

## ОЦЕНКА СРЕДНЕГО ПЕРИОДА ВЕТРОВОГО ВОЛНЕНИЯ ПО ЕДИНИЧНЫМ СНИМКАМ СУДОВОГО НАВИГАЦИОННОГО РАДАРА С ПРИМЕНЕНИЕМ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ

В. А. Голиков<sup>1,2</sup>, М. А. Криницкий<sup>1,2</sup>, Н. Д. Тилинина<sup>1</sup>

<sup>1</sup> *Институт океанологии им. П. П. Ширшова РАН,  
Россия, 117997, Москва, Нахимовский проспект, д. 36;*

<sup>2</sup> *Московский физико-технический институт  
(национальный исследовательский университет),  
Россия, 141701, Долгопрудный, Институтский пер., д. 9,  
e-mail: [golikov.va@phystech.edu](mailto:golikov.va@phystech.edu)*

В настоящей работе представлен метод оценки среднего периода ветрового волнения по данным судового навигационного радара в подходе глубокого обучения. В работе применяется сверточная нейронная сеть на основе ResNet, обрабатывающая единичные предобработанные радарные изображения. Модель оптимизируется на данных периода ветрового волнения, полученных с волномерного Spotter буя в нескольких научных экспедициях. Для оценки качества работы модели рассчитаны среднеквадратичные отклонения и коэффициент детерминации между оценками нейросети и измерениями с буя на отложенной выборке. Результаты демонстрируют применимость нейронных сетей для оценки периода волнения на основе данных мгновенных радарных снимков.

**Ключевые слова:** нейронные сети, ветровое волнение, судовый навигационный радар, радарное изображение, период волнения

### Введение

Морские радары X-диапазона являются важнейшими инструментами для навигации и обеспечения безопасности судов, работающих в открытом океане и в портах. В литературе показано, что из цифровых изображений радарного сигнала, отраженного от поверхности моря, можно извлечь различные значимые данные: характеристики океанских волн (Young et al., 1985), поверхностные течения (Ivonin et al., 2011; Campana et al., 2017; Lund et al., 2020), разливы нефти на поверхности океана (Li et al., 2022), карты льда (Fujiyoshi et al., 2013), дрейф льда (Lund et al., 2018), реконструированный приповерхностный ветер (Chen et al., 2015). Более того, эти параметры поверхности океана могут использоваться для расчета волновой климатологии в глобальном масштабе, как, например, в Глобальном атласе океанских волн (<http://www.sail.msk.ru/atlas/>), основанном на данных программы судов добровольного наблюдения Всемирной метеорологической организации (VOS, <https://www.vos.noaa.gov/>).

Океанские волны становятся видимыми на радарных изображениях поверхности океана при скоростях ветра выше 3 м/с, когда рябь на поверхности достаточно

развита, чтобы рассеивать электромагнитные сигналы, излучаемые передатчиком радара в режиме Брэгговского рассеяния (Hatten et al., 1998). Для оценки различных волновых характеристик по таким радарным изображениям существует обширный набор методов. Традиционный подход к оценке параметров океанских волн на основе серии изображений радарного сигнала использует трехмерный Фурье-анализ и линейное дисперсионное соотношение для отделения волнового сигнала от фонового шума (Young et al., 1985). В (Nieto-Borge et al., 2004) интенсивность радарного рассеяния предварительно переводится в высоту морской поверхности, из которой затем извлекаются остальные волновые характеристики. Также существует метод, основанный на оценке соотношения сигнал–шум (Nieto-Borge et al., 2008), который, однако, использует передаточную модулирующую функцию и калибровочные коэффициенты, индивидуальные для каждой радарной антенны и требующие эмпирической настройки (Borge et al., 1999). В (Ermoshkin, Kapustin, 2019) показана возможность восстановления спектров ветровых волн по данным когерентного радиолокационного зондирования на основе метода разности фазовых углов. Ряд коммерческих и научных команд внедрила эти методы для мониторинга ветрового волнения в реальном времени: WaMoS II (Borge et al., 1999), MIROS (Gangeskar, 2000), SeaDarQ (Greenwood et al., 2018), WaveFinder (Park et al., 2006), когерентный на прием радар Центра Гельмгольца Hereon (Horstmann et al., 2021) и SeaVision (Tilinina et al., 2022).

Методы машинного обучения также продемонстрировали свои возможности в оценке параметров океанских волн. В отличие от традиционных подходов, требующих калибровки под каждую отдельную антенну, в машинном обучении при наличии достаточного количества разнообразных данных потенциально возможно преодолеть это ограничение. Vicen-Bueno et al. (2012) показали несколько более высокую точность искусственной нейронной сети в определении значимой высоты волны по сравнению с традиционным подходом, основанным на анализе соотношения сигнал–шум. В настоящее время основное ограничение при использовании нейронных сетей заключается в необходимости наличия большого обучающего подмножества различных условий волнения для тренировки нейронной сети. Ludeno, Serafino (2019) предложили метод для генерации синтетических данных, имитирующих радарные изображения взволнованной морской поверхности с известными характеристиками. На основе этой работы в (Rezvoov et al., 2024) реализован алгоритм предварительного обучения нейросети на синтетических радарных снимках с последующим дообучением на реальных данных.

По мере развития методов машинного обучения различные модели продемонстрировали свою эффективность в обработке радарных изображений для оценки параметров океанских волн: (Cornejo-Bueno et al., 2016; Kumar et al., 2017; Mahjoobi et al., 2009; Elbisy et al., 2015) использовали метод опорных векторов (SVM), (Salcedo-Sanz et al., 2015), (Cornejo-Bueno et al., 2016) применяли регрессию на основе опорных векторов (SVR) на базе анализа затененных изображений. В современных исследованиях также применяются и модели типа искусственных нейронных сетей. Один из типов используемых нейросетей – многослойный перцептрон (MLP).

Пример применения нейронной сети MLP для анализа радарных изображений для определения параметров волн был продемонстрирован (Vicen-Bueno et al., 2012; Cornejo-Bueno et al., 2016) на основе данных с радаров, установленных на нефтяных платформах. Отдельным направлением исследований является применение методов машинного обучения и нейросетей в задачах ассимиляции данных ветрового волнения. Например, в работе (Whale et al., 2015) авторы продемонстрировали применимость нейронных сетей для ассимиляции данных региональных моделей волн в сочетании с данными высокочастотных радаров для успешного прогнозирования параметров ветрового волнения в реальном времени. Основным недостатком вышеперечисленных моделей является их неумение извлекать пространственные корреляции из изображений.

В то же время еще один тип искусственных нейронных сетей – сверточные нейронные сети (CNN) – показал свою эффективность в широком спектре задач наук о Земле, сопряженных с распознаванием образов на изображениях и других сеточных массивах данных, распределенных в пространстве. Choi et al. (2020) продемонстрировали применение CNN для оценки значимой высоты волны (SWH) в реальном времени на основе серии реальных оптических фотоснимков океана. Xue et al. (2020) для оценки SWH использовали изображения с радара с синтетической апертурой Sentinel-1 (SAR). Duan et al. (2020) с помощью CNN извлекали характеристики волнения из синтетических радарных изображений. В работах (Chen et al., 2021; Wei et al., 2021) оценивали SWH, используя комбинацию сверточных и рекуррентных нейронных сетей, что позволяло работать с последовательностями радарных снимков. Huang et al. (2021) перед обработкой пространственно-временных последовательностей радарных изображений извлекали из них дополнительные параметры, такие как отношение сигнал/шум на радарных изображениях и эмпирическое разложение ансамбля. Такие гибридные подходы продемонстрировали улучшенную производительность по сравнению с отдельными нейронными сетями и классическими спектральными методами. В (Zuo et al., 2024) для оценки периода ветрового волнения и SWH последовательность радарных снимков обрабатывается комбинацией сверточной нейронной сети для извлечения пространственных характеристик изображений и механизма внимания для эффективной работы с временными последовательностями.

В настоящей статье мы применяем глубокую сверточную нейронную сеть на основе ResNet50, аналогичную представленной в (Krinitskiy et al., 2023), к большой базе данных радарных изображений взволнованной морской поверхности для оценки среднего периода ветрового волнения. Основываясь на допущении о стационарности волновых характеристик на небольшом промежутке времени, мы разработали метод оценки среднего периода волнения не по последовательности радарных изображений, а по единичным снимкам. В отличие от других исследований, мы собрали набор данных, включающий как радарные изображения поверхности океана, так и одновременные измерения параметров волн на месте в более, чем четырех научных экспедициях, охватывающих более 82 местоположений и содержащих около

95.000 изображений, а также более 62 часов непрерывных наблюдений с использованием волномерного буя Spotter. Набор данных параметров волн, записанных бую Spotter и рассчитанных по радарным изображениям с использованием спектральных методологий, доступен на PANGAEA (Gavrikov et al., 2021) для первых трех экспедиций.

### Сбор данных

Методология сбора данных для настоящего исследования аналогична описанной в работе (Tilina et al., 2022). Мы добавили еще одну исследовательскую экспедицию (в дополнение к трем, упомянутым в (Tilina et al., 2022)) и повторно отобрали данные для использования в рамках применения подхода глубокого обучения. Подробное описание процедур отбора данных и их предобработки представлено в разделе методов. На рисунке 1 показаны маршруты и местоположения измерений четырех научных экспедиций в Атлантическом океане и Северном Ледовитом океане, где были собраны данные радарных снимков, полученные с применением приставки SeaVision, а также сопутствующие показания волномерного буя Spotter. Выбор мест для наблюдений за волнами зависел от местных погодных условий и доступности судового времени. В данной статье и далее под станциями мы подразумеваем места, где проводились наблюдения за ветровыми волнами.

Стратегия наблюдений на каждой станции в этом исследовании предполагала одновременные наблюдения на месте с использованием волнового буя Spotter (<https://www.sofarocan.com/products/spotter>) и запись оцифрованного сигнала навигационного радара X-диапазона в виде изображений морского шума. Волновой буй Spotter измеряет вертикальные и горизонтальные смещения поверхности океана с частотой дискретизации до 2.5 Гц (Raghukumar et al., 2019) и обеспечивает высокоточные оценки характеристик ветровых волн. Эта стратегия позволила нам собрать обучающую выборку для нейронной сети на основе данных волнового буя в диапазоне значимых высот волн от нескольких сантиметров до 4 метров и периодах от 4 до 11 секунд.

SeaVision предоставляет одно стабилизированное по направлению (на север) изображение морского шума за один оборот антенны (примерно одно изображение каждые 2 секунды). Исследовательские суда «Академик Сергей Вавилов» (ASV) и «Академик Иоффе» (AI) оснащены стандартными радарными X-диапазона: JRC JMA-9110-6XA и JMA-9122-6XA, соответственно. Радары установлены на высоте 23 м. Оба радара имеют одинаковые основные характеристики: частота 9.41 ГГц (радиоволна длиной около 3 см), 6-футовая антенна с горизонтальным разрешением по направлению 1.2° и почти идентичные минимальные длины импульсов: 0.08 мкс и 0.07 мкс соответственно. Пространственное разрешение изображений составляет 12 м благодаря режиму «короткого импульса» (SP1) навигационного радара. Изображения хранятся во внешней памяти вместе с GPS-координатами, скоростью относительно земли

(SOG) и курсом относительно земли. Эти файлы позже объединяются и конвертируются в формат NetCDF для последующей обработки. Характеристики радарной антенны, а также подробное описание процесса сбора изображений с помощью системы SeaVision, можно найти в работе (Tilinina et al., 2022).

В общей сложности мы собрали около 95.000 изображений SeaVision и 62 часа одновременных измерений на месте с помощью буя Spotter. В это исследование мы включили только станции с одновременными наблюдениями буя Spotter и SeaVision, хотя полный набор данных включает многочисленные местоположения, где измерения проводились только с помощью SeaVision (рисунок 1).

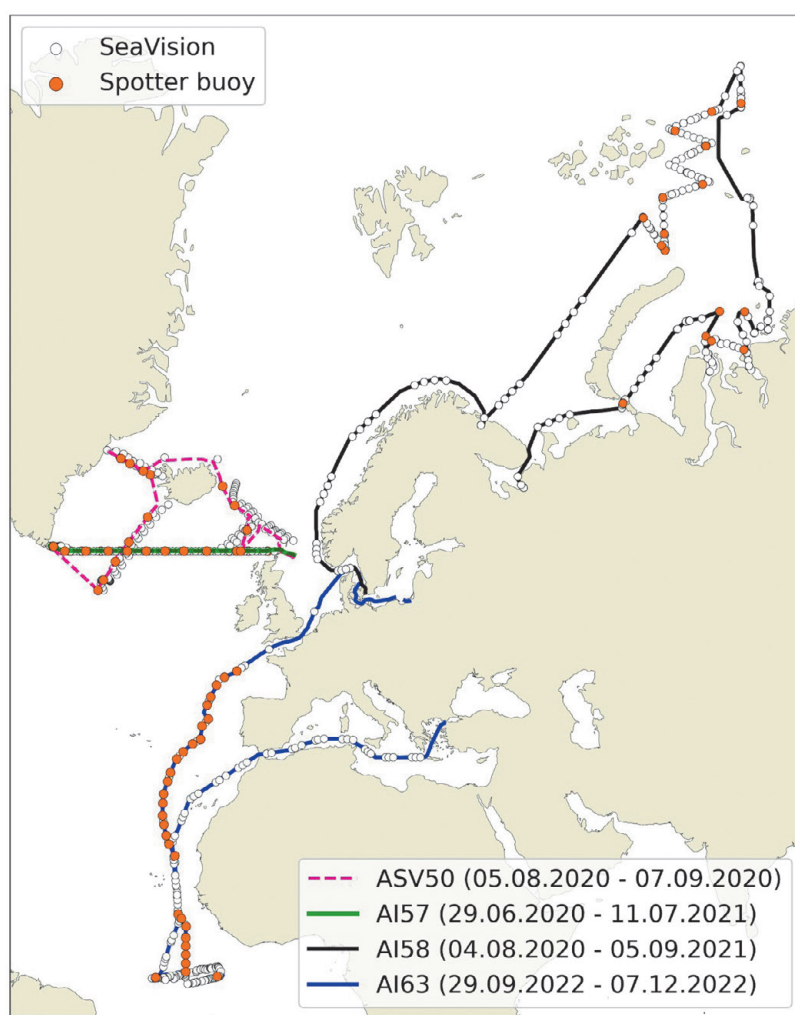


Рис. 1 – Карта маршрутов научных рейсов, в которых собирались данные. В местах, отмеченных белыми точками, собирались данные SeaVision, оранжевыми – SeaVision и Spotter буюм. ASV – НИС «Академик Сергей Вавилов», AI – НИС «Академик Иоффе»

Все четыре экспедиции были проведены Институтом океанологии им. П. П. Ширшова РАН в рамках государственной программы регулярных океанографических наблюдений.



## Методы

### *Предобработка изображений и выбор оптимального сектора*

Оцифрованные изображения морской поверхности синхронизированы по направлению (на север) и представляют собой тензоры, центрированные в местоположении судна – одно изображение примерно каждые 2 секунды (один оборот антенны радара). Эти тензоры записаны в радиальных координатах и имеют размерность  $[t, \varphi, r]$ , где  $t$  обозначает астрономическое время получения изображений (количество радарных изображений на этой станции),  $\varphi$  – угловую координату, а  $r$  – радиальную координату. Физический размер пикселя по оси  $r$  – 1.875 м.

Важно отметить, что в силу физических механизмов рассеяния радиоволн взволнованной водной поверхностью, чувствительных к скорости и направлению ветра, ориентации судна, шероховатости поверхности океана, радиолокационное изображение неравномерно по структуре и интенсивности (см., например, Lyzenga, Walker, 2015). Каждое изображение имеет области, где волновое поле проявляется наиболее четко и области, связанные с радиолокационной тенью, «мертвой зоной», помехами и т. п., которые исключаются из рассмотрения, поскольку не несут полезного сигнала. Под «четкостью» мы понимаем визуальную различимость волновых структур на изображении, которая характеризуется высокой амплитудой изменения интенсивности сигнала. Для радиолокационной тени, наоборот, характерны низкие значения пространственно-временной изменчивости. Поэтому в данной работе мы определяем области с разной степенью информативности сигнала, основываясь на сравнении его временной дисперсии.

Для выделения наиболее информативной части сигнала, во-первых, изображения маскируются в радиусе 300 м вокруг судна), чтобы избежать искажений из-за самого судна. Во-вторых, из оставшейся части изображений мы выделяем сектор в 180 градусов с наиболее информативной частью волнового поля.

Для этого для каждого изображения мы выделяем все снимки в 5-минутном временном интервале, предшествующем моменту соответствующего снимка. Далее мы считаем дисперсию полученного подмассива по времени, находя пространственное распределение дисперсии сигнала размерности  $[\varphi, r]$ . Далее этот массив делится на 64 равных сектора по 5.625 градусов. По каждому сектору считается среднее значение дисперсии (получен массив размера [64]). Чтобы исключить область тени мачты, мы исключаем восемь последовательных секторов с наименьшим средним значением дисперсии. Затем мы определяем 32 последовательных сектора с наивысшим средним значением дисперсии из оставшихся секторов. Наконец, мы выбираем аналогичный сегмент из исходного радарного изображения. Выбор такой широкой области в 180 градусов гарантирует включение сегмента радарного изображения, соответствующего самым хорошо различимым волнам, что позволит обеспечить надежную оценку их параметров.

Наконец, в результате анализа описанных карт дисперсий, было выбрано расстояние в 3500 м, дальше которого временная дисперсия сигнала

значительно затухает. Все значения волновых изображений за этой отметкой также маскируются.

Финальным этапом предобработки данных является интерполяция радарных изображений из полярной системы координат в декартовую и их последующая нормализация. Этот этап необходим, поскольку исходные данные представлены в полярной системе координат, тогда как сверточные нейронные сети ожидают входные данные в виде тензора, определенного в декартовой системе координат. Использование изображений в полярной системе напрямую могло бы привести к геометрическим искажениям, отрицательно влияющим на обучение модели и точность прогнозов.

Чтобы избежать этого, изображения преобразованы в декартовую систему координат с использованием алгоритма интерполяции, обеспечивающего равномерное распределение данных в пространстве. После этого данные были нормализованы – приведены к нулевому среднему и единичному стандартному отклонению. Нормализация данных – стандартная практика в глубоких нейронных сетях, повышающая стабильность их оптимизации (см., например, Goodfellow et al., 2016), что способствует улучшению качества работы модели.

### *Особенности обучения*

Для разработки надежных и эффективных моделей в машинном обучении важно разделить данные на обучающий, тестовый и валидационный наборы. Обучающая выборка используется для непосредственного обучения модели, позволяя ей выявлять закономерности и взаимосвязи в данных. Валидационный набор используется для отбора модели с наилучшей обобщающей способностью и предотвращения переобучения – ситуации, при которой модель чрезмерно адаптируется к обучающим данным, включая шум и случайные зависимости, которые не обобщаются на новые данные. Тестовая выборка предназначена для финальной проверки производительности модели на данных, которые она ранее не видела, что позволяет объективно оценить ее способность обобщать знания на реальные сценарии.

В настоящей работе особое внимание уделено разбиению исходных данных на тренировочную, тестовую и валидационную выборки, чтобы данные в них были максимально нескоррелированы и отражали при этом общую картину всего набора данных.

Во-первых, данные для обучения собирались на нескольких станциях, причем каждая станция предоставляла измерения в определенный временной интервал. Поскольку измерения, выполненные на одной станции, могут быть сильно коррелированы из-за их временной близости, разбиение данных проводилось на уровне станций, а не отдельных измерений. Это означает, что все данные, относящиеся к одной станции, полностью включались только в одну из выборок – тренировочную, тестовую или валидационную. Такой подход позволяет избежать утечки информации между выборками и гарантирует независимость данных для проверки и обучения модели.

Во-вторых, рисунок 2 иллюстрирует распределение целевой переменной – усредненного в 10-минутном окне периода ветрового волнения – во всем исходном наборе данных. Данные распределены неравномерно, что могло бы затруднить оценку качества модели или привести к неточной оценке ее устойчивости. Это связано с тем, что при неудачном разбиении в какую-либо из выборок могут не попасть редко встречающиеся значения целевой переменной, что приведет либо к недообучению, если редкие значения не попадут в тренировочную выборку, либо к неполной оценке качества на этих редких примерах, если они не попадут в валидационную или тестовую выборки.

Для обеспечения репрезентативности выборок и достоверности результатов разбиение данных выполнялось с использованием стратифицированного подхода, который формирует тренировочную валидационную и тестовую выборки с одинаковым распределением целевой переменной. Для реализации этого подхода использовалась функция `StratifiedShuffleSplit` из библиотеки `scikit-learn` (Pedregosa et al., 2011).

Наконец, итоговое разбиение данных, включая распределение целевой переменной в каждой выборке, представлено на рисунке 2. Для построения этого распределения использовался объединенный набор данных, включающий измерения со всех станций. Слева размещен график для отдельных измерений, справа эти измерения усреднены по станциям. Видно, что хвосты распределений присутствуют во всех трех выборках.




Рис. 2 – Распределение данных по периоду волнения: **а** – по измерениям; **б** – по станциям

### *Используемая модель*

Для оценки среднего периода ветрового волнения в нашей работе используется одна из самых распространенных моделей в задачах компьютерного зрения – сверточная нейронная сеть ResNet (He, 2016) в конфигурации ResNet50. Благодаря остаточным слоям ResNet способен эффективно масштабироваться на большом количестве данных для достижения передовых результатов в различных задачах компьютерного зрения, от регрессии и классификации до сегментации изображений.



ResNet50 является одной из наиболее эффективных сверточных нейронных сетей для обработки изображений, которая была взята за отправную точку для разработки нашей модели. Однако, изначально авторами ResNet обучался на данных трехканальных RGB изображений, тензорами вида  $[c, h, w]$ , где  $c$  – три цветовых канала, а  $h, w$  – размер входного изображения. В нашей работе число входных каналов варьируется: изначально изображения радарных данных являются одноканальными (с размером  $[1, h, w]$ ). Затем на входном слое и на части скрытых слоев нейросети добавляется 2 канала в случае, если мы используем позиционное кодирование, описанное в следующем разделе. Такой слой имеет тот же размер ядра, шаг и отступ свертки что и в оригинальной ResNet50, но принимает измененное число входных каналов.

Для решения задачи регрессии выходной слой классификатора ResNet50 был заменен полносвязной нейронной головой, которая принимает выходные признаки сверточной сети и выдает прогноз целевой переменной – среднего периода ветрового волнения. Наконец, классическая функция активации ReLu была заменена на более совершенную Mish (Misra, 2020).

### *Позиционное кодирование*

Операция свертки обладает свойством эквивариантности к преобразованию переноса. Это означает, что результат ее применения зависит только от взаимного расположения элементов данных, но не от их абсолютного положения в пространстве изображения. Это свойство обеспечивает одинаковую обработку всех областей изображения, что является преимуществом в задачах, где абсолютное положение элементов не имеет существенного значения. Однако для геофизических данных, характеризующихся выраженными пространственными зависимостями, одинаковая обработка всех участков может быть нежелательной, поскольку одна и та же характеристика может принимать разные значения в зависимости от ее географического расположения. Для борьбы с этим свойством существуют различные методы позиционного кодирования, в которых фильтрам свертки (или другим архитектурам с идентичной проблемой) сообщается информация об их текущем местоположении (Liu, 2018; Vaswani, 2017). В настоящей работе позиционное кодирование задается двумерными полями гармонических функций с различными частотами в направлениях  $x$  и  $y$ , которые посредством конкатенации дополняют входные в слои нейронной сети тензоры. Эти изображения создаются путем применения синусоидальных и косинусоидальных функций по вертикальным ( $h$ ) и горизонтальным ( $w$ ) измерениям входа. Мы генерируем две группы изображений для каждой оси, каждая для  $d$  различных частот. Изменяя частоту, мы создаем разнообразный набор периодических изображений, которые объединяются с входным вектором и подаются сверточным слоям нейронной сети. Этот шаг позволяет модели лучше улавливать локальные пространственные характеристики изображений.

### *Аугментация данных*

Модель ResNet50 является достаточно высокопараметризованной моделью (порядка 25 миллионов обучаемых весов), склонной к переобучению, когда модель слишком хорошо подстраивается под обучающие данные и имеет посредственное качество на новых, невидимых ранее данных. Одним из эффективных способов избежать переобучения является аугментация данных, которая увеличивает разнообразие обучающего набора, искусственно создавая дополнительные примеры на основе исходных данных, посредством их небольших случайных преобразований. Выбор способов аугментации зависит от особенностей задачи и может включать различные преобразования изображений, такие как вращение, отражение, изменение яркости и контрастности, случайное обрезание и масштабирование. Эти методы помогают сделать модель более устойчивой к изменениям и шумам в данных, улучшая ее способность к обобщению и снижая вероятность того, что она будет подстраиваться под случайные шумы или несущественные детали, присутствующие в обучающем наборе.

Поскольку чрезмерное искажение входных данных может помешать модели оценить целевую характеристику, в данной работе мы ограничиваемся применением в качестве аугментаций сглаженного низкочастотного аддитивного гауссовского шума и небольших аффинных преобразований (поворот на первые градусы и сдвиг). Под сглаженным низкочастотным шумом подразумевается шум, сгенерированный в размерности 10 на 10 пикселей и интерполированный до размера входного изображения.

### **Результаты**

Для оценки качества обученной модели использовались метрики среднеквадратичного отклонения (RMSE) и коэффициента детерминации ( $R^2$ ), которые позволяют количественно определить точность среднего 10-минутного периода ветрового волнения, измеряемого волновым бумом Spotter. Период определяется как обратная величина центра масс спектра энергии волнения с усреднением по временным интервалам в 10 минут.

Результаты показали, что среднеквадратичная ошибка модели составляет 1.18 секунды, а коэффициент детерминации ( $R^2$ ) равен 0.61. Хотя  $R^2$  находится на нижнем пороге достоверности, он подтверждает наличие корреляции между оценкой модели и измерениями буя. Эти показатели свидетельствуют о том, что предложенный метод способен оценивать временную характеристику волнения с приемлемой точностью даже на основе единичных радарных изображений.

На рисунке 3 представлена диаграмма рассеяния оцененных моделью и измеренных значений, сглаженная методом ядерной оценки плотности (Wascom, 2021). Анализ диаграммы показал стабильную работу модели для большинства диапазонов

значений периода волнения. Однако при значениях, превышающих 10 секунд, наблюдается тенденция к занижению модельной оценки, что, вероятно, связано с ограниченным количеством таких случаев в обучающих данных.

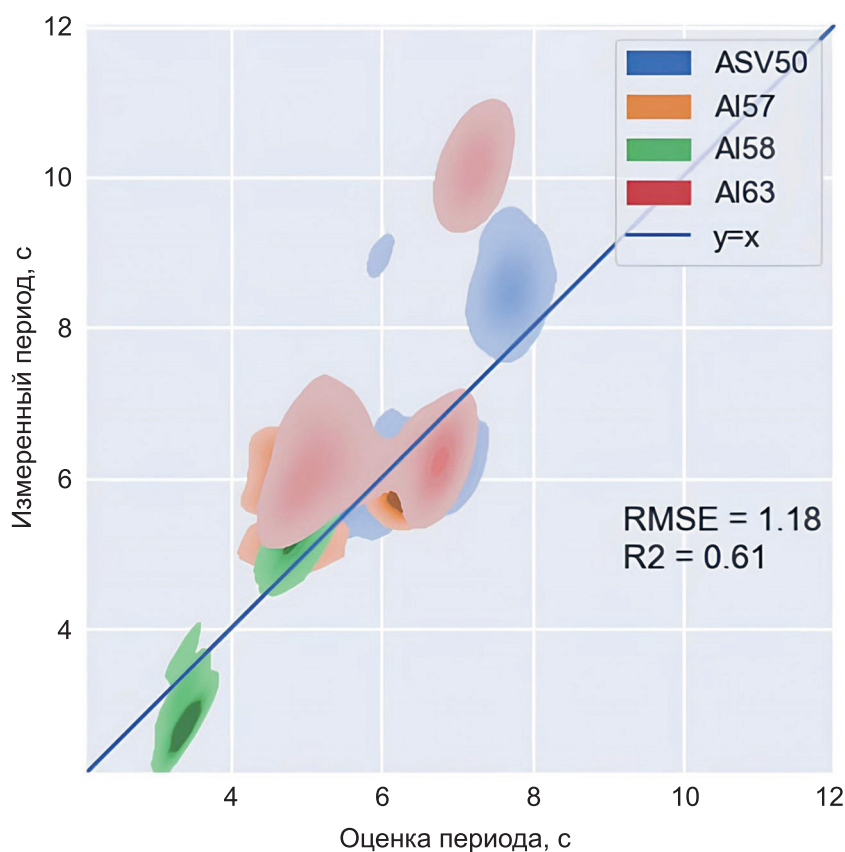


Рис. 3 – Сравнение измеренного периода волнения и результата работы нейросети на тестовой выборке. На рисунке изображены сглаженные распределения тестовых примеров. Интенсивность цвета отражает плотность распределения

Таким образом, полученные результаты демонстрируют, что предложенная архитектура нейронной сети и подходы к предобработке данных обеспечивают высокую точность оценки периода ветрового волнения, что делает этот метод перспективным для использования в реальном времени на борту судов для оперативной оценки параметров волнения.

### Заключение

В данной работе представлен новый подход для оценки среднего 10-минутного периода ветрового волнения на основе пространственных радарных изображений морской поверхности с использованием методов глубокого обучения. Основное преимущество предложенного подхода заключается в способности нейронной сети эффективно обрабатывать сложные визуальные паттерны радарных изображений и

предоставлять оценку временных характеристик волнения без необходимости в последовательности временных данных.

Результаты экспериментов показали, что, несмотря на отсутствие временной последовательности изображений, предложенная модель способна оценивать период волнения с приемлемым качеством. Это открывает возможность использования метода в условиях ограниченности данных. Например, этот подход может применяться для оперативного мониторинга волновой обстановки в реальных условиях, особенно на этапе, когда радаром еще не была собрана последовательность снимков, достаточная для применения более точных алгоритмов – классических либо нейросетевых.

Тем не менее, метод имеет ограничения. В частности, при экстремальных условиях наблюдается занижение модельной оценки периода волнения, что указывает на необходимость расширения обучающей выборки. В будущем планируется развивать модель для повышения ее устойчивости в различных географических регионах и волновых условиях. Дополнительно будут изучены подходы для анализа неопределенности результатов нейросетевой оценки среднего периода ветровых волн, что позволит повысить доверие к результатам модели и улучшить ее интеграцию в реальные приложения.

Перспективным направлением развития является также применение предложенного подхода для прогнозирования других океанографических параметров, что может стать следующим шагом в исследовании.

**Благодарности.** Разведочный анализ данных, сбор и гармонизация исходных данных исследования выполнены в рамках Госзадания № FMWE-2022-0002. Разработка, оптимизация и исследование нейросетевого алгоритма выполнены в рамках Соглашения № 075-03-2024-117 от 17.01.2024 Московского физико-технического института. Эксперименты по подбору архитектуры нейросети проведены при поддержке стратегического проекта «Исследовательское лидерство (от бакалавра до нобелевского лауреата)» программы «Приоритет-2030» Московского физико-технического института.

### Список литературы

1. *Borge J. C. N., Reichert K., Dittmer J.* Use of nautical radar as a wave monitoring instrument // Coastal Engineering. 1999. Vol. 37. P. 331. [https://doi.org/10.1016/S0378-3839\(99\)00032-0](https://doi.org/10.1016/S0378-3839(99)00032-0).
2. *Campana J., Terrill E. J., de Paolo T.* A New Inversion Method to Obtain Upper-Ocean Current-Depth Profiles Using X-Band Observations of Deep-Water Waves // Journal of Atmospheric and Oceanic Technology. 2017. Vol. 34. P. 957. <https://doi.org/10.1175/JTECH-D-16-0120.1>.
3. *Chen Z., He Y., Yang W.* Study of Ocean Waves Measured by Collocated HH and VV Polarized X-Band Marine Radars // International Journal of Antennas and Propagation. 2016. Vol. 2016. P. 1. <https://doi.org/10.1155/2016/8257930>.
4. *Chen Z., He Y., Zhang B., Qiu Z.* Determination of nearshore sea surface wind vector from marine X-band radar images // Ocean Engineering. 2015. Vol. 96. P. 79. <https://doi.org/10.1016/j.oceaneng.2014.12.019>.

5. *Cornejo-Bueno L., Nieto Borge J. C., Alexandre E., Hessner K., Salcedo-Sanz S.* Accurate estimation of significant wave height with Support Vector Regression algorithms and marine radar images // *Coastal Engineering*. 2016. Vol. 114. P. 233. <https://doi.org/10.1016/j.coastaleng.2016.04.007>.
6. *Duan W., Yang K., Huang L., Ma X.* Numerical Investigations on Wave Remote Sensing from Synthetic X-Band Radar Sea Clutter Images by Using Deep Convolutional Neural Networks // *Remote Sensing*. 2020. Vol. 12. P. 1117. <https://doi.org/10.3390/rs12071117>.
7. *Elbisy M. S.* Sea Wave Parameters Prediction by Support Vector Machine Using a Genetic Algorithm // *Journal of Coastal Research*. 2015. Vol. 314. P. 892. <https://doi.org/10.2112/JCOASTRES-D-13-00087.1>.
8. *Ermoshkin A. V., Kapustin I. A.* Estimation of the wind-driven wave spectrum using a high spatial resolution coherent radar // *Russ. J. Earth Sci.* 2019. Vol. 19. P. 1. <https://doi.org/10.2205/2019ES000662>.
9. *Fujiyoshi Y., Osumi K., Ohi M., Yamada Y.* Sea Ice Identification and Derivation of Its Velocity Field by X-Band Doppler Radar // *Journal of Atmospheric and Oceanic Technology*. 2013. Vol. 30. P. 1240. <https://doi.org/10.1175/JTECH-D-12-00155.1>.
10. *Gangeskar R.* Wave height derived by texture analysis of X-band radar sea surface images, In: *IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment // Proceedings (Cat. No.00CH37120); 2000; Honolulu, HI, USA. IEEE; 2000. P. 2952–9. https://doi.org/10.1109/IGARSS.2000.860301.*
11. *Gavrikov A., Ivonin D., Sharmar V., Tilinina N., Gulev S., Suslov A., Fadeev V., Trofimov B., Bargman S., Salavatova L., Koshkina V., Shishkova P., Sokov A.* Wind waves in the North Atlantic and Arctic from ship navigational radar (SeaVision system) and wave buoy Spotter during three research cruises in 2020 and 2021, 2021. <https://doi.org/10.1594/PANGAEA.939620>.
12. *Greenwood C., Vogler A., Morrison J., Murray A.* The approximation of a sea surface using a shore mounted X-band radar with low grazing angle // *Remote Sensing of Environment*. 2018. Vol. 204. P. 439. <https://doi.org/10.1016/j.rse.2017.10.012>.
13. *Goodfellow I., Bengio Y., Courville A.* *Deep Learning*: MIT Press, 2016.
14. *Hatten H., Seemann J., Horstmann J., Ziemer F.* Azimuthal dependence of the radar cross section and the spectral background noise of a nautical radar at grazing incidence // *IGARSS'98. Sensing and Managing the Environment. 1998 IEEE International Geoscience and Remote Sensing. Symposium Proceedings. (Cat. No.98CH36174); 1998 Jul.; 1998. Vol. 5. P. 2490–2. https://doi.org/10.1109/IGARSS.1998.702255.*
15. *He K., Zhang X., Ren S., Sun J.* Deep Residual Learning for Image Recognition // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 Jun.; Las Vegas, NV, USA. IEEE; 2016. P. 770–8. https://doi.org/10.1109/CVPR.2016.90.*
16. *Horstmann J., Bødewadt J., Carrasco R., Cysewski M., Seemann J., Streßer M.* A Coherent on Receive X-Band Marine Radar for Ocean Observations // *Sensors*. 2021. Vol. 21. P. 7828. <https://doi.org/10.3390/s21237828>.
17. *Huang W., Liu X., Gill E.* Ocean Wind and Wave Measurements Using X-Band Marine Radar: A Comprehensive Review // *Remote Sensing*. 2017. Vol. 9. P. 1261. <https://doi.org/10.3390/rs9121261>.
18. *Huang W., Yang Z., Chen X.* Wave Height Estimation From X-Band Nautical Radar Images Using Temporal Convolutional Network // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. Vol. 14. P. 11395. <https://doi.org/10.1109/JSTARS.2021.3124969>.



19. *Ivonin D. V., Telegin V. A., Bakhanov V. V., Ermoshkin A. V., Azarov A. I.* Sample application of a low-cost X-band monitoring system of surface currents at the Black Sea shore // *Russ. J. Earth Sci.* 2011. Vol. 12. P. 1. <https://doi.org/10.2205/2011ES000507>.
20. *Krinitskiy M. A., Golikov V. A., Anikin N. N., Suslov A. I., Gavrikov A. V., Tilinina N. D.* Estimating Significant Wave Height from X-Band Navigation Radar Using Convolutional Neural Networks // *Moscow Univ. Phys.* 2023. Vol. 78. P. S128. <https://doi.org/10.3103/S0027134923070159>.
21. *Lee J.-H., Nam Y.-S., Lee J., Liu Y., Kim Y.* Estimation of Significant Wave Height Using Wave-Radar Images // *JMSE.* 2024. Vol. 12. P. 1134. <https://doi.org/10.3390/jmse12071134>.
22. *Li B., Xu J., Pan X., Ma L., Zhao Z., Chen R., Liu Q., Wang H.* Marine Oil Spill Detection with X-Band Shipborne Radar Using GLCM, SVM and FCM // *Remote Sensing.* 2022. Vol. 14. P. 3715. <https://doi.org/10.3390/rs14153715>.
23. *Liu R., Lehman J., Molino P., Such F. P., Frank E., Sergeev A., Yosinski J.* An Intriguing Failing of Convolutional Neural Networks and the CoordConv Solution. 2018. <https://doi.org/10.48550/arXiv.1807.03247>.
24. *Lund B., Collins C. O., Tamura H., Graber H. C.* Multi-directional wave spectra from marine X-band radar // *Ocean Dynamics.* 2016. Vol. 66. P. 973. <https://doi.org/10.1007/s10236-016-0961-z>.
25. *Lund B., Graber H. C., Persson P. O. G., Smith M., Doble M., Thomson J., Wadhams P.* Arctic Sea Ice Drift Measured by Shipboard Marine Radar // *JGR Oceans.* 2018. Vol. 123. P. 4298. <https://doi.org/10.1029/2018JC013769>.
26. *Lund B., Haus B. K., Graber H. C., Horstmann J., Carrasco R., Novelli G., Guigand C. M., Mehta S., Laxague N. J. M., Özgökmen T. M.* Marine X-Band Radar Currents and Bathymetry: An Argument for a Wave Number-Dependent Retrieval Method // *JGR Oceans.* 2020. Vol. 125. P. e2019JC015618. <https://doi.org/10.1029/2019JC015618>.
27. *Lyzenga D. R., Walker D. T.* A Simple Model for Marine Radar Images of the Ocean Surface // *IEEE Geoscience and Remote Sensing Letters.* 2015. Vol. 12. P. 2389. <https://doi.org/10.1109/LGRS.2015.2478390>.
28. *Mahjoobi J., Adeli Mosabbe E.* Prediction of significant wave height using regressive support vector machines // *Ocean Engineering.* 2009. Vol. 36. P. 339. <https://doi.org/10.1016/j.oceaneng.2009.01.001>.
29. *Misra D.* Mish: A Self Regularized Non-Monotonic Activation Function, 2020.
30. *Nieto Borge, José C., Rodríguez G. R., Hessner K., González P. I.* Inversion of Marine Radar Images for Surface Wave Analysis // *J. Atmos. Oceanic Technol.* 2004. Vol. 21. P. 1291. [https://doi.org/10.1175/1520-0426\(2004\)021<1291:IOMRIF>2.0.CO;2](https://doi.org/10.1175/1520-0426(2004)021<1291:IOMRIF>2.0.CO;2).
31. *Nieto-Borge J. C., Hessner K., Jarabo-Amores P., de la Mata-Moya D.* Signal-to-noise ratio analysis to estimate ocean wave heights from X-band marine radar image time series, IET Radar, Sonar & Navigation. 2008. Vol. 2. P. 35. <https://doi.org/10.1049/iet-rsn:20070027>.
32. *Park G., Choi J., Kang Y.-T., Ha M. K., Jang H., Park J. H., Park S. G., Kwon S.-H.* The Application of Marine X-band Radar to Measure Wave Condition during Sea Trial // *Journal of Ship and Ocean Technology.* 2006. Vol. 10. P. 34.
33. *Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay E.* Scikit-learn: Machine Learning in Python // *Journal of Machine Learning Research.* 2011. Vol. 12. P. 2825.
34. *Raghukumar K., Chang G., Spada F., Jones C., Janssen T., Gans A.* Performance Characteristics of “Spotter,” a Newly Developed Real-Time Wave Measurement Buoy // *Journal of Atmospheric and Oceanic Technology.* 2019. Vol. 36. P. 1127. <https://doi.org/10.1175/JTECH-D-18-0151.1>.
35. *Rezvov V., Krinitskiy M., Gavrikov A., Golikov V., Borisov M., Suslov A., Tilinina N.* Improving data-driven estimation of significant wave height through preliminary training on synthetic

- X-band radar sea clutter imagery // *Front. Mar. Sci.* 2024. Vol. 11. P. 1363135. <https://doi.org/10.3389/fmars.2024.1363135>.
36. *Salcedo-Sanz S., Nieto Borge J. C., Carro-Calvo L., Cuadra L., Hessner K., Alexandre E.* Significant wave height estimation using SVR algorithms and shadowing information from simulated and real measured X-band radar images of the sea surface // *Ocean Engineering*. 2015. Vol. 101. P. 244. <https://doi.org/10.1016/j.oceaneng.2015.04.041>.
  37. *Tilinina N., Ivonin D., Gavrikov A., Sharmar V., Gulev S., Suslov A., Fadeev V., Trofimov B., Bargman S., Salavatova L., Koshkina V., Shishkova P., Ezhova E., Krinitskiy M., Razorenova O., Koltermann K. P., Tereschenkov V., Sokov A.* Wind waves in the North Atlantic from ship navigational radar: SeaVision development and its validation with the Spotter wave buoy and WaveWatch III // *Earth Syst. Sci. Data*. 2022. Vol. 14. P. 3615. <https://doi.org/10.5194/essd-14-3615-2022>.
  38. *Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł. Ukasz, Polosukhin I.* Attention is All you Need // *Advances in Neural Information Processing Systems*. 2017. Curran Associates, Inc. 2017.
  39. *Vicen-Bueno R., Lido-Muela C., Nieto-Borge J. C.* Estimate of significant wave height from non-coherent marine radar images by multilayer perceptrons // *EURASIP Journal on Advances in Signal Processing*. 2012. Vol. 2012. P. 84. <https://doi.org/10.1186/1687-6180-2012-84>.
  40. *Waskom M. L.* Seaborn: statistical data visualization // *Journal of Open Source Software*. 2021. Vol. 6. P. 3021. <https://doi.org/10.21105/joss.03021>.
  41. *Xue S., Geng X., Yan X.-H., Xie T., Yu Q.* Significant wave height retrieval from Sentinel-1 SAR imagery by convolutional neural network // *J. Oceanogr.* 2020. Vol. 76. P. 465. <https://doi.org/10.1007/s10872-020-00557-3>.
  42. *Young I. R., Rosenthal W., Ziemer F.* A three-dimensional analysis of marine radar images for the determination of ocean wave directionality and surface currents // *J. Geophys. Res.* 1985. Vol. 90. P. 1049. <https://doi.org/10.1029/JC090iC01p01049>.
  43. *Zuo S., Wang D., Wang X., Suo L., Liu S., Zhao Y., Liu D.* Wave Height and Period Estimation from X-Band Marine Radar Images Using Convolutional Neural Network, *JMSE*. 2024. Vol. 12. P. 311. <https://doi.org/10.3390/jmse12020311>.

Статья поступила в редакцию 20.10.2024, одобрена к печати 19.12.2024.

**Для цитирования:** Голиков В. А., Криницкий М. А., Тилинина Н. Д. Оценка среднего периода ветрового волнения по единичным снимкам судового навигационного радара с применением методов глубокого обучения // *Океанологические исследования*. 2024. № 52 (4). С. 20–38. [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).2](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).2).

## MEAN WIND WAVE PERIOD ESTIMATION FROM INDIVIDUAL SHIP NAVIGATION RADAR IMAGES USING DEEP LEARNING METHODS

V. A. Golikov<sup>1,2</sup>, M. A. Krinitskiy<sup>1,2</sup>, N. D. Tilinina<sup>1</sup>

<sup>1</sup> Shirshov Institute of Oceanology, Russian Academy of Sciences,  
36, Nakhimovskiy prospekt, Moscow, 117997, Russia;

<sup>2</sup> Moscow Institute of Physics and Technology  
(National Research University),  
9, Institutskiy pereulok, Dolgoprudny, 141701, Russia,  
e-mail: golikov.va@phystech.edu

This paper presents a method for approximating the wind wave period based on ship navigation radar data in a deep learning approach. In this work, a convolutional neural network ResNet is applied, which processes radar images and approximates the values of the wind wave period. The study evaluates the errors of the method in the measure of the standard deviation of the neural network compared to the values measured by the Spotter wave buoy, which allows us to assess the quality of the proposed algorithm. The results demonstrate the efficiency of using neural networks to approximate wave characteristics from radar image data.

**Keywords:** neural networks, wind waves, ship navigation radar, radar image, wave period

**Acknowledgement:** Exploratory data analysis, source data acquisition and harmonization were supported by the State Assignment No. FMWE-2022-0002. Neural network development, optimization and analysis were supported within the Agreement No. 075-03-2024-117 dated 17.01.2024 of the Moscow Institute of Physics and Technology. Experiments on selecting the neural network architecture were carried out with the support of the strategic project “Research Leadership (from Bachelor to Nobel Laureate)” of the Priority-2030 program of the Moscow Institute of Physics and Technology.

### References

1. Borge, J. C. N., K. Reichert, and J. Dittmer, 1999: Use of nautical radar as a wave monitoring instrument. *Coastal Engineering*, **37**, 331, [https://doi.org/10.1016/S0378-3839\(99\)00032-0](https://doi.org/10.1016/S0378-3839(99)00032-0).
2. Campana, J., E. J. Terrill, and T. de Paolo, 2017: A New Inversion Method to Obtain Upper-Ocean Current-Depth Profiles Using X-Band Observations of Deep-Water Waves. *Journal of Atmospheric and Oceanic Technology*, **34**, 957, <https://doi.org/10.1175/JTECH-D-16-0120.1>.
3. Chen, Z., Y. He, W. Yang, 2016: Study of Ocean Waves Measured by Collocated HH and VV Polarized X-Band Marine Radars. *International Journal of Antennas and Propagation*, 2016, **1**, <https://doi.org/10.1155/2016/8257930>.
4. Chen, Z., Y. He, B. Zhang, and Z. Qiu, 2015: Determination of nearshore sea surface wind vector from marine X-band radar images. *Ocean Engineering*, **96**, 79, <https://doi.org/10.1016/j.oceaneng.2014.12.019>.
5. Cornejo-Bueno, L., J. C. Nieto Borge, E. Alexandre, K. Hessner, and S. Salcedo-Sanz, 2016: Accurate estimation of significant wave height with Support Vector Regression

- algorithms and marine radar images. *Coastal Engineering*, **114**, 233, <https://doi.org/10.1016/j.coastaleng.2016.04.007>
6. Duan, W., K. Yang, L. Huang, and X. Ma, 2020: Numerical Investigations on Wave Remote Sensing from Synthetic X-Band Radar Sea Clutter Images by Using Deep Convolutional Neural Networks. *Remote Sensing*, **12**, 1117, <https://doi.org/10.3390/rs12071117>.
  7. Elbisy, M. S., 2015: Sea Wave Parameters Prediction by Support Vector Machine Using a Genetic Algorithm. *Journal of Coastal Research*, **314**, 892, <https://doi.org/10.2112/JCOASTRES-D-13-00087.1>.
  8. Ermoshkin, A. V. and I. A. Kapustin, 2019: Estimation of the wind-driven wave spectrum using a high spatial resolution coherent radar. *Russ. J. Earth Sci.*, **19**, 1, <https://doi.org/10.2205/2019ES000662>.
  9. Fujiyoshi, Y., K. Osumi, M. Ohi, and Y. Yamada, 2013: Sea Ice Identification and Derivation of Its Velocity Field by X-Band Doppler Radar. *Journal of Atmospheric and Oceanic Technology*, **30**, 1240, <https://doi.org/10.1175/JTECH-D-12-00155.1>.
  10. Gangeskar, R., 2000: Wave height derived by texture analysis of X-band radar sea surface images, In: *IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment*. Proceedings (Cat. No.00CH37120); 2000; Honolulu, HI, USA. IEEE; 2952–9, <https://doi.org/10.1109/IGARSS.2000.860301>.
  11. Gavrikov, A., D. Ivonin, V. Sharmar, N. Tilinina, S. Gulev, A. Suslov, V. Fadeev, B. Trofimov, S. Bargman, L. Salavatova, V. Koshkina, P. Shishkova, and A. Sokov, 2021: *Wind waves in the North Atlantic and Arctic from ship navigational radar (SeaVision system) and wave buoy Spotter during three research cruises in 2020 and 2021*, <https://doi.org/10.1594/PANGAEA.939620>.
  12. Greenwood, C., A. Vogler, J. Morrison, and A. Murray, 2018: The approximation of a sea surface using a shore mounted X-band radar with low grazing angle. *Remote Sensing of Environment*, **204**, 439, <https://doi.org/10.1016/j.rse.2017.10.012>.
  13. Goodfellow, I., Y. Bengio, and A. Courville, 2016: *Deep Learning*: MIT Press.
  14. Hatten, H., J. Seemann, J. Horstmann, and F. Ziemer, 1998: Azimuthal dependence of the radar cross section and the spectral background noise of a nautical radar at grazing incidence. *IGARSS '98. Sensing and Managing the Environment. 1998 IEEE International Geoscience and Remote Sensing. Symposium Proceedings*. (Cat. No.98CH36174); 1998 Jul.; 2490–2, **5**, <https://doi.org/10.1109/IGARSS.1998.702255>
  15. He, K., X. Zhang, S. Ren, and J. Sun, 2016: Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*; 2016 Jun.; Las Vegas, NV, USA. IEEE; 770–8, <https://doi.org/10.1109/CVPR.2016.90>.
  16. Horstmann, J., J. Bödewadt, R. Carrasco, M. Cysewski, J. Seemann, and M. Streßer, 2021: A Coherent on Receive X-Band Marine Radar for Ocean Observations. *Sensors*, **21**, 7828, <https://doi.org/10.3390/s21237828>.
  17. Huang, W., X. Liu, and E. Gill, 2017: Ocean Wind and Wave Measurements Using X-Band Marine Radar: A Comprehensive Review. *Remote Sensing*, **9**, 1261, <https://doi.org/10.3390/rs9121261>.
  18. Huang, W., Z. Yang, and X. Chen, 2021: Wave Height Estimation From X-Band Nautical Radar Images Using Temporal Convolutional Network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **14**, 11395, <https://doi.org/10.1109/JSTARS.2021.3124969>.
  19. Ivonin, D. V., V. A. Telegin, V. V. Bakhanov, A. V. Ermoshkin, and A. I. Azarov, 2011: Sample application of a low-cost X-band monitoring system of surface currents at the Black Sea shore. *Russ. J. Earth Sci.*, **12**, 1, <https://doi.org/10.2205/2011ES000507>.



20. Krinitskiy, M. A., V. A. Golikov, N. N. Anikin, A. I. Suslov, A. V. Gavrikov, and N. D. Tili-nina, 2023: Estimating Significant Wave Height from X-Band Navigation Radar Using Convolutional Neural Networks. *Moscow Univ. Phys.*, **78**, S128, <https://doi.org/10.3103/S0027134923070159>.
21. Lee, J.-H., Y.-S. Nam, J. Lee, Y. Liu, Y. Kim, 2024: Estimation of Significant Wave Height Using Wave-Radar Images. *JMSE*, **12**, 1134, <https://doi.org/10.3390/jmse12071134>.
22. Li, B., J. Xu, X. Pan, L. Ma, Z. Zhao, R. Chen, Q. Liu, and H. Wang, 2022: Marine Oil Spill Detection with X-Band Shipborne Radar Using GLCM, SVM and FCM. *Remote Sensing*, **14**, 3715, <https://doi.org/10.3390/rs14153715>.
23. Liu, R., J. Lehman, P. Molino, F. P. Such, E. Frank, A. Sergeev, and J. Yosinski, 2018: *An Intriguing Failing of Convolutional Neural Networks and the CoordConv Solution*, <https://doi.org/10.48550/arXiv.1807.03247>.
24. Lund, B., C. O. Collins, H. Tamura, and H. C. Graber, 2016: Multi-directional wave spectra from marine X-band radar. *Ocean Dynamics*, **66**, 973, <https://doi.org/10.1007/s10236-016-0961-z>.
25. Lund, B., H. C. Graber, P. O. G. Persson, M. Smith, M. Doble, J. Thomson, and P. Wadhams, 2018: Arctic Sea Ice Drift Measured by Shipboard Marine Radar. *JGR Oceans*, **123**, 4298, <https://doi.org/10.1029/2018JC013769>.
26. Lund, B., B. K. Haus, H. C. Graber, J. Horstmann, R. Carrasco, G. Novelli, C. M. Guigand, S. Mehta, N. J. M. Laxague, and T. M. Özgökmen, 2020: Marine X-Band Radar Currents and Bathymetry: An Argument for a Wave Number-Dependent Retrieval Method. *JGR Oceans*, **125**, e2019JC015618, <https://doi.org/10.1029/2019JC015618>.
27. Lyzenga, D. R. and D. T. Walker, 2015: A Simple Model for Marine Radar Images of the Ocean Surface. *IEEE Geoscience and Remote Sensing Letters*, **12**, 2389, <https://doi.org/10.1109/LGRS.2015.2478390>.
28. Mahjoobi, J. and E. Adeli Mosabbebeh, 2009: Prediction of significant wave height using regressive support vector machines. *Ocean Engineering*, **36**, 339, <https://doi.org/10.1016/j.oceaneng.2009.01.001>.
29. Misra, D., 2020: *Mish: A Self Regularized Non-Monotonic Activation Function*.
30. Nieto Borge, C. José, G. R. Rodríguez, K. Hessner, and P. I. González, 2004: Inversion of Marine Radar Images for Surface Wave Analysis. *J. Atmos. Oceanic Technol.*, **21**, 1291, [https://doi.org/10.1175/1520-0426\(2004\)021<1291:IOMRIF>2.0.CO;2](https://doi.org/10.1175/1520-0426(2004)021<1291:IOMRIF>2.0.CO;2).
31. Nieto Borge, J. C., K. Hessner, P. Jarabo-Amores, and D. de la Mata-Moya, 2008: Signal-to-noise ratio analysis to estimate ocean wave heights from X-band marine radar image time series, IET Radar, Sonar & Navigation, **2**, 35, <https://doi.org/10.1049/iet-rsn:20070027>.
32. Park, G., J. Choi, Y.-T. Kang, M. K. Ha, H. Jang, J. H. Park, and S. G. Park, S.-H. Kwon, 2006: The Application of Marine X-band Radar to Measure Wave Condition during Sea Trial. *Journal of Ship and Ocean Technology*, **10**, 34.
33. Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, 2011: Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, **12**, 2825.
34. Raghukumar, K., G. Chang, F. Spada, C. Jones, T. Janssen, and A. Gans, 2019: Performance Characteristics of “Spotter,” a Newly Developed Real-Time Wave Measurement Buoy. *Journal of Atmospheric and Oceanic Technology*, **36**, 1127, <https://doi.org/10.1175/JTECH-D-18-0151.1>.
35. Rezvov, V., M. Krinitskiy, A. Gavrikov, V. Golikov, M. Borisov, A. Suslov, and N. Tilinina, 2024: Improving data-driven estimation of significant wave height through preliminary training on synthetic X-band radar sea clutter imagery. *Front. Mar. Sci.*, **11**, 1363135, <https://doi.org/10.3389/fmars.2024.1363135>.



36. Salcedo-Sanz, S., J. C. Nieto Borge, L. Carro-Calvo, L. Cuadra, K. Hessner, and E. Alexandre, 2015: Significant wave height estimation using SVR algorithms and shadowing information from simulated and real measured X-band radar images of the sea surface. *Ocean Engineering*, **101**, 244, <https://doi.org/10.1016/j.oceaneng.2015.04.041>.
37. Tilinina, N., D. Ivonin, A. Gavrikov, V. Sharmar, S. Gulev, A. Suslov, V. Fadeev, B. Trofimov, S. Bargman, L. Salavatova, V. Koshkina, P. Shishkova, E. Ezhova, M. Krinitskiy, O. Razorenova, K. P. Koltermann, V. Tereschenkov, and A. Sokov, 2022: Wind waves in the North Atlantic from ship navigational radar: SeaVision development and its validation with the Spotter wave buoy and WaveWatch III. *Earth Syst. Sci. Data*, **14**, 3615, <https://doi.org/10.5194/essd-14-3615-2022>.
38. Vaswani, A., N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, Ukasz, and I. Polosukhin, 2017: *Attention is All you Need*. *Advances in Neural Information Processing Systems*; 2017; Curran Associates, Inc.
39. Vicen-Bueno, R., C. Lido-Muela, and J. C. Nieto-Borge, 2012: Estimate of significant wave height from non-coherent marine radar images by multilayer perceptrons. *EURASIP Journal on Advances in Signal Processing*, 2012, **84**, <https://doi.org/10.1186/1687-6180-2012-84>.
40. Waskom, M. L., 2021: Seaborn: statistical data visualization. *Journal of Open Source Software*, **6**, 3021, <https://doi.org/10.21105/joss.03021>.
41. Xue, S., X. Geng, X.-H. Yan, T. Xie, and Q. Yu, 2020: Significant wave height retrieval from Sentinel-1 SAR imagery by convolutional neural network. *J. Oceanogr.*, **76**, 465, <https://doi.org/10.1007/s10872-020-00557-3>.
42. Young, I. R., W. Rosenthal, and F. Ziemer, 1985: A three-dimensional analysis of marine radar images for the determination of ocean wave directionality and surface currents. *J. Geophys. Res.*, **90**, 1049, <https://doi.org/10.1029/JC090iC01p01049>.
43. Zuo, S., D. Wang, X. Wang, L. Suo, S. Liu, Y. Zhao, and D. Liu, 2024: Wave Height and Period Estimation from X-Band Marine Radar Images Using Convolutional Neural Network. *JMSE*, **12**, 311, <https://doi.org/10.3390/jmse12020311>.

Submitted 20.10.2024, accepted 19.12.2024.

**For citation:** Golikov, V. A., M. A. Krinitskiy, and N. D. Tilinina, 2024: Mean wind wave period estimation from individual ship navigation radar images using deep learning methods. *Journal of Oceanological Research*, **52** (4), 20–38, [https://doi.org/10.29006/1564-2291.JOR2024.52\(4\).2](https://doi.org/10.29006/1564-2291.JOR2024.52(4).2).