

ОЦЕНКА ДИНАМИКИ АТМОСФЕРЫ ПО РЕЗУЛЬТАТАМ НЕЙРОСЕТЕВОГО МАСШТАБИРОВАНИЯ ПОЛЕЙ ПРИПОВЕРХНОСТНОГО ВЕТРА НАД БАРЕНЦЕВЫМ И КАРСКИМ МОРЯМИ

В. Ю. Резвов^{1,2}, М. А. Криницкий^{1,2}, А. В. Гавриков²

¹ *Московский физико-технический институт,
Россия, 141701, Долгопрудный, Институтский пер. д. 9,
e-mail: rezvov.vyu@phystech.edu;*

² *Институт океанологии им. П. П. Ширшова РАН,
Россия, 117997, Москва, Нахимовский проспект, д. 36*

В настоящей работе рассматривается использование подхода глубокого обучения для масштабирования (повышения пространственного разрешения) приповерхностного ветра над Баренцевым и Карским морями с помощью глубоких искусственных нейронных сетей с пропускными соединениями для повышения пространственного разрешения при одновременном снижении вычислительных затрат по сравнению с негидростатическим моделированием. Входные данные низкого разрешения получены из глобального атмосферного реанализа ERA5, а высокое разрешение обеспечивается моделью Weather Research and Forecasting (WRF). Результаты нейросетевого масштабирования сравниваются с опорными результатами билинейной интерполяции. Модель улучшает распределение параметров жизненного цикла мезомасштабных структур, приближая их к данным высокоразрешенного моделирования, и в 50 раз превосходит его по быстродействию. Высота ветрового волнения, полученная с использованием граничных условий из нейросетевой модели вместо негидростатической, демонстрирует близкие значения. Разработанная нейросетевая модель также показывает отклонение менее 3 % от высокоразрешенного динамического моделирования по количеству мезомасштабных структур.

Ключевые слова: масштабирование, приповерхностный ветер, полярные мезоциклоны, новоземельская бора, искусственные нейронные сети, машинное обучение, глубокое обучение, ветровое волнение

Введение

Ограниченное количество неравномерно распределенных метеорологических станций и сложные погодные условия значительно затрудняют сбор информации для дальнейшего изучения погоды и климата в арктическом регионе (Суркова, Крылов, 2018). Несмотря на имеющиеся наблюдения за скоростью приповерхностного ветра, осуществляемые на метеорологических станциях Росгидромета, на нефтяных платформах и судах, наиболее подробные исследования ветровых условий, например, для Баренцева моря, представлены в серии «Моря СССР» (Гидрометеорология...1990),

вышедшей более тридцати лет назад. При этом в конце первой четверти XXI в. Арктика снова находится в фокусе изучения ее текущего и будущего климата (Суркова, Крылов, 2018).

Арктическое усиление, проявляющееся во все более высоких темпах потепления, по сравнению с низкими широтами, приводит также к изменению структуры и распределения полей ветра и других атмосферных переменных. Данное явление имеет значительные последствия, так как оказывает влияние, среди прочего, на судоходство в рамках Северного морского пути и добычу полезных ископаемых в условиях меняющейся ледовой и ветровой обстановки, что ведет к необходимости точного прогнозирования ветра с высоким пространственным разрешением. Определение скорости ветра у поверхности в прибрежных районах Северного Ледовитого океана со сложным рельефом также крайне важно для минимизации последствий чрезвычайных ситуаций природного характера.

В арктическом регионе преобладающими являются зональные западные переносы. При этом атмосферная циркуляция в Арктике характеризуется положением климатического арктического фронта. Арктический фронт отделяет арктические воздушные массы от масс умеренных широт, при этом районы с высокой повторяемостью циклонов также могут указывать на климатический фронт (Золотокрылин и др., 2014). Одной из особенностей атмосферной циркуляции, связанной, в том числе, с наличием климатического арктического фронта, являются полярные мезоциклоны. Эти циклоны представляют собой небольшие, но очень мощные системы, формирующиеся над морскими акваториями севернее основной бароклинической зоны (Turner, 2003). В (Никитин и др., 2016) было предложено полярным циклоном «называть подтип мезоциклонов, расположенный (1) над морской поверхностью ближе к полюсу (как Северному, так и Южному) от основной бароклинической зоны, (2) с приповерхностным ветром, превышающим 15 м/с, и (3) имеющий размер меньше 1000 км». Ключевым процессом является термическая конвекция, возникающая, когда холодный воздух перемещается с ледяного покрова на более теплую морскую поверхность. Этот переход ведет к быстрому нагреву и увлажнению воздуха, что вызывает вертикальную неустойчивость и усиливает конвекцию.

Еще одним характерным мезомасштабным атмосферным явлением в данном регионе является новоземельская бора. Архипелаг Новая Земля, находясь в области активных синоптических процессов, обусловленных циклонической активностью, из-за особенностей своей топографии, является разделителем водных и воздушных масс Карского и Баренцева морей. При этом Карское и Баренцево моря кардинально отличаются по своим гидрометеорологическим условиям, в особенности, по ледовой обстановке. Карское море большую часть года покрыто льдом, в результате чего образуется холодная воздушная масса с термически стабильным атмосферным пограничным слоем (АПС). Напротив, Баренцево море находится под влиянием теплых вод Северо-Атлантического течения, что приводит к отсутствию льда большую часть года и образованию теплой воздушной массы с неустойчивым АПС. Когда воздушные потоки направлены на запад, холодная воздушная масса из Карского моря пересекает

хребет Новой Земли и попадает на более теплую поверхность Баренцева моря, что приводит к образованию боры (Ефимов, Комаровская, 2018).

Несмотря на возможность воспроизведения динамики полярных мезоциклонов с помощью региональных и глобальных гидростатических моделей с высоким разрешением (Stoll et al., 2020; Moreno-Chamarro et al., 2025), эти и другие мезомасштабные экстремальные погодные явления могут быть недостаточно достоверно представлены в глобальных реанализах с низким разрешением. Ряд исследований, посвященных, например, новоземельской боре, основываются на моделировании с высоким разрешением (Шестакова, 2016; Ефимов, Комаровская, 2018), что также повышает необходимость высокоразрешенного прогнозирования приповерхностного ветра в прибрежных областях Арктики.

Работа (Krinitiskiy et al., 2021) подчеркивает важное значение полярных циклонов в процессах взаимодействия атмосферы и океана, а также в океанической циркуляции как на синоптических, так и на климатических временных масштабах. Мощный ветер, возникающий в таких циклонах, усиливает турбулентные потоки тепла с поверхности океана, что развивает глубокую конвекцию в океане. Кроме того, полярные циклоны представляют потенциальную угрозу для инфраструктуры, связанной с добычей нефти и газа на шельфе, а также для морской навигации (Krinitiskiy et al., 2021). Таким образом, о воспроизведении полей приповерхностного ветра той или иной моделью в арктическом регионе можно судить, в том числе, по качеству воспроизведения характеристик жизненного цикла мезомасштабных явлений.

Данные атмосферных реанализов и низкоразрешенных моделей с разрешением сетки от десятков до сотен километров позволяют учитывать только крупные особенности рельефа подстилающей поверхности и требуют применение методов повышения пространственного разрешения (масштабирования) для получения данных о ветре с высоким разрешением, поскольку в реальности характерные масштабы изменения атмосферных полей над сложным рельефом гораздо меньше (Резвов и др., 2024). Под масштабированием в настоящей работе понимается именно повышение пространственного разрешения полей.

Существуют две основные группы методов масштабирования атмосферных переменных. Динамическое масштабирование использует модельные данные с грубым разрешением в качестве начальных и граничных условий, запускающих более подробное региональное моделирование. В таком подходе сложный рельеф и особенности подстилающей поверхности учитываются напрямую в гидродинамическом моделировании на заданной области. Статистическое масштабирование, наоборот, позволяет избежать численного решения системы гидродинамических уравнений с некоторым образом заданными параметризациями подсеточных явлений. В этом подходе устанавливаются статистические взаимосвязи между данными в высоком и низком пространственных разрешениях с помощью различных методов, таких как классический регрессионный анализ или искусственные нейронные сети (ИНС). ИНС являются одним из наиболее динамично развивающихся, но до сих пор не до конца изученных подходов статистического масштабирования.

Метрики качества помогают оценить, насколько эффективно набор выходных данных модели разрешает ключевые геофизические явления, важные для конкретной задачи и географической области (Jagannathan et al., 2020; Reed et al., 2022; Резвов и др., 2024). Главной проблемой классических поточечных метрик, например, средней абсолютной ошибки (MAE), среднего квадрата ошибки (MSE), средней квадратической ошибки (RMSE) и др., является то, что они не учитывают информацию о пространственной структуре полей геофизических переменных. В работе (Davis et al., 2006) впервые представлена систематизированная концепция феноменологического (object-based) метода, позволяющего избежать ряд недостатков поточечных метрик и основанного на идентификации некоторых «объектов» в полях геофизических переменных и сравнении их атрибутов по данным моделирования/прогноза и фактическим данным. В настоящей работе, помимо поточечных метрик, в качестве таких «объектов» для валидации удобно использовать рассмотренные выше полярные мезоциклоны и новоземельскую бору.

Целью настоящей работы является анализ динамики атмосферы по результатам нейросетевого масштабирования полей приповерхностного ветра над Баренцевым и Карским морями на основе оценки качества воспроизведения мезомасштабных атмосферных явлений.

Раздел 1 предлагает автоматизированный алгоритм идентификации и построения траекторий когерентных вихревых структур. Раздел 2 описывает используемые в работе наборы данных и конфигурации обучения искусственных нейронных сетей. Раздел 3 посвящен результатам нейросетевого масштабирования полей приповерхностного ветра над Баренцевым и Карским морями.

1. Автоматизированный алгоритм идентификации и построения траекторий когерентных вихревых структур

Идея расширить теорию вихрей до понятия «когерентная вихревая структура» (КВС) принадлежит А. С. Монину, определившему КВС как «неслучайную нелинейную устойчивую суперпозицию крупномасштабных компонент турбулентности» (Монин, Яглом, 1965). В терминах потоков, а не полей, КВС – это «трехмерная область потока, в которой, по крайней мере, одна фундаментальная переменная потока (компонента скорости, плотность, температура и т. д.) проявляет значительную автокорреляцию или корреляцию с другой переменной на пространственном и/или временном диапазоне, который значительно больше, чем наименьшие характерные масштабы потока» (Robinson, 1991).

Особое внимание в настоящее время приковано к новому поколению методов идентификации когерентных вихревых структур. Одним из примеров является Rortex-критерий (Liu et al., 2018), учитывающий не только абсолютную величину завихренности, но и направление этого вектора (Liu et al., 2016; Kolář et al., 2010). Если определить собственные вектора и собственные значения тензора градиентов

скорости $\nabla \mathbf{u}$, то одному из единичных собственных векторов $\mathbf{e}_r$ будет соответствовать вещественное собственное число λ_r . Вектор $\mathbf{e}_r$ и задает ось вращения когерентной вихревой структуры: $\mathbf{R} = R\mathbf{e}_r$. Представленный таким образом вектор чисто вихревого движения получил название Rortex-вектора (Liu et al., 2018).

Помимо вещественного собственного значения λ_r , у тензора градиентов скорости $\nabla \mathbf{u}$ имеются еще 2 комплексно-сопряженных собственных числа $\lambda_{\pm} = \lambda_{cr} \pm i\lambda_{ci}$. Мнимая часть λ_{ci} получила название локальной силы вращения вихря (Zhou et al., 1999).

В каждой точке модуль Rortex-вектора рассчитывается через завихренность ω как:

$$R = \omega \cdot \mathbf{e}_r - \sqrt{(\omega \cdot \mathbf{e}_r)^2 - 4\lambda_{ci}^2}.$$

Когерентные вихревые структуры следует искать в областях, где $R \neq 0$. При этом, как было сказано ранее, в отличие от предыдущего поколения критериев, в Rortex-критерии исследуемая величина может иметь разный знак, определяющий направление вращения вокруг оси $\mathbf{e}_r$.

Для более правильного расчета Rortex-критерия использовались данные о ветре на высоте изобарической поверхности 850 гПа вместо приповерхностного ветра для уменьшения влияния поверхностного трения на выявление когерентных вихревых структур.

Для разделения областей с $R \neq 0$ на отдельные когерентные структуры, по аналогии с (Koshkina et al., 2023), применялся метод кластеризации DBSCAN (кластеризация пространственно-распределенных данных на основе оценки пространственной плотности в условиях зашумленных данных). В качестве входных признаков на алгоритм подавались координаты точек, соответствующих критерию. Как кратко описано в (Schubert et al., 2017), алгоритм DBSCAN оценивает плотность входных признаков, основываясь на пороговом значении числа соседей (*minPts*) в радиусе ϵ при заданной метрике расстояния. Объекты, у которых число соседей в этом радиусе (включая саму точку) превышает порог *minPts*, считаются основными точками. Все соседи в радиусе ϵ от основной точки считаются частью того же кластера, что и основная точка. Если какая-либо из соседних точек также является основной, соответствующие кластеры объединяются. Точки, которые не являются основными, но находятся в чьей-то ϵ -окрестности, называются «граничными точками». Граничные точки, принадлежащие нескольким кластерам, присваиваются только одному из них. Точки, которые не попадают в ϵ -окрестность ни одной основной точки, считаются шумом и не входят ни в один кластер.

Обязательными гиперпараметрами алгоритма, таким образом, являются максимальная дистанция ϵ между точками внутри одного кластера и минимальное количество соседних точек в кластере *minPts*. Существенной модификацией метода, предложенной в (Koshkina et al., 2023), является добавление третьего гиперпараметра – минимального порогового количества точек в кластере. Такое дополнительное ограничение учитывает геофизический характер задачи и очищает полученные

кластеризованные данные от множества малых вихревых структур, содержащих меньшее количество точек. Поскольку в настоящем исследовании кластеризация основана на величине Rortex-критерия, различающегося по знаку, то кластеризация циклонических и антициклонических структур проводится отдельно друг от друга.

Важно отметить, что математическая формулировка Rortex-критерия включает в себя только вращение вихря, подобное вращению твердого тела. В гидродинамических терминах такое ограничение соответствует ядру вихря.

В (Krinitskiy et al., 2021) отмечается принципиальное влияние соотношения скорости атмосферных объектов и разрешения атмосферных данных по времени на задачу построения траекторий таких объектов. Построение траекторий циклонов синоптического масштаба не ограничено временным разрешением, так как расстояния, которые вихри проходят за 1 час, – минимальный временной шаг реанализа ERA5 (Hersbach et al., 2016) – составляют порядка 40–70 км, в то время как их размеры в поперечнике варьируются от 500 км до более, чем 2500 км (Neu et al., 2013). Однако мезомасштабные атмосферные явления, такие как ПМЦ, преодолевают расстояние, по порядку равное их размеру за время, сравнимое с временным шагом сеточных данных (Verezemskaya et al., 2017). Мезомасштабные когерентные вихревые структуры также характеризуются большей изменчивостью направления движения по сравнению с циклонами синоптического масштаба.

В настоящей статье разработан алгоритм построения траекторий вероятных когерентных вихревых структур на основании проведенной перед этим кластеризации и идентификации таких структур.

На этапе инициализации из данных по кластеризации на первом временном шаге извлекаются координаты глобальных экстремумов Rortex-критерия, то есть экстремальные значения для каждого кластера. Для каждого кластера определяются статистические значения атмосферных полей, а именно, медианное значение и 95-й перцентиль скорости ветра внутри кластера.

Затем при переходе к следующему шагу данных по времени производится шаг трекинга кластеров на основе их перемещения во времени. Этот процесс включает как отслеживание новых экстремумов, так и обновление существующих кластеров. Построение траекторий происходит без учета скоростей центров кластеров, а просто по ближайшему локальному экстремуму.

Для каждого кластера из списка, составленного на предыдущем шаге, используется последняя известная позиция его центра. Проверяется, что кластер находится в пределах границ домена с учетом исключения пяти узлов сетки с каждой стороны домена. По координатам центра каждого кластера на предыдущем шаге происходит поиск ближайшего локального экстремума по данным на новом шаге по времени. Для этого вычисляется расстояние от текущего положения кластера до всех локальных экстремумов в радиусе поиска, равном полутора эффективным радиусам кластера. Из этих близких экстремумов выбирается ближайший экстремум, и его координаты используются для обновления положения кластера. После этого для нового кластера, добавленного к треку, вычисляются те же статистики атмосферных переменных.

Если по текущему кластеру не найдено подходящих координат, его данные не обновляются, а если кластер перемещается, информация сохраняется. Если кластер оказался с отсутствующими данными, например, из-за выхода за пределы домена, то такие кластеры исключаются из списка треков. Для каждого оставшегося кластера заново определяются центры – глобальные экстремумы.

Описанная процедура построения траекторий повторяется с данными на каждом временном шаге. При этом сохраняются только треки, имеющие как минимум 3 шага по времени.

2. Используемые данные и конфигурации искусственных нейронных сетей

Для решения задачи статистического масштабирования приповерхностного ветра в качестве данных в высоком разрешении используется результат негидростатического атмосферного моделирования WRF версии 4.1 с исследовательским динамическим ядром WRF-ARW (Weather Research and Forecast model Advanced Research core) (Skamarock et al., 2019).

Модель WRF обладает значительным потенциалом, так как для каждого из таких процессов доступен широкий выбор схем параметризации, которые имеют свои преимущества в зависимости от региона. Например, работа (Oberto et al., 2012) анализирует точность воспроизведения атмосферных осадков, что является ключевым показателем для арктического региона, показывая, что модель WRF хорошо воспроизводит осадки, особенно в весенний и летний периоды. Авторы исследования (Dong et al., 2018) утверждают, что WRF хорошо справляется с моделированием сильного и устойчивого приповерхностного ветра в арктическом регионе. В работе (Gavrikov, Gulev, 2020) также показано, что модель WRF демонстрирует хорошее соответствие с данными наблюдений, как по количеству осадков, так и в воспроизведении циклонов, полей приповерхностного ветра и турбулентных потоков. Все эти параметры имеют критическое значение для работы в арктических условиях.

Позиционирование вычислительной области показано на рисунке 1. Пространственное разрешение домена составляет 6 км, а количество узлов сетки – 210×280.

В использованной в настоящей работе модели высокого разрешения WRF была настроена следующая конфигурация физических процессов. Для параметризации радиационных потоков применялась схема RRTMG (Iacono et al., 2008). Параметризация приземного слоя осуществлялась с использованием схемы Eta (Janjić, 1994), основанной на теории подобия Монина-Обухова, с добавленным вязким подслоем. Вертикальный турбулентный обмен параметризовался с помощью схемы MYNN (Nakanishi, Niino, 2009), которая представляет собой классическую k - ϵ модель. Эта модель основана на локальном перемешивании турбулентной кинетической энергии, но ее коэффициенты были оптимизированы с помощью вихреразрешающих моделей. Масштаб перемешивания определяется как минимальный из масштабов турбулентности, плавучести и поверхностного слоя, согласно теории подобия Монина-Обухова.

Конвективные процессы описывались модифицированной схемой Каина-Фритша (Kain, 2004). Для капель и других частиц использовалась схема WSM6 (Hong, Lim, 2006).




Рис. 1 – Вычислительная область, в которой проводится статистическое масштабирование приповерхностного ветра

Выходная продукция модели WRF – это трехмерные данные об атмосфере в высоком пространственном (6 км) и временном (1 час) разрешении. По вертикали нижний уровень находится на высоте примерно 30 м, а верхний – 50 гПа. Начальными и граничными условиями послужили данные оперативного анализа GFS (Global Forecast System, NOAA, USA).

Эксперимент проведен для периода 2015–2023 гг. Во избежание дрейфа результатов моделирования была применена процедура спектрального подталкивания атмосферной динамики с характерным размером, превышающим 500 км.

В качестве входных данных с низким разрешением для исследуемых моделей статистического масштабирования используются данные, полученные из билинейной интерполяции данных глобального климатического реанализа ERA5 на сетку WRF с часовым разрешением по времени, – зональный и меридиональный компоненты скорости ветра на высоте 10 м, на уровне 850 гПа, температуру воздуха на высоте 2 м, атмосферное давление, приведенное к уровню моря, и температуру поверхности океана над морским участком домена.

Набор целевых данных с более высоким разрешением представлен данными описанной выше модели WRF с такими же временными интервалами и аналогичен

по составу набору переменных низкого разрешения. При этом маска суши не использовалась, так как информация из этого статического предиктора была бы сильно скоррелирована с отсутствием данных о температуре поверхности океана над сушей. Кроме того, не использовались данные об орографии, включая шероховатость и рельеф, для предотвращения переобучения над сушей.

Все используемые переменные были нормированы с помощью среднего и стандартного отклонения, вычисленных для каждой переменной по всему массиву используемых данных WRF и ERA5. Это сделано для того, чтобы и входные данные, и целевые переменные находились в одном и том же метрическом пространстве.

Конфигурации искусственных нейронных сетей

Ряд исследований предлагает U-Net на базе (Ronneberger et al., 2015) в качестве основы для лучшей адаптации к задаче пространственного масштабирования. Данная архитектура основана на симметричной структуре кодировщик–декодер, что позволяет эффективно учитывать как локальные, так и глобальные паттерны изображения. В аналогичной задаче пространственного масштабирования архитектура с пропускными соединениями позволяет извлекать характерную структуру атмосферных полей, соответствующую различным пространственным масштабам. Архитектура модели включает в себя последовательность сверточных блоков для уменьшения пространственного разрешения входных данных (кодировщик) и аналогичную последовательность блоков для восстановления разрешения до исходного уровня (декодер). Применение билинейной интерполяции при увеличении разрешения и возможность использования пакетной нормализации позволяют улучшить устойчивость модели к изменению входных данных и ускорить сходимость во время обучения.

Рассматриваемая в настоящей работе архитектура содержит следующие основные компоненты. Входной сверточный блок выполняет начальную обработку поступающих на вход данных, используя два последовательных сверточных слоя с функцией активации ReLU. На вход поступают нормированные данные реанализа ERA5 размерностью $7 \times 210 \times 280$, соответствующие одному моменту времени. Кодировщик содержит четыре последовательных блока, каждый из которых выполняет сверточную обработку с увеличением количества каналов и последующее сжатие изображения при помощи операции MaxPool2d. Сверточная часть каждого блока кодировщика включает три сверточных слоя (Conv2d) с ядром размером 3×3 и функцию активации Mish для нелинейного преобразования признаков. «Бутылочное горлышко» – это центральный блок сети, где достигается максимальная глубина кодирования признаков, обеспечивая баланс между сжатием скрытого представления и сохранением значимой информации. Декодер состоит из четырех блоков, которые выполняют билинейную интерполяцию для восстановления пространственного разрешения и используют сверточные операции для объединения признаков. Каждый блок включает в себя операцию конкатенации признаков предыдущего слоя и кодировщика из пропускных соединений, три последовательных сверточных слоя, нелинейную активацию Mish,

операцию Upsample для увеличения пространственного разрешения до требуемого – 210×280 . Выходной слой выполняет финальную сверточную операцию, приводя количество каналов выходных данных к числу, соответствующему целевым значениям из модели WRF.

Функции потерь и поточечные метрики качества

Для обучения искусственной нейронной сети путем обратного распространения ошибки в настоящей работе используется подход, близкий по смыслу к статистической коррекции. Обозначим x – элемент исходных интерполированных данных в низком разрешении из глобального реанализа ERA5 на сетку высокого разрешения пространственной размерностью 210×280 , f – сверточная искусственная нейронная сеть с пропускными соединениями с обучаемыми параметрами θ . Тогда при загрузке элемента x в нейронную сеть f на выходе получается массив $f(x, \theta)$ с такой же пространственной размерностью. Если y – элемент исходных данных в высоком разрешении из модели WRF, взятый в тот же момент времени, что и элемент x , тогда все используемые в настоящей работе функции потерь при обучении можно обозначить как:

$$\mathcal{L}(f(x, \theta), y - x).$$

Таким образом, искусственная нейронная сеть обучается аппроксимировать разность между высокоразрешенными данными WRF и интерполированными значениями реанализа ERA5. В результате масштабированные значения атмосферных переменных для расчета метрик качества определяются как:

$$y^* = x + f(x, \theta).$$

В настоящей работе используются три варианта функций потерь. Простейшей конфигурацией для $\mathcal{L}$ является средний квадрат ошибки (mean squared error, *MSE*):

$$\mathcal{L} = \left\langle \sum_{i,j} \left(f_{i,j}(x, \theta) - y_{i,j} - x_{i,j} \right)^2 \right\rangle, \quad (5.4)$$

где угловыми скобками обозначено осреднение по всем 210×280 узлам сетки. Индексами i, j снизу обозначается соответствующий узел каждого из массивов x , y и $f(x, \theta)$.

Так как в наборах данных ERA5 и WRF совпадают 7 переменных, то суммирование и осреднение происходит сначала по каждой из переменных отдельно. После этого для получения скалярного значения функции потерь рассчитывается модуль этого вектора. Конфигурация обучения с такой функцией ошибки в дальнейшем будет обозначаться MSE-all.

Тем не менее, недостатком описанной выше функции MSE является равнозначность ветровых и неветровых переменных при суммировании. В результате была предложена конфигурация обучения с функцией ошибки MSE-UV850, оценивающей средний квадрат ошибки по аналогичной формуле, но суммирующей только по ортогональным компонентам скорости ветра у поверхности и на уровне 850 гПа, поскольку

качество масштабирования в дальнейшем оценивается по точности воспроизведения мезомасштабной динамики на уровне 850 гПа и качеству масштабирования приповерхностного ветра в идентифицированных когерентных вихревых структурах.

Также применялась упрощенная конфигурация обучения с функцией потерь MSE-UV, оценивающая средний квадрат ошибки по сумме только ортогональных компонент скорости приповерхностного ветра у поверхности.

В качестве простейших метрик качества масштабирования в настоящей работе используются различные варианты среднеквадратических ошибок RMSE и средних абсолютных ошибок MAE. Обе эти метрики считаются отдельно для модуля скорости приповерхностного ветра, модуля скорости ветра на уровне 850 гПа, температуры воздуха у поверхности и атмосферного давления, приведенного к уровню моря. Кроме того, для скорости ветра у поверхности и на 850 гПа рассчитываются дополнительно метрики SSIM (индекс структурной схожести) и PSNR (пиковое отношение сигнала к шуму).

Разбиение на выборки и методология обучения

Для всех конфигураций обучения нейросетевой модели, исследуемых в настоящей работе, используются одни и те же обучающая (тренировочная), валидационная и тестовая выборки. Данные, описывающие поля атмосферных переменных, достаточно сильно скоррелированы на временных масштабах порядка нескольких дней. Кроме того, наблюдается сезонная повторяемость атмосферных процессов, приводящая к корреляциям на масштабах, составляющих целое число лет (Hohlein et al., 2020). Чтобы корректно учесть такую особенность данного временного ряда, и обучающая, и валидационная, и тестовая выборки состоят из полных последовательных лет. Наличие целого числа сезонных циклов в тренировочной выборке позволяет также осреднить сезонную изменчивость, которая может влиять на результат обучения.

Кроме того, наличие одних и тех же элементов в разных выборках может привести к тому, что нейросеть переобучится, т. е. будет работать на валидационной и на тестовой выборке данных гораздо качественнее, чем на вновь поступающих данных, с которыми сеть «не знакома». Для предотвращения эффекта переобучения необходимо исключить перекрытие информации между данными обучения, валидации и проверки.

Таким образом, в настоящей главе в качестве тренировочной выборки был выбран семилетний интервал с января 2015 г. по декабрь 2021 г. Оставшиеся данные – 2022 г. и 2023 г. были включены в валидационную и тестовую выборки соответственно.

Обучение и оценка при всех конфигурациях модели были проведены при помощи возможностей фреймворка машинного обучения PyTorch для языка Python. Оптимизация нейросетевых методов выполняется с помощью оптимизатора Adam (Kingma, Ba, 2017). В качестве начального коэффициента скорости обучения (learning rate) для всех исследуемых моделей было выбрано значение $\eta_0 = 10^{-4}$. Обучение проводится в

течение не менее чем 150 эпох без преждевременной остановки. Большее количество эпох может быть выбрано с учетом остановки в момент, когда $\eta = \eta_{\min} = 10^{-9}$.

3. Результаты

Конфигурации обучения архитектуры искусственной нейронной сети с пропускными соединениями различаются как MSE-all, MSE-UV850, MSE-UV в соответствии с разными функциями ошибок при обучении. Все метрики качества были рассчитаны на тестовой выборке, не участвовавшей в процедурах обучения и валидации. Значения метрик качества для различных конфигураций обучения указаны в таблице 1. Наилучшие значения каждой метрики выделены полужирным. При этом опорным методом является билинейная интерполяция данных реанализа ERA5 на сетку модели WRF.

Табл. 1 – Значения поточечных метрик качества на тестовой выборке при различных конфигурациях обучения ИНС и на опорном решении

	Интерполяция	Конфигурация MSE-all	Конфигурация MSE-UV850	Конфигурация MSE-UV
RMSE _{wind} , м/с	1,743	1.470	1.409	1.442
MAE _{wind} , м/с	1,112	1.088	1.045	1.060
RMSE ₈₅₀ , м/с	2,205	2.185	2.059	2.717
MAE ₈₅₀ , м/с	1,756	1.684	1.583	2.041
RMSE _{T2} , °C	3,059	2.309	5.790	7.868
MAE _{T2} , °C	2,023	1.634	4.025	5.757
RMSE _{SLP} , гПа	1,657	0.908	3.210	3.471
MAE _{SLP} , гПа	1,344	0.713	2.692	2.610
PSNR _{wind}	19,001	21.010	21.960	22.571
PSNR ₈₅₀	16,739	17.859	20.610	20.694
SSIM _{wind}	0,373	0.393	0.404	0.438
SSIM ₈₅₀	0,276	0.290	0.307	0.227

Как легко заметить из таблицы 1, наилучшие значения ветровых среднеквадратической и средней абсолютной ошибок показывает конфигурация модели, обучаемая на основе одновременной минимизации ошибки в полях ветра у поверхности и на высоте 850 гПа. Несмотря на то, что конфигурация MSE-UV сосредоточена на масштабировании приповерхностного ветра, по значениям метрик для этой переменной она уступает конфигурации MSE-UV850. Конфигурация MSE-all распределяет выразительную способность модели по всем переменным, что приводит к сниженным показателям качества для ветровых переменных и повышению остальных показателей. Важным представляется преимущество конфигурации MSE-UV850 по метрике SSIM₈₅₀, так как эта мера показывает качество воспроизведения структуры поля ветра на уровне 850 гПа, что важно для дальнейшей идентификации и построения

траекторий мезомасштабных когерентных вихревых структур. Для наилучшей конфигурации обучения MSE-UV850 была рассчитана пространственная спектральная плотность $E(k)$ кинетической энергии ветра. Для всего домена на тестовом датасете $E(k)$ показана на рисунке 2.




Рис. 2 – Пространственная спектральная плотность кинетической энергии ветра в 2023 г. (синий – ERA5, зеленый – WRF, желтый – статистическая модель)

Видно, что особенно в высокочастотной области пространственная спектральная плотность кинетической энергии приповерхностного ветра нейросетевого статистического масштабирования смещается от ERA5 в сторону WRF, что свидетельствует о появлении высокоразрешенной структуры ветра в результатах нейросетевого масштабирования.

Отдельное исследование было посвящено анализу производительности нейросетевой модели статистического масштабирования.

В режиме обучения на всех конфигурациях ИНС продолжительность одной эпохи составила в среднем 6 минут 30 секунд при оптимальной загрузке графического сопроцессора. Таким образом, для максимальных 150 эпох общая продолжительность обучения не превышает приблизительно 17 часов. В режиме применения общее время нейросетевого моделирования на датасете продолжительностью 9 лет, с 2015 по 2023 гг., составило 1 час 30 минут. Таким образом, среднее время моделирования одного года составляет около 10 минут.

Для исследования производительности модели WRF были проведены эксперименты на вычислительных ресурсах Института океанологии им. П. П. Ширшова РАН. Было определено оптимальное количество ядер (256) для используемой конфигурации модели WRF, рассчитывающей прогноз для Арктики. С повышением количества вычислительных ядер производительность возрастает нелинейно. Выше значения 256 ядер производительность не растет. Скорость расчетов при выборе оптимального количества ядер составляет 1 минута 40 секунд за сутки модельного времени. Таким

образом, в режиме применения среднее время моделирования одного года составит около 10 часов, что в 60 раз медленнее режима применения статистической нейросетевой модели. Если объединить режим обучения (около 17 часов) и режим применения (около 1.5 часов) для всего набора данных на статистической модели, это по-прежнему будет более, чем в 4 раза быстрее, чем на негидростатической модели WRF только в режиме применения.

Алгоритм DBSCAN оценивает плотность входных признаков, основываясь на пороговом значении числа соседей $\min Pts = 20$ в радиусе $\epsilon = 5$ при заданной метрике расстояния на сфере. За условную единицу радиуса берется сторона ячейки равномерной квадратной сетки (в настоящей работе, 6 км). Было добавлено минимальное пороговое количество точек в кластере $\min Size = 40$. Кластеризация была проведена для всего временного промежутка с 2015 по 2023 гг., по данным WRF, по данным пространственного нейросетевого масштабирования и по данным глобального реанализа ERA5. С каждой стороны пространственного домена были не приняты по 5 точек сетки для исключения краевых эффектов.

Для каждого из набора данных – WRF, интерполированного реанализа ERA5 и масштабированных с помощью ИНС данных, на всем временном промежутке с 2015 по 2023 гг. были рассчитаны треки когерентных вихревых структур. Для всего множества треков для каждого из набора данных посчитана статистика максимума медианы скорости ветра внутри кластеров вдоль трека и максимума 95-го перцентиля скорости ветра внутри кластеров вдоль трека.

Для каждого из указанных статистических параметров были рассчитаны гистограммы распределения отдельно для каждого из наборов данных. На рисунке 3 показаны гистограммы для тестовой выборки (2023 г.).

Как видно из рисунка 3, ядерная оценка плотности и распределение близки для максимума медианы и 95-го перцентиля скорости ветра в треке у данных WRF и у результата масштабирования. Это более надежно, чем поточечные метрики, и свидетельствует о том, что нейросетевая модель статистического масштабирования сдвигает структуру ветра интерполированного реанализа ERA5 ближе к WRF.




Рис. 3 – Статистика идентифицированных треков когерентных вихревых структур по результатам трекинга на тестовой выборке (2023 г.): а) максимум медианы скорости ветра в треке, б) максимум 95-го перцентиля скорости ветра в треке

На рисунке 4 изображены диаграммы квантиль-квантиль, показывающие схожесть распределений статистик треков когерентных вихревых структур. Близость к диагонали показывает близость распределений. По тестовой выборке видно, что за исключением структур с наиболее высокими скоростями ветра, распределения треков из масштабированных данных и данных WRF близки, в отличие от распределения треков по данным интерполированного реанализа ERA5. При этом даже в «хвостах» распределений треков с наиболее высокими скоростями приповерхностного ветра нейросетевое масштабирование улучшает статистику треков относительно ERA5.




Рис. 4 – Диаграммы квантиль-квантиль для сравнения статистик идентифицированных треков когерентных вихревых структур по результатам трекинга на тестовой выборке (2023 г.). Зеленым обозначено сравнение треков по данным ERA5 и WRF, синим – по масштабированным данным и данным WRF: **а)** максимум медианы скорости ветра вдоль трека, **б)** максимум 95-го перцентиля скорости ветра вдоль трека

Кроме того, проведено сравнение числа идентифицированных треков когерентных вихревых структур по данным реанализа ERA5, гидродинамической модели WRF и нейросетевого масштабирования на тренировочной и тестовой выборках (таблица 2).

Табл. 2 – Число идентифицированных треков когерентных вихревых структур

	ERA5	WRF	Масштабирование
Число треков на тестовой выборке (2023 г.)	15193	28672	29435

Результаты, показанные в таблице 2, свидетельствуют о том, что в данных ERA5 в современном климате примерно в 2 раза недооценивается мезомасштабная динамика атмосферы в российском секторе Арктики в мерах количества мезомасштабных

когерентных структур. При этом по числу идентифицированных треков нейросетевое масштабирование близко к WRF, отличаясь не более, чем на 3 %. Таким образом, ИНС добавляет к поступающим на вход интерполированным полям ERA5 высокочастотную пространственную информацию.

Далее качество воспроизведения полярных мезоциклонов рассматривается на отдельных примерах из научной литературы. В качестве примера приведены мезоциклоны, наблюдавшиеся в акваториях Баренцева и Карского морей в 2022 г.

В районе Баренцева моря 14–15 февраля 2022 г. наблюдался явно выраженный полярный мезоциклон с горизонтальными размерами около 600 км (Петриченко и др., 2023). На рисунке 5 представлено сравнение полей приповерхностного ветра в Баренцевом море в момент наибольшего развития полярного мезоциклона (08:00 UTC 14 февраля 2022).




Рис. 5 – Поля приповерхностного ветра над акваторией Баренцева моря с ПМЦ 08:00 UTC 15.02.2022 г.: а) ERA5; б) масштабирование нейросетью; в) WRF

Как видно из рисунка 5, ИНС воспроизводит наличие полярного мезоциклона по данным ERA5, что подтверждается данными WRF. ИНС уменьшает область с высокими скоростями ветра у побережья Кольского полуострова и правильно изменяет направление ветра к северо-востоку от Кольского полуострова. Стоит отметить значительную детализацию скорости приповерхностного ветра над сушей, включая Кольский п-ов, п-ов Канин, о. Колгуев и Новую Землю.

Для оценки качества детализации приповерхностного ветра данные ERA5, WRF и нейросетевого масштабирования также сравнивались с данными двух метеостанций, расположенных в районе Баренцева моря (таблица 3) по значениям модуля скорости ветра в период прохождения полярного мезоциклона с 13 по 15 февраля 2022 г.

На метеостанциях в этот период нейросеть показывает значения RMSE, сравнимые с WRF, и лучшие, чем реанализ ERA5, усваивающий данные со станций.

Табл. 3 – Число идентифицированных треков когерентных вихревых структур

Модель	Метрика	Кармакулы	Бугрино
ERA5	RMSE, м/с	7,31	1,57
	R	0,62	0,95
WRF	RMSE, м/с	8,24	1,36
	R	0,80	0,93
Нейросеть	RMSE, м/с	4,77	1,20
	R	0,80	0,96

В этот же период времени, с 14 по 17 февраля 2022 г. наблюдалась новоземельская бора. При этом данный эпизод является характерным случаем развития боры над Новой Землей. Бора начинается на севере архипелага и, постепенно ослабевая, опускается к его южной части (Кошкина, Гавриков, 2024). В данных ERA5 бора также была отмечена, однако ее начало произошло на несколько дней позже, она наблюдалась только в южной части региона и была менее интенсивной. Вероятно, такое различие связано с более низким разрешением и гидростатической основой численной модели реанализа (рисунок 6). Синим прямоугольником на рисунке 6б обозначен полигон для спектральной оценки качества воспроизведения приповерхностного ветра (рисунок 6а).

Из рисунка 6 видно, что по аналогии с WRF, в результатах нейросетевого масштабирования четко выделяется новоземельская бора как над сушей, так и по структуре ветра над прибрежной частью Баренцева моря. Кроме того, нейросетевой метод сдвигает распределение скорости ветра в прибрежной части Карского моря в сторону WRF. Кривая спектральной плотности по результатам нейросетевого масштабирования сместилась от данных ERA5 к данным WRF, особенно в высокочастотной области.

Далее проводится оценка ветрового волнения, смоделированного при замене граничных атмосферных условий ветрового моделирования. В настоящей работе для оценки качества нейросетевого масштабирования рассматривается модель WAVEWATCH III версии 6.07.1 (WW3). WW3 основана на решении сеточными методами уравнения баланса спектрального волнового действия в приближении фазового

осреднения (WW3DG, 2019). В прогностическом эксперименте для оценки качества нейросетевого масштабирования в качестве граничных атмосферных условий волновой модели подставляются интерполированные данные по скорости ветра из реанализа ERA5, из высокоразрешенной негидростатической атмосферной модели WRF и из результатов нейросетевой статистической модели. Сетки модели WW3 и атмосферных данных совпадают.




Рис. 6 – а) Сравнение эпизода новоземельской боры с 14 по 17 февраля 2022 г. по пространственной спектральной плотности кинетической энергии ветра (синий – реанализ ERA5, зеленый – WRF, желтый – результат нейросетевого масштабирования). Поля приповерхностного ветра над Новой Землей 08:00 UTC 15.02.2022 г.: б) ERA5; в) масштабирование нейросетью; г) WRF

Результаты волнового моделирования сравниваются с натурными измерениями двумя акустическими доплеровскими профилографами течений ADCP, места расположения которых указаны на рисунке 7.




Рис. 7 – Расположение акустических доплеровских профилографов течений ADCP

Акустические доплеровские профилографы течений ADCP определяли параметры волнения в период с 18 октября по 11 декабря 2020 г. (ADCP1) и с 18 по 31 октября 2020 г. (ADCP2) с частотой 10 минут. Данные по смоделированному ветровому волнению определяются с временным разрешением 1 час. Для каждого из 2 профилографов были посчитаны среднеквадратическая ошибка, смещение и коэффициент корреляции с 95 % доверительными интервалами. Результаты показаны в таблице 4.

Табл. 4 – Значения среднеквадратической ошибки RMSE, коэффициента корреляции R и смещения B смоделированной значимой высоты ветрового волнения в сравнении с измерениями на ADCP. ДИ – 95 % доверительный интервал

Модель	Метрика	ADCP1		ADCP2	
			ДИ		ДИ
ERA5	RMSE, м	0,465	[0,458; 0,472]	0,272	[0,249; 0,293]
	R	0,877	[0,871; 0,882]	0,835	[0,798; 0,866]
	B, м	–0,361	[–0,368; –0,354]	–0,176	[–0,198; –0,152]
WRF	RMSE, м	0,399	[0,393; 0,406]	0,319	[0,291; 0,348]
	R	0,879	[0,874; 0,884]	0,792	[0,747; 0,830]
	B, м	–0,268	[–0,274; –0,262]	–0,198	[–0,227; –0,170]
Нейросеть	RMSE, м	0,417	[0,410; 0,424]	0,311	[0,286; 0,334]
	R	0,882	[0,877; 0,887]	0,816	[0,775; 0,850]
	B, м	–0,298	[–0,305; –0,292]	–0,203	[–0,231; –0,176]

Как показывает таблица 4, на обоих профилографах значимая высота волнения, смоделированная нейросетевым методом и негидростатическим атмосферным моделированием WRF, показывает сопоставимые значения по всем трем метрикам сравнения с натурными измерениями. Значимая высота ветрового волнения, полученная

моделированием при использовании атмосферных граничных условий, рассчитанных разработанной нейросетевой моделью и WRF, демонстрирует отклонение не более чем на 5 % в мере среднеквадратического отклонения.

Заключение

Настоящее исследование было направлено на разработку, реализацию и верификацию нейросетевой модели статистического масштабирования полей приповерхностного ветра в регионе Баренцева и Карского морей. В качестве основной архитектуры была выбрана глубокая сеть с пропускными соединениями, зарекомендовавшая себя как перспективный инструмент в задачах пространственной детализации полей ветра.

Рассматриваются подходы к оценке качества масштабирования ветра, учитывающие пространственную структуру полей, основанные на идентификации и отслеживании когерентных атмосферных структур.

Для выделения и отслеживания вихрей в данных по ветру над Баренцевым и Карским морями применен Rortex-критерий совместно с алгоритмом кластеризации DBSCAN, что позволило построить количественные характеристики жизненного цикла когерентных вихревых структур.

Использование архитектуры с пропускными соединениями обеспечило восстановление пространственной структуры ветрового поля при статистическом масштабировании. Результаты демонстрируют точность воспроизведения динамических характеристик приповерхностного ветра на уровне негидростатического моделирования, а также существенное улучшение в сравнении с билинейной интерполяцией данных глобального реанализа. Разработанная модель показала высокую вычислительную эффективность, превосходя по быстродействию высокоразрешенное негидростатическое моделирование более, чем в 50 раз, при этом приближаясь к нему по качеству воспроизведения характеристик вихревых структур. Проведенный анализ ветрового волнения на основе масштабированных полей ветра подтвердил реалистичность полученных результатов. Кроме того, выявлено, что нейросетевая модель существенно снижает систематические ошибки ERA5 в оценке количества мезомасштабных когерентных структур, обеспечивая отклонение от моделирования WRF на уровне не более 3 %.

Таким образом, предложенный подход статистического масштабирования на основе сверточной нейросетевой архитектуры с пропускными соединениями представляет собой эффективный инструмент повышения пространственного разрешения атмосферных данных в арктическом регионе.

Благодарности. Разработка нейросетевой статистической модели масштабирования приповерхностного ветра над Баренцевым и Карским морями выполнена в рамках Соглашения № 075-03-2025-662 от 17.01.2025 Московского физико-технического института. Оценка динамики атмосферы по результатам нейросетевого масштабирования проведена при поддержке государственного задания FMWE-2024-0017 Института океанологии им. П. П. Ширшова РАН.

Список литературы

1. Гавриков А. В. Оценка качества воспроизведения осадков над Северной Атлантикой и влияния гидростатической аппроксимации в атмосферной модели WRF-ARW // Океанология. 2017. Т. 57. № 2. С. 261–267.
2. Гидрометеорология и гидрохимия морей СССР. Т. 1: Баренцево море. Вып. 1: Гидрометеорологические условия. Л.: Гидрометиздат, 1990. 280 с.
3. Ефимов В. В., Комаровская О. И. Новоземельская бора: анализ и численное моделирование // Известия Российской академии наук. Физика атмосферы и океана. 2018. Т. 54. № 1. С. 83–96. <https://doi.org/10.7868/S0003351518010099>.
4. Золотокрылин А. Н., Титкова Т. Б., Михайлов А. Ю. Климатические вариации арктического фронта и ледовитости Баренцева моря зимой // Лед и Снег. 2014. Т. 54. № 1. С. 85–90. <https://doi.org/10.15356/2076-6734-2014-1-85-90>.
5. Кошкина В. С., Гавриков А. В. Исследование применимости методов идентификации когерентных вихревых структур в модельных экспериментах // Океанологические исследования. 2024. Т. 52. № 4. С. 90–107.
6. Кошкина В. С., Гавриков А. В., Тилинина Н. Д. Автоматическая идентификация новоземельской боры // Океанологические исследования. 2024. Т. 52. № 4. С. 74–89. [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).5](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).5).
7. Криницкий М. А., Тилинина Н. Д., Резвов В. Ю., Суслов А. И., Голиков В. А., Ежова Е. А., Вереземская П. С., Гавриков А. В. Методы машинного обучения в исследованиях океана и атмосферы. М.: ООО «Сам Полиграфист», 2024. 170 с.
8. Монин А. С. Статистическая гидромеханика. Механика турбулентности. Ч. 1. 1965. 639 с.
9. Никитин М. А., Ривин Г. С., Розинкина И. А., Чумаков М. М. Использование прогностической системы COSMO-Ru для исследования свойств полярных циклонов: эпизод 25–27 марта 2014 года // Труды Гидрометцентра России. 2016. Вып. 361. С. 128–145.
10. Петриченко С. А., Калмыкова О. В., Козлов С. В., Кулижникова Л. К. Использование композиции индексов конвективной неустойчивости для прогноза зарождения полярных мезоциклонов в Арктическом регионе России // Российская Арктика. 2023. Т. 5. № 2. С. 54–64.
11. Резвов В. Ю., Криницкий М. А., Тилинина Н. Д. Поточечные и комплексные меры качества в исследованиях атмосферы и океана: обзор методов и подходов // Океанологические исследования. 2024. Т. 52. № 4. С. 193–223. [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).10](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).10).
12. Суркова Г. В., Крылов А. А. Изменения средних и экстремальных скоростей ветра в Арктике в конце XXI века // Арктика и Антарктика. 2018. № 3. С. 26–36. <https://doi.org/10.7256/2453-8922.2018.3.27395>.
13. Шестакова А. А. Новоземельская бора: подветренные характеристики и структура натекающего потока // Арктика и Антарктика. 2016. № 2. С. 86–98. <https://doi.org/10.7256/2453-8922.2016.2.21479>.
14. Davis C., Brown B., Bullock R. Object-based verification of precipitation forecasts. Part I: Methodology and application to mesoscale rain areas // Monthly Weather Review. 2006. Vol. 134. No. 7. P. 1772–1784. <https://doi.org/10.1175/MWR3145.1>.
15. Dong H., Cao S., Takemi T., Ge Y. WRF simulation of surface wind in high latitudes // Journal of Wind Engineering and Industrial Aerodynamics. 2018. Vol. 179. P. 287–296. <https://doi.org/10.1016/j.jweia.2018.06.009>.
16. Gavrikov A. V., Gulev S. K. The North Atlantic High-Resolution Regional Climate Model Experiment for Oceanic and Atmospheric Applications // Oceanology. 2020. Vol. 60. P. 725–727. <https://doi.org/10.1134/S0001437020060041>.

17. *Hersbach H., Bell B., Berrisford P., Hirahara S., Horányi A., Muñoz-Sabater J., Nicolas J., Peubey C., Radu R., Schepers D., Simmons A., Soci C., Abdalla S., Abellan X., Balsamo G., Bechtold P., Biavati G., Bidlot J., Bonavita M., De Chiara G., Dahlgren P., Dee D., Diamantakis M., Dragani R., Flemming J., Forbes R., Fuentes M., Geer A., Haimberger L., Healy S., Hogan R. J., Hólm E., Janisková M., Keeley S., Laloyaux P., Lopez P., Lupu C., Radnoti G., de Rosnay P., Rozum I., Vamborg F., Villaume S., Thépaut J.-N.* The ERA5 global reanalysis // *Quarterly Journal of the Royal Meteorological Society*. 2020. Vol. 146. No. 730. P. 1999–2049. <https://doi.org/10.1002/qj.3803>.
18. *Höhlein K., Kern M., Hewson T., Westermann R.* A comparative study of convolutional neural network models for wind field downscaling // *Meteorological Applications*. 2020. Vol. 27. Article e1961. <https://doi.org/10.1002/met.1961>.
19. *Hong S. Y., Lim J. O. J.* The WRF single-moment 6-class microphysics scheme (WSM6) // *Asia-Pacific Journal of Atmospheric Sciences*. 2006. Vol. 42. No. 2. P. 129–151.
20. *Iacono M. J., Delamere J. S., Mlawer E. J., Shephard M. W., Clough S. A., Collins W. D.* Radiative forcing by long-lived greenhouse gases: Calculations with the AER radiative transfer models // *Journal of Geophysical Research*. 2008. Vol. 113. D13103. <https://doi.org/10.1029/2008JD009944>.
21. *Jagannathan K., Jones A. D., Ray I.* The making of a metric: Coproducing decision-relevant climate science // *Bulletin of the American Meteorological Society*. 2020. Vol. 102. No. 8. P. 1–33. <https://doi.org/10.1175/BAMS-D-19-0296.1>.
22. *Janjić Z. I.* The Step-Mountain Eta Coordinate Model: Further Developments of the Convection, Viscous Sublayer, and Turbulence Closure Schemes // *Monthly Weather Review*. 1994. Vol. 122. P. 927–945. [https://doi.org/10.1175/1520-0493\(1994\)122<0927:TSMECM>2.0.CO;2](https://doi.org/10.1175/1520-0493(1994)122<0927:TSMECM>2.0.CO;2).
23. *Kain J. S.* The Kain–Fritsch Convective Parameterization: An Update // *Journal of Applied Meteorology and Climatology*. 2004. Vol. 43. P. 170–181. [https://doi.org/10.1175/1520-0450\(2004\)043<0170:TKCPAU>2.0.CO;2](https://doi.org/10.1175/1520-0450(2004)043<0170:TKCPAU>2.0.CO;2).
24. *Kingma D. P., Ba J.* Adam: A method for stochastic optimization: Preprint arXiv:1412.6980. 2014.
25. *Kolář V., Moses P., Šístek J.* Local corotation of line segments and vortex identification // In *Proceedings of the Seventeenth Australasian Fluid Mechanics Conference*. 2010. P. 251–254.
26. *Koshkina V. S., Gavrikov A. V., Gulev S. K.* Methods of identifying atmospheric mesoscale coherent structures over the North Atlantic // *Oceanology*. 2023. Vol. 63. No. Suppl. 1. P. S101–S110. <https://doi.org/10.1134/S000143702307007X>.
27. *Krinitskiy M., Grashchenkov K., Tilinina N., Gulev S.* Tracking of atmospheric phenomena with artificial neural networks: a supervised approach // *Procedia Computer Science*. 2021. Vol. 186. P. 403–410. <https://doi.org/10.1016/j.procs.2021.04.209>.
28. *Liu C., Wang Y., Yang Y., et al.* New omega vortex identification method // *Sci. China Phys. Mech. Astron.* 2016. Vol. 59. P. 684711. <https://doi.org/10.1007/s11433-016-0022-6>.
29. *Liu C., Gao Y., Tian S., Dong X.* Rortex – A new vortex vector definition and vorticity tensor and vector decompositions // *Physics of Fluids*. 2018. Vol. 30. No. 3. P. 035103. <https://doi.org/10.1063/1.5023001>.
30. *Moreno-Chamarro E., Arsouze T., Acosta M., Bretonnière P.-A., Castrillo M., Ferrer E., Frigola A., Kuznetsova D., Martin-Martinez E., Ortega P., Palomas S.* The very-high-resolution configuration of the EC-Earth global model for HighResMIP // *Geoscientific Model Development*. 2025. Vol. 18. P. 461–482. <https://doi.org/10.5194/gmd-18-461-2025>.
31. *Nakanishi M., Niino H.* Development of an improved turbulence closure model for the atmospheric boundary layer // *Journal of the Meteorological Society of Japan*. Ser. II. 2009. Vol. 87. No. 5. P. 895–912. <https://doi.org/10.2151/jmsj.87.895>.

32. Neu U., Akperov M. G., Bellenbaum N., Benestad R., Blender R., Caballero R., Coccozza A., Dacre H. F., Feng Y., Fraedrich K., Grieger J., Gulev S., Hanley J., Hewson T., Inatsu M., Keay K., Kew S. F., Kindem I., Leckebusch G. C., Liberato M. L. R., Lionello P., Mokhov I. I., Pinto J. G., Raible C. C., Reale M., Rudeva I., Schuster M., Simmonds I., Sinclair M., Sprenger M., Tilinina N. D., Trigo I. F., Ulbrich S., Ulbrich U., Wang X. L., Wernli H. IMILAST: A Community Effort to Intercompare Extratropical Cyclone Detection and Tracking Algorithms // *Bulletin of the American Meteorological Society*. 2013. Vol. 94. No. 4. P. 529–547. <https://doi.org/10.1175/BAMS-D-11-00154.1>.
33. Oberto E., Milelli M., Pasi F., Gozzini B. Intercomparison of two meteorological limited area models for quantitative precipitation forecast verification // *Natural Hazards and Earth System Sciences*. 2012. Vol. 12. P. 591–606. <https://doi.org/10.5194/nhess-12-591-2012>.
34. Reed K. A., Goldenson N., Grotjahn R., Gutowski W. J., Jagannathan K., Jones A. D., Leung L. R., McGinnis S. A., Pryor S. C., Srivastava A. K., Ullrich P. A., Zarzycki C. M. Metrics as tools for bridging climate science and applications // *Wiley Interdisciplinary Reviews: Climate Change*. 2022. Vol. 13. No. 6. P. e799. <https://doi.org/10.1002/wcc.799>.
35. Robinson S. et al. Coherent motions in the turbulent boundary layer // *Annual Review of Fluid Mechanics*. 1991. Vol. 23. No. 1. P. 601–639.
36. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* / Eds. Navab N., Hornegger J., Wells W., Frangi A. Cham: Springer, 2015. Lecture Notes in Computer Science, Vol. 9351. https://doi.org/10.1007/978-3-319-24574-4_28.
37. Schubert E., Sander J., Ester M., Kriegel H. P., Xu X. DBSCAN Revisited, Revisited: Why and How You Should (Still) Use DBSCAN // *ACM Trans. Database Syst.* 2017. Vol. 42. No. 3. Article 19. <https://doi.org/10.1145/3068335>.
38. Skamarock W., Klemp J., Dudhia J., Gill D. O., Liu Z., Berner J., Wang W., Powers J. G., Duda M. G., Barker D., Huang X.-Y. A Description of the Advanced Research WRF Model Version 4.1. 2019. <https://doi.org/10.5065/1dfh-6p97>.
39. Stoll P. J., Valkonen T. M., Graversen R. G., Noer G. A well-observed polar low analysed with a regional and a global weather-prediction model // *Quarterly Journal of the Royal Meteorological Society*. 2020. Vol. 146. P. 1740–1767. <https://doi.org/10.1002/qj.3764>.
40. Turner J. Polar Lows: Mesoscale Weather Systems in the Polar Regions. Cambridge: Cambridge University Press, 2003. 612 p.
41. Verezemskaya P., Tilinina N., Gulev S., Renfrew I. A., Lazzara M. Southern Ocean mesocyclones and polar lows from manually tracked satellite mosaics // *Geophysical Research Letters*. 2017. Vol. 44. P. 7985–7993. <https://doi.org/10.1002/2017GL074053>.
42. The WAVEWATCH III Development Group (WW3DG). User manual and system documentation of WAVEWATCH III version 6.07.1 // <https://raw.githubusercontent.com/wiki/NOAA-EMC/WW3/files/manual.pdf> (дата обращения: 10.06.2024).
43. Zhou J., Adrian R. J., Balachandar S., Kendall T. Mechanisms for generating coherent packets of hairpin vortices in channel flow // *Journal of Fluid Mechanics*. 1999. Vol. 387. P. 353–396.

Статья поступила в редакцию 09.04.2025, одобрена к печати 28.06.2025.

Для цитирования: Реззов В. Ю., Криницкий М. А., Гавриков А. В. Оценка динамики атмосферы по результатам нейросетевого масштабирования полей приповерхностного ветра над Баренцевым и Карским морями // *Океанологические исследования*. 2025. № 53 (2). С. 149–175. [https://doi.ocean.ru/10.29006/1564-2291.JOR-2025.53\(2\).8](https://doi.ocean.ru/10.29006/1564-2291.JOR-2025.53(2).8).

ASSESSMENT OF ATMOSPHERIC DYNAMICS BASED ON NEURAL NETWORK DOWNSCALING OF NEAR-SURFACE WIND OVER THE BARENTS AND KARA SEAS

V. Yu. Rezvov^{1,2}, M. A. Krinitskiy^{1,2}, A. V. Gavrikov²

¹ *Moscow Institute of Physics and Technology,
9, Institutskiy per., Dolgoprudny, Moscow Region, 141701, Russia,
e-mail: rezvov.vyu@phystech.edu;*

² *Shirshov Institute of Oceanology, Russian Academy of Sciences,
36, Nakhimovskiy prospekt, Moscow, 117997, Russia*

This study explores the use of deep learning for downscaling of near-surface wind over the Barents and Kara Seas, utilizing deep artificial neural networks with skip connections to increase spatial resolution while reducing computational costs compared to non-hydrostatic modeling. The low-resolution input data is sourced from the global atmospheric reanalysis ERA5, while high-resolution data is obtained using the Weather Research and Forecasting (WRF) model. The results of neural network downscaling are compared with the baseline from bilinear interpolation. The neural network model improves the distribution of mesocyclone life cycle parameters, aligning them closer to the high-resolution modeling data, and outperforms bilinear interpolation by 50 times in terms of speed. The height of wind-induced waves, obtained using boundary conditions from the neural network model instead of non-hydrostatic modeling, shows similar values to those obtained with non-hydrostatic modeling. The developed neural network model shows a deviation of less than 3 % from high-resolution dynamic modeling in terms of the number of mesoscale structures.

Keywords: downscaling, near-surface wind, polar mesocyclones, Novaya Zemlya bora, artificial neural networks, machine learning, deep learning, wind-induced waves

Acknowledgements: The development of the neural network statistical model for near-surface wind downscaling over the Barents and Kara Seas was carried out under Agreement No. 075-03-2025-662 dated January 17, 2025, with the Moscow Institute of Physics and Technology (MIPT). The assessment of atmospheric dynamics based on the results of the neural network downscaling was supported by the state assignment FMWE-2024-0017 of the Shirshov Institute of Oceanology of the Russian Academy of Sciences (RAS).

References

1. Davis, C., B. Brown, and R. Bullock, 2006: Object-based verification of precipitation forecasts. Part I: Methodology and application to mesoscale rain areas. *Monthly Weather Review*, **134** (7), 1772–1784, <https://doi.org/10.1175/MWR3145.1>.
2. Dong, H., S. Cao, T. Takemi, and Y. Ge, 2018: WRF simulation of surface wind in high latitudes. *Journal of Wind Engineering and Industrial Aerodynamics*, **179**, 287–296, <https://doi.org/10.1016/j.jweia.2018.06.009>.
3. Efimov, V. V. and O. I. Komarovskaya, 2018: Novozemelskaya bora: analiz i chislennoye modelirovaniye (Novaya Zemlya Bora: Analysis and Numerical Modeling). *Izvestiya Rossiiskoi akademii nauk. Fizika atmosfery i okeana*, **54** (1), 83–96, <https://doi.org/10.7868/S0003351518010099>.

4. Gavrikov, A., 2017: Estimating the reproduction quality of precipitation over the North Atlantic and influence of the hydrostatic approximation in the WRF–ARW atmospheric model. *Oceanology*, **57** (2), 232–238, <https://doi.org/10.1134/S0001437017020047>.
5. Gavrikov, A. V. and S. K. Gulev, 2020: The North Atlantic High-Resolution Regional Climate Model Experiment for Oceanic and Atmospheric Applications. *Oceanology*, **60**, 725–727, <https://doi.org/10.1134/S0001437020060041>.
6. Hersbach, H., B. Bell, P. Berrisford, S. Hirahara, A. Horányi, J. Muñoz-Sabater, J. Nicolas, C. Peubey, R. Radu, D. Schepers, A. Simmons, C. Soci, S. Abdalla, X. Abellan, G. Balsamo, P. Bechtold, G. Biavati, J. Bidlot, M. Bonavita, G. De Chiara, P. Dahlgren, D. Dee, M. Diamantakis, R. Dragani, J. Flemming, R. Forbes, M. Fuentes, A. Geer, L. Haimberger, S. Healy, R. J. Hogan, E. Hólm, M. Janisková, S. Keeley, P. Laloyaux, P. Lopez, C. Lupu, G. Radnoti, P. de Rosnay, I. Rozum, F. Vamborg, S. Villaume, and J.-N. Thépaut, 2020: The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, **146** (730), 1999–2049, <https://doi.org/10.1002/qj.3803>.
7. Höhlein, K., M. Kern, T. Hewson, and R. Westermann, 2020: A comparative study of convolutional neural network models for wind field downscaling. *Meteorological Applications*, **27**, Article e1961, <https://doi.org/10.1002/met.1961>.
8. Hong, S. Y. and J. O. J. Lim, 2006: The WRF single-moment 6-class microphysics scheme (WSM6). *Asia-Pacific Journal of Atmospheric Sciences*, **42** (2), 129–151.
9. *Gidrometeorologiya i gidrokhimiya morey SSSR*. Barentsevo more, Vyp. 1. Gidrometeorologicheskie usloviya (Hydrometeorology and Hydrochemistry of the Seas of the USSR. Vol. 1. Barents Sea. Issue 1. Hydrometeorological Conditions), Leningrad, Gidrometeoizdat, 1990, 280 p.
10. Iacono, M. J., J. S. Delamere, E. J. Mlawer, M. W. Shephard, S. A. Clough, and W. D. Collins, 2008: Radiative forcing by long-lived greenhouse gases: Calculations with the AER radiative transfer models. *Journal of Geophysical Research*, **113**, D13103, <https://doi.org/10.1029/2008JD009944>.
11. Jagannathan, K., A. D. Jones, and I. Ray, 2020: The making of a metric: Coproducing decision-relevant climate science. *Bulletin of the American Meteorological Society*, **102** (8), 1–33, <https://doi.org/10.1175/BAMS-D-19-0296.1>.
12. Janjić, Z. I., 1994: The Step-Mountain Eta Coordinate Model: Further Developments of the Convection, Viscous Sublayer, and Turbulence Closure Schemes. *Monthly Weather Review*, **122**, 927–945, [https://doi.org/10.1175/1520-0493\(1994\)122<0927:TSMECM>2.0.CO;2](https://doi.org/10.1175/1520-0493(1994)122<0927:TSMECM>2.0.CO;2).
13. Kain, J. S., 2004: The Kain–Fritsch Convective Parameterization: An Update. *Journal of Applied Meteorology and Climatology*, **43**, 170–181, [https://doi.org/10.1175/1520-0450\(2004\)043<0170:TKCPAU>2.0.CO;2](https://doi.org/10.1175/1520-0450(2004)043<0170:TKCPAU>2.0.CO;2).
14. Kingma, D. P. and J. Ba, 2014: *Adam: A method for stochastic optimization*. Preprint arXiv:1412.6980.
15. Kolář, V., P. Moses, and J. Šístek, 2010: Local corotation of line segments and vortex identification. In: *Proceedings of the Seventeenth Australasian Fluid Mechanics Conference*, 251–254.
16. Koshkina, V. S., A. V. Gavrikov, and S. K. Gulev, 2023: Methods of identifying atmospheric mesoscale coherent structures over the North Atlantic. *Oceanology*, **63** (Suppl. 1), S101–S110, <https://doi.org/10.1134/S000143702307007X>.
17. Koshkina, V. S. and A. V. Gavrikov, 2024: Issledovanie primenimosti metodov identifikatsii kogerentnykh vikhrvykh struktur v modelnykh eksperimentakh (Study of the Applicability of Methods for Identifying Coherent Vortex Structures in Model Experiments). *Journal of Oceanological Research*, **52** (4), 90–107.

18. Koshkina, V. S., A. V. Gavrikov, and N. D. Tilinina, 2024: Avtomaticheskaya identifikatsiya novozemelskoy bory (Automatic Identification of the Novaya Zemlya Bora). *Journal of Oceanological Research*, **52** (4), 74–89, [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).5](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).5).
19. Krinitskiy, M., K. Grashchenkov, N. Tilinina, and S. Gulev, 2021: Tracking of atmospheric phenomena with artificial neural networks: a supervised approach. *Procedia Computer Science*, **186**, 403–410, <https://doi.org/10.1016/j.procs.2021.04.209>.
20. Krinitskiy, M. A., N. D. Tilinina, V. Y. Rezvov, A. I. Suslov, V. A. Golikov, E. A. Yezhova, P. S. Verezemskaya, and A. V. Gavrikov, 2024: *Metody mashinnogo obucheniya v issledovaniyakh okeana i atmosfery (Methods of Machine Learning in Ocean and Atmospheric Research)*. Moscow, Sam Poligrafist, 170 p.
21. Liu, C., Y. Wang, and Y. Yang et al., 2016: New omega vortex identification method. *Science China Physics, Mechanics & Astronomy*, **59**, 684711, <https://doi.org/10.1007/s11433-016-0022-6>.
22. Liu, C., Y. Gao, S. Tian, and X. Dong, 2018: Rortex – A new vortex vector definition and vorticity tensor and vector decompositions. *Physics of Fluids*, **30** (3), 035103, <https://doi.org/10.1063/1.5023001>.
23. Monin, A. S., 1965: *Statisticheskaya gidromekhanika. Mekhanika turbulentnosti*. Ch. 1. (Statistical Hydromechanics. Mechanics of Turbulence. Part 1). 639 p.
24. Moreno-Chamarro, E., T. Arsouze, M. Acosta, P.-A. Bretonnière, M. Castrillo, E. Ferrer, A. Frigola, D. Kuznetsova, E. Martin-Martinez, P. Ortega, and S. Palomas, 2025: The very-high-resolution configuration of the EC-Earth global model for HighResMIP. *Geoscientific Model Development*, **18**, 461–482, <https://doi.org/10.5194/gmd-18-461-2025>.
25. Nakanishi, M., and H. Niino, 2009: Development of an improved turbulence closure model for the atmospheric boundary layer. *Journal of the Meteorological Society of Japan*. Series II, **87** (5), 895–912, <https://doi.org/10.2151/jmsj.87.895>.
26. Neu, U., M. G. Akperov, N. Bellenbaum, R. Benestad, R. Blender, R. Caballero, A. Coccozza, H. F. Dacre, Y. Feng, K. Fraedrich, J. Grieger, S. Gulev, J. Hanley, T. Hewson, M. Inatsu, K. Keay, S. F. Kew, I. Kindem, G. C. Leckebusch, M. L. R. Liberato, P. Lionello, I. I. Mokhov, J. G. Pinto, C. C. Raible, M. Reale, I. Rudeva, M. Schuster, I. Simmonds, M. Sinclair, M. Sprenger, N. D. Tilinina, I. F. Trigo, S. Ulbrich, U. Ulbrich, X. L. Wang, and H. Wernli, 2013: IMILAST: A Community Effort to Intercompare Extratropical Cyclone Detection and Tracking Algorithms. *Bulletin of the American Meteorological Society*, **94** (4), 529–547, <https://doi.org/10.1175/BAMS-D-11-00154.1>.
27. Nikitin, M. A., G. S. Rivin, I. A. Rozinkina, and M. M. Chumakov, 2016: Ispol'zovanie prognosticheskoy sistemy COSMO-Ru dlya issledovaniya svoystv polyarnykh tsiklonov: epizod 25–27 marta 2014 goda (Using the COSMO-Ru Forecast System to Study the Properties of Polar Cyclones: Episode of March 25–27, 2014). *Trudy Gidromettsentra Rossii*, **361**, 128–145.
28. Oberto, E., M. Milelli, F. Pasi, and B. Gozzini, 2012: Intercomparison of two meteorological limited area models for quantitative precipitation forecast verification. *Natural Hazards and Earth System Sciences*, **12**, 591–606, <https://doi.org/10.5194/nhess-12-591-2012>.
29. Petrichenko, S. A., O. V. Kalmykova, S. V. Kozlov, and L. K. Kulizhnikova, 2023: Ispolzovanie kompozitsii indeksov konvektivnoy neustoychivosti dlya prognoza zarozhdeniya polyarnykh mezotsiklonov v Arkticheskom regione Rossii (Use of Composite Indices of Convective Instability for Predicting the Formation of Polar Mesocyclones in the Russian Arctic Region). *Rossiyskaya Arktika*, **5** (2), 54–64.
30. Reed, K. A., N. Goldenson, R. Grotjahn, W. J. Gutowski, K. Jagannathan, A. D. Jones, L. R. Leung, S. A. McGinnis, S. C. Pryor, A. K. Srivastava, P. A. Ullrich, and C. M. Zarzycki,

- 2022: Metrics as tools for bridging climate science and applications. Wiley Interdisciplinary Reviews: Climate Change, **13** (6), e799, <https://doi.org/10.1002/wcc.799>.
31. Rezvov, V. Yu., M. A. Krinitskiy, and N. D. Tilinina, 2024: Potocechnye i kompleksnye mery kachestva v issledovaniyakh atmosfery i okeana: obzor metodov i podkhodov (Point and Comprehensive Quality Measures in Atmosphere and Ocean Studies: Review of Methods and Approaches). *Journal of Oceanological Research*, **52** (4), 193–223, [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).10](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).10).
 32. Robinson, S., et al., 1991: Coherent motions in the turbulent boundary layer. *Annual Review of Fluid Mechanics*, **23** (1), 601–639.
 33. Ronneberger, O., P. Fischer, and T. Brox, 2015: U-Net: Convolutional Networks for Biomedical Image Segmentation. In Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Eds. N. Navab, J. Hornegger, W. Wells, and A. Frangi, Springer, Cham, *Lecture Notes in Computer Science*, 9351, https://doi.org/10.1007/978-3-319-24574-4_28.
 34. Schubert, E., J. Sander, M. Ester, H. P. Kriegel, and X. Xu, 2017: DBSCAN Revisited, Revisited: Why and How You Should (Still) Use DBSCAN. *ACM Transactions on Database Systems*, **42** (3), Article 19, <https://doi.org/10.1145/3068335>.
 35. Shestakova, A. A., 2016: Novozemel'skaya bora: podvetrennye kharakteristiki i struktura natekayushchego potoka (Novaya Zemlya Bora: Leeward Characteristics and Structure of the Incoming Flow). *Arktika i Antarktika*, **2**, 86–98, <https://doi.org/10.7256/2453-8922.2016.2.21479>.
 36. Skamarock, W., J. Klemp, J. Dudhia, D. O. Gill, Z. Liu, J. Berner, W. Wang, J. G. Powers, M. G. Duda, D. Barker, and X.-Y. Huang, 2019: A Description of the Advanced Research WRF Model Version 4.1, <https://doi.org/10.5065/1dfh-6p97>.
 37. Stoll, P. J., T. M. Valkonen, R. G. Graversen, and G. Noer, 2020: A well-observed polar low analysed with a regional and a global weather-prediction model. *Quarterly Journal of the Royal Meteorological Society*, **146**, 1740–1767, <https://doi.org/10.1002/qj.3764>.
 38. Surkova, G. V., and A. A. Krylov, 2018: Izmeneniya srednikh i ekstremal'nykh skorostei vetra v Arktike v kontse XXI veka (Changes in Average and Extreme Wind Speeds in the Arctic by the End of the 21st Century). *Arktika i Antarktika*, **3**, 26–36, <https://doi.org/10.7256/2453-8922.2018.3.27395>.
 39. Turner, J., 2003: *Polar Lows: Mesoscale Weather Systems in the Polar Regions*. Cambridge University Press, Cambridge, 612 p.
 40. Verezemskaya, P., N. Tilinina, S. Gulev, I. A. Renfrew, and M. Lazzara, 2017: Southern Ocean mesocyclones and polar lows from manually tracked satellite mosaics. *Geophysical Research Letters*, **44**, 7985–7993, <https://doi.org/10.1002/2017GL074053>.
 41. The WAVEWATCH III Development Group (WW3DG). User manual and system documentation of WAVEWATCH III version 6.07.1. <https://raw.githubusercontent.com/wiki/NOAA-EMC/WW3/files/manual.pdf>, (last accessed in 10.06.2024).
 42. Zhou, J., R. J. Adrian, S. Balachandar, and T. Kendall, 1999: Mechanisms for generating coherent packets of hairpin vortices in channel flow. *Journal of Fluid Mechanics*, **387**, 353–396.
 43. Zolotokrylin, A. N., T. B. Titkova, and A. Yu. Mikhailov, 2014: Klimaticheskie variatsii arkticheskogo fronta i ledovitosti Barentseva morya zimoi (Climatic Variations of the Arctic Front and Ice Cover in the Barents Sea in Winter). *Led i Sneg*, **54** (1), 85–90, <https://doi.org/10.15356/2076-6734-2014-1-85-90>.

Submitted 09.04.2025, accepted 28.06.2025.

For citation: Rezvov, V. Yu., M. A. Krinitskiy, and A. V. Gavrikov, 2025: Assessment of atmospheric dynamics based on neural network downscaling of near-surface wind over the Barents and Kara Seas. *Journal of Oceanological Research*, **53** (2), 149–175, [https://doi.ocean.ru/10.29006/1564-2291.JOR-2025.53\(2\).8](https://doi.ocean.ru/10.29006/1564-2291.JOR-2025.53(2).8).