Palmer R. Wstep do teorii obliczen neuronowych. Wyd. II. Warszawa: WNT, 1995.
71. Hinton G.E., Osindero S., The Y.W. A fast learning algorithm for deep belief nets // Neural Comput. 2006. V. 18. P. 1527–1554. DOI: 10.1162/neco.2006.18.7.1527
72. Hirahara S., Ishii M., Fukuda Y. Centennial-scale sea surface temperature analysis and its uncertainty // Journal of Climate. 2014. V. 27. P. 57–75. Doi: 10.1175/JCLI-D-12-00837.1
73. Hirst A.C. Unstable and damped equatorial modes in simple coupled ocean-atmosphere models // J. Atmos. Sci. 1986. V. 43. P. 606–632. DOI: 10.1175/1520-0469(1986)043<0606:UADEMI>2.0.CO;2
74. Hoerling M.P., Kumar A., Zhong M. El Nino, La Nina, and nonlinearity of their teleconnections // J. Climate. 1997. V. 10(8). P. 1769–1786. DOI: 10.1175/1520-0442(1997)0102.0.CO;2
75. Horii T., Hanawa K. A relationship between timing of El Nino onset and subsequent evolution // Geophys. Res. Let. 2004. V. 31. P. 1634 –1648. DOI: 10.1029/2003GL019239
76. Hu S., Fedorov A.V. The extreme El Niño of 2015–2016: The role of westerly and easterly wind bursts, and preconditioning by the failed 2014 event // Climate Dynamics. 2017. V. 52. P. 7339–7357. DOI: 10.1007/s00382-017-3531-2
77. Hu Z.Z., Kumar A., Xue Y., Jha B. Why were some La Niñas followed by another La Niña? // Clim. Dyn. 2014. V. 42. P. 1029–1042. DOI: 10.1007/s00382-013-1917-3
78. Hu J., Weng B., Huang T., Gao J., Ye F., You L. Deep residual convolutional neural network combining dropout and transfer learning for ENSO forecasting // Geophysical Research Letters. 2021. V. 48. P. e2021GL093531. DOI: 10.1029/2021GL093531

79. Huang B., Thorne P.W., Banzon V.F., Boyer T., Chepurin G., Lawrimore J.H., Menne M.J., Smith T.M., Vose R.S., Zhang H-M. Extended Reconstructed Sea Surface Temperature version 5 (ERSSTv5), Upgrades, validations, and intercomparisons // *Journal of Climate*. 2017. V. 30. P. 8179–8205. DOI: 10.1175/JCLI-D-16-0836.1

80. IPCC, 2021: *Climate Change 2021: The Physical Science Basis*. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2391 pp. DOI:10.1017/9781009157896.

81. IPCC, 2022: *Climate Change 2022: Impacts, Adaptation and Vulnerability*. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Lösschke, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA, 3056 pp. DOI: 10.1017/9781009325844.

82. Ishii M., Shouji A., Sugimoto S., Matsumoto T. Objective Analyses of SeaSurface Temperature and Marine Meteorological Variables for the 20th Century using ICOADS and the Kobe Collection // *Int. J. Climatol*. 2005. V. 25. P. 865–879. DOI: 10.1002/joc.1169

83. Jin F.-F. An equatorial ocean recharge paradigm for ENSO. Part I: Conceptual model // *J. Atmos. Sci.* 1997. V. 54. P. 811–829. DOI: 10.1175/1520-0469(1997)054<0811:AEORPF>2.0.CO;2

84. Kane R.P. Relationship of El Nino-Southern Oscillation and Pacific Sea Surface Temperature with Rainfall in Various Regions of the Globe // *Mon. Wea. Rev.* 1997. V. 125. P. 1792–1800.

85. Kao H.Y., Yu J.Y. Contrasting eastern Pacific and central Pacific types of ENSO // *Journal of Climate*. 2009. V. 22. P. 615–632. DOI: 10.1175/2008JCLI2309.1
86. Kiladis G.N., Diaz H.Z. Global climatic anomalies associated with extremes in the Southern Oscillation // *J. Climate*. 1989. V. 2(9). P. 1069–1090.
87. Kirtman B. P., Min D., Infanti J. M., Kinter J. L., Paolino D. A., Zhang Q., Wood E. F. The North American multimodel ensemble: phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction // *Bull. Am. Meteorol. Soc.* 2014. V. 95(4). P. 585–601. DOI: 10.1175/bams-d-12-00050.1
88. Klimauskas G. Neural Ware – User manual. Natick, USA: Neural Ware Inc., 1992
89. Knight J. R., Folland C. K., Scaife A. A. Climate impacts of the Atlantic multidecadal oscillation // *Geophys. Res. Lett.* 2006. V. 33(17). P. L17706 DOI: 10.1029/2006GL026242
90. Kug J.S., Ham Y.G. Are there two types of La Niña? // *Geophys. Res. Lett.* 2011. V. 38. P. L16704. DOI: 10.1029/2011GL048237
91. Kug J.S., Jin F.F., An S.I. Two types of El Niño events: Cold tongue El Niño and warm pool El Niño // *J Clim.* 2009. V. 22. P. 1499–1515
92. L’Heureux M.L. et al. Strength Outlooks for the El Niño-Southern Oscillation // *Weather Forecast.* 2019. V. 34. P. 165–175. DOI: 10.1175/WAF-D-18-0126.1
93. Larkin N.K., Harrison D.E. Global seasonal temperature and precipitation anomalies during El Niño autumn and winter // *Geophysical Research Letter.* 2005. V. 32(16). P. L16705. DOI: 10.1029/2005GL022860.
94. Latif M., Kleeman R. Eckert C. Greenhouse warming, decadal variability, or El Niño? An attempt to understand the anomalous 1990s // *J. Clim.* 1997. V. 10. P. 2221–2239
95. Lau K. M. Elements of a stochastic-dynamical theory of long-term variability of the El Niño-Southern Oscillation // *J. Atmos. Sci.* 1985. V. 42. P. 1552–1558

96. Levine A.F., McPhaden M.J. How the July 2014 easterly wind burst gave the 2015–2016 El Niño a head start // *Geophys. Res. Lett.* 2016. V. 43(12). P. 6503–6510. DOI: 10.1002/2016GL069204
97. Li J., Fan K., Zhou L. Satellite Observations of El Niño Impacts on Eurasian Spring Vegetation Greenness during the Period 1982–2015 // *Remote Sens.* 2017. V. 9. P. 628. DOI: 10.3390/rs9070628
98. Liang Y., Fedorov A.V. Linking the Madden-Julian Oscillation, tropical cyclones and westerly wind bursts as part of El Niño development // *Clim. Dyn.* 2021. V. 57. P. 1039–1060. DOI: 10.1007/s00382-021-05757-1
99. Lin J., Qian T. Switch Between El Nino and La Nina is Caused by Subsurface Ocean Waves Likely Driven by Lunar Tidal Forcing // *Sci. Rep.* 2019. V. 9. P. 13106 DOI: 10.1038/s41598-019-49678-w
100. Lin J.L. Ocean-atmosphere interaction in the lifecycle of ENSO: the coupled wave oscillator // *Chinese Annals of Mathematics, Series B.* 2009. V. 30. P. 715-728. DOI:10.1007/S11401-009-0072-Y
101. Liu Z., Alexander M. Atmospheric bridge, oceanic tunnel, and global climatic teleconnections // *Rev. Geophys.* 2007. V. 45. P. RG2005. DOI: 10.1029/2005RG000172
102. Livezey R.E., Masutani M., Leetmaa A., Rui H., Ji M., Kumar A. Teleconnective response of the Pacific-North American region atmosphere to large central equatorial Pacific SST anomalies // *J. Climate.* 1997. V. 10(2). P. 1787–1820. DOI: 10.1175/1520-0442(1997)0102.0.CO;2v
103. Lubkov A.S., Voskresenskaya E.N., Marchukova O.V. Application of a neural network model to forecasting of El Niño and La Niña // *IOP Conf. Ser.: Earth Environ. Sci.* 2019. V. 386. P. 012040. Doi: 10.1088/1755-1315/386/1/012040
104. Lubkov A.S., Voskresenskaya E.N., Marchukova O.V., Evstigneev V.P. European temperature anomalies in the cold period associated with ENSO events // *IOP Conf. Ser.: Earth Environ. Sci.* 2020. V. 606. P. 012031. DOI: 10.1088/1755-1315/606/1/012031

105. Ludescher J., Bunde A., Schellnhuber H.J. Forecasting the El Niño type well before the spring predictability barrier // *npj. Clim. Atmos. Sci.* 2023. V. 6 P. 196 DOI: 10.1038/s41612-023-00519-8
106. Luo J.J., Yuan C., Sasaki W., Behera S.K., Masumoto Y., Yamagata T., Masson S. Current status of intraseasonal-seasonal-to-interannual prediction of the Indo-Pacific climate. In *Indo-Pacific Climate Variability and Predictability // World Scientific Publishing Company: Singapore.* 2016. P. 63–107. DOI: 10.1142/9789814696623_0003
107. Mantua N. J., Hare S. R., Zhang Y., Wallace J. M., Francis R. C. A Pacific interdecadal climate oscillation with impacts on salmon production // *Bull. Am. Meteorol. Soc.* 1997. V. 78(6). P. 1069-1080. DOI: 10.1175/1520-0477(1997)078<1069:apicow>2.0.co;2
108. Marchukova O.V., Voskresenskaya E.N., Lubkov A.S. Diagnostics of the La Niña events in 1900–2018 // *IOP Conf. Ser.: Earth Environ. Sci.* 2020. V. 606. P. 012036. DOI: 10.1088/1755-1315/606/1/012036
109. Maslova V.N., Voskresenskaya E.N., Lubkov A.S. Multidecadal change of winter cyclonic activity in the Mediterranean associated with AMO and PDO // *Terr. Atmos. Ocean. Sci.* 2017. V. 28. P. 965–977. DOI: 10.3319/TAO.2017.04.23.01
110. McCulloch W. S., Pitts W. A logical calculus of the ideas immanent in nervous activity // *The Bulletin of Mathematical Biophysics.* 1943. V. 5(4). P. 115–133. DOI: 10.1007/bf02478259
111. McPhaden M.J., Yu X. Equatorial waves and the 1997–98 El Niño // *Geophys. Res. Lett.* 1999. V. 26(19). P. 2961–2964. DOI: 10.1029/1999GL004901
112. McWilliams J., Gent P. A coupled air-sea model for the tropical Pacific // *J. Atmos. Sci.* 1978. V. 35 P. 962–989. DOI: 10.1175/1520-0469(1978)035<0962:ACAASM>2.0.CO;2
113. Minsky M., Papert S. *Perceptrons: An Introduction to Computational Geometry* (2nd edition with corrections, first edition 1969), The MIT Press, Cambridge MA. 1972. ISBN 0-262-63022-2.

114. Mo K. C., White G. H. Teleconnections in the Southern Hemisphere // *Mon. Wea. Rev.* 1985. V. 113. P. 22–37. DOI: 10.1175/1520-0493(1985)113<0022:TITSH>2.0.CO;2.
115. Mokhov I.I., Smirnov D.A. Study of the mutual influence of the El Niño–Southern Oscillation processes and the North Atlantic and Arctic Oscillations // *Izv. Atmos. Oceanic Phys.* 2006. V. 42(5). P. 598–614. DOI: 10.1134/S0001433806050069
116. Mokhov I.I., Timazhev A.V. Assessing the Probability of El Niño-related Weather and Climate Anomalies in Russian Regions // *Russian Meteorology and Hydrology.* 2017. V. 42(10). P. 635–643. DOI: 10.3103/S1068373917100028
117. Mokhov I.I., Timazhev A.V.. Seasonal Temperature Extremes in the North Eurasian Regions Depending on ENSO Phase Transitions // *Atmosphere.* 2022. V. 13(2). P. 249. DOI: 10.3390/atmos13020249
118. Mu B., Qin B., Yuan S. ENSO-ASC 1.0.0: ENSO deep learning forecast model with a multivariate air–sea coupler // *Geoscientific Model Development.* 2021.V. 14(11). P. 6977–6999. DOI: 10.5194/gmd-14-6977-2021
119. Mu M., Duan W.S., Chen D.K., Yu W.D. Target observations for improving initialization of high-impact ocean-atmospheric environmental events forecasting. *Natl. Sci. Rev.* 2015. V. 2(2). P. 226–236. DOI: 10.1093/nsr/nwv021
120. Münnich M., Cane M.A., Zebiak S.E. A Study of Self-excited Oscillations of the Tropical Ocean–Atmosphere System. Part II: Nonlinear Cases // *J. Atmos. Sci.* 1991. V. 48. P. 1238–1248. DOI: 10.1175/1520-0469(1991)048<1238:ASOSEO>2.0.CO;2.
121. Neelin J.D., Battisti D.S., Hirst A.C., Fei-Fei J., Wakata Y., Yamagata T., Zebiak S.E. ENSO theory // *J. Geophys. Res.* 1998. V. 103(C7). P. 14261–14290. DOI: 10.1029/97JC03424
122. Nooteboom P.D., Feng Q.Y., López C. Using network theory and machine learning to predict El Niño // *Earth Syst. Dyn.* 2018. V. 9. P. 969–983. DOI: 10.5194/esd-9-969-2018

123. Okumura Y.M., Sun T.Y., Wu X. Asymmetric modulation of El Niño and La Niña and the linkage to tropical Pacific decadal variability // *J. Climate*. 2017. V. 30. P. 4705–4733. DOI: 10.1175/JCLI-D-16-0680.1
124. Patil K.R., Doi T., Jayanthi V.R., Behera S. Deep learning for skillful long-lead ENSO forecasts // *Front. Clim.* 2023. V. 4. P. 1058677. DOI: 10.3389/fclim.2022.1058677
125. Petersik P.J., Dijkstra H.A. Probabilistic forecasting of El Niño using neural network models // *Geophys. Res. Lett.* 2020. V. 47. P. e2019GL086423. DOI: 10.1029/2019GL086423
126. Philander S.G. El Niño, La Niña, and the southern oscillation. *Int. Geophys. V. 46. Ser. Academic Press: San Diego, CA. 1989. 289 pp.*
127. Picaut J., Masia F., du Penhoat Y. An advective-reflective conceptual model for the oscillatory nature of the ENSO // *Science*. 1997. V. 277 P. 663–666. DOI: 10.1126/science.277.5326.663
128. Polonsky A.B., Basharin D.V. 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*. 2017. V. 151. P. 101–107. DOI: 10.1016/j.gloplacha.2016.11.007
129. Polyakova E.I., Journel A.G., Polyakov I.V., Bhatt U.S. Changing relationship between the North Atlantic Oscillation and key North Atlantic climate parameters // *Geophys. Res. Lett.* 2006. V. 33. P. L03711. DOI: 10.1029/2005GL024573.
130. Puy M., Vialard J., Lengaigne M., Guilyardi E. Modulation of equatorial Pacific westerly/easterly wind events by the Madden–Julian oscillation and convectively-coupled Rossby waves // *Clim. Dyn.* 2016. V. 46. P. 2155–2178. DOI: 10.1007/s00382-015-2695-x
131. Puy M., Vialard J., Lengaigne M., Guilyardi E., DiNezio P. N., Voltaire A., Balmaseda M., Madec G., Menkes C., McPhaden M. J. Influence of westerly wind events stochasticity on El Niño amplitude: The case of 2014 vs. 2015 // *Climate Dyn.* 2019. V. 52. P. 7435–7454. DOI: 10.1007/s00382-017-3938-9

132. Qi Q.Q., Duan W.S., Zheng F., Tang Y.M. On the “spring predictability barrier” for strong El Niño events as derived from an intermediate coupled model ensemble prediction system // *Sci. China Earth Sci.* 2017. V. 60. P. 1614–1631. DOI: 10.1007/s11430-017-9087-2
133. Qian C., Wu Z., Fu C., Wang D. On changing El Niño: A view from time-varying annual cycle, interannual variability, and mean state // *J. Clim.* 2011. V. 24(24). P. 6486–6500. DOI: 10.1175/jcli-d-10-05012.1
134. Quinn W.H., Neal V.T., Antunez de Mayolo S.E. El Niño occurrences over the past four and a half centuries // *J. Geophys. Res.* 1987. V. 92(C13). P. 14449–14461. DOI: 10.1029/JC092iC13p14449.
135. Rasmusson E.M., Carpenter T.H. Variations in Tropical Sea Surface Temperature and Surface Wind Fields Associated with the Southern Oscillation/El Niño // *Mon. Wea. Rev.* 1982. V. 110. P. 354–384. DOI: 10.1175/1520-0493(1982)1102.0.CO;2
136. Rayner N.A., Parker D.E., Horton E.B., Folland C.K., Alexander L.V., Rowell D.P., Kent E.C., Kaplan A. Global analyses of sea surface temperature, sea ice, and night marine air temperature since the late nineteenth century // *Journal of Geophysical Research.* 2003. V. 108(D14). P. 4407. DOI: 10.1029/2002JD002670
137. Ren H., Scaife A.A., Dunstone N., Tian B., Liu Y., Ineson S., Lee J.-Y., Smith D., Liu C., Thompson V., Vellinga M., MacLachlan C. Seasonal predictability of winter ENSO types in operational dynamical model predictions // *Clim. Dynam.* 2019. V. 52(7–8). P. 3869–3890. DOI: 10.1007/s00382-018-4366-1
138. Ren H.L., Jin F.F. Niño indices for two types of ENSO // *Geophys. Res. Lett.* 2011. V. 38. P. L04704. DOI: 10.1029/2010GL046031
139. Reynolds R.W., Rayner N.A., Smith T.M., Stokes D.C., Wang W. An improved in situ and satellite SST analysis for climate // *Journal of Climate.* 2002. V. 15. P. 1609–1625. DOI: 10.1175/1520-0442(2002)015,1609: AIISAS.2.0.CO;2.
140. Ropelewski C.F., Halpert M.S. Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation // *Monthly Weather Review.*

1987. V. 115. P. 1606–1626. DOI: 10.1175/1520-0493(1987)115<1606:GARSPP>2.0.CO;2

141. Rosenblatt F. Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms. Cornell Aeronautical Laboratory. Report no. VG-1196-G-8. Spartan Books, 1962. p. 616

142. Rumelhart D., Hinton G., Williams R. Learning representations by back-propagating errors // Nature. 1986. V. 323. P. 533–536. DOI: 10.1038/323533a0

143. Saji N.H., Goswami B.N., Vinayachandran P.N., Yamagata T. A dipole mode in the tropical Indian Ocean // Nature. 1999. V. 401(6751). P. 360–363. DOI: 10.1038/43854

144. Sankar-Rao M., Lau K.M., Yang S. On the relationship between Eurasian snow cover and the Asian summer monsoon // Int. J. Climatol. 1996. V. 16 P. 605–616. DOI: 10.1002/(SICI)1097-0088(199606)16:6<605::AID-JOC41>3.0.CO;2-P

145. Schlesinger M. E., Ramankutty N. An oscillation in the global climate system of period 65–70 years. Nature. 1994. V. 367(6465). P. 723–726. DOI: 10.1038/367723a0

146. Shabbar A., Khandekar M. The impact of El Nino-Southern Oscillation on the temperature field over Canada // Atmosphere-Ocean. 1996. V. 34(2). P. 401–416. DOI: 10.1080/07055900.1996.9649570

147. Shinoda T., Hurlburt H.E., Metzger E.J. Anomalous tropical ocean circulation associated with La Nina Modoki // J. Geophys. Res. 2013. V. 116. P. C12001. DOI: 10.1029/2011JC007304

148. Singh A., Delcroix T., Cravatte S. Contrasting the flavors of El-Nino-Southern Oscillation using sea surface salinity observations // J. Geophys. Res. 2011. V. 116. P. C06016. DOI: 10.1029/2010JC006862

149. Suarez M. J., Schopf P. S. A delayed action oscillator for ENSO // J. Atmos. Sci. 1988. V. 45. P. 3283–3287

150. Takahashi K., Montecinos A., Goubanova K., Dewitte B. ENSO regimes: Reinterpreting the canonical and Modoki El Nino // Geophys.Res.Let. 2011. V. 38. P. L10704. DOI: 10.1029/2011GL047364

151. Tang Y., Zhang R. H., Liu T., Duan W., Yang D., Zheng F., Mu M. Progress in ENSO prediction and predictability study // *Natl. Sci. Rev.* 2018. V. 5(6). P. 826-839. DOI: 10.1093/nsr/nwy105
152. Tangang F.T., Hsieh W.W., Tang B. Forecasting the equatorial sea surface temperatures by neural network models // *Climate Dyn.* 1997. V. 13. P. 135–147. DOI: 10.1007/s003820050156
153. Tangang F.T., Tang B., Monahan A.H. Forecasting ENSO events: A neural network-extended EOF approach // *J. Clim.* 1998. V. 11. P. 29–41 DOI: 10.1175/1520-0442(1998)011<0029:FEEANN>2.0.CO;2
154. Tao L., Duan W., Vannitsem S. Improving forecasts of El Niño diversity: a nonlinear forcing singular vector approach // *Clim. Dynam.* 2020. V. 55(3–4). P. 739–754. DOI: 10.1007/s00382-020-05292-5
155. Tao L.J., Duan W.S. Using a nonlinear forcing singular vector approach to reduce model error effects in ENSO forecasting // *Weather Forecast.* 2019. V. 34. P. 1321–1342. DOI: 10.1175/WAF-D-19-0050.1
156. Tedeschi R.G., Cavalcanti I.F.A., Grimm A.M. Influences of two types of ENSO on South American precipitation // *International Journal of Climatology.* 2013. V. 33(6). P. 1382–1400. DOI: 10.1002/joc.3519
157. Thompson D.W., Wallace J.M. Arctic Oscillation // *Geophys. Res. Lett.* 1998. V. 25. P. 1297–1300. DOI: 10.1029/98GL00950
158. Tippett M. K., Barnston A. G., Li S. Performance of recent multimodel ENSO forecasts. *J. Appl. Meteorol. Climatol.* 2012. V. 51(3). P. 637–654. DOI: 10.1175/JAMC-D-11-093.1
159. Torrence C., Compo G. P. A Practical Guide to Wavelet Analysis // *Bull. Amer. Meteor. Soc.* 1998. V. 79. P. 61–78. DOI: 10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2.
160. Trenberth K. E., Caron J. M. The Southern Oscillation revisited: Sea level pressures, surface temperatures, and precipitation. *J. Clim.* 2000. V. 13(24). P. 4358–4365. DOI: 10.1175/1520-0442(2000)013<4358:tsorsl>2.0.co;2

161. Trenberth K.E., Stepaniak D.P. Indices of El Niño evolution // *J. of Climate*. 2001. V. 14. P. 1697–1701.
162. Tseng Y., Hu Z.Z., Ding R. An ENSO prediction approach based on ocean conditions and ocean-atmosphere coupling // *Clim. Dyn.* 2017. V. 48. P. 2025–2044. DOI: 10.1007/s00382-016-3188-2
163. Tseng Y.-H., Huang J.-H., Chen H.-C. Improving the predictability of two types of ENSO by the characteristics of extratropical precursors // *Geophysical Research Letters*. 2022. V. 49. P. e2021GL097190. DOI: 10.1029/2021GL097190
164. Vallès-Casanova I., Lee S. K., Foltz G. R., Pelegrí J. L. On the spatiotemporal diversity of Atlantic Niño and associated rainfall variability over West Africa and South America // *Geophys. Res. Lett.* 2020. V. 47(8). P. e2020GL087108. DOI: 10.1029/2020GL087108
165. Vecchi G.A., Harrison D. Tropical Pacific sea surface temperature anomalies, El Niño, and equatorial Westerly Wind Events // *J. Clim.* 2000. V. 13(11). P. 1814–1830. DOI: 10.1175/1520-0442(2000)013<1814:TPSSTA>2.0.CO;2
166. Venables W.N., Ripley B.D. *Linear Statistical Models*. In: *Modern Applied Statistics with S*. Statistics and Computing. Springer: New York, NY. 2002. Doi: 10.1007/978-0-387-21706-2_6
167. Voskresenskaya E.N., Marchukova O.V., Maslova V.N., Lubkov A.S. Interannual climate anomalies in the Atlantic-European region associated with La-Niña types // *IOP Conf. Ser.: Earth Environ. Sci.* 2018. V.107. P. 012043. DOI: 10.1088/1755-1315/107/1/012043
168. Voskresenskaya, E.N., Polonsky, A.B. Air pressure fluctuations in the North Atlantic and their relationship with El Niño-southern oscillations // *Phys. Oceanogr.* 1993. V. 4. P. 275–282. DOI: 10.1007/BF02197626
169. Walker G. T. Correlation in seasonal variations of weather // *Mem. India Meteorol. Dept.* 1924. V. 24. P. 275–332.
170. Wallace J. M., Gutzler D. S. Teleconnections in the geopotential height field during the Northern Hemisphere winter // *Mon. Wea. Rev.* 1981. V. 109(4). P. 784–812. DOI: 10.1175/1520-0493(1981)109<0784:titghf>2.0.co;2

171. Wang B., Fang Z. Chaotic oscillations of tropical climate: A dynamic system theory for ENSO // *J. Atmos. Sci.* 1996. V. 53. P. 2786–2802. DOI: 10.1175/1520-0469(1996)053<2786:COOTCA>2.0.CO;2
172. Wang H., Asefa T. Impact of different types of ENSO conditions on seasonal precipitation and streamflow in the Southeastern United States // *International Journal of Climatology*. 2018. V. 38(3). P. 1438–1451. DOI: 10.1002/joc.5257
173. Wang H., Hu S., Li X. An Interpretable Deep Learning ENSO Forecasting Model // *Ocean-Land-Atmos Res.* 2023. V. 2. P. 0012. DOI:10.34133/olar.0012
174. Wang Y., Jiang J., Zhang H. A scalable parallel algorithm for atmospheric general circulation models on a multi-core cluster // *Future Gener. Comput. Syst.* 2017. V. 72. P. 1–10. DOI: 10.1016/j.future.2017.02.008
175. Wang C., Weisberg R.H., Virmani J.I. Western Pacific interannual variability associated with the El Niño-Southern Oscillation // *J. Geophys. Res.* 1999. V. 104(C3). P. 5131–5149. DOI: 10.1029/1998JC900090.
176. Webster P.J., Yang S. Monsoon and ENSO: Selectively interactive systems // *Q. J. R. Meteorol. Soc.* 1992. V. 118. P. 877–926. DOI: 10.1002/qj.49711850705
177. Weisberg R. H. Wang C. A. Western Pacific oscillator paradigm for the El Niño-Southern Oscillation // *Geophys. Res. Lett.* 1997. V. 24. P. 779–782. DOI: 10.1029/97GL00689
178. Wu A., Hsieh W. W., Tang B. Neural network forecasts of the tropical Pacific sea surface temperatures // *Neural Networks*. 2006. V. 19(2). P. 145–154. DOI: 10.1016/j.neunet.2006.01.004
179. Wu X., Okumura Y. M., Deser C., Dinezio P. N. Two-year dynamical predictions of ENSO event duration during 1954–2015 // *J. Climate*. 2021. V. 34(10). P. 4069–4087. DOI: 10.1175/JCLI-D-20-0619.1
180. Xu J. Chan J.C.L. The role of the Asian-Australian monsoon system in the onset time of El Niño events // *J. of Clim.* 2001. V. 14(3). P. 418–433. DOI: 10.1175/1520-0442(2001)014<0418:TROTAA>2.0.CO;2

181. Xu J., Powell A. Uncertainty estimation of the global temperature trends for multiple radiosondes, reanalyses, and CMIP3/IPCC climate model simulations // *Theor. Appl. Climatol.* 2012. V. 108. P. 505–518. DOI: 10.1007/s00704-011-0548-z
182. Xue Y., Leetmaa A., Ji M. ENSO prediction with Markov models: The impact of sea level // *J. Clim.* 2000. V. 13. P. 849–871. DOI: 10.1175/1520-0442(2000)013<0849:EPWMMT>2.0.CO;2
183. Yang S. Xu L. Linkage between Eurasian winter snow cover and regional Chinese summer rainfall // *Int. J. Climatol.* 1994. V. 14. P. 739–750. DOI: 10.1002/joc.3370140704
184. Yeh S.-W., Kug S.-J., Dewitte B., Kwon M.-H., Kirtman B. P., Jin F.-F. El Niño in a changing climate. // *Nature.* 2009. V. 461. P. 511–514. DOI: 10.1038/nature08316. PMID: 19779449
185. Yu J.-Y., Zou Y. The enhanced drying effect of central-Pacific El Niño on US winter // *Environ. Res. Lett.* 2013. V. 8. P. 014–019. DOI: 10.1088/1748-9326/8/1/014019.
186. Yu Y.S., Duan W.S., Xu H., Mu M. Dynamics of nonlinear error growth and season-dependent predictability of El Niño events in the Zebiak–Cane model // *Q. J. R. Meteorol. Soc.* 2009. V. 135. P. 2146–2160. DOI: 10.1002/qj.526
187. Yuan Y, Yang S. Impacts of different types of El Niño on the East Asian climate: Focus on ENSO Cycles // *J. Clim.* 2012. V. 25(21) P. 7702–7722. DOI: 10.1175/JCLI-D-11-00576.1
188. Yuan Y., Yan H.M. Different types of La Niña events and different responses of the tropical atmosphere // *Chinese Science Bulletin.* 2013. V. 58. P. 406–415. DOI: 10.1007/s11434-012-5423-5
189. Yuan Y., Yang H., Li C.Y. Study of El Niño events of different types and their potential impact on the following summer precipitation in China (in Chinese) // *Acta Meteorol. Sin.* 2012. V. 70. P. 467–478. DOI: 10.11676/qxxb2012.039
190. Zebiak S.E., Cane M.A. A model El Niño-southern oscillation. *Mon. Weather Rev.* 1987. V. 115. P. 2262–2278. DOI: 10.1175/1520-0493(1987)115<2262:AMENO>2.0.CO;2

191. Zhang C., Gottschalck J. SST Anomalies of ENSO and the Madden–Julian Oscillation in the Equatorial Pacific // *J. Climate*. 2002. V. 15. P. 2429–2445. DOI: 10.1175/1520-0442(2002)015<2429:SAOEAT>2.0.CO;2.
192. Zhang S., Wang H., Jiang H., Ma W. Evaluation of ENSO Prediction Skill Changes since 2000 Based on Multimodel Hindcasts // *Atmosphere*. 2021. V. 12(3). P. 365. doi: 10.3390/atmos12030365
193. Zhang W., Wang L., Xiang B., Qi L., He J. Impacts of two types of La Niña on the NAO during boreal winter // *Climate Dynamics*. 2014. V. 44. P. 1351–1366. DOI: 10.1007/s00382-014-2155-z
194. Zhang Y., Wallace J. M., Battisti D. S. ENSO-like interdecadal variability: 1900–93. *J. Clim.* 1997. V. 10(5). P. 1004–1020. DOI: 10.1175/1520-0442(1997)010<1004:eliv>2.0.co;2
195. Zhou L., Zhang R.H. A Hybrid Neural Network Model for ENSO Prediction in Combination with Principal Oscillation Pattern Analyses // *Adv. Atmos. Sci.* 2022. V. 39. P. 889–902. DOI: 10.1007/s00376-021-1368-4

ПРИЛОЖЕНИЕ А. Объективная пространственно-временная классификация явлений Эль-Ниньо

В приложении предложена классификация событий Эль-Ниньо, которая обобщает пространственные и временные особенности явлений.

Классификация выполнялась иерархическим кластерным анализом методом Варда. Мерой тесноты связи было выбрано Эвклидово расстояние. Идентификация начала событий Эль-Ниньо выполнялась с применением индексов $Nino3.4+Nino3$ (5° с.ш. – 5° ю.ш. и 170° – 90° з.д.), $Nino1+2$ (0° – 10° ю.ш. и 90° – 80° з.д.) и $Nino3.4$ (5° с.ш. – 5° ю.ш. и 170° – 120° з.д.). При их расчете принималось во внимание наличие тренда, а также 20-летнего масштаба межгодовой изменчивости, связанный с Тихоокеанской декадной осцилляцией.

Важную роль в процессе идентификации начала явления играет подход к исследованию. Определение времени начала события Эль-Ниньо выполнялось в два этапа. Сначала определялись сами события по индексу $Nino3.4+Nino3$, основываясь на двух критериях. Первый из них – температурный: аномалия ТПО должна превышать $0,5^\circ\text{C}$. Вторым критерий – временной: длительность аномалии составляет не менее 4 месяцев. На следующем этапе по индексу $Nino1+2$ или индексу $Nino3.4$ производилась корректировка месяца начала Эль-Ниньо в случае интенсификации явления в одном из двух выбранных регионах. Таким образом было выбрано 30 событий Эль-Ниньо. При этом отмечено, что практически все явления начинаются в промежутке с апреля по ноябрь, а максимальная фаза развития наблюдается в промежутке с октября по январь.

Классификация, по которой проводилась типизация событий Эль-Ниньо, осуществлялась на основе индексов АТПО, рассчитанных для районов 1-5, приведенных на рис. А.1, и их изменения в процессе развития явления. Для каждого события было выбрано по 50 значений индекса АТПО следующим образом. Экваториальная часть Тихого океана была разделена на 5 районов, как показано на рис. А.1. Для каждого района выбирались значения рассчитанного в нем индекса АТПО в апреле, мае, июне, июле, августе, сентябре, октябре, ноябре,

декабре "0 года" и январе года "+1". Далее, для *каждого* из случаев Эль-Ниньо значения индексов АТПО пересчитывались в баллы от 0 до 3 по следующей схеме. Температурный диапазон от 0°C до максимального значения, наблюдаемого в любом из 50 выбранных значений индексов, делился на 4 равных диапазона. При этом, значению параметра, попавшему в определенный диапазон, присваивался соответствующий балл, где 3 балла воспринималось как высокие температурные аномалии, а 0 – как отсутствие аномалии. Это позволило рассматривать все события как равноценные, то есть без учета их интенсивности.




Рисунок А.1 – области, в которых рассчитывались аномалии ТПО

В результате новой объективной пространственно-временной классификации по АТПО было выявлено 2 типа Эль-Ниньо (табл. А.1), имеющие существенные различия в характере распространения аномалии температуры и месяце начала явления. К первому типу классификатор отнес 20 событий, начало которых наблюдается весной и в начале лета (рис. А.2-в), при этом весной 14 событий, а это составляет больше половины случаев. Аномалия ТПО распространяется в западном направлении. Максимальная фаза развития наблюдается осенью и в начале зимы, в среднем, в октябре-декабре (рис. А.2-г). Полученному типу дано название *Весенне-летний восточный (ВВТ)*.

Оставшиеся 10 событий классификатор отнес ко второму типу (табл. А.1). Второй тип начинается осенью (рис А.2-а). Исключением является лишь два события: Эль-Ниньо 2009 года, которое началось в июле и Эль-Ниньо 1940,

начало которого идентифицировано в январе. Аномалия ТПО как в момент зарождения, так и в максимальную фазу развития, расположена преимущественно в центре экваториальной зоны Тихого океана. Максимальная фаза наблюдается в ноябре-январе (рис. А.2-б), а длительность события не превышает 7-8 месяцев. Исключение составляют два наиболее интенсивных и продолжительных события выделенного типа: 1/1940 – 12/1941 и 10/1986 – 12/1987, длительность которых превышает 1 год, а фаза максимального развития приходится на март-май и июль-сентябрь, соответственно. Этому типу событий дано название *Осеннего-Центрального* (ОЦТ).

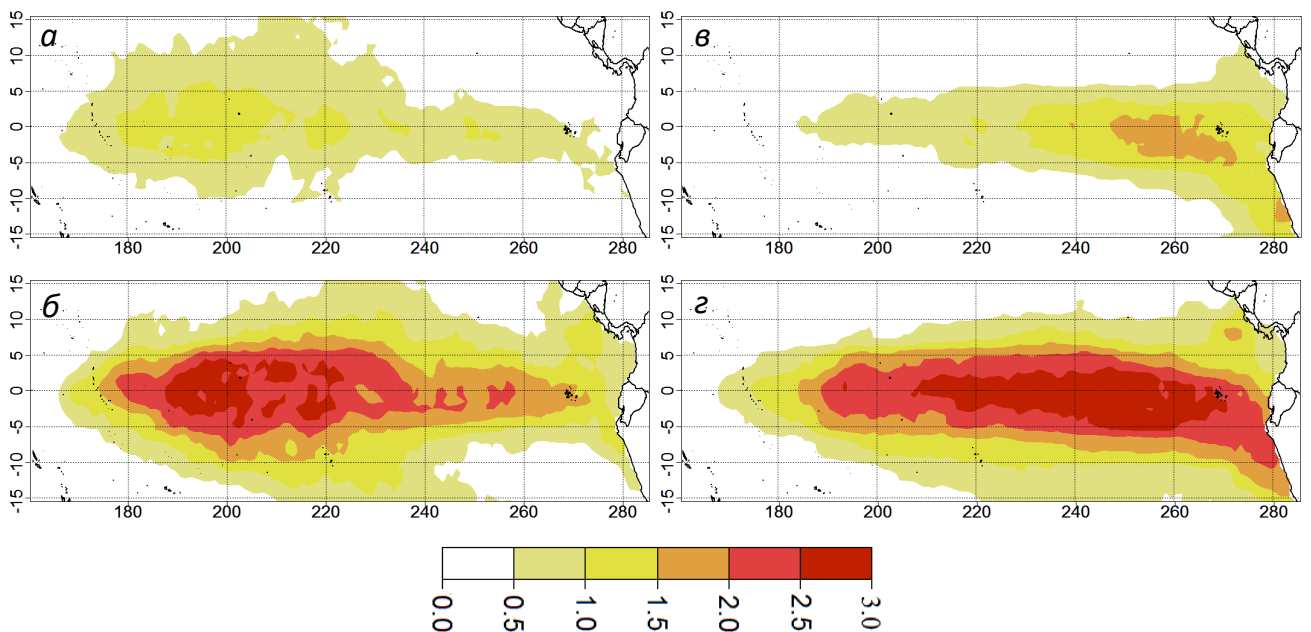


Рисунок А.2 – композитные карты распределения АТПО в баллах для Осеннего-Центрального типа, а – во время начала явления (сентябрь-октябрь), б – во время фазы максимального развития аномалии (ноябрь-январь) и для Весеннего-Восточного типа, в – в начале (май-июль) и z – во время фазы максимального развития явления (октябрь-декабрь).

Выделенные типы имеют неоднородную структуру поля распределения аномалии а также заметные различия в месяце интенсификации событий. Из рис. А.3 видно, что начало событий Эль-Ниньо ВВТ имеют выраженный пик в апреле,

мая и июле. В то время, как Эль-Ниньо ОЦТ интенсифицируется преимущественно в сентябре и октябре.

Таблица А.1 – Результаты классификации на основе балла АТПО, тип 1 – ВВТ, 2 – ОЦТ

Клас-я	Мес./год Эль-Ниньо	Макс. месяц	Значение	Клас-я	Мес./год Эль-Ниньо	Макс. месяц	Значение
1	5/1877	12-2	2,71	1	7/1963	10-12	1,19
2	10/1885	11-12	1,03	1	4/1965	10-12	1,74
1	5/1888	11-1	2,37	2	11/1968	11-12	0,83
1	7/1896	11-1	1,64	1	4/1969	10-12	1,05
1	8/1899	12-2	1,59	1	4/1972	10-12	2,26
1	6/1902	9-11	1,61	1	5/1976	9-11	1,12
1	7/1904	9	0,97	2	10/1977	11-12	0,75
1	5/1905	8-11	1,37	1	5/1982	11-1	2,51
2	9/1911	11-1	1,51	2	10/1986	7-9	1,53
1	6/1918	11-1	1,36	2	10/1991	12-2	1,35
1	4/1925	12-2	1,49	2	10/1994	11-1	0,98
1	7/1930	11-1	1,75	1	5/1997	10-12	2,49
2	1/1940	3-5/1941	1,35	2	9/2002	11-12	1,16
1	7/1951	10-11	1,07	1	9/2006	12	0,93
1	4/1957	11-1	1,43	2	7/2009	11-1	1,52




Рисунок А.3 – распределения событий Эль-Ниньо ВВТ (сплошная) и ОЦТ (штрихованная) относительно месяца начала явления

Таким образом, методом объективной пространственно-временной классификации выделено два типа явлений Эль-Ниньо: весенний восточный и осенний-центральный и выявлены их характерные особенности.

Для первого типа свойственны интенсификация отрицательной аномалии температуры у берегов Южной Америки и последующее ее распространение в западном направлении. Начало этих событий приходится на весенний сезон и начало лета. Максимальной фазы они достигают в октябре-декабре.

Второй, осенний центральный тип характеризуется тем, что в центре Тихого океана отмечается как интенсификация теплой АТПО, так и локализация этой аномалии в фазу максимального развития. Начало явления приурочено к осени, а максимальная фаза достигается в период с ноября по январь.

ПРИЛОЖЕНИЕ Б. Сравнение предложенной нейросетевой модели с некоторыми моделями глубокого обучения

В этом приложении на рис. Б.1 приведены сравнительные оценки разработанной в работе с некоторыми моделями глубокого обучения работ [Geng, Wang, 2021; Zhou, Zhang, 2022; Patil et al., 2023]. Очевидно, что для всех случаев предлагаемая модель лучше справляется с воспроизведением ЭНЮК, особенно с большими сроками залаговременности прогноза. С заблаговременностью менее 7 месяцев модель [Zhou, Zhang, 2022] оказалась заметно лучше.

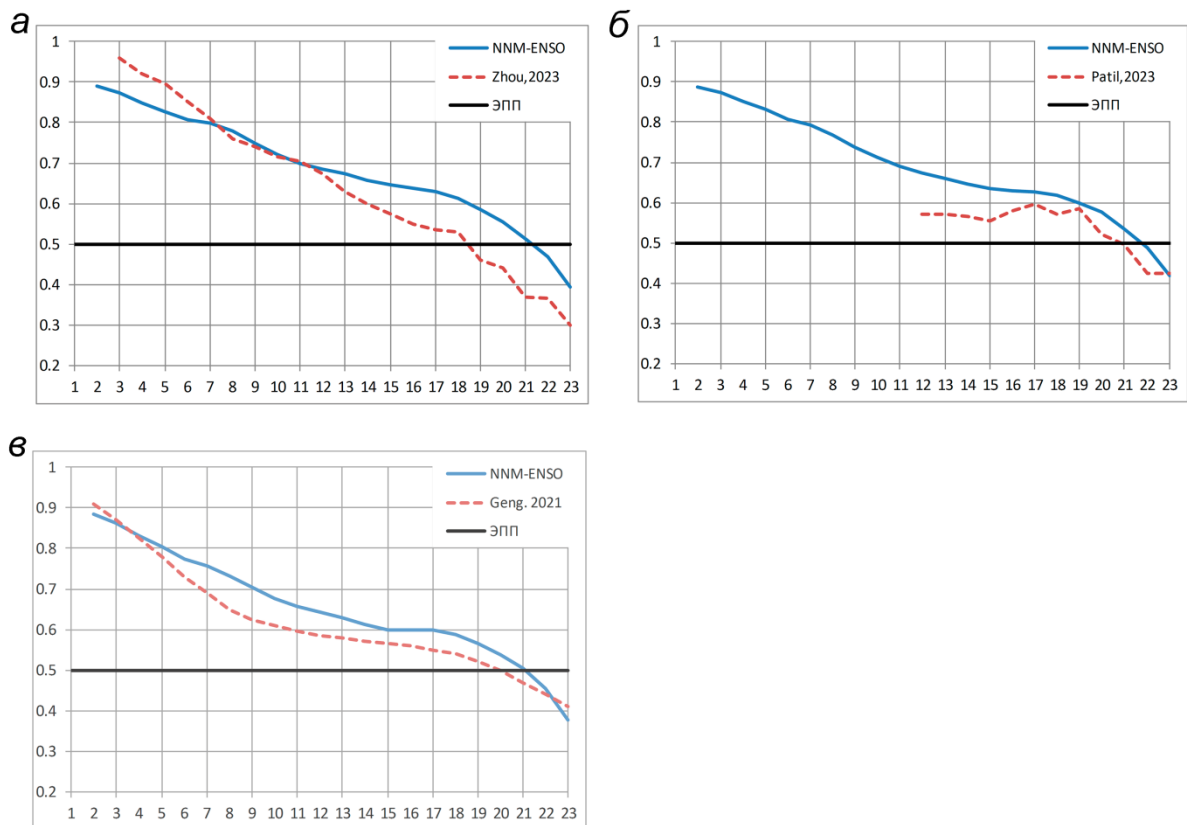


Рисунок Б.1 – Сравнение способностей прогнозировать трехмесячное скользящее среднее индекса Niño 3.4 моделями глубокого обучения в сравнении с предложенной моделью за временные периоды *а* – 1994–2020гг., *б* – 1984–2021гг. и *в* – 1994–2017гг.

ПРИЛОЖЕНИЕ В. Влияние учета теплосодержания океана на глубине до 300м на качество моделирования

В приложении сопоставлены результаты моделирования с учетом теплосодержания океана в слое 0-300м (ТСО300) и обычной модели из параграфа 4.2 на контрольной выборке (2007-2023 г.). Следует отметить, что обучающий период модели с учетом ТСО300 был короче на десять лет, что связано с доступностью данных ТСО300, ряд которого начинается с 1958г. Из графика на рис. В.1а видно, что способности модели с учетом ТСО300 несколько выше с заблаговременностью до 6 месяцев и ниже с большей заблаговременностью. При этом условия Эль-Ниньо модель ТСО300 воспроизводит лучше базовой с заблаговременностью до 10 месяцев (рис. В.1б). Условия Ла-Нинья наоборот модель ТСО300 воспроизводит несколько хуже со средней и высокой заблаговременностью прогноза (рис. В.1в). Модель с учетом ТСО300 отличается высокой повторяемостью ошибочных условий Эль-Ниньо и Ла-Нинья на больших сроках заблаговременности от 6 месяцев (рис. В.1г).

В целом, применение ТСО300 несколько улучшает прогностические способности с заблаговременностью до 6 месяцев, однако с большей заблаговременностью способности базовой модели несколько лучше, что вероятно связано с более коротким обучающим периодом модели ТСО300.

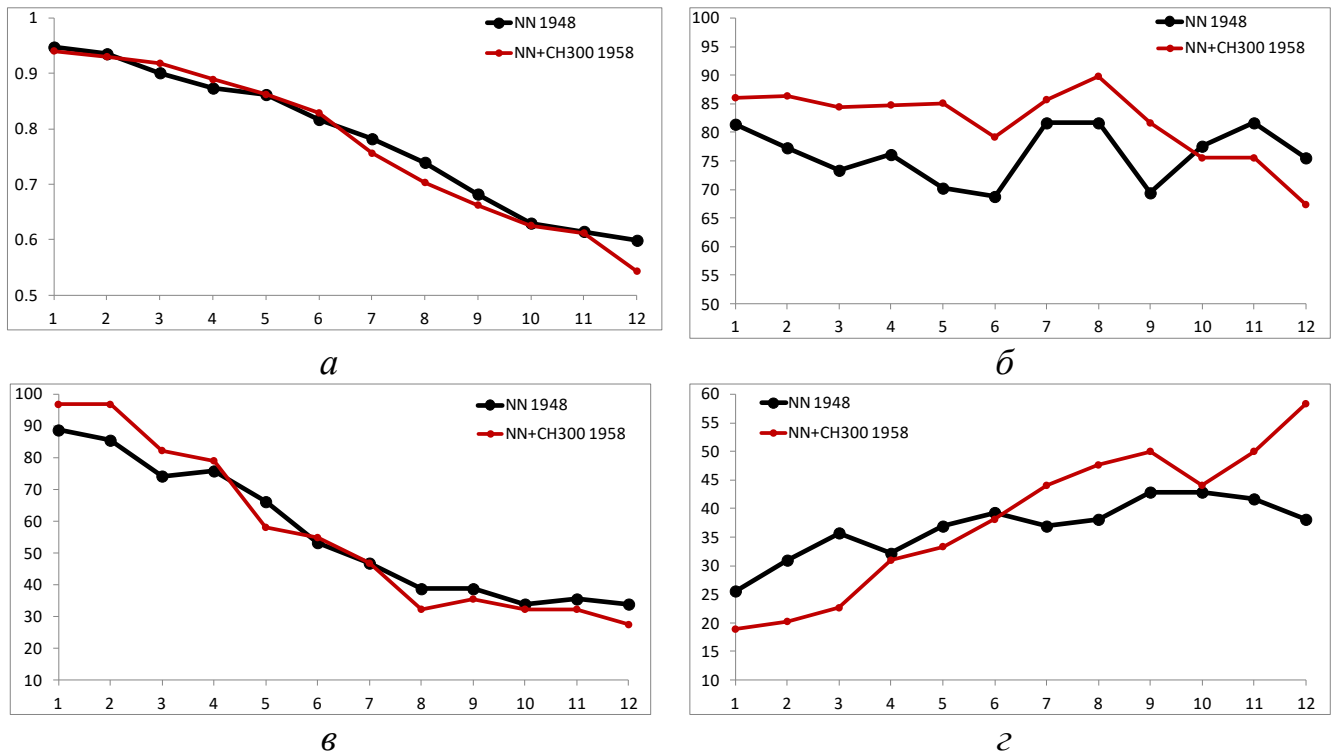


Рисунок В.1 – (а) – коэффициент корреляции за контрольный период (2007-2023) в зависимости от заблаговременности прогноза; (б) – повторяемость воспроизведения условий Эль-Ниньо; (в) – повторяемость воспроизведения условий Ла-Нинья; (г) – ошибочные условия Эль-Ниньо или Ла-Нинья. NN 1948 – обычная модель из параграфа 4.2; NN CH300 1958 – модель с учетом TCO300.