

ОКЕАНОЛОГИЯ OCEANOLOGY

Оригинальная статья / Original paper

<https://doi.org/10.30758/0555-2648-2026-72-1-6-18>

УДК 528.854, 551.465



Автоматическое определение вихрей по спутниковым данным видимого диапазона с использованием методов глубокого машинного обучения на примере Норвежского моря

В.В. Кулак¹, Д.М. Демчев^{1,2,3✉}, Ф.А. Гневашев^{4,1},
Т.А. Алексеева^{3,5}, И.Л. Башмачников^{4,1}

¹ *Международный центр охраны окружающей среды и дистанционного зондирования им. Нансена, Санкт-Петербург, Россия*


² *Центр морских исследований МГУ имени М.В. Ломоносова, Москва, Россия*

³ *ГНЦ РФ Арктический и антарктический научно-исследовательский институт, Санкт-Петербург, Россия*

⁴ *Санкт-Петербургский государственный университет, Санкт-Петербург, Россия*

⁵ *Институт космических исследований РАН, Москва, Россия*

✉ denis@niersc.spb.ru

 ДМД, 0000-0001-6907-1729; ФАГ, 0000-0001-8742-8031; ТАА, 0000-0002-1575-8784;
ИЛБ, 0000-0002-1257-4197

Аннотация. Океанские вихри являются важным фактором крупномасштабной динамики вод Мирового океана, включая полярные и субполярные районы. Статистически достоверная информация о количестве и характеристиках мезомасштабных и субмезомасштабных вихрей позволит оценить их влияние на крупномасштабные течения, динамику ледяной кромки и другие динамические и биохимические процессы в океане. В работе предлагается алгоритм глубокого машинного обучения на базе нейросети SegFormer для эффективного автоматического выделения вихрей по данным видимого диапазона спутника Sentinel-3. Обучение осуществлялось на 52 изображениях Норвежского моря за 2017–2025 гг., на которых было выделено 938 вихрей. Достигнутые высокие метрики качества $IoU = 0,87$ и $Dice = 0,93$ показывают высокое качество работы алгоритма. Полученные результаты особенно актуальны для полярных районов океана, где преобладающие размеры вихрей существенно меньше, чем, например, в субтропических и тропических широтах. Выделение вихрей на снимках видимого диапазона является © Авторы, 2026

© Authors, 2026

перспективными дополнением к исследованию проявлений вихрей в радиодиапазоне и позволит в дальнейшем получить более объективные данные для комплексного изучения динамики мезомасштабных и субмезомасштабных вихрей в океане.

Ключевые слова: океанские вихри, глубокое машинное обучение, Sentinel-3, Норвежское море

Для цитирования: Кулак В.В., Демчев Д.М., Гневашев Ф.А., Алексеева Т.А., Башмачников И.Л. Автоматическое определение вихрей по спутниковым данным видимого диапазона с использованием методов глубокого машинного обучения на примере Норвежского моря. *Проблемы Арктики и Антарктики*. 2026;72(1):6–18. <https://doi.org/10.30758/0555-2648-2026-72-1-6-18>

Поступила 26.09.2025

После переработки 08.12.2025

Принята 22.12.2025

Ocean eddy automatic detection in satellite optical images of the Norwegian Sea using deep machine learning

Veronika V. Kulak¹, Denis M. Demchev^{1,2,3}✉, Fedor A. Gnevashev⁴,
Tatiana A. Alekseeva^{3,5}, Igor L. Bashmachnikov^{4,1}

¹ Scientific Foundation “Nansen International Environmental and Remote Sensing Centre” (Nansen Centre, NIERSC), St. Petersburg, Russia


² Lomonosov Moscow State University Marine Research Center (LMSU MRC), Moscow, Russia

³ State Scientific Center of the Russian Federation Arctic and Antarctic Research Institute, St. Petersburg, Russia

⁴ Saint Petersburg State University, St. Petersburg, Russia

⁵ Space Research Institute Russian Academy of Science, Moscow, Russia

✉denis@niersc.spb.ru

 DMD, 0000-0001-6907-1729; FAG, 0000-0001-8742-8031; TAA, 0000-0002-1575-8784; ILB, 0000-0002-1257-4197

Abstract. Ocean eddies are an important factor in the large-scale dynamics of the global ocean, including polar and subpolar regions. A robust statistical information on the number and characteristics of mesoscale and submesoscale eddies will yield new insights on their effect on dynamics of large-scale currents, ice-edge variability, and other dynamic and biochemical processes in the ocean. Optical images complement the results of the eddy identification study in radar and satellite altimetry images, each of which has its inherent limitations. In optical images, eddies are often observed as spiral or mushroom-shaped structures in chlorophyll distribution, which are formed through the effect of eddy rotation and convergence/divergence patterns. Massive studies of characteristics of ocean eddies require algorithms for their automatic identification. Although several such algorithms have been suggested for satellite altimetry and radar data, no such algorithm exists for satellite optical images. In this study we propose a machine deep learning algorithm for efficient automatic eddy detection in Sentinel-3 optical images. The Lofoten Basin of the Norwegian Sea, an area with a small Rossby deformation radius of less than 10 km, but densely populated with eddies, was selected as a region for algorithm training and validation. Even though the study area is known as one of the cloudiest areas of the northern polar latitudes, 52 mostly cloud-free images were collected over the 9 years of Sentinel-3 data, where 938 eddies were detected. For automatic eddy identification we used SegFormer neural network architecture with an AdamW optimizer, applied for 512×512 pixel tiles. In the course of validation high quality metrics were obtained: *Precision* = 0.94, *Recall* = 0.91, *Intersection of Union* = 0.87 and *Dice* = 0.93. This demonstrates high efficiency of the algorithm developed. The algorithm additionally identified several eddies missed during visual image inspection. The results of the study are particularly relevant to polar ocean regions, where the predominant eddy sizes are significantly smaller than in the tropics. The robust identification of eddies in optical images is a promising step forward in understanding mesoscale and sub-mesoscale eddy dynamics.

Keywords: ocean eddy, deep learning, Sentinel-3, Norwegian Sea

For citation: Kulak V.V., Demchev D.M., Gnevashev F.A., Alekseeva T.A., Bashmachnikov I.L. Ocean eddy automatic detection in satellite optical images of the Norwegian Sea using deep machine learning. *Arctic and Antarctic Research*. 2026;72(1):6–18. (In Russ.). <https://doi.org/10.30758/0555-2648-2026-72-1-6-18>

Received 26.09.2025

Revised 08.12.2025

Accepted 22.12.2025

Введение

Вихри в океане представляют собой вращающиеся сильно нелинейные структуры, существующие как обособленные динамические образования, содержащие жидкие частицы, совершившие не менее одного оборота частицы вокруг оси и переносящие не только энергию, но и массу. Кинетическая энергия вихрей в среднем на 2 порядка больше кинетической энергии крупномасштабных течений, в связи с чем мезомасштабные вихри вносят существенный вклад в энергетический баланс вод океана [1]. Вихри играют важнейшую роль в трансфронтальном обмене, в том числе полярных районов Южного и Северного Ледовитого океанов [2–5], воздействуют на биологическую продуктивность морских вод [6, 7].

Массовые исследования характеристик вихрей в океане за длительный период проводятся только по данным спутниковой альтиметрии [8, 9]. Существует несколько примеров массового регионального изучения характеристик вихрей и за отдельные месяцы или годы по данным визуального анализа спутниковых снимков в радио-, инфракрасном и видимом диапазонах [10–12]. В каждом из диапазонов электромагнитного спектра масштаб исследования вихрей имеет свои ограничения. Спутниковая альтиметрия (AVISO) позволяет выделять только наиболее крупные вихри, что связано с ограниченным разрешением данных ($1/4^\circ \times 1/4^\circ$ для интерполированных данных спутниковой альтиметрии AVISO). Особенно большие сложности использования спутниковой альтиметрии для анализа вихревой активности возникают в Северном Ледовитом океане, где радиус деформации Россби мал, а деградация альтиметрических наблюдений вблизи кромки льда существенно снижает точность альтиметрических данных. Вихри могут быть выделены на радиолокационных изображениях (РЛИ), полученных с радаров с синтезированной апертурой, которые имеют пространственное разрешение менее 100 м [13–16]. На РЛИ также существуют естественные ограничения при выявлении вихревых структур, связанные с ограниченным диапазоном скоростей ветра (3–12 м/с). Крупные вихри часто не могут быть выделены на РЛИ из-за существенной изменчивости характеристик сигнала на расстоянии их радиуса, что связано с пространственной изменчивостью характеристик поверхности моря и поля ветра. Циклоны на РЛИ проявляются гораздо более четко, чем антициклоны, что создает диспропорцию при их выделении, во многом искусственную [11, 17]. Несмотря на ограничения, связанные с наличием облачности, изображения инфракрасного и видимого диапазонов часто позволяют лучше фиксировать вихри крупных масштабов, чем радиоизображения [12, 18, 19]. В связи с этим представляется необходимой синергия исследования вихрей видимого, инфракрасного и радиолокационного диапазонов, которая также может позволять отследить эволюцию вихря при наличии последовательных снимков в разных диапазонах [18].

Спиралевидные и грибовидные структуры океанических вихрей на изображениях видимого диапазона привлекли внимание исследователей с момента появления первых данных с искусственных спутников Земли [15, 20, 21]. Основными причинами

формирования спиралевидных структур в поле хлорофилла считаются адвективное вовлечение окружающих вод с разной концентрацией планктона и биогенов во вращательное движение [8], усиление вертикальных движений в центральных частях и на периферии вихрей, а также изменение глубины верхнего перемешанного слоя в вихрях по сравнению с окружающим океаном [22]. Усиление агеострофических вертикальных скоростей в вихрях может быть вызвано рядом причин: трением, инерционными силами, экмановской накачкой из-за формирования градиентов поля ветра над вихрем (результат аномального теплообмена между океаном и атмосферой над вихрем), формированием субмезомасштабных вихрей и филаментов на периферии более крупных вихрей [7, 23, 24]. Доминирующие факторы могут меняться во времени и от региона к региону. Примерно 1 % вихрей, как циклонических, так и антициклонических, имеют внешнее кольцо повышенных значений хлорофилла, связанных с механизмом вовлечения окружающих вод, аномальной экмановской накачкой или агеострофическими вертикальными движениями на границах вихрей [22, 25].

Массовые исследования характеристик вихрей в океане требуют алгоритмов их автоматического выделения. Такие алгоритмы предложены для спутниковой альтиметрии [8]. Существует ряд работ, связанных с применением компьютерного зрения для задач выделения вихрей по радиолокационным данным [26–30]. В приводимых работах используются различные алгоритмы на базе сверточных нейронных сетей U-Net и ее модификации, DeeplabV3+, YOLO и ее модификации, SegFormer. Аналогичные алгоритмы могут быть использованы и для изображений видимого диапазона. Однако до сегодняшнего дня таких публикаций не было.

Основной целью данного исследования является разработка нейросетевого алгоритма для автоматической идентификации океанических вихрей на снимках видимого диапазона, который позволяет проводить массовую идентификацию вихрей на обширных акваториях. В качестве объекта изучения взята Лофотенская котловина Норвежского моря, характеризующаяся высоким уровнем вихревой активности и постоянным присутствием вихрей разных горизонтальных масштабов [5, 31].

Исходные данные

Для выявления и анализа вихрей в районе Норвежского моря использовались данные видимого диапазона, полученные радиометрами OLCI (Ocean and Land Color Instrument), установленными на космические аппараты системы Sentinel-3. Сбор данных выполняется в 21 спектральном канале в видимом и ближнем инфракрасном диапазонах, которые включают каналы, подходящие для оценки концентрации хлорофилла а. Съемка каждого участка планеты выполняется с пространственным разрешением 300×300 м ежедневно (за исключением зимнего периода в высоких широтах, в связи с наступлением полярной ночи или при низком склонении Солнца в период съемки). Пространственное разрешение послужило основополагающим фактором выбора исходных данных, так как обычно используемые поля цвета у океана представлены с разрешением 4×4 км и часто представляют собой композитные изображения из нескольких снимков за разные дни. Такие изображения непригодны для выявления небольших субмезомасштабных и мезомасштабных вихрей высоких широт не только в связи с их размерами, но и в связи с малым временем жизни (часто не более 1–3 суток).

Для выявления вихревых структур был выбран канал с центральной длиной волны 510 нм, что связано с хорошей отражательной способностью хлорофилла а в данной части спектра [33]. Материалы дистанционного зондирования были

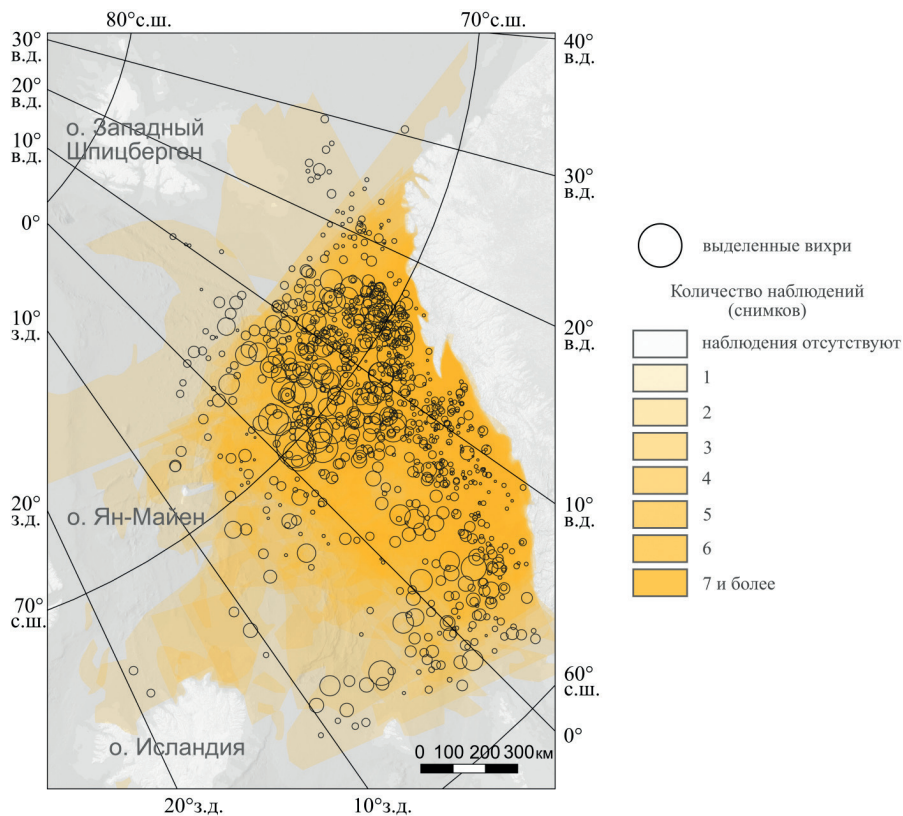


Рис. 1. Пространственное распределение выделенных вихрей в районе исследования (каждый вихрь представлен в виде круга, радиус которого соответствует масштабу в низу рисунка). Цветом в каждой точке карты показано количество использованных снимков видимого диапазона спутника Sentinel-3, свободных от облачности

Fig. 1. Spatial distribution of detected eddies in the study area (every eddy depicted in the form of a circle whose radius corresponds to the map scale). The color at each point on the map shows the number of cloud-free Sentinel-3 images

получены через интернет-портал NASA-Earthdata (<https://search.earthdata.nasa.gov/>) в формате NetCDF, включающем в себя данные первого уровня обработки (содержит значения TOA — Top of Atmospheric Reflectance, представляющие отношение отраженного излучения к падающему), данные географической привязки, а также метаданные. Обработка, геопривязка и конвертация в формат GeoTIFF выполнялись с помощью программы SNAP Европейского космического агентства, разработанной оператором Sentinel-3. Также применялась локальная коррекция контрастов изображений для улучшения их визуальной и автоматической интерпретируемости. Обработанные растровые снимки импортировались в геоинформационную систему QGIS для визуального анализа и ручного выделения вихрей, для последующего использования разметки для обучения нейросетевой модели. На полученных визуализациях в оттенках интенсивности отраженного сигнала вихри проявлялись в виде спиралевидных структур, связанных с захватом вод с разным содержанием хлорофилла а и вертикальными движениями в вихрях [22].




Рис. 2. Пример выделения вихрей на изображении видимого диапазона Sentinel-3 от 03.07.2019. В оттенках серого представлена нормированная яркость отраженного сигнала на длине волны 510 нм. Оранжевыми линиями изображены контуры выделенных вихрей

Fig. 2. An example of detected eddies on Sentinel-3 image for 03.07.2019.

The normalized intensity at a wavelength of 510 nm is shown in grayscale. The vortices are outlined in orange

В связи с большой средней облачностью в районе исследования набор снимков с достаточной площадью открытого неба над Норвежским морем был весьма ограничен, но он включает снимки за все дни наблюдений. Прежде всего отбирались изображения Лофотенской котловины, где отмечается наиболее интенсивная вихревая активность в Норвежском море [5, 34, 35]. В результате просмотра большого объема информации были отобраны снимки на временном интервале с апреля по август включительно. Некоторые снимки были отбракованы по причине недостаточной прозрачности атмосферы, несмотря на наличие участков, свободных от сплошной облачности. Для дальнейшей работы использовались снимки с площадью открытого неба не менее 40 тыс. км², что составляет не менее 3 % Норвежского моря. В итоге для обучения нейросети были отобраны 52 снимка с 2017 по 2025 г. (рис. 1), которые были сбалансированы по количеству хорошо различимых и слабо различимых вихрей, что обеспечило равномерную выборку для обучения нейросети и возможность ориентировать ее на поиск самых разнообразных вихревых структур. Средняя площадь свободной от облаков поверхности моря на отобранных снимках составила 247 тыс. км² ($\approx 16,5\%$), минимальная — 44 тыс. км² ($\approx 2,9\%$), максимальная — 691 тыс. км² ($\approx 46,1\%$) при общей площади снимка около 1,5 млн км².

Пример отобранного снимка с выделенными вихрями представлен на рис 2. Для данного примера площадь свободной от облаков морской поверхности составила 146 тыс. км², а общая площадь ядер вихрей — 35 тыс. км², что составляет 24 % от площади свободной от облаков морской поверхности. Средний размер вихрей на

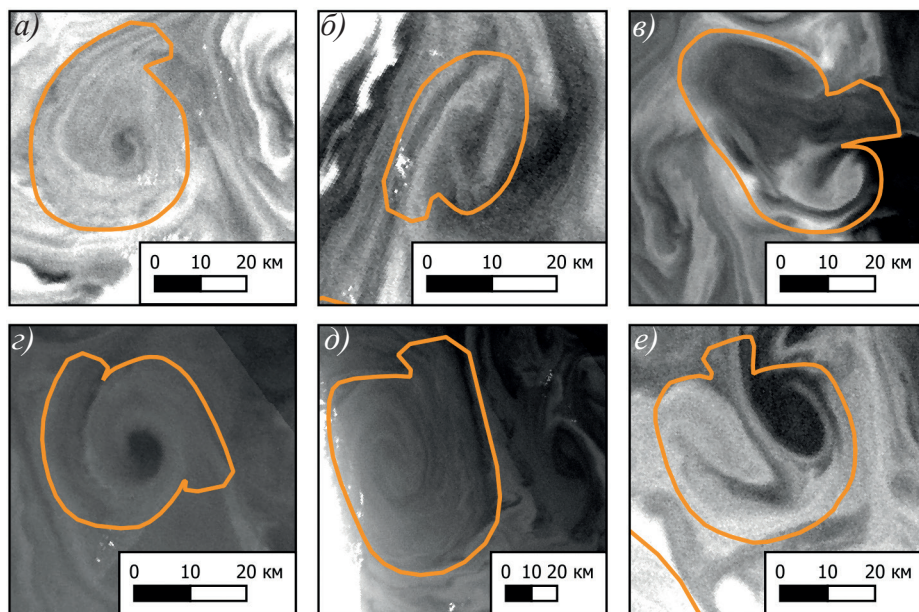


Рис. 3. Примеры выделения вихрей. (а) и (z) — циклонический тип, (б) и (д) — антициклонический тип, (в) и (е) — диполи.

В оттенках серого показана нормированная яркость отраженного сигнала на длине волны 510 нм. Оранжевые линии изображают контуры выделенных вихрей

Fig. 3. Examples of detected eddies. (a) and (z) — cyclonic type, (б) and (д) — anticyclonic type, (в) and (е) — dipoles.

The normalized intensity at a wavelength of 510 nm is shown in grayscale. The boundary of the isolated eddies is indicated by an orange outline

данном снимке составил 14 км (большая полуось) на 11 км (малая полуось), максимальный средний радиус вихря — 48 км, минимальный — 2,6 км. Среднее расстояние между границами соседних вихрей оценивается примерно в 30 км.

Для целей автоматической идентификации вихря разметка проводилась с включением в структуру вихря 2 основных компонентов: ядро вихря с выраженной закруткой и «ножка» — условно линейный участок, визуально интерпретируемый как зона захвата окружающих водных масс вращающимся ядром вихря, с различной концентрацией взвешенного планктона. Граница ядра вихря проводилась по различимой на изображении внешней изолинии его спиралевидной структуры. Результаты разметки экспортировались в векторный формат GeoJSON с сохранением географической привязки. Несколько примеров выделения вихревых структур различного типа (циклон, антициклон и диполь) представлены на рис. 3.

Для обучения нейросетевой модели за период с 2017 по 2025 г. было выделено 876 участков акватории (тайлов), а для валидации — 293 участка акватории. На обработанных снимках всего визуально было выделено 938 вихрей (не каждый тайл содержал вихри, а некоторые тайлы содержали несколько разных вихрей): 684 циклона, 158 антициклонов и 96 диполей (рис. 1). Обучающий массив содержал 777 антициклонических и циклонических вихрей (включая диполи), а валидационный массив — 242 вихря. Как обучающий, так и валидационный массивы содержали все типы вихрей.

Алгоритм сегментации SegFormer

Для решения задачи семантической сегментации использован алгоритм машинного обучения SegFormer — современная архитектура на основе трансформера, эффективно применяемая в задачах компьютерного зрения. В качестве базовой модели была выбрана модель SegFormer-b4-finetuned-ade-512-512 (<https://huggingface.co/nvidia/segformer-b4-finetuned-ade-512-512>). SegFormer сочетает в себе преимущества модели для обработки изображений Vision Transformer (ViT) и сверточной нейронной сети, обеспечивая высокую точность при относительно низких вычислительных затратах. Архитектура состоит из последовательности трансформерных блоков и иерархической структуры признаков, что позволяет эффективно обрабатывать изображения разных масштабов. В отличие от традиционных сверточных подходов, SegFormer использует иерархический энкодер на основе Transformer, который не требует позиционного кодирования (positional encoding), упрощает обработку изображений произвольного масштаба и улучшает обобщающую способность модели на разных данных. Энкодер генерирует многоуровневые (multi-scale) признаковые карты, которые затем передаются в компактный декодер, состоящий исключительно из многослойных перцептронов. Такой подход исключает необходимость использования тяжелых сверточных слоев или механизмов самовнимания (self-attention) на стадии декодирования, позволяя при этом эффективно объединять информацию о глобальном контексте и локальных деталях [36]. Архитектура модели не требует специальных ручных настроек и обладает высокой устойчивостью к изменению разрешения входных изображений, что делает ее особенно привлекательной для практического применения.

В рамках текущей проблемы была поставлена задача бинарной семантической сегментации изображений видимого диапазона открытого моря: 0 — фон (отсутствие вихрей), 1 — вихрь (этот единый класс вихревых образований включает в себя циклоны и антициклоны). Это упрощение было сделано осознанно, чтобы выявить возможность применения SegFormer для выявления вихрей. Для обучения использовались спутниковые изображения видимого диапазона в формате GeoTIFF, каждое из которых сопровождалось маской сегментации, выполненной вручную. Процесс обучения модели был реализован в виде цикла по эпохам с последовательным проходом по обучающим батчам (поднаборам общего набора данных, участвующих в обучении сети). На каждой итерации вычислялись логиты (вероятностные параметры модели), рассчитывалась функция потерь и обновлялись веса модели с помощью оптимизатора AdamW со скоростью обучения $5 \cdot 10^{-5}$ — значение, рекомендованное для дообучения трансформерных архитектур. Обучение проводилось в течение 100 эпох с размером батча 4. Качество обучения контролировалось через метрики precision, recall и mIoU, вычисляемые в бинарном режиме. Для предотвращения переобучения и выбора оптимальной модели сохранялась версия с наилучшим значением mIoU. Для задачи классификации пикселей использовалась функция потерь кросс-энтропия, эффективная при работе с несбалансированными классами (фон и вихрь).

Оценка качества автоматического выделения вихрей алгоритмом SegFormer

Процедура оценки качества работы SegFormer была проведена для 293 валидационных участков акватории (тайлов), не все из которых содержали вихри. Геометрия и методология нарезки тайлов полностью повторяли параметры обучающего набора.




Рис. 4. Примеры автоматической сегментации при пороге бинаризации 0,5. (а), (б), (в) — исходные поля, (з), (д), (е) — соответствующие верхним рисункам маски вихрей по результатам работы алгоритма SegFormer: зеленым (TP — true positive, истинно положительные области) показано пересечение областей, выделенных экспертом и предсказанных моделью, желтым (FN — false negative, ложно отрицательные области) — выделенных экспертом, но не предсказанных моделью, красным (FP — false positive, ложно положительные области) — не выделенных экспертом, но предсказанных моделью. Красными стрелками выделены вихри, не отмеченные экспертом, но выделенные SegFormer, синими стрелками — неявные структуры, не отмеченные ни экспертом, ни алгоритмом SegFormer

Fig. 4. Examples of automatic segmentation with a threshold of 0.5. (a), (б), (в) — original fields; (з), (д), (е) — vortex masks corresponding to the upper figures based on the SegFormer algorithm results: green (TP — true positive) shows the intersection of regions identified by the expert and predicted by the model; yellow (FN — false negative) — identified by the expert but not predicted by the model; red (FP — false positive) — not identified by the expert but predicted by the model. Red arrows highlight vortices not identified by the expert but identified by SegFormer; blue arrows — implicit structures not identified either by the expert or by the SegFormer algorithm

Иллюстрация работы алгоритма для 3 случайно выбранных тайлов приведена на рис. 4. Видно хорошее соответствие областей, выделенных экспертом и нейросетевым алгоритмом. При этом наличие помех в виде близкой облачности не повлияло на качество сегментации (рис. 4а–з). В последнем столбце (рис. 4д–е) алгоритмом SegFormer было выделено 2 вихря (отмечены красными стрелками), которые были пропущены экспертом. В то же время неявные структуры, вихревая природа которых неочевидна, алгоритмом были классифицированы как фон (отмечены синими стрелками рис. 4д–е).

Для оценки качества сегментации использовался комплекс метрик, охватывающих степень перекрытия предсказанных масок с эталонной разметкой.

Метрика *Accuracy* позволяет оценить общее количество верно предсказанных пикселей, без учета их общего объема и вклада ошибочных предсказаний:

$$Accuracy(A, B) = \frac{1}{n} \sum_{i=0}^n (A_i = B_i),$$

где A — аннотированная область вихря, B — область вихря, выделенная с помощью SegFormer для вихря i , n — количество вихрей.

Метрика *Precision* позволяет рассчитать, сколько из пикселей, отнесенных нейросетью к интересующему классу, были предсказаны верно (true positive — TP), с учетом ошибочно предсказанных пикселей (false positive — FP):

$$Precision = \frac{TP}{TP+FP}.$$

Для учета непредсказанных пикселей (false negative — FN), являющихся пикселями интересующего класса, но ошибочно не отнесенных нейросетью к этому классу, используется метрика *Recall*:

$$Recall = \frac{TP}{TP+FN}.$$

На основе опыта оценки качества при решении задач семантической сегментации [37] наиболее полную информацию несет коэффициент *Dice (DSC, или F1 Score)* [38] и метрика *Intersection of Union (IoU, или индекс Жаккара)*, которые связаны между собой:

$$DSC = \frac{2 * Precision * Recall}{Precision + Recall}$$

$$IoU = \frac{|A \cap B|}{|A \cup B|} = \frac{2 * |A \cap B|}{|A| + |B|} = \frac{F1}{2 - F1}.$$

Средние значения метрик на валидационном наборе данных при стандартном пороге бинаризации 0,5 (алгоритм относит пиксель к классу «вихрь», если полученная при расчетах SegFormer вероятность отнесения объекта к классу «вихрь» превышает 50 %) указывают на высокое качество разработанного алгоритма (см. таблицу).

Незначительный дисбаланс между метриками *Precision* (0,94) и *Recall* (0,91) свидетельствует, что модель демонстрирует склонность к некоторой недооценке площади вихрей. Полученные высокие (порядка 0,9) значения *Dice* и *IoU* указывают на значительное перекрытие между предсказанными алгоритмом и выделенными экспертом областями вихрей, что говорит о высокой точности разработанного алгоритма в обнаружении основных структур.

Таблица

Метрики качества автоматического выделения вихрей алгоритмом SegFormer

Table

Quality metrics for automatic eddy detection with SegFormer

Метрика	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>Dice Score (F1)</i>	<i>IoU (Jaccard Index)</i>
Значение	0,98	0,94	0,91	0,93	0,87

Выводы

Таким образом, реализован эффективный алгоритм автоматического выделения океанических вихрей на основе спутниковых данных цвета океана, полученных с мультиспектрального сканера OLCI спутника Sentinel-3 на основе метода глубокого машинного обучения SegFormer. SegFormer продемонстрировал высокое качество сегментации, что подтверждается высокими значениями метрик качества: $DSC = 0,93$, $IoU = 0,87$, $Accuracy = 0,98$. На валидационном наборе данных, содержащем 242 визуально идентифицированных вихря, алгоритм успешно обнаружил 200 объектов. Это говорит о возможности эффективного применения архитектуры трансформеров для задачи выделения вихрей в данных дистанционного зондирования океана в видимом диапазоне. Дальнейшая модификация алгоритма будет основана на разработке многоклассовой модели сегментации, способной дифференцировать различные типы вихревых структур (циклоны, антициклоны, диполи), что позволит проводить более детальный анализ динамики вихревых процессов.

Основным естественным ограничением исследований вихрей по снимкам видимого диапазона является облачность. Нами показано, что даже для района Норвежского моря, характеризующегося одним из наиболее высоких значений среднегодовой оптической плотности облаков в полярных и субполярных районах [32], в месяц удается получить несколько изображений, охватывающих большую часть моря, что делает задачу автоматического выделения вихрей важным вкладом в формирование более достоверной статистики характеристик вихрей, чем могла бы быть получена только по данным РЛИ.

Реализация разработанного алгоритма позволит в будущем получить репрезентативные статистики вихрей в поле хлорофилла для различных районов Северного Ледовитого океана. Наличие таких альтернативных данных со сравнимым с РЛИ пространственным разрешением позволит полнее оценить репрезентативность данных РЛИ, для которых ранее были разработаны аналогичные алгоритмы, а также получить синергетический эффект. Разработанный алгоритм может быть не только использован для исследования динамики вихрей, но и внедрен в оперативный мониторинг.

Конфликт интересов. Авторы декларируют отсутствие конфликта интересов.

Финансирование. Исследование выполнено при финансовой поддержке гранта СПбГУ № 129659573.

Competing interests. The authors have declared that there are no competing interests.

Funding. The research is funded by the SPbSU project № 129659573.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Wunsch C., Ferrari R. Vertical mixing, energy, and the general circulation of the oceans. *Annual Review of Fluid Mechanics*. 2004;36(1):281–314. <https://doi.org/10.1146/annurev.fluid.36.050802.122121>
2. Koshlyakov M.N., Tarakanov R.Y. Water transport across the subantarctic front and the global ocean conveyor belt. *Oceanology*. 2011;51:721–735. <https://doi.org/10.1134/S0001437011050110>
3. Meneghello G., Marshall J., Cole S.T., Timmermans M.L. Observational inferences of lateral eddy diffusivity in the halocline of the Beaufort Gyre. *Geophysical Research Letters*. 2017;44(24):12–331. <https://doi.org/10.1002/2017gl075126>
4. Meneghello G., Marshall J., Campin J.M., Doddridge E., Timmermans M.L. The ice-ocean governor: Ice-ocean stress feedback limits Beaufort Gyre spin-up. *Geophysical Research Letters*. 2018;45(20):11–293. <https://doi.org/10.1029/2018GL080171>
5. Bashmachnikov I.L., Raj R.P., Golubkin P., Kozlov I.E. Heat transport by mesoscale eddies in the Norwegian and Greenland seas. *Journal of Geophysical Research: Oceans*. 2023;128(2):e2022JC018987. <https://doi.org/10.1029/2022JC018987>

6. Klein P., Lapeyre G. The oceanic vertical pump induced by mesoscale and submesoscale turbulence. *Annual Review of Marine Science*. 2009;1(1):351–375. <https://doi.org/10.1146/annurev.marine.010908.163704>
7. Gaube P., Chelton D.B., Strutton P.G., Behrenfeld M.J. Satellite observations of chlorophyll, phytoplankton biomass, and Ekman pumping in nonlinear mesoscale eddies. *Journal of Geophysical Research: Oceans*. 2013;118(12):6349–6370. <https://doi.org/10.1002/2013JC009027>
8. Chelton D.B., Schlax M.G., Samelson R.M. Global observations of nonlinear mesoscale eddies. *Progress in Oceanography*. 2011;91(2):167–216. <https://doi.org/10.1016/j.pocean.2011.01.002>
9. Kubryakov A., Kozlov I., Manucharyan G. Large mesoscale eddies in the Western Arctic Ocean from satellite altimetry measurements. *Journal of Geophysical Research: Oceans*. 2021;126(5):e2020JC016670. <https://doi.org/10.1029/2020JC016670>
10. Atadzhanova O.A., Zimin A.V., Romanenkov D.A., Kozlov I.E. Satellite radar observations of small eddies in the White, Barents and Kara Seas. *Physical Oceanography*. 2017;2:75–83. <https://doi.org/10.22449/1573-160X-2017-2-75-83>
11. Bashmachnikov I.L., Kozlov I.E., Petrenko L.A., Glok N.I., Wekerle C. Eddies in the North Greenland Sea and Fram Strait from satellite altimetry, SAR and high-resolution model data. *Journal of Geophysical Research: Oceans*. 2020;125(7):e2019JC015832. <https://doi.org/10.1029/2019JC015832>
12. Morozov E.A., Kozlov I.E. Eddies in the Arctic Ocean revealed from MODIS optical imagery. *Remote Sensing*. 2023;15(6):1608. <https://doi.org/10.3390/rs15061608>
13. Ivanov A.Y., Ginzburg A.I. Oceanic eddies in synthetic aperture radar images. *Journal of Earth System Science*. 2002;111(3):281–295. <https://doi.org/10.1007/BF02701974>
14. Johannessen J.A., Kudryavtsev V., Akimov D., Eldevik T., Winther N., Chapron B. On radar imaging of current features: 2. Mesoscale eddy and current front detection. *Journal of Geophysical Research: Oceans*. 2005;110(C7). <https://doi.org/10.1029/2004JC002802>
15. Лаврова О.Ю., Костяной А.Г., Лебедев С.А., Митягина М.И., Гинзбург А.И., Шеремет Н.А. *Комплексный спутниковый мониторинг морей России*. М.: ИКИ РАН; 2011. 480 с.
16. Kozlov I.E., Artamonova A.V., Manucharyan G.E., Kubryakov A.A. Eddies in the Western Arctic Ocean from spaceborne SAR observations over open ocean and marginal ice zones. *Journal of Geophysical Research: Oceans*. 2019;124(9):6601–6616. <https://doi.org/10.1029/2019JC015113>
17. Zhurbas V., Väli G., Kuzmina N. Rotation of floating particles in submesoscale cyclonic and anticyclonic eddies: a model study for the southeastern Baltic Sea. *Ocean Science*. 2019;15(6):1691–1705. <https://doi.org/10.5194/os-15-1691-2019>
18. Гинзбург А.И., Крек Е.В., Костяной А.Г., Соловьев Д.М. Эволюция мезомасштабного антициклонического вихря и вихревых диполей/мультиполей на его основе в Юго-Восточной Балтике (спутниковая информация: май–июль 2015 г.). *Океанологические исследования*. 2017;45(1):10–22. [https://doi.org/10.29006/1564-2291.JOR-2017.45\(1\).3](https://doi.org/10.29006/1564-2291.JOR-2017.45(1).3)
Ginzburg A.I., Krek E.V., Kostianoy A.G., Solovyev D.M. Evolution of mesoscale anticyclonic vortex and vortex dipoles/multipoles on its base in the south-eastern Baltic (satellite information May–July 2015). *Okeanologicheskie issledovaniya = Journal of Oceanological Research*. 2017;45:10–22. (In Russ.). [https://doi.org/10.29006/1564-2291.JOR-2017.45\(1\).3](https://doi.org/10.29006/1564-2291.JOR-2017.45(1).3)
19. Новикова Ю.С., Башмачников И.Л. Вихри Лофотенской котловины по данным спутниковой альтиметрии, изображениям в радиолокационном и видимом диапазонах. В: *Моря России: Год науки и технологий в РФ — Десятилетие наук об океане ООН. Тезисы докладов Всероссийской научной конференции. Севастополь, 2021*. Севастополь: ФИЦ МГИ; 2021. С. 291–292.
20. Федоров К.Н., Гинзбург А.И. Грибовидные течения (вихревые диполи) — одна из наиболее распространенных форм когерентных движений в океане. В: *Когерентные структуры и самоорганизация океанских движений*. Баренблатт Г.И. (ред.). М.: Наука; 1992. С.12–20.
21. Munk W., Armi L., Fischer K., Zachariasen F. Spirals on the sea. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*. 2000;456(1997):1217–1280. <https://doi.org/10.1098/rspa.2000.0560>

22. Xu G., Dong C., Liu Y., Gaube P., Yang J. Chlorophyll rings around ocean eddies in the North Pacific. *Scientific Reports*. 2019;9(1):2056. <https://doi.org/10.1038/s41598-018-38457-8>
23. Башмачников И.Л., Белonenko Т.В., Куйбин П.А. Приложение теории колоннообразных Q-вихрей с винтовой структурой к описанию динамических характеристик Лофотенского вихря Норвежского моря. *Вестник Санкт-Петербургского университета. Науки о Земле*. 2017;(3):221–236. <https://doi.org/10.21638/11701/spbu07.2017.301>
24. Siegelman L., Klein P., Rivière P., Thompson A.F., Torres H.S., Flexas M., Menemenlis D. Enhanced upward heat transport at deep submesoscale ocean fronts. *Nature Geoscience*. 2020;13(1):50–55. <https://doi.org/10.1038/s41561-019-0489-1>
25. Calil P., Richards K. Transient upwelling hot spots in the oligotrophic North Pacific. *Journal of Geophysical Research: Oceans*. 2010;115(C2). <https://doi.org/10.1029/2009JC005360>
26. Xia L., Chen G., Chen X., Ge L., Huang B. Submesoscale oceanic eddy detection in SAR images using context and edge association network. *Frontiers in Marine Science*. 2022;9:1023624. <https://doi.org/10.3389/fmars.2022.1023624>
27. Xu M., Li H., Yun Y., Yang F., Li C. End-to-end pixel-wisely detection of oceanic eddy on SAR images with stacked attention network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2023;16:9711–9724. <https://doi.org/10.1109/JSTARS.2023.3322404>
28. Zhang D., Gade M., Wang W., Zhou H. EddyDet: A deep framework for oceanic eddy detection in synthetic aperture radar images. *Remote Sensing*. 2023;15(19):4752. <https://doi.org/10.3390/rs15194752>
29. Zi N., Li X.M., Gade M., Fu H., Min S. Ocean eddy detection based on YOLO deep learning algorithm by synthetic aperture radar data. *Remote Sensing of Environment*. 2024;307:114139. <https://doi.org/10.1016/j.rse.2024.114139>
30. Sandalyuk N., Khachatryan E. Automatic eddy detection in the MIZ based on YOLO algorithm and SAR images. *Science of Remote Sensing*. 2025;100228. <https://doi.org/10.1016/j.srs.2025.100228>
31. Raj R., Johannessen J., Eldevik T., Nilsen J., Halo I. Quantifying mesoscale eddies in the Lofoten Basin. *Journal of Geophysical Research: Oceans*. 2016;121(7):4503–4521. <https://doi.org/10.1002/2016JC011637>
32. Zhang M., Xie S., Liu X., Lin W., Zheng X., Golaz J.C., Zhang Y. Cloud phase simulation at high latitudes in EAMv2: Evaluation using CALIPSO observations and comparison with EAMv1. *Journal of Geophysical Research: Atmospheres*. 2022;127:e2022JD037100. <https://doi.org/10.1029/2022JD037100>
33. Schirber M. The full palette of photosynthesis. *Astrobiology at NASA*. October 25, 2013. Available at: <https://astrobiology.nasa.gov/news/the-full-palette-of-photosynthesis/> (accessed 20.09.2025).
34. Koszalka I., LaCasce J., Andersson M., Orvik K., Mauritzen C. Surface circulation in the Nordic Seas from clustered drifters. *Deep Sea Research Part I: Oceanographic Research Papers*. 2011;58(4):468–485. <https://doi.org/10.1016/j.dsr.2011.01.007>
35. Belonenko T.V., Travkin V.S., Koldunov A.V., Volkov D.L. Topographic experiments over dynamical processes in the Norwegian Sea. *Russian Journal of Earth Science*. 2021;21(1):ES1006. <https://doi.org/10.2205/2020ES000747>
36. Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J.M., Luo P. SegFormer: Simple and efficient design for semantic segmentation with transformers. *Advances in Neural Information Processing Systems*. 2021;34:12077–12090.
37. Maier-Hein L., Eisenmann M., Reinke A. et al. Why rankings of biomedical image analysis competitions should be interpreted with care. *Nature Communications*. 2018;9(1):5217. <https://doi.org/10.1038/s41467-018-07619-7>
38. Dice L.R. Measures of the amount of ecologic association between species. *Ecology*. 1945;26(3):297–302. <https://doi.org/10.2307/1932409>