

## ПРЕДВЫЧИСЛЕНИЕ ЛЕДОВЫХ УСЛОВИЙ ДЛЯ ОБЕСПЕЧЕНИЯ ХОЗЯЙСТВЕННОЙ ДЕЯТЕЛЬНОСТИ В МОРЯХ РОССИЙСКОЙ АРКТИКИ С ПОМОЩЬЮ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ

Н. О. Никитин<sup>1</sup>, Ю. И. Борисова<sup>4</sup>, Я. В. Аксенкин<sup>1</sup>, К. Башкова<sup>1</sup>, Е. И. Луценко<sup>1</sup>,  
А. В. Калюжная<sup>1</sup>, Д. О. Якимушкин<sup>2</sup>, А. М. Котилевская<sup>2</sup>, Т. Н. Верташ<sup>2</sup>,  
А. А. Колюбакин<sup>3</sup>, Е. С. Багорьян<sup>2</sup>, А. В. Бухановский<sup>1</sup>

<sup>1</sup> Исследовательский центр «Сильный ИИ в промышленности», Университет ИТМО (Санкт-Петербург, Российская Федерация)

<sup>2</sup> ООО «Арктический научный центр» (Москва, Российская Федерация)

<sup>3</sup> ООО «РН-Эксплорейшн» (Москва, Российская Федерация)

<sup>4</sup> Лаборатория композитного искусственного интеллекта, Университет ИТМО (Санкт-Петербург, Российская Федерация)

### Для цитирования

Никитин Н. О., Борисова Ю. И., Аксенкин Я. В. и др. Предвычисление ледовых условий для обеспечения хозяйственной деятельности в морях российской Арктики с помощью методов глубокого обучения // Арктика: экология и экономика. — 2025. — Т. 15, № 1. — С. 119—130. — DOI: 10.25283/2223-4594-2025-1-119-130.

Статья поступила в редакцию 4 декабря 2024 г.

*Представлена технология предвычисления ледовых условий в морях российской Арктики для решения прогностических задач в сеточной постановке для заданной локальной акватории. Технология основана на применении моделей глубокого обучения в виде сверточных нейронных сетей. Она позволяет решать задачи долгосрочного предвычисления ледовых условий (сплоченности и толщины) с заданным временным и пространственным разрешением. Экспериментальные исследования по оценке качества прогнозирования сплоченности льда подтвердили эффективность ансамблевого моделирования по сравнению с одиночными моделями, а также с существующими прогнозами (SEAS5). Предложенный подход превзошел по качеству глобальную прогностическую систему на основе глубокого обучения IceNet, обладая при этом меньшей вычислительной сложностью.*

**Ключевые слова:** Северный морской путь, ледовые условия, прогнозная модель, искусственные нейронные сети.

### Введение

Задачи прогнозирования ледовых условий имеют многоплановый характер в зависимости от времени года и вида хозяйственной деятельности, осуществляемой на акватории арктических морей [1].

В период зимнего ледового плавания решаются задачи обеспечения навигации на Северном морском пути (СМП) крупнотоннажных судов арктического ледового класса, в том числе с поддерж-

кой атомных ледоколов. На первый план выходит необходимость оценки тяжести ледовых условий, которая часто ассоциируется с толщиной ледового покрова.

В летне-осенний период для движения судов низкого ледового класса необходимо картирование параметров ледовой обстановки, аналогичное представленному на картах, разрабатываемых Арктическим и антарктическим научно-исследовательским институтом (АНИИ) [2]. По данным дистанционного зондирования без наземных наблюдений имеется возможность определять сплоченность льдов, а также их возраст. Для качественного и безопасного выполнения сезонных морских работ, та-

© Никитин Н. О., Борисова Ю. И., Аксенкин Я. В., Башкова К., Луценко Е. И., Калюжная А. В., Якимушкин Д. О., Котилевская А. М., Верташ Т. Н., Колюбакин А. А., Багорьян Е. С., Бухановский А. В., 2025

ких как бурение или сейсмическая съемка, помимо ограничений на волнение моря крайне желательно полное отсутствие льда на акватории. То есть в терминологии ледовых карт [3] значения сплоченности летнего льда должны быть ниже 0,1. Поэтому важно точное картирование положения границы дрейфующих льдов, включая остаточные формы. В данной публикации рассматривается разработка системы предвычисления ледовой обстановки для обеспечения морских работ на акватории морей российской Арктики в безледный период.

В настоящее время ПАО «НК «Роснефть» осуществляет активную работу по проведению геофизической съемки и стратиграфического бурения в морях российской Арктики. Помимо производственного значения [4] результаты стратиграфического бурения также способствовали изучению фундаментальных вопросов геологии акваторий Северного Ледовитого океана, а также обоснованию внешней границы континентального шельфа России [5].

Для успешного планирования и выполнения сезонных работ по стратиграфическому бурению в «НК «Роснефть» была поставлена задача разработки системы предвычисления ледовой обстановки на акватории морей российской Арктики с большой заблаговременностью (от двух месяцев).

В вычислительной гидрометеорологии сейчас используется несколько подходов к ретроспективному и прогностическому моделированию ледовых условий (ЛУ) [6]:

- на основе сопряженных систем уравнений, описывающих состояние атмосферы, океана и ледового покрова;
- на основе физико-статистических моделей, опирающихся на долгосрочный период наблюдений.

При физическом моделировании динамики морского льда используются общие методы численного гидрометеорологического прогнозирования [7—9]. Такие модели, как NEMO-SEAICE [10], позволяют воспроизводить ледовые условия как на глобальном [11], так и на региональном [12] уровне. Учитывая универсальность численных моделей, следует отметить, что их адаптация к конкретной территории связана со значительными усилиями профильного специалиста и задействованием больших вычислительных ресурсов. Кроме того, методы численного гидрометеорологического прогнозирования требуют задания граничных и начальных условий, в связи с чем возникает необходимость в качественных исходных данных, которые не всегда доступны для целевой акватории [13]. Наиболее популярное решение на основе физического моделирования на данный момент — прогностическая система SEAS5 [14]. Это продукт Европейского центра среднесрочных прогнозов погоды, с 2017 г. ставший оперативным. Продукт содержит предсказание сплоченности льда с суточным временным разрешением и заблаговременностью прогноза семь месяцев. Система состоит из 51 предвычисления различными моделями, объединенными в ансамбль. Так как моделиро-

вание производится для всей Арктики (глобальная модель), в результатах данных предвычислений прибрежные участки акватории арктических морей воспроизводятся с большей ошибкой.

В настоящее время предложено большое количество методов прогнозирования характеристик льда на основе данных — от поиска простых линейных зависимостей [15; 16] и регрессионных моделей [17] до глубоких нейронных сетей [18]. К преимуществам простых регрессионных моделей можно отнести их интерпретируемость и прозрачность. Взаимосвязь между целевой переменной и дополнительными предикторами, такими как яркостная температура, концентрация водяного пара, величина нисходящего длинноволнового излучения, показателна и может быть физически обоснована. При этом зачастую они могут быть эффективно использованы для прогноза окна работ только на изолированном участке акватории, таком как юго-западная часть Карского моря, где для локаций осваиваемых геологических структур удалось построить эмпирическую модель оценки начала и продолжительности безледного периода [19]. Для охвата большой акватории общей регрессионной моделью необходимо уменьшить пространственное разрешение, что приводит к огрублению локальной динамики. Применение нейросетевых подходов на основе сверточных нейронных сетей позволяет избежать сокращения пространственного разрешения, так как операции свертки эффективно извлекают пространственные признаки из данных и значительно сокращают объем информации для обработки. Поэтому такие нейросетевые архитектуры популярны как для глобального моделирования ледовых условий, так и для региональных прогностических моделей [20]. Применяются также модели на основе метода поиска аналогов-прецедентов по набору признаков, характеризующих текущий сезон, как для арктических, так и для неарктических морей [21—23]. Их недостатком является невозможность воспроизведения новых, ранее не встречавшихся конфигураций кромки (что может быть актуальным требованием в связи с изменениями ледовитости арктических морей в современный климатический период [24; 25]).

В последние годы для задачи прогностического моделирования морского льда стали широко использоваться методы глубокого обучения на основе сверточных нейронных сетей, распространенным вариантом которых является архитектура U-Net [36].

В случае большого числа наблюдаемых параметров физико-статистические модели включают инструментарий машинного обучения. Однако применение таких подходов связано со сложностью выбора конкретных моделей и данных для их создания или обучения, а также объединения в ансамбли. В каких-то акваториях лучше работает одна конфигурация прогностической модели, в каких-то — другая; при этом априорно определить оптимальный вариант невозможно. Поэтому перспективным ви-

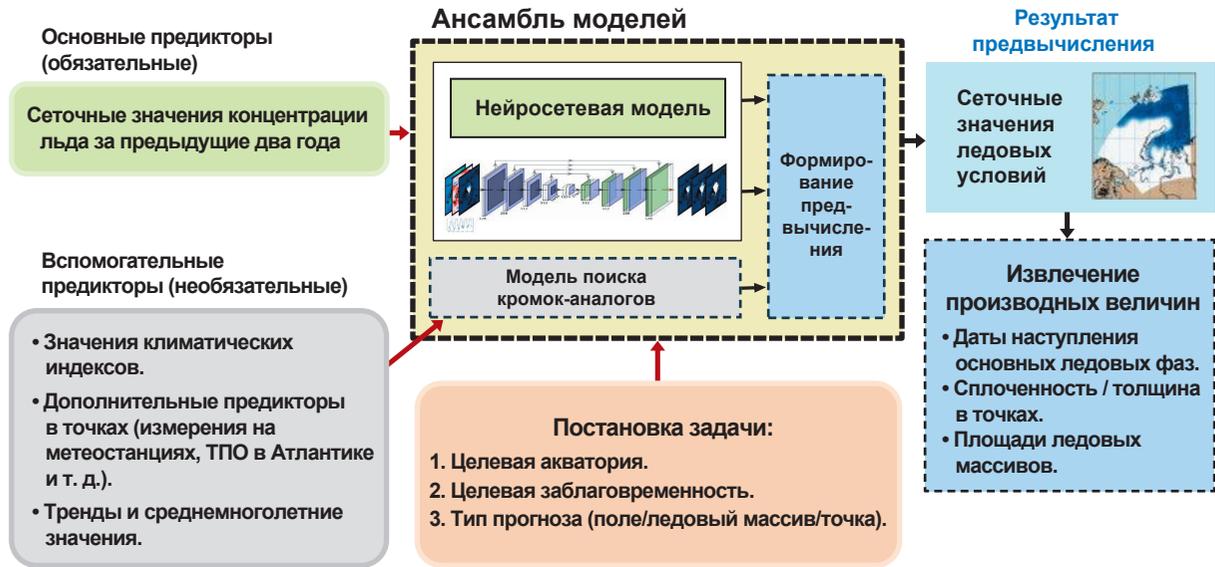


Рис. 1. Сценарий применения модели в оперативном режиме. Составлено авторами  
Fig. 1. Scenario for using the model in operational mode. Compiled by the authors

дится реализованный в данной работе подход, основанный на применении ансамблей [18] нейросетевых моделей глубокого обучения.

Одним из наиболее эффективных ансамблевых нейросетевых решений является IceNet — модель, которая предсказывает кромку льда по всей Арктике [36] (максимальная заблаговременность прогноза — шесть месяцев с месячным временным разрешением). Однако этот подход очень ресурсоемок (ансамбль включает 25 моделей) и требует получения большого числа оперативных данных.

Таким образом, имеющиеся решения являются ресурсоемкими и требующими большого объема данных, что делает их внедрение долгим и дорогостоящим. При этом при решении практических задач часто требуется не масштабный прогноз на всю Арктику, а быстрое предвычисление лишь на заданную акваторию, уточненное за счет недавно полученных данных. Переход к региональной постановке задачи позволяет также повысить качество моделирования ледовых условий [26].

Данная работа ставит целью проверить гипотезу о возможности создания быстро обучаемой и нересурсоемкой ансамблевой нейросетевой модели, использующей минимальное количество дополнительной информации, но сопоставимой при этом по качеству с лучшими решениями в сфере прогнозирования моделирования морского льда. Практический результат работы — модели для расчета ледовых условий и их программная реализация, способные решать поставленную задачу в том числе в автоматизированной постановке [27].

### Материалы и методы исследования

Основная идея предлагаемого решения — адаптируемость модели под конкретную акваторию без необходимости участия эксперта в ее конфигуриро-

вании. Пользователь указывает: (1) координаты границ акватории, (2) временную отсечку для начала предвычисления ледовых условий и заблаговременность прогноза, (3) временное и пространственное разрешение прогноза.

В качестве архитектуры модели используется сверточная нейронная сеть (Convolutional Neural Network — CNN) с архитектурой кодировщика-декодировщика. Она обладает сравнительно невысокой ресурсоемкостью — содержит всего пять слоев свертки и пять слоев транспонированной свертки. Динамическая генерация структуры слоев различных размерностей входных данных позволяет модулю быстро подстраиваться под новые типы данных и делает его применение достаточно гибким как для задач в специфичных постановках, так и для большого количества экспериментов с изменяющимися заблаговременностями прогноза.

На этапе формирования обучающей выборки используется весь доступный период продукта OSISAF [28] (с 1990 г.). «Ocean and Sea Ice Satellite Application Facility» — реанализ ледовых параметров норвежского и датского метеорологических институтов, содержащий информацию о концентрации льда. Выборка формируется для каждого месяца отдельно и состоит из предыстории параметра на  $n$  шагов назад с заданной дискретностью (по умолчанию семь дней). Величина предыстории и шаг дискретности в днях могут настраиваться пользователем. Целевые значения каждой отдельной модели включают значения на один месяц вперед с заданным шагом. Шаг может устанавливаться пользователем. Сценарий применения модели показан на рис. 1. Полный цикл использования включает в себя обучение нейросетевой модели и получение предвычисления с использованием обученной модели.

Такая система обучения позволяет экономить вычислительные ресурсы за счет формирования малых выборок, так как модели для каждого месяца обучаются последовательно. Также к преимуществам подхода относится возможность варьировать временную дискретность прогноза, т. е. либо ускорять обучение модели, либо повышать временное разрешение.

При этом для каждого временного интервала (по умолчанию — каждого месяца) обучается отдельная модель с такой архитектурой. Затем модели объединяются в ансамбль и далее используется в предсказательном режиме. Модели принимают на вход оперативные данные о предыстории параметра в рамках двухлетнего окна и формируют предвычисление сплоченности льда на заданное число шагов (например, на год вперед).

Возможно использование модели и в режиме расчета толщины льда. Из-за специфики моделируемого параметра (толщины льда), а именно ограниченности кромкой, с целью согласованности данных сплоченности льда и толщины льда восстановление толщины льда производилось на основе данных о сплоченности, определяющих положение кромки. Сплоченность льда в течение тридцати дней до целевого месяца используется как предиктор, при этом средняя за месяц толщина по данным Ocean Reanalysis System (ORAS) рассматривается как целевая переменная. Алгоритм для восстановления толщины льда может быть применен только к уже вычисленным значениям сплоченности, что делает заблаговременность идентичной по обоим параметрам.

### Оценка эффективности модели

Эффективность модели оценивалась на задачах прогнозирования ледовых условий в морях российской Арктики — Карском, Баренцевом, Лаптевых, Восточно-Сибирском, Чукотском.

Данными для моделирования на основе глубокого обучения послужил продукт OSISAF [28]. Однако из-за того, что этот продукт предоставляет непрерывные поля сплоченности льда, часто возникают артефакты, связанные с неточным воспроизведением малых значений. Для устранения таких артефактов и повышения качества данных было выполнено объединение продукта OSISAF с продуктом мультисенсорной съемочной системы MASIE (Multisensor Analyzed Sea Ice Extent) [25].

Так как MASIE специализируется исключительно на определении положения границы ледовой кромки, где сплоченность льда не ниже 0,2, этот продукт предоставляет более качественную информацию о низких значениях параметра, но не позволяет моделировать полное распределение сплоченности от 0 до 1. Продукт OSISAF содержит весь диапазон значений параметра, в связи с чем было принято решение уточнить в нем положение низких значений сплоченности льда. На рис. 2 представлено сравнение участков с артефактами для продуктов OSISAF и MASIE со спутниковой съемкой Landsat 8 (компо-

зит в видимом диапазоне). Как видно из примеров, объединение двух продуктов в единый гибридный позволяет избавиться от артефактов. Так, ошибочное наличие льда в Белом море и Пясинском заливе исключается на гибридном продукте, корректность результата подтверждается данными дистанционного зондирования Земли.

В созданном гибридном продукте кромка льда бралась по данным MASIE, сплоченность — по данным OSISAF (порог отсечения — сплоченность не менее 0,2). Это позволило повысить качество воспроизведения однолетнего тонкого разреженного льда, что подтверждается валидацией по картам ААНИИ. Характеристики наборов данных приведены в табл. 1.

Сравнение результатов расчета ЛУ с помощью ансамблевых моделей было произведено на отложенной выборке с реальными данными комбинированного продукта OSISAF и MASIE для предвычисления сплоченности льда, а также с прогнозом state-of-the-art системы SEAS5 [14], основанной на дифференциальных уравнениях с усвоением оперативных данных. Также было выполнено сравнение с ледовыми картами ААНИИ.

В качестве дополнительных предикторов рассматривались несколько источников:

- атмосферные параметры из реанализа ERA5;
- параметры динамики океана продукта ORAS5;
- значения климатических индексов;
- дополнительные предикторы в точках (измерения на метеостанциях, ТПО в Атлантике и др.);
- тренды и среднемноголетние значения.

Валидация производилась на основе тестовой территории, включающей моря российской Арктики. Как критерий качества была выбрана бинарная точность (accuracy, %) воспроизведения ледовой кромки с концентрацией льда 0,2. Расчет точности производился по формуле

$$\text{accuracy}(N, h) = \frac{\sum \mu(N, h)}{\sum N}, \quad (1)$$

где  $N$  — число всех ячеек сетки;  $\mu(N, h)$  — функция определения значения ячейки сетки по порогу;  $h$  — порог отсечения для преобразования сеточных значений сплоченности в бинарную маску кромки (использован порог 0,2).

Расчет осуществлялся с шагом семь дней, для каждого из шагов рассчитывались метрики ошибок, далее производилось их осреднение по всему горизонту прогноза.

Так как одним из основных преимуществ разрабатываемого подхода является повышение качества при понижении ресурсоемкости моделирования, было произведено сравнение с более сложной ансамблевой моделью (IceNet) для той же задачи с целью оценки конкурентоспособности решения. В проведенном эксперименте валидационный набор данных ограничен 2012—2020 гг., заблаговременность — шестью месяцами, временное разре-

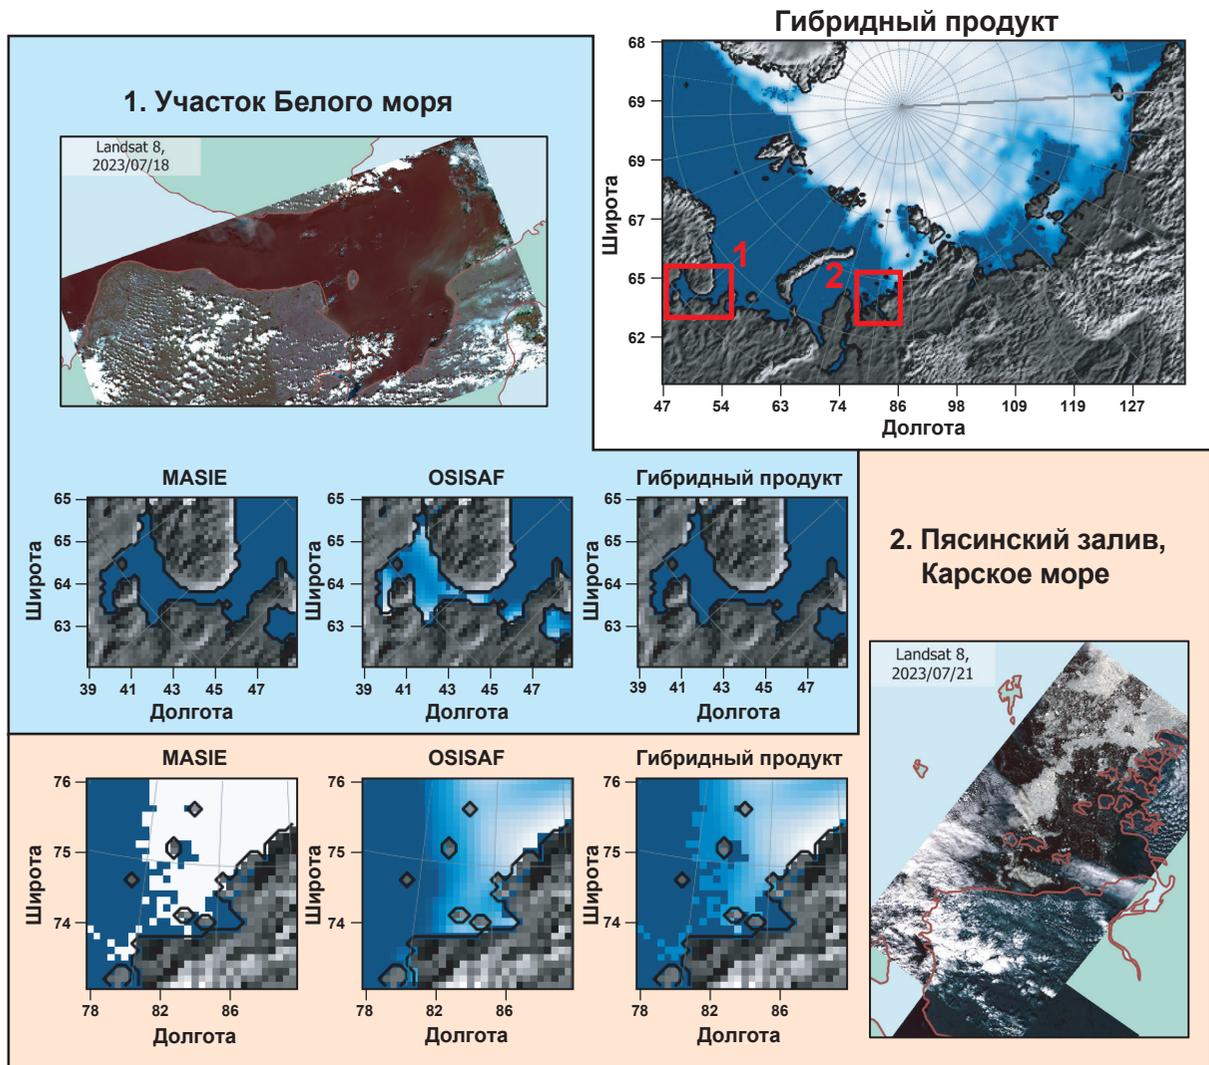


Рис. 2. Сравнение продуктов OSISAF, MASIE и разработанного гибридного продукта в зонах наличия артефактов с данными ДЗЗ спутника Landsat 8. Составлено авторами с использованием картографической основы NaturalEarth [30] и топографической основы GEBCO [31]

Fig. 2. Comparison of OSISAF, MASIE and the developed hybrid product in areas of artefacts with the Landsat 8 remote sensing data. Compiled by authors using the NaturalEarth [30] cartographic base and the GEBCO [31] topographic base

Таблица 1. Рассматриваемые массивы данных

Table 1. Data arrays under consideration

Название реанализа (разработчик)	Временной диапазон	Периодичность в настоящее время	Пространственное разрешение
OSISAF (Франция, Норвегия, Дания, Нидерланды)	1978 — настоящее время	1 ч	25 км
Кромка льда MASIE (NIC — Naval Ice Center, NOAA, США)	2014 — настоящее время	1 день	4 км
Ледовые карты ААНИИ (Росгидромет, ФГБУ ААНИИ)	2003 — настоящее время	7 дней	1:15 000 000

ние — месяц (в соответствии с доступными данными IceNet). В качестве точки старта расчетов брался последовательно каждый из 12 месяцев (т. е. вы-

полнено 72 независимых запуска модели). Осредненная для всех горизонтов прогноза (1, 2, 3, 4, 5 и 6 мес) точность для различных моделей для не-

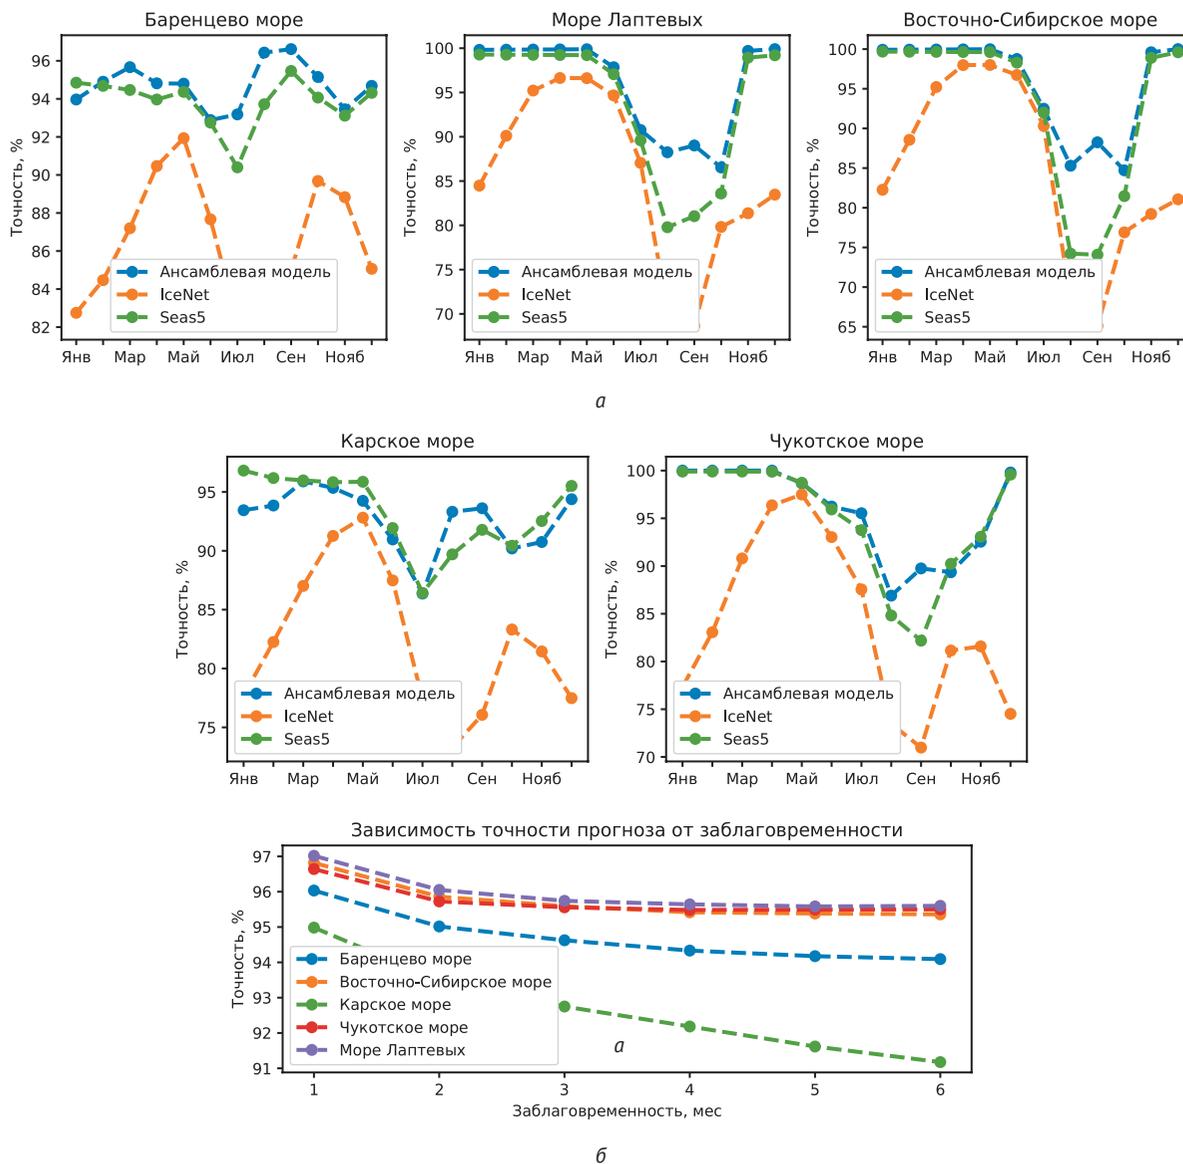


Рис. 3. Сравнение точности для прогнозов ансамблевой модели, SEAS5, IceNet для Баренцева, Восточно-Сибирского морей, моря Лаптевых, Карского и Чукотского морей. Значения точности усреднены для заблаговременностей от 1 до 6 мес и всех сезонов (а). Сравнение точности прогноза ансамблевой модели для различных морей в зависимости от заблаговременности прогноза. Значения точности усреднены по месяцам от января до декабря. Внизу показан график точности для разработанной ансамблевой модели МО (б). Составлено авторами

Fig. 3. Accuracy comparison of the ensemble model, SEAS5, and IceNet forecasts for the Barents, East Siberian, Laptev, Kara and Chukchi Seas. The accuracy values are averaged for lead times from 1 to 6 months and all seasons (a). Forecast accuracy comparison of the ensemble model for different seas depending on the forecast lead time. The accuracy values are averaged for months from January to December. The accuracy plot for the developed ensemble ML model is shown below (b). Compiled by authors

скольких морей представлена на рис. 3а. Как видно из рисунка, применение ансамблевой модели позволяет достичь лучшего качества прогноза. Высокие абсолютные значения точности объясняются учетом зимнего сезона с низкой изменчивостью.

Так как все представленные модели могут быть запущены в любую временную отсечку в течение года и дата старта прогноза сказывается на его качестве, было произведено сравнение точности моделей при старте в начале каждого месяца (с января по декабрь) с последующим осреднением (рис. 3б).

Таким образом, применение ансамблевой модели позволяет получить качество, сопоставимое с «тяжеловесной» системой на основе физического моделирования SEAS5. Однако увеличение заблаговременности выше 6—7 мес ведет к резкому снижению качества моделирования из-за роста неопределенности.

Также преимуществом ансамблевой модели является настраиваемая заблаговременность прогноза. Таким образом, усваивая свежие данные для предсказания ледовой обстановки в определенный

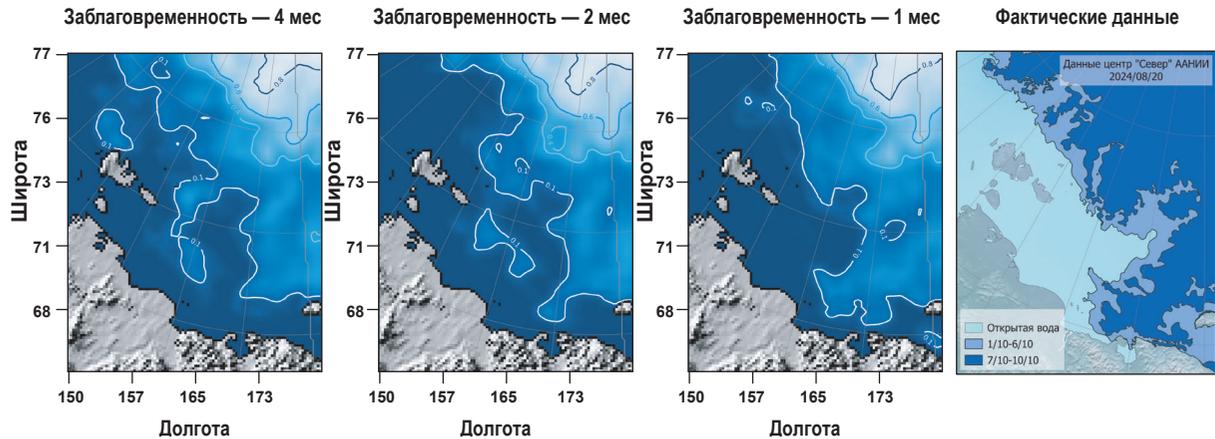


Рис. 4. Сравнение предвычисления на 20.08.2024 с различными заблаговременностями с фактическими данными ААНИИ [2]. Составлено авторами с используемой картографической основы Natural Earth [28], топографическая основа GEBCO [29]  
Fig. 4. Comparison of forecasts for 20.08.2024 with different lead times with the AARI actual data [2]. Compiled by authors using the Natural Earth [28] cartographic base and the GEBCO [29] topographic base

период, можно уточнить предвычисления модели, тем самым повысив качество. Примером могут послужить предвычисления для Восточно-Сибирского моря на период таяния льда, которые представлены на рис. 4. Из этого примера следует, что участок льда с высокой сплоченностью воспроизводится наиболее корректно. Таким образом, в ходе усвоения данных решается задача повышения точности воспроизведения границ остаточных полей дрейфующего льда с низкой сплоченностью.

### Результаты исследований и их обсуждение

В работе решалась задача предвычисления ледовых условий для обеспечения работ, выполняемых при отсутствии дрейфующего льда на акватории в сезон летней навигации.

Были получены следующие результаты:

- сравнение с лучшими из представленных в открытом доступе решениями SEAS5 (прогноз на основе численных моделей) и IceNet (прогноз на основе ансамблевой нейросетевой модели для всей акватории Арктики) показало эффективность предложенного подхода, которая выражается в улучшении качества моделирования для всех акваторий;
- реализованный подход имеет высокую производительность с точки зрения вычислительных затрат — затрачиваемое время ограничено часами в отличие от дней и недель, необходимых для физического моделирования и сложных систем на основе глубокого обучения;
- реализованный подход является гибким и легко адаптируемым под различные акватории и постановки задач, обладая при этом невысокой по сравнению с другими решениями вычислительной сложностью.

С точки зрения значимости результатов разработанное решение в настоящее время наиболее применимо для задач стратегического планирования морских операций на предстоящий сезон работ.

Для решения оперативных задач в настоящее время используется фактическая и оперативная информация, а также кратко- и среднесрочные прогнозы. Представленная реализация предназначена в первую очередь для описания положения границы дрейфующих льдов в период летней навигации. Соответственно подбирались исходные параметры и метрики качества. Поэтому авторы стремились к наибольшей точности воспроизведения границы дрейфующих льдов с низкой сплоченностью (0,1—0,2). В зависимости от производственных задач направление исследований будет смещаться в сторону повышения точности описания других характеристик ледовой обстановки.

Анализ результатов предвычисления ледовых условий за 2012—2020 и 2020—2024 гг. демонстрирует эффективную работу моделей, решающих задачи прогнозирования ЛУ в морях Северного Ледовитого океана. Результаты моделирования концентрации льда с помощью алгоритмов на основе ансамблей сверточных нейронных сетей показывают адекватное качество воспроизведения концентрации льда по сравнению с «тяжеловесными» системами на основе физического моделирования и аналогами на основе глубокого обучения.

Среди недостатков разработанного подхода можно отметить низкую устойчивость модели для больших заблаговременностей (более года) по сравнению с более консервативными моделями на основе поиска аналогов. Также в текущей реализации нейросетевая модель может порождать «нефизические» переходы между месяцами при переключении с одной модели в ансамбле на другую.

Задачи предвычисления ледовых условий в сезон зимней навигации отличаются от тех, которые стоят при обеспечении летней навигации, выполняемых при наличии льда различной сплоченности и при отсутствии льда. Реализованный подход в представленном виде уже может быть использован для



Рис. 5. Возможные целевые параметры предвычисления ледовых условий в сезон зимней навигации: участки затрудненного движения по ледовым условиям и полыньи. Составлено авторами на основе следующих материалов: фактические треки судов приведены по данным автоматизированной информационной системы Арктического научного центра, ледовая обстановка – по данным ледовых карт ААНИИ за 12 апреля 2019 г., картографическая основа подготовлена фирмой ООО «Торинс» на основе данных Всероссийского научно-исследовательского геологического института им. А. П. Карпинского

Fig. 5. Possible target parameters for predicting ice conditions during the winter navigation season: areas of severe ice conditions and polynyas. Compiled by authors based on the following materials: actual vessel tracks are given according to automated information system of Arctic Scientific Center data, ice conditions are based on AARI ice maps for April 12, 2019, and the cartographic basis prepared by Torins LLC as of the A. P. Karpinsky Russian Geological Research Institute data

непрерывного предвычисления ледовой обстановки (толщины и сплоченности льда) на протяжении всего года. Вместе с тем авторы полагают, что возможно повышение качества предвычисления для решения задач обеспечения движения судов на СМП в период ледового плавания. Для этого входные параметры и метрики качества модели следует дополнить предвычислением характеристик, влияющих на возможности движения судов во льду [32; 33], например, картированием:

- факторов, затрудняющих движение судов: таких как участки сжатий, зоны торошения и др. [34; 35];
- факторов, облегчающих движение судов: наличие полыней/разводий, ориентированных разрывов.

Данная постановка задачи схематично проиллюстрирована на рис. 5.

### Заключение

В работе предложен подход к прогностическому моделированию ледовой обстановки в конкретных акваториях на основе ансамбля из сверточных нейронных сетей с различными функциями потерь и инерционным прогнозом.

В ходе разработки модели был найден компромисс между структурной сложностью ансамбля моделей, числом входных данных, необходимых для обучения, вычислительной сложностью обучения и качеством моделирования для различных заблаговременностей (исследовались варианты от нескольких месяцев до трех лет).

Результаты исследования (модели и их программная реализация) могут быть использованы при пла-

нировании геолого-разведочных работ на шельфе и оптимизации маршрутов судов в районах Северного морского пути.

Разработанное решение представляет собой отдельный продукт, дополняющий ледовый прогноз в составе гидрометобеспечения. На данном этапе решения на основе всей совокупности источников ледовой информации рекомендуется принимать с привлечением специалиста, понимающего развитие ледовых процессов на данном участке моря.

В качестве перспективных направлений развития метода предвычисления ледовых условий можно рассматривать:

- расширение функциональности для режима оперативного прогноза кромки льда (3 ч — 7 сут); исследование вариантов архитектур, позволяющих более эффективно использовать дополнительные предикторы, атмосферные параметры, климатические индексы);
- расширение моделирования на акватории неарктических замерзающих морей России (Охотского, Берингова и др.);
- адаптацию модели для решения задач зимней навигации: предвычисления формирования разводий (полыней), разрывов в ледяном покрове и участков с тяжелыми ледовыми условиями.

### Финансирование

Работа выполнена в рамках государственного задания Министерства науки и высшего образования Российской Федерации (проект № FSER-2024-0004).

## Литература/References

1. Миронов Е. У. и др. Современное состояние и перспективы исследований ледяного покрова морей российской Арктики // Рос. Арктика. — 2020. — № 3. — С. 13—29.  
*Mironov E. U. et al.* The current state and prospects of research on the ice cover of the seas of the Russian Arctic. *The Russian Arctic*, 2020, no. 3, pp. 13—29. (In Russian).
2. Обзорные ледовые карты Северного Ледовитого океана. — URL: <https://www.aari.ru/data/realtime/ledovye-karty-2>.  
Overview ice maps of the Arctic Ocean. Available at: <https://www.aari.ru/data/realtime/ledovye-karty-2>. (In Russian)
3. SIGRID-3: A vector archive format for sea ice charts: developed by the International Ice Charting Working Group's Ad Hoc Format Team for the WMO Global Digital Sea Ice Data Bank Project. Available at: <https://repository.oceanbestpractices.org/handle/11329/97>.
4. Мальшев Н. А., Верзбицкий В. Е., Колюбакин А. А. и др. Технологические аспекты и опыт стратиграфического бурения в морях российской Арктики // Геология нефти и газа. — 2024. — № 3. — С. 19—30. — DOI: 10.47148/0016-7894-2024-3-19-30.  
*Malyshev N. A., Verzhbitskii V. E., Kolyubakin A. A., Komissarov D. K., Borodulin A. A., Obmetko V. V., Popova A. B., Danilkin S. M., Vasil'eva I. S., Timoshenko T. A., Aleksandrova G. N., Gatovskii Yu. A., Suslova A. A., Nikishin A. M.* Technological aspects and experience of stratigraphic drilling in the seas of the Russian Arctic. *Geologiya nefi i gaza*, 2024, no. 3, pp. 19—30. DOI: 10.47148/0016-7894-2024-3-19-30. (In Russian).
5. Петров О. В., Понимаскин А. И., Токарев М. Ю. и др. Результаты стратиграфического бурения в Восточно-Сибирском море с целью геологического изучения зоны сочленения структур континентального шельфа и глубоководных акваторий Северного Ледовитого океана // Докл. Рос. акад. наук. Науки о Земле. — 2023. — Т. 512, № 2. — С. 261—271. — DOI: 10.31857/S268673972360100X.  
*Petrov O. V., Ponomaskin A. I., Tokarev M. Yu., Leont'ev D. I., Tolmacheva T. Yu., Razumkova E. S., Shurekova O. V., Stavitskaya V. N., Komissarov D. K., Kolyubakin A. A., Verzhbitskii V. E. et al.* First results of stratigraphic drilling in the East Siberian Sea focused on the geological studies of the suture zone of the continental shelf's marginal structures and deep-water areas of the Arctic Ocean. *Doklady Earth Sciences*, 2023, vol. 512, no. 2, pp. 261—271. DOI: 10.31857/S268673972360100X. (In Russian).
6. Guemas V. et al. A review on Arctic sea-ice predictability and prediction on seasonal to decadal time-scales. *Quarterly J. of the Royal Meteorological Society*, 2016, vol. 142, no. 695, pp. 546—561.
7. Wang M., Overland J. E. A sea ice free summer Arctic within 30 years: An update from CMIP5 models. *Geophysical Research Letters*, 2012, vol. 39, no. 18.
8. Zhang J., Rothrock D. A. Modeling global sea ice with a thickness and enthalpy distribution model in generalized curvilinear coordinates. *Monthly Weather Rev.*, 2003, vol. 131, no. 5, pp. 845—861.
9. Wang W., Chen M., Kumar A. Seasonal prediction of Arctic sea ice extent from a coupled dynamical forecast system. *Monthly Weather Rev.*, 2013, vol. 141, no. 4, pp. 1375—1394.
10. Madec G. et al. NEMO ocean engine. [S. l.], 2017.
11. Hvatov A. et al. Adaptation of NEMO-LIM3 model for multigrad high resolution Arctic simulation. *Ocean Modelling*, 2019, vol. 141, p. 101427.
12. Pemberton P. et al. Sea-ice evaluation of NEMO-Nordic 1.0: a NEMO-LIM3. 6-based ocean-sea-ice model setup for the North Sea and Baltic Sea. *Geoscientific Model Development*, 2017, vol. 10, no. 8, pp. 3105—3123.
13. Dominicus S., Mishra A. K. Sea ice concentration estimation techniques using machine learning: An end-to-end workflow for estimating concentration maps from sar images. *arXiv preprint arXiv:2205.01403*, 2022.
14. Johnson S. J. et al. SEAS5: the new ECMWF seasonal forecast system. *Geoscientific Model Development*, 2019, vol. 12, no. 3, pp. 1087—1117.
15. Petty A. A. et al. Skillful spring forecasts of September Arctic sea ice extent using passive microwave sea ice observations. *Earth's Future*, 2017, vol. 5, no. 2, pp. 254—263.
16. Kapsch M. L. et al. The importance of spring atmospheric conditions for predictions of the Arctic summer sea ice extent. *Geophysical Research Letters*, 2014, vol. 41, no. 14, pp. 5288—5296.
17. Wang L. et al. Predicting summer Arctic sea ice concentration intraseasonal variability using a vector autoregressive model. *J. of Climate*, 2016, vol. 29, no. 4, pp. 1529—1543.
18. Kim J. et al. Satellite-based prediction of Arctic sea ice concentration using a deep neural network with multi-model ensemble. *Remote Sensing*, 2018, vol. 11, no. 1, p. 19.
19. Сочнев О. Я., Корнишин К. А., Ефимов Я. О. и др. Межгодовая изменчивость продолжительности безледного периода в юго-западной части Карского моря // Проблемы Арктики и Антарктики. — 2019. — Т. 65, № 3. — С. 239—254.  
*Sochnev O. Ya., Kornishin K. A., Yefimov Ya. O., Mironov Ye. U., Porubayev V. S.* Interannual variability of the ice-free period duration in the southwestern Kara Sea. *Problemy Arktiki i Antarktiki [Arctic and Antarctic Research]*, 2019, vol. 65, no. 3, pp. 239—254. (In Russian).
20. Kim Y. J. et al. Prediction of monthly Arctic sea ice concentrations using satellite and reanalysis data based on convolutional neural networks. *The Cryosphere*, 2020, vol. 14, no. 3, pp. 1083—1104.
21. Думанская И. О. Ледовые условия морей европейской части России. — Москва; Обнинск: ИГ-СОЦИН, 2014. — 605 с.  
*Dumanskaya I. O.* Ice conditions of the seas of the European part of Russia. Moscow; Obninsk, IG-SOCIN, 2014, 605 p. (In Russian).

22. Думанская И. О. Ледовые условия морей азиатской части России. — Москва; Обнинск: ИГ-СОЦИН, 2017. — 640 с.  
*Dumanskaya I. O. Ice conditions of the seas of the Asian part of Russia. Moscow; Obninsk, IG-SOCIN, 2017, 640 p. (In Russian).*
23. Думанская И. О., Котилевская А. М. Оценка возможности использования прогностических методик XX века в современной практике ледового обслуживания мореплавания на неарктических морях России // Тр. ГМЦ РФ. — 2009. — Вып. 343. — С. 67—88.  
*Dumanskaya I. O., Kotilevskaya A. M. Assessment of the possibility of using predictive methods of the twentieth century in the modern practice of ice navigation services in the non-Arctic seas of Russia. Tr. GMTS RF, 2009, iss. 343, pp. 67—88. (In Russian).*
24. Тимофеева А. Б., Юлин А. В., Иванов В. В. и др. Ледовитость российских арктических морей трассы Северного морского пути в современный климатический период // Арктика: экология и экономика. — 2024. — Т. 14, № 1. — С. 135—146.  
*Timofeeva A. B., Yulin A. V., Ivanov V. V., Sharatunova M. V., Pavlova E. A. Ice cover of the Russian Arctic seas along the Northern sea route in the current climatic period. Arctic: Ecology and Economy, 2024, vol. 14, no. 1, pp. 135—146. DOI: 10.25283/2223-4594-2024-1-135-146. (In Russian).*
25. Шишкин А. Н., Корнишин К. А., Дейнего И. Д., Тарасов П. А. Северный морской путь: современный климатический период и прогнозы // Нефтяное хоз-во. — 2024. — № 6. — С. 40-44.  
*Shishkin A. N., Kornishin K. A., Deinego I. D., Tarasov P. A. Northern sea route: present climate and future projections. Oil industry, 2024, no. 6, pp. 40—44. (In Russian).*
26. Lemieux J. F. et al. The Regional Ice Prediction System (RIPS): verification of forecast sea ice concentration. Quarterly J. of the Royal Meteorological Society, 2016, vol. 142, no. 695, pp. 632—643.
27. Топаж А. Г., Таровик О. В., Бахарев А. А. Автоматическая маршрутизация судов во льдах: постановка задачи и инструменты решения // Арктика: экология и экономика. — 2022. — Т. 12, № 1. — С. 123—139. — DOI: 10.25283/2223-4594-2022-1-123-139.  
*Topaj A. G., Tarovik O. V., Bakharev A. A. Automatic routing of vessels in ice: problem statement and solution tools. Arctic: Ecology and Economy, 2022, vol. 12, no. 1, pp. 123—139. DOI: 10.25283/2223-4594-2022-1-123-139. (In Russian).*
28. Tonboe R. et al. Product user manual for osi saf global sea ice concentration. Danish Meteorological Institute. Copenhagen, Denmark, 2016.
29. US National Ice Center and National Snow and Ice Data Center. Multisensor Analyzed Sea Ice Extent—Northern Hemisphere (MASIE-NH), Version 1. 2010.
30. Cartographic foundations of Natural Earth Data. Available at: <https://www.naturalearthdata.com/>.
31. The topographic basis of GEBCO. Available at: <https://www.gebco.net/>.
32. Сазонов К. Е., Добродеев А. А. Ледовая ходкость крупнотоннажных судов. — СПб.: ФГУП «Крылов. гос. науч. центр», 2017.  
*Sazonov K. E., Dobrodeev A. A. Ice handling of large-tonnage vessels. St. Petersburg, FSUE Krylov State Scientific Center, 2017.*
33. Таровик О. В. Модели для прогнозирования параметров рейсов судов в Арктике: существующие подходы и возможные пути развития // Арктика: экология и экономика. — 2021. — Т. 11, № 3. — С. 422—435. — DOI: 10.25283/2223-4594-2021-3-422-435.  
*Tarovik O. V. Models to predict the parameters of ship voyages in the Arctic: existing approaches and possible ways of development. Arctic: Ecology and Economy, 2021, vol. 11, no. 3, pp. 422—435. DOI: 10.25283/2223-4594-2021-3-422-435. (In Russian).*
34. Бузин И. В., Клячкин С. В., Фролов С. В. и др. Сжатия ледяного покрова в Печорском море: природное явление и его влияние на морские операции // Арктика: экология и экономика. — 2022. — Т. 12, № 4. — С. 500—512. — DOI: 10.25283/2223-4594-2022-4-500-512.  
*Buzin I. V., Klyachkin S. V., Frolov S. V., Smirnov K. G., Mikhaltseva S. V., Sokolova Yu. V., Gudoshnikov Yu. P., Voinov G. N., Grigoryev M. N. Compression of the ice cover in the Pechora Sea: a natural phenomenon and its impact on marine operations. Arctic: Ecology and Economy, 2022, vol. 12, no. 4, pp. 500—512. DOI: 10.25283/2223-4594-2022-4-500-512. (In Russian).*
35. Бузин И. В., Клячкин С. В., Фролов С. В. и др. Некоторые оценки тяжелых ледовых условий в Печорском море по данным наблюдений и моделирования (моделирование и анализ) // Арктика: экология и экономика. — 2024. — Т. 14, № 1. — С. 24—35. — DOI: 10.25283/2223-4594-2024-1-24-35.  
*Buzin I. V., Klyachkin S. V., Frolov S. V., Smirnov K. G., Mikhaltseva S. V., Sokolova Yu. V., Gudoshnikov Yu. P., Voinov G. N., Grigoryev M. N. Some estimates of the severe ice conditions in the Pechora Sea based on observational and modeling data (simulation and analysis). Arctic: Ecology and Economy, 2024, vol. 14, no. 1, pp. 24—35. DOI: 10.25283/2223-4594-2024-1-24-35. (In Russian).*
36. Andersson T. R. et al. Seasonal Arctic sea ice forecasting with probabilistic deep learning. Nature communications, 2021, vol. 12, no. 1, p. 5124.

### Информация об авторах

Никитин Николай Олегович, кандидат технических наук, руководитель группы научно-технического развития, Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А), e-mail: nnikitin@itmo.ru.

**Борисова Юлия Ивановна**, аспирант, младший научный сотрудник, лаборатория композитного ИИ, Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А), e-mail: jul.borisova@itmo.ru.

**Аксенкин Ярослав Витальевич**, инженер, исследовательский центр в сфере искусственного интеллекта «Сильный ИИ в промышленности», Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А), e-mail: yaaksenkin@itmo.ru.

**Башкова Ксения**, аспирант, инженер, исследовательский центр в сфере искусственного интеллекта «Сильный ИИ в промышленности», Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А), e-mail: bashkova@itmo.ru.

**Луценко Елизавета Ивановна**, инженер, исследовательский центр в сфере искусственного интеллекта «Сильный ИИ в промышленности», Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А).

**Калюжная Анна Владимировна**, кандидат технических наук, доцент, старший научный сотрудник исследовательского центра «Сильный ИИ в промышленности», Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А).

**Якимущин Дмитрий Олегович**, ведущий специалист отдела инновационных проектов на шельфе Арктического научного центра (119607, Россия, Москва, Ленинский просп., д. 55/1, стр. 2), e-mail: DO\_Yakimushkin@arc.rosneft.ru.

**Котилевская Алина Михайловна**, главный специалист отдела инновационных проектов на шельфе Арктического научного центра (119607, Россия, Москва, Ленинский просп., д. 55/1, стр. 2), e-mail: AM\_Kotilevskaia@arc.rosneft.ru.

**Верташ Таисия Николаевна**, ведущий специалист отдела петрофизики и ресурсной базы Арктического научного центра (119607, Россия, Москва, Ленинский просп., д. 55/1, стр. 2), e-mail: TN\_Vertash@arc.rosneft.ru.

**Колюбакин Андрей Анатольевич**, менеджер по совместным проектам геолого-геофизической службы РН-Эксплорейшн (115054, Россия, Москва, Дубининская ул., д. 31А), e-mail: a\_kolubakin@rn-exr.rosneft.ru.

**Багорьян Евгений Сергеевич**, главный специалист отдела инновационных проектов на шельфе Арктического научного центра (119607, Россия, Москва, Ленинский просп., д. 55/1, стр. 2), e-mail: ES\_Bagorian@arc.rosneft.ru.

**Бухановский Александр Валерьевич**, доктор технических наук, научный руководитель исследовательского центра в сфере искусственного интеллекта «Сильный ИИ в промышленности», Университет ИТМО (197101, Россия, Санкт-Петербург, Кронверкский просп., д. 49, литер А), e-mail: avbukhanovskii@itmo.ru.

---

## PREDICTION OF ICE CONDITIONS TO SUPPORT ECONOMIC ACTIVITY IN THE RUSSIAN ARCTIC SEAS USING DEEP LEARNING METHODS

**Nikitin, N. O.<sup>1</sup>, Borisova, Yu. I.<sup>4</sup>, Aksenkin, Ya. V.<sup>1</sup>, Bashkova, K.<sup>1</sup>, Lutsenko, E. I.<sup>1</sup>, Kalyuzhnaya, A. V.<sup>1</sup>, Yakimushkin, D. O.<sup>2</sup>, Kotilevskaya, A. M.<sup>2</sup>, Vertash, T. N.<sup>2</sup>, Kolubakin, A. A.<sup>3</sup>, Bagoryan, E. S.<sup>2</sup>, Bukhanovsky, A. V.<sup>1</sup>**

<sup>1</sup> Research Centre “Strong AI in Industry”, ITMO University (St. Petersburg, Russian Federation)

<sup>2</sup> Arctic Research Centre LLC (Moscow, Russian Federation)

<sup>3</sup> RN-Exploration LLC (Moscow, Russian Federation)

<sup>4</sup> Laboratory of Composite AI, ITMO University (St. Petersburg, Russian Federation)

### For citing

*Nikitin N. O., Borisova Yu. I., Aksenkin Ya. V., Bashkova K., Lutsenko E. I., Kalyuzhnaya A. V., Yakimushkin D. O., Kotilevskaya A. M., Vertash T. N., Kolubakin A. A., Bagoryan E. S., Bukhanovsky A. V.* Prediction of ice conditions to support economic activity in the Russian Arctic seas using deep learning methods. *Arctic: Ecology and Economy*, 2025, vol. 15, no. 1, pp. 119—130. DOI: 10.25283/2223-4594-2025-1-119-130. (In Russian).

The article was received on December 4, 2024

### Abstract

The paper presents a technology for predicting ice conditions in the Russian Arctic seas to solve forecasting problems in a grid setting for a given local water area. The technology is based on the application of in-depth training models in the form of convolutional neural networks. It allows solving problems of long-term predict-

ing ice conditions (concentration and thickness) with a given temporal and spatial resolution. Experimental studies to assess the quality of ice concentration forecasting have confirmed the effectiveness of ensemble modelling in comparison with single models, as well as with existing forecasts (SEAS5). The proposed approach surpasses the global forecasting system based on in-depth training IceNet, while having a lower computational complexity.

**Keywords:** *Northern Sea Route, ice conditions, forecast model, artificial neural networks.*

### Funding

The research was carried out within the state assignment of the Ministry of Science and Higher Education of the Russian Federation (project no. № FSER-2024-0004).

---

### Information about the authors

**Nikitin, Nikolay Olegovich**, PhD of Engineering Sciences, Head of Scientific and Technical Development Group, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: nnikitin@itmo.ru.

**Borisova, Yulia Ivanovna**, postgraduate, Junior Researcher, Laboratory of Composite AI, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: jul.borisova@itmo.ru.

**Aksenkin, Yaroslav Vitalievich**, Engineer, Artificial Intelligence Research Centre “Strong AI in Industry”, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: yaaksenkin@itmo.ru.

**Bashkova, Ksenia**, postgraduate, Engineer, Artificial Intelligence Research Centre “Strong AI in Industry”, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: bashkova@itmo.ru.

**Lutsenko, Elizaveta Ivanovna**, Engineer, Artificial Intelligence Research Centre “Strong AI in Industry”, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: eilutsenko@itmo.ru.

**Kalyuzhnaya, Anna Vladimirovna**, PhD of Engineering Sciences, Associate Professor, Senior Researcher, Research Centre “Strong AI in Industry”, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: anna.kalyuzhnaya@itmo.ru.

**Yakimushkin, Dmitrii Olegovich**, Top Specialist, Department of Offshore Innovation Projects, Arctic Research Centre (55/1, p. 2, Leninsky Prosp., Moscow, Russia, 119607), e-mail: DO\_Yakimushkin@arc.rosneft.ru.

**Kotilevskaya, Alina Mikhailovna**, Chief Specialist, Arctic Research Centre (55/1, p. 2, Leninsky Prosp., Moscow, Russia, 119607), e-mail: AM\_Kotilevskaia@arc.rosneft.ru.

**Vertash, Taisiya Nikolaevna**, Top Specialist, Department of Petrophysics and Resource Base, Arctic Research Centre (55/1, p. 2, Leninsky Prosp., Moscow, Russia, 119607), e-mail: TN\_Vertash@arc.rosneft.ru.

**Kolubakin, Andrey Anatolyevich**, Joint Projects Manager, Geological and Geophysical Service, RN-Exploration (31A, Dubininskaya St., Moscow, Russia, 115054), e-mail: a\_kolubakin@rn-exp.rosneft.ru.

**Bagoryan, Evgeny Sergeevich**, Main Specialist, Department of Innovative Shelf Projects of the Arctic Research Centre (55/1, p. 2, Leninsky Prosp., Moscow, Russia, 119607), e-mail: ES\_Bagorian@arc.rosneft.ru.

**Bukhanovsky, Alexander Valeryevich**, Doctor of Engineering Sciences, Scientific Director, Artificial Intelligence Research Centre “Strong AI in Industry”, ITMO University (49, letter A, Kronverksky Prosp., St. Petersburg, Russia, 197101), e-mail: avbukhanovskii@itmo.ru.

© Nikitin N. O., Borisova Yu. I., Aksenkin Y. V., Bashkova K., Lutsenko E. I., Kalyuzhnaya A. V., Yakimushkin D. O., Kotilevskaya A. M., Vertash T. N., Kolubakin. A. A., Bagoryan E. S., Bukhanovsky A. V., 2025