

СОВРЕМЕННЫЕ СРЕДСТВА И МЕТОДЫ МОНИТОРИНГА ПЛАВАЮЩЕГО МОРСКОГО МАКРОМУСОРА И ВНЕДРЕНИЕ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ

О. Белоусова^{1,2}, М. А. Криницкий^{1,2}, М. П. Погожева^{1,3}

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

² *Московский физико-технический институт
(национальный исследовательский университет),
Россия, 141701, Долгопрудный, Институтский пер., д. 9;*

³ *Государственный океанографический институт им. Н. Н. Зубова, Росгидромет,
Россия, Москва, 119034, Кропоткинский пер., д. 6,
e-mail: belousova.o@phystech.edu*

Загрязнение мусором морских акваторий на сегодняшний день признано проблемой мирового масштаба на уровне всех международных организаций и конвенций, отвечающих за сохранность океанов и морей. В настоящем обзоре рассматриваются современные методы и средства обнаружения морского мусора, плавающего на поверхности моря. Задача обнаружения морского мусора на поверхности воды осложняется большим разнообразием объектов, разной степенью их деградации, часто их малыми размерами, частичным погружением в подповерхностный слой, бесцветностью, слиянием с водной поверхностью, затрудненными условиями наблюдений. Основные подходы сбора данных о морском плавающем мусоре на сегодня включают визуальные наблюдения (с морских судов, самолетов), траления, а также дистанционное зондирование, особенно с использованием радиолокационных систем. В задаче обработки собранных данных в последнее десятилетие значительно продвинулись вперед методы глубокого обучения, что позволило вывести распознавание и идентификацию мусора на новый уровень благодаря различным модификациям искусственных нейронных сетей. В обзоре мы анализируем ключевые исследования по представленной теме и подчеркиваем достижения и перспективы применения искусственного интеллекта для улучшения методов обнаружения и классификации морского мусора размером от 2.5 см.

Ключевые слова: морской мусор, мониторинг состояния морской среды, искусственный интеллект, обнаружение объектов, дистанционное зондирование, машинное обучение, искусственные нейронные сети

Введение

На сегодня одной из наиболее серьезных проблем остается загрязнение мусором Мирового океана (Sheavly et al., 2007; Barboza, 2018). По данным анализа выловленного морского мусора в различных морских водоемах мира, пластик составляет 68–96 % всех зафиксированных объектов (Galgani et al., 2015). Пластиковые отходы, загрязняющие вещества и прочие виды мусора потенциально угрожают гидросфере и ее биоразнообразию (Gregory, 2009; Valdenegro-Toro, 2019). Пластиковые отходы, стекло,

металл и другие виды мусора непрерывно накапливаются на побережьях (Ershova et al., 2024), в водной среде (Katsanevakis, 2014; Iñiguez et al., 2016), а также собираются в большие океанские мусорные пятна (Lebreton et al., 2018). Это подтверждается данными из экспедиций в различных регионах (Pogojeva et al., 2021; González-Fernández et al., 2022). Загрязнение Мирового океана оказывает негативное воздействие на водные организмы и ставит под угрозу экологическую устойчивость. Фрагменты пластикового мусора могут становиться ловушками для рыб и других водных организмов, а также загрязнять воду, нанося ущерб местной флоре и фауне (Derraik, 2002; Gall, Thompson 2015; Carney Almroth and Eggert, 2019). Потенциальное нарушение экологической устойчивости делает решение этой проблемы все более актуальным.

Морской мусор определяется Программой ООН по окружающей среде (United Nations Environment Programme, UNEP) как любой стойкий, изготовленный или обработанный твердый материал, выброшенный, утилизированный или оставленный в морской и прибрежной среде (UNEP, 1995). Плавающий мусор представляет собой часть мусора в морской среде, которая переносится ветром и течениями по поверхности моря и, таким образом, способен напрямую указывать на пути перемещения мусора в море. Плавающие объекты могут переноситься течениями до тех пор, пока они не опустятся на морское дно, не окажутся на берегу или не деградируют со временем (Andrady, 2015). Согласно международной классификации, к макромусору относят морской мусор размером более 2.5 см (Galgani et al., 2023). Такая фракция морского мусора наносит прямой вред морским организмам в основном через заглатывание и запутывание, а также может изменять местообитания бентоса, служить транспортом для инвазивных видов (напр., Aliani et al., 2003; Boerger et al., 2010; van Franeker et al., 2011; Domènech et al., 2019).

В настоящее время мониторинг плавающего мусора проводится специально обученными наблюдателями с научных судов в качестве попутных исследований (Derraik, 2002; Lippiatt et al., 2013). Такие исследования трудо- и времязатратны и требуют специальных навыков от наблюдателей (Lippiatt et al., 2013), поэтому используются нечасто и охватывают очень незначительные площади Мирового океана. Автоматизация этого процесса может способствовать массовому внедрению наблюдений на морских судах, для чего в подходе автоматического анализа результатов оптической съемки потребуется лишь установка камеры в носовой части судна и специализированное программное обеспечение. Несмотря на кажущуюся простоту подхода автоматизированного видеонаблюдения, на практике оказывается, что реализация этой схемы в морских условиях сопряжена со множеством организационных мероприятий (Lippiatt et al., 2013), а также технически сложна.

В данной работе мы рассматриваем различные ключевые аспекты существующих методик наблюдений и мониторинга плавающего морского макромусора (>2.5 см) с акцентом на обработку данных с применением методов машинного обучения. Одним из важнейших этапов каждой методики наблюдения за морским плавающим мусором является сбор данных, характеризующих плотность распределения мусора по поверхности воды, локализацию мест скопления, путей распределения, идентификацию

частиц, распределение их по общепринятым категориям (Fleet et al., 2021). Особое внимание в статье уделяется исследованию перспектив применения искусственного интеллекта для совершенствования методов обнаружения и классификации плавающего морского мусора. В свете бурного развития наук о данных, особое внимание мы уделяем использованию методов машинного обучения в задаче обнаружения объектов на поверхности воды.

При составлении данного обзора использовались открытые, доступные источники: существующие опубликованные методики, статьи в академических рецензируемых журналах, официальные документы и веб-ресурсы государственных и международных организаций, служб и ведомств. Для поиска вводились следующие поисковые фразы и ключевые слова: обнаружение объектов в океане, дистанционное зондирование, сбор данных о морском мусоре, машинное обучение, нейронные сети в задаче поиска морского мусора.

Методы сбора данных

Визуальные наблюдения

Мониторинг морского мусора должен предоставлять информацию о плотности плавающего мусора в исследуемом районе, его составе и потенциальных источниках поступления для принятия впоследствии административных мер по снижению загрязнения.

На сегодняшний день существуют утвержденные методики мониторинга плавающего морского мусора, разработанные региональными морскими конвенциями по защите морей от загрязнений (Барселонская (UNEP/MAP, 2011), Хельсинкская (HELCOM, 2023), Бухарестская (Black Sea Commission, 2018), Конвенция по защите морской среды Северо-Восточной Атлантики (ОСПАР) (OSPAR, 2012), и др.), а также различными международными и региональными организациями, такими как: ООН (UNEP, 2009), Европейская комиссия (ЕК) (Galgani et al., 2023), Программа арктического мониторинга и оценки (АМАП) (AMAP, 2021), Национальное управление океанических и атмосферных исследований (NOAA) (Arthur et al., 2009 и пр.) и отдельными научными группами (Ryan et al., 2010) и др. Большая часть из них основана на визуальных наблюдениях с морских судов трансектным методом, подразумевающим регистрацию плавающих объектов по ходу движения судна в заданной координатами полосе наблюдения.

При выполнении авиасъемок также возможно регистрировать плавающий мусор, однако размерная категория сильно меняется в зависимости от высоты полетов и условий наблюдения (Pichel et al., 2012). Обычно удается идентифицировать объекты размером более 30–50 см. Этот способ нельзя рассматривать как основной метод мониторинга, однако он может служить хорошим дополнением при исследовании мест скопления и источников поступления мусора в море.

Для уменьшения стоимости работ, как правило, для мониторинга плавающего мусора используют попутные наблюдения с судов, выполняющих другие задачи в интересующем районе. Это могут быть другие мониторинговые работы, инженерно-экологические изыскания, научные экспедиции, паромное сообщение и любые другие работы, позволяющие вести попутные наблюдения с соответствующего судна. Точка обзора выбирается максимально близко к воде около носовой части судна, избегая кильватерной струи. Высота наблюдателя над уровнем моря должна обеспечить возможность различать объекты на поверхности воды величиной от 2.5 см. В начале наблюдений фиксируются координаты начала трека, а по завершении – конца. Важным показателем для последующих расчетов является ширина трансекты, в которой фиксируются частицы мусора. В среднем, она составляет 10 м, но может варьироваться в зависимости от скорости судна, высоты точки наблюдения и условий исследований. Наблюдения ведутся обученными специалистами, выполняющими только этот вид наблюдений и не совмещающих эту работу с другими исследованиями (например, регистрацией морских млекопитающих, птиц и пр.). Длина трансект должна выбираться таким образом, чтобы минимизировать риски возникновения ошибок, вызванных человеческим фактором и усталостью наблюдателя в результате пристального внимания к маленьким объектам в течение длительного времени. Рекомендуется проводить наблюдения в среднем около 1 часа (несколько км), а после менять наблюдателей или делать перерывы. При этом унифицированная длина трансект упрощает дальнейшую обработку данных.

В настоящее время также ведется разработка мобильных приложений для оптимизации этого вида работ. Например, в 2019 г. в ходе экспедиции параллельно с визуальными наблюдениями было протестировано и применено мобильное приложение Floating Litter Monitoring (FLM), которое может использоваться для упрощения и стандартизации сбора данных о плавающем мусоре. Приложение позволяет в автоматическом режиме записывать координаты встреченных объектов мониторинга и сопутствующие метаданные, не отвлекаясь на другое оборудование и записи в блокноте. В приложении создается перечень морского мусора и его классификация по категориям. Данные записываются в формате csv, который при необходимости может открываться стандартной программой Microsoft Office Excel для последующей обработки информации (Погожева и др., 2021). Если применение мобильного приложения для сбора данных невозможно, то стоит использовать упрощенные таблицы данных (Vighi et al., 2022).

Сбор данных о плавающем мусоре предполагает его классификацию на различные категории по типу, виду материала, из которого он изготовлен, а также размеру. Для возможности сравнения результатов с другими видами морского мусора (например, пляжный, донный, поступающий с реками) существует единый список для мониторинга морского мусора (Fleet et al., 2021). Для упрощения процесса мониторинга вырабатывается список наиболее часто встречающихся объектов. В настоящее время также ведется разработка мобильных приложений для оптимизации этого вида работ.

Так как мониторинг плавающего морского мусора не предполагает его сбор, то его размер – это единственный параметр, позволяющий оценить объем отслеживаемого

материала. Размер оценивается визуально в процессе наблюдения, исходя из максимальной длины или ширины частицы. Минимальный размер учитываемых частиц составляет 2.5 см. Этот размер утвержден международными методиками, в том числе и для пляжного мусора. Соответственно, частицы меньшего размера не учитываются при съемке, а условия наблюдений и ширина трансекты задаются исходя из этой минимальной размерной категории. При визуальной оценке размера частиц сложно точно оценить размеры, поэтому выбираются приблизительные диапазоны размерности частиц. Принято выделять следующие размерные категории: 2.5–5 см; 5–10 см; 10–20 см; 20–30 см; 30–50 см. Для возможности сравнения результатов и работы с базами данных важно придерживаться данных общепринятых размерных категорий. Для регистрации данных применяется единый протокол сбора данных по плавающему мусору. Он используется для ведения общей отчетности, поддержания баз данных по плавающему мусору, достоверного сравнения полученных результатов, разработки обзоров, картографических и других материалов для визуализации данных.

Использование тралов

Иногда для целей мониторинга используют попутный лов тралами при ловле рыбы. Мусор из рыболовных тралов собирают отдельно, оценивают обработанную площадь, идентифицируют, распределяют по категориям и регистрируют. Этот вид мониторинга используется лишь фрагментарно и иногда описывается в некоторых научных работах. Сложность и дороговизна таких работ затрудняет регулярное повторение процедуры траления, необходимое для систематических исследований (De Vries, 2022). При этом отмечается, что обследования плавающего мусора стоит проводить не реже одного раза в год.

Методология оценки плавающего мусора, которая в том числе применяется в работах, описанных ниже в этом разделе, была подготовлена Программой ООН по окружающей среде (United Nations Environment Programme, UNEP) и Межгосударственной океанографической комиссией (Intergovernmental Oceanographic Commission, ИОС, 2023).

Согласно стандартам этого положения, траления должны быть сосредоточены в местах, где накапливается мусор в больших количествах и исключено вредное влияние тралов на уязвимые морские виды. Сведения по собранному мусору должны быть классифицированы как минимум по 4 типам мест сбора: побережья городов, побережья сельской местности, поблизости от устья крупных рек, вдали от берега. Зона обследования должна представлять собой квадрат 5×5 км, поделенный на 25 блоков размером 1×1 км. Для обеспечения беспристрастной выборки следует случайным образом выбрать группу из 3 подблоков для траления. После выбора трех квадратов начинается траление, которое должно проводиться при скорости судна не более 3–4 узлов (6–7 км/ч) и расстоянии между тралениями не менее 200 м. Судно должно двигаться по прямой против течения так, чтобы траловая сеть располагалась на одной линии позади кормы.

В качестве примера можно привести совместную работу норвежских и российских ученых (Grøsvik et al., 2018), где было произведено обширное исследование шельфа Баренцева моря на предмет наличия антропогенного мусора. Путем учета разных видов выловленного мусора при т. н. «пелагическом» тралении (то есть при ловле фрагментов мусора тралом в верхних слоях морской воды) были рассчитаны распределение и численность морского мусора.

Распределение и обилие морского мусора в верхних шестидесяти метрах исследовалось путем траления в поверхностных водах мелкоячеистым тралом “Harstad trawl” с входным отверстием 20×20 м. Размер ячеек лежит в диапазоне от 100 мм в передней части до 30 мм в конце сетки. Траление проводилось на трех глубинах – 0, 20 и 40 м от верхней линии трала соответственно, и со скоростью траления три узла. Характеристики эффективности траления, такие как расстояние между траловыми досками, вертикальное раскрытие трала, контролировались в реальном времени датчиками Scanmar. После улова морской мусор сортировался и классифицировался по типу материала и взвешивался. В ходе обследований экосистемы Баренцева моря авторы решили использовать простую классификацию морского мусора: пластик, дерево, металл, резина, стекло, бумага и текстиль. Данные (категория и количество) регистрировались в стандартной базе данных на борту и позднее переносились в базу данных ИМИ/ПИПРО (Институт морских исследований / Полярный научно-исследовательский институт морского рыбного хозяйства и океанографии) (Grøsvik et al., 2018).

Дистанционное зондирование

В зависимости от задач, иногда альтернативой визуальному методу мониторинга морского мусора на поверхности воды может быть дистанционное зондирование Земли (ДЗЗ), в частности, поверхности океана. Проблемы и преимущества ДЗЗ затронуты, например, в работе (Масе, 2012). Суть методов ДЗЗ заключается в получении информации об объекте или явлении без непосредственного физического контакта. По способу получения исходных данных методы ДЗЗ разделяют на активные, в которых сигнал излучается сканирующим инструментом, а характеристики объектов и поверхностей получают в подходе анализа отраженного сигнала, и пассивные, в которых анализируется отраженный сигнал естественного источника или естественное излучение самих предметов и поверхностей (Гвишиани и др., 2022). Важной характеристикой ДЗЗ является масштаб измерений. Масштабы измерений характеризуются пространственным, временным и спектральным разрешениями, телесным углом обзора и направлением поляризации. Отмечается, что сильнее всего на результаты сканирования влияют именно разрешения по спектру, времени и пространству (Гвишиани и др., 2022).

Спектральное разрешение влияет как на качество обработки и хранения данных, так и на вероятность обнаружения объектов (Аси́фа-Ruz et al., 2018). Повышение спектрального разрешения позволяет распознавать такие объекты, величина которых на цифровом изображении не превышает одного пикселя. С другой стороны, уширение спектра увеличивает фактический объем выборки данных, уменьшает соотношение

полезных данных к шуму и повышает уровень технических и временных затрат при обработке и разметке данных. На сегодняшний день не был должным образом дан ответ на ключевой вопрос в зондировании при помощи спутников: насколько хорошо различные формы морского мусора можно удаленно обнаружить и классифицировать с помощью спутниковых наблюдений в видимом и ближнем инфракрасном спектральном диапазоне, и каким образом (Hu, 2021)?

Временное разрешение в подходах ДЗЗ ограничено характеристиками орбиты (для спутников), продолжительностью полета (для самолетов) и погодными условиями. Геостационарные спутники проводят частые (ежечасные и более частые) наблюдения, нередко характеризующиеся низким пространственным разрешением, где размер пикселя может составлять первые километры или сотни метров. Спутники на полярной орбите значительно различаются, но обычно время возврата составляет от нескольких дней до месяца и более в зависимости от ширины полосы обзора и высоты. Время полета самолетов обычно ограничено 10 часами для пилотируемых и 30 часами для беспилотных летательных аппаратов (БПЛА). Охват территории также ограничен воздушной скоростью самолета, что затрудняет съемку больших территорий с высокой частотой повторения. Погода является серьезным ограничивающим фактором для всех оптических наблюдений, но в меньшей степени для наблюдений в микроволновой части спектра (Hu, 2021; Fallati et al., 2019; Tran et al., 2022).

Пространственное разрешение является, возможно, наиболее острой проблемой при анализе данных ДЗЗ (Touzelis et al., 2021). Оно должно быть достаточным не только для обнаружения фрагментов, но и для их идентификации как определенного типа мусора или конкретного объекта. Коммерческие спутники ограничены разрешением 25–50 см, что делает возможным их применение для поиска объектов размеров в несколько метров (Maximenko et al., 2019). В тех работах, где ученые полагаются на данные со спутников, используются либо самые детальные снимки из доступных (например, WorldView-3), либо применяется так называемый «паншарпенинг» (pansharpening, от сочетания слов panchromatic и sharpening) – процесс слияния панхроматических изображений высокого разрешения и многоспектральных изображений низкого разрешения для создания одного цветного изображения высокого разрешения (Booth et al., 2023).

Методы анализа данных

Анализ данных визуальных наблюдений и тралений

После сбора данных любым из описанных выше способов встает не менее важный вопрос их обработки и анализа. При регистрации данных о плавающем морском макромулусоре используется единый список для мониторинга морского мусора (Joint category list) (Fleet et al., 2021), а также единый протокол сбора данных по плавающему мусору (Galgani et al., 2023). Унифицированные протоколы используются

для ведения общей отчетности, поддержания баз данных по плавающему мусору, достоверного сравнения полученных результатов, разработки обзоров, построения пространственных и временных трендов, визуализации данных и использования их в океанологических моделях. В случае применения визуального трансектного метода наблюдения с судов, а также при тралении, данные регистрируются либо в бумажных протоколах с дальнейшим занесением в унифицированные электронные таблицы, либо сразу регистрируются при помощи мобильных приложений, которые, как правило, сохраняют данные в виде таблиц в формате данных, разделяемых запятой (например, файлы типа *.csv). Эти форматы позволяют проводить дальнейшую обработку данных, вычисления плотности мусора на осмотренной площади акватории, анализ данных по различным районам, категориям, размерам и пр. Накопление определенного массива данных дает возможность отслеживать пространственно-временные зависимости, использовать для анализа методы математического моделирования.

Как уже было обозначено во введении, настоящая работа сфокусирована в основном на компьютерных методах анализа данных и их внедрении в процесс мониторинга плавающего макромусора, а именно машинном обучении и его подвидах: глубоком обучении (Deep Learning, DL), сверточных нейронных сетях (Convolutional Neural Networks, CNN), компьютерном зрении (Computer Vision, CV) и других.

Анализ данных, полученных методами ДЗЗ

При мониторинге на основе ДЗЗ задачи анализа и распознавания объектов выполняются после сбора всей информации. Плавающий морской макромусор можно идентифицировать либо с помощью обученных наблюдателей, либо автоматизированными системами, разработанными с помощью методов машинного обучения. И хотя этот новый подход быстро развивается в применении к мониторингу мусора на побережьях (Maximenko et al., 2019), алгоритмы автоматического распознавания плавающего морского макромусора все еще несовершенны и нуждаются в доработке, так как условия наблюдения и природные факторы (характеристики морской поверхности, солнечные блики, ветер, время суток и т. д.) усложняют задачу.

За последние годы был достигнут существенный прогресс в прикладном применении этих методологий для обнаружения, количественной оценки, классификации и отслеживания плавающих объектов. Автоматизированная фото- и видеорегистрация плавающего макромусора стала возможной благодаря системам, специально настроенным на получение изображений с любой платформы, с больших и малых судов, самолетов или ИСЗ, при помощи систем, таких как LITTERCAM (Hanke and Piha, 2011). Однако, хотя визуальное наблюдение за мусором достигло определенной степени зрелости, методы, основанные на получении и анализе изображений, все еще находятся в стадии разработки или экспериментальном состоянии (Vighi et al., 2022).

Системы распознавания также могут быть применены автоматически к видеозаписям, но могут возникнуть проблемы, связанные с разрешением видео, и окончательная верификация объектов должна выполняться оператором-человеком. Самая

большая проблема этого подхода – идентификация предметов и исключение ложно-отрицательных результатов в задаче обнаружения плавающего морского мусора, что было выяснено Технической группой ЕС по морскому мусору – MSFD (Veiga et al., 2016; Vighi et al., 2022; Galgani et al., 2023).

При анализе данных, полученных методами ДЗЗ, следует учитывать, что данные о морском мусоре обладают следующими характерными особенностями (NOAA NCCOS, 2021):

1. Небольшие размеры объектов: объекты морского мусора, как правило, занимают лишь небольшую часть площади на фотографиях поверхности моря.
2. Разнообразие форм и материалов: объекты сильно различаются по размеру, форме, цвету и материалу, что затрудняет их классификацию.
3. Сложный визуальный фон: фотографии поверхности океана часто содержат различные типы естественных объектов (водорослей, медуз, рыб и пр.) и ярко выделяющиеся особенности самой поверхности (напр., морскую пену), не являющиеся мусором. Такие особенности зачастую снижают показатели качества алгоритмов компьютерного зрения, применяемых при идентификации и классификации морского мусора на снимках.

Существуют следующие популярные методы преодоления описанных выше проблем:

- обрезка исходного изображения до небольшого размера перед выполнением обнаружения объектов (Lippiatt et al., 2013; Selvam et al., 2021). Это увеличивает отношение количества пикселей объекта к количеству пикселей фона в каждом отдельном кадре изображения, что зачастую повышает качество применяемых алгоритмов идентификации;
- искусственное дополнение данных – увеличение масштаба изображения (De Vries, 2022); при этом также допускается преобразование изображения (поворот, изменение цветовой гаммы) таким образом, чтобы можно было представить их как новые данные без потери семантического содержания;
- точная настройка соотношения сторон детектора объектов на этапе первоначального предложения поля привязки детектора объектов. Соотношения сторон устанавливаются на основе значений, обычно встречающихся в данных обучения и оценки. Это позволяет правильно локализовать длинные объекты и объекты неправильной формы на аэрофотоснимках;
- применение трансферного обучения – подхода в машинном обучении, целью которого является применение знаний, полученных из одной задачи, к другой целевой задаче. За счет трансферного обучения можно сэкономить вычислительные ресурсы в процессе обучения и тем самым проводить больше экспериментов и больше итераций в рамках одного эксперимента.

Глубокое обучение – это разновидность машинного обучения на основе искусственных нейронных сетей. Традиционно под методами глубокого обучения понимают применение полносвязных искусственных нейронных сетей. Однако распознавание «текстур» (т. е. изображений с повторяющимися элементами, такими как,

например, морская поверхность) при помощи полносвязных нейросетей не освоено до конца; применением такого типа архитектуры является скорее исключением. При этом именно разнообразие текстур и визуальных особенностей материала объектов в задачах идентификации плавающего морского мусора является основным препятствием для разработки универсальных точных алгоритмов классического компьютерного зрения. По этой причине для распознавания объектов морского мусора во множестве работ применяются сверточные нейронные сети (CNN), которые лучше полносвязных нейросетей приспособлены для обработки пространственно распределенных данных, представленных в виде изображений.

В качестве примеров применения подходов анализа данных, получаемых дистанционным зондированием Земли, в борьбе с проблемой накопления мусора в морских средах, следует упомянуть задачу отслеживания перемещения мусора (Acuña-Ruz et al., 2018; Kylili et al., 2019; Kikaki et al., 2022).

Кроме того, в некоторых работах упоминается применение методов обнаружения объектов непосредственно на поверхности океана или путем применения этих методов под водой. В следующем разделе мы приводим обзор статей, посвященных исследованиям мусора в океане, а именно методам идентификации и методам классификации.

Заслуживает отдельного рассмотрения проект The Ocean Cleanup. Это международная некоммерческая организация, целью которой является детекция пластикового мусора в океанах и реках и их очистка от пластикового мусора с использованием передовых технологий (de Vries, 2022). Проект активно изучает Большое тихоокеанское мусорное пятно, а также 1000 наиболее загрязненных рек мира, которые, по данным исследований, ответственны за 80 % пластикового мусора, попадающего в океан (de Vries et al., 2021). Для сбора данных The Ocean Cleanup использует систему ADIS (Automatic Debris Imaging System – система автоматического отображения мусора), которая способна отслеживать пластиковое загрязнение на поверхности воды в реальном времени. Камеры на судах и мостах фиксируют изображения, которые затем анализируются моделями искусственного интеллекта для определения типа и плотности мусора.

Методы глубокого обучения для идентификации морского мусора

На острове Чилоэ в Чили морской мусор антропогенного происхождения стал значительной проблемой. Исследователи (Acuña-Ruz et al., 2018) пытались решить задачу распознавания, используя три различных метода классификации мусора на побережьях: SVM (Метод опорных векторов), RF (Случайный лес) и LDA (Линейный дискриминантный анализ). В этом исследовании модель на базе SVM показала наилучшие результаты для классификации мусора на спутниковых изображениях с общей точностью 80 %. Эта модель успешно обнаружила размокший пенопласт и другие пластиковые смеси на побережье с пространственным разрешением от 0.3 м

до 1.2 м с низким уровнем ошибки. Модели RF и LDA продемонстрировали точность 77 % и 70 % соответственно.

В работе (Xue et al., 2021), авторы, учитывая особые характеристики глубоководного мусора, применили гибридную сверточную нейронную сеть под названием Shuffle-Xception, которая в основном использует разделяемую свертку (separable convolution) и остаточные соединения (residual connections). Кроме того, в архитектуре Shuffle-Xception объединены преимущества групповой свертки и стратегии перетасовки каналов. Предложенный метод позволил существенно повысить точность классификации глубоководного мусора. Авторы сравнивали между собой Shuffle-Xception, ResNetv2-34, ResNetB2-152, MobileNet; LeNet & Xception. По всем семи классам объектов было выявлено, что метрика качества F1-score была выше при использовании Shuffle-Xception, а их точность (precision) составила в среднем 95 %. Это позволяет предположить, что Shuffle-Xception является оптимальным вариантом для классификации глубоководных объектов мусора. В другой своей публикации (Xue et al., 2021) авторы предложили одноступенчатую сеть под названием ResNet50-YOLOV3; по сравнению с другими сетями обнаружения, результаты ResNet50-YOLOV3 превзошли их как по точности, так и по скорости со средней точностью (mAP) 83 %.

Цель исследования Jakovljevic и соавторов (Jakovljevic et al., 2020) заключалась в разработке эффективного метода для картографирования плавучего пластика. Это исследование разделено на две части: вначале авторы использовали изображения с беспилотных летательных аппаратов (БПЛА) для картографирования местоположения пластика, а во второй части был применен подход траления для сбора мусора. Авторы успешно использовали семантическую сегментацию пикселей для обнаружения и картографирования пластика в водных объектах с использованием расширения ResUNet50, сверточной нейронной сети (Xue et al., 2021). Было обнаружено, что даже в мелких водах эта модель показала хорошие результаты средним значением F1-меры равной 0.89 по всем трем категориям пластика, которые анализировались в исследовании. Авторы исследования подчеркивают важность использования сбалансированных наборов обучающих данных, поскольку в рамках данного исследования обнаружили, что смешанные пиксели (т. е. пиксели в областях, где смешиваются объекты разных классов) могут быть ошибочно восприняты моделью как главный класс. Авторы продолжают исследования, вылавливая мусор в верховьях рек с помощью сетей. Они пришли к выводу, что ежегодно сеть собирает около 10 000 м³ материалов, включая древесину (60 %), пластиковую упаковку (35 %) и другие отходы (5 %). Это соотношение материалов приводит к выводу о том, что необходимо обучать системы классификации для определения типов древесины и других органических веществ, смываемых реками в океан (Jakovljevic et al., 2020).

В исследовании Savastano с соавторами (Savastano et al., 2021) был использован радиолокатор с синтетической апертурой (SAR) для обнаружения пластиковых морских отходов на Балеарских островах. В рамках исследования на наборе данных из пикселей, помеченных как пластик или как не пластик, обучались 3 разных нейронных сети с использованием таких методов машинного обучения с учителем, как:

RF (Случайный лес), SVM (support vector machine, метод опорных векторов) и Гауссовский наивный байесовский классификатор (GNB). Авторы не предлагают заключений относительно моделей SVM или RF, однако отмечают, что при визуальном анализе GNB показал лучшие результаты на неразмеченных изображениях, и что GNB характерен существенно сниженным уровнем ложноположительных результатов. Однако при применении к проверочному набору данных точность (accuracy) метода GNB на помеченных областях оказалась самой низкой и составила лишь 0.68. В то же время точность у моделей RF и SVM достигла 0.86. Противоречивые и неоднозначные результаты этого эксперимента указывают на необходимость дальнейших исследований для определения наиболее подходящих моделей; необходимо определить причины ложноположительных результатов и предоставить возможность улучшить результаты (Savastano et al., 2021).

В так называемом гибридном методе отслеживания и обнаружения мусора Kikaki с соавторами (Kikaki et al., 2022) разработали метод, представляющий собой смешение двух задач со слабо контролируемой семантической сегментацией; использовались модели RF и U-Net – сверточная нейронная сеть, модифицированная так, чтобы ее можно было бы эффективно применить к меньшему числу примеров (обучающих образов) и чтобы она более точно решала задачу сегментации. При обучении модели RF признаковое описание объектов состояло из входных признаков (спектральные индексы, пиксели, текстурные признаки), извлеченных из матриц GLCM (gray-level co-occurrence matrices, матрицы совместного появления). При анализе мультиспектральных изображений Sentinel-2 авторы использовали модель U-Net, с помощью которой вычислялась бинарная маска, означающая присутствие мусора в каждом отдельном пикселе. В работе использовался набор данных MARIDA (Архив морского мусора), основанный на мультиспектральных спутниковых данных Sentinel-2. По утверждению авторов, MARIDA можно считать эталоном для тренировки моделей машинного обучения, так как в данном наборе присутствует большое множество классов объектов: помимо собственно морского мусора, модель также различает водоросли, корабли, природный органический материал, волны и пену, разные типы воды (прозрачная, мутная вода, вода с отложениями, мелководье) и облака. По результату тестирования подхода, изложенного в статье, на данных MARIDA авторы заключили, что набор данных MARIDA является ценным ресурсом для разработки и оценки алгоритмов машинного обучения при использовании дистанционного зондирования с помощью зонда Sentinel-2. В качестве метрики качества в исследовании использовалось F1-score. В итоге модель RF (Случайный лес) достигла общей точности 93 %, с оценкой F1-score 0.68, в то время как наивысшая точность у модели U-Net CNN составила 91 %, а F1-score – 0.60. Стоит отметить, что применительно к распознаванию только морского мусора нейросетевая модель на базе архитектуры U-Net продемонстрировала точность на уровне 70 %, в то время как у наилучшей версии RF результат достиг 92 %.

В исследовании Sannigrahi с соавторами (Sannigrahi et al., 2022) авторы предложили так называемый ядерный нормализованный дифференцированный вегетационный

индекс (kNDVI) для обнаружения плавающего пластика в океане. Авторы разработали две модели машинного обучения, на основе SVM и Случайных лесов. Для повышения качества модели SVM авторы использовали радиальную базисную функцию (RBF) в качестве ядра. В исследовании авторы пришли к заключению, что RF показал более перспективные результаты, с более высокой точностью, меньшим количеством ошибок и меньшей неопределенностью при классификации пикселей спутниковых снимков с характерным наличием пластика. При решении задачи распознавания с применением модели RF авторы использовали четыре спектральных индекса дистанционного зондирования: индекс плавающего мусора (FDI), нормализованный дифференцированный вегетационный индекс (NDVI), Пластиковый Индекс (PI) и упомянутый выше kNDVI. Авторы предполагают, что незначительно обветренные пластиковые объекты могут повлиять на конечный результат, поскольку пластик отражает свет по-разному в зависимости от толщины, цвета или степени разложения. Несмотря на это, в исследовании модель RF достигла значения точности (доли верных ответов, Ассигасы) в 88 % и 94 % на двух реальных испытательных площадках – Бейруте и Калабрии. Авторы заключают, что дистанционное зондирование и методы машинного обучения – это перспективное сочетание подходов для обнаружения морского мусора.

Fulton и соавторы (Fulton et al., 2019) оценили четыре популярных нейросетевых алгоритма обработки изображений: Tiny-YOLO, FasterRCNN (с Inception V2), YOLOv2 и SSD (Single Shot Multi Detector с MobileNetv2) для сравнения результатов по обнаружению морского мусора, в частности, пластика. Авторы выяснили, что все четыре модели хорошо справились с их набором изображений. Faster-RCNN превзошел другие модели по точности с 81 % mAP (Mean average precision, усредненная точность). Авторы отмечают, что Tiny-YOLO и YOLOv2 имеют наилучший баланс между скоростью и точностью; при этом их показатель mAP составил соответственно 31.6 % и 47.9 %. Однако анализ имеет больше смысла, если принимается во внимание средняя точность обнаружения пластика (precision). Этот показатель равняется 70.3 % и 82.3 % соответственно для моделей Tiny-YOLO и YOLOv2. По сравнению с вышеупомянутыми моделями, точность Faster RCNN достигла 83.3 %. Наконец, SSD показал наименьший результат по обнаружению, 67.4 % в мере mAP с показателем точности в категории пластика 69.8 %. При этом выявлено, что SSD является самым медленным при использовании GPU из всех исследованных алгоритмов, но самым быстрым при работе на CPU. Таким образом, исследователи, ограниченные в вычислительных мощностях и времени (не имеющие доступа к GPU), могут выбрать SSD в качестве модели, хотя результаты будут хуже, чем у Faster-RCNN (Fulton et al., 2019).

Watanabe и соавторы (Watanabe et al., 2019) исследовали применение беспилотных летательных аппаратов, автономных подводных аппаратов и других автономных роботов для создания системы мониторинга морского мусора. В своей работе они использовали алгоритм YOLOv3 для обнаружения объектов в морских средах. Применяя эту архитектуру, они установили, что объекты можно обнаруживать практически в реальном времени. При тестировании модели на распознавании морской флоры и

фауны их модель достигла показателя mAP в 69.6 %, а на распознавании подводного морского мусора – 77 %. Однако данное исследование было проведено только для одного визуального процессора (VPU), поэтому в выводах авторы указывают, что эксперимент необходимо в будущем провести на различных других графических процессорах (Watanabe et al., 2019).

В одном из исследований в рамках проекта Ocean Cleanup (de Vries et al., 2021) описано использование искусственного интеллекта для мониторинга плотности пластиковых отходов в океане. Авторы сравнивали между собой результаты моделей Faster R-CNN (FRCNN) и YOLOv5 на наборе данных, собранном собственноручно в Тихом океане в районе Большого мусорного пятна. Было обнаружено, что YOLOv5 показала лучшую производительность обнаружения мелких объектов (YOLOv5: 0.15 м, FRCNN: 0.35 м). Тем не менее, в работе авторы заявляют, что «обнаружение самых маленьких объектов непостоянно и ненадежно». Для дальнейшего повышения надежности своих результатов они предлагают использовать параллельные наборы данных и выразили необходимость сбора дополнительных кадров.

Kylili и соавторам в своей работе за 2019 г. (Kylili et al., 2019) предоставили несколько тысяч изображений для разработанного ими алгоритма и его оптимизации. При обучении на трех категориях пластикового морского мусора, то есть бутылках, ведрах и соломинках, классификатор на основе модели VGG16, обученный в этом исследовании, смог успешно распознать упомянутые плавучие объекты с вероятностью успеха более 85 %. По выводам авторов, высокий уровень точности и эффективности разработанного инструмента машинного обучения представляет собой шаг к выявлению истинных масштабов плавающего пластика. Авторы особенно сосредоточились на достоверности своих результатов, подкрепляя результаты указанием процента потерь, а также изменяя структуру модели с использованием трех различных сценариев (Kylili et al., 2019). В 2021 г. Kylili и соавторы (Kylili et al., 2021A) в своей работе смогли повысить точность обнаружения плавающих мусорных отходов на кипрском побережье до 90 %, увеличив свой набор данных и количество классов. В этом исследовании была использована усовершенствованная модель VGG16. Авторы обнаружили, что модель VGG16 способна точно определять морской мусор даже с изображений низкого разрешения. Авторы особо отмечают важность аугментации данных для расширения набора данных и считают, что эти исследования могут успешно использоваться для мониторинга морского мусора. В своем заключении они предлагают применить YOLOv3 в реальном времени к видеоданным. Авторы продолжили свои исследования в работе 2021 г. (Kylili et al., 2021B), на этот раз собирая фотографии различных участков берега острова Кипр и используя сеть YOLOv5 (разработчики модели – коллектив Jocher et al., 2020) и YOLACT++ (разработчики модели – Bolya et al., 2019) для классификации и локализации мусора на изображениях.

Авторы продолжают исследовать методы глубокого обучения по обнаружению и отслеживанию мусора в работах 2022 г. за авторством Teng и др. (Teng et al., 2022). Для оценки и мониторинга количества мусора и объектов мусора они сначала применяли технику отслеживания центроидов объектов мусора. Они смогли достичь

средней точности 72 % на предварительно обученной модели YOLOv5 (разработчики модели – коллектив Jocher et al., 2020) и добились качества классификации 89 %. Авторы предположили, что их метод может быть использован как более экономически эффективный способ по сравнению с ручными обследованиями для оценки количества мусора. Они считают, что их результаты могут быть интегрированы в другие цифровые приложения или другие методы дистанционного обследования, что, вероятно, повысит его производительность.

В таблице 1 мы приводим краткое обобщение исследований, перечисленных выше, касающихся методов идентификации и классификации объектов морского мусора. В первом столбце помещена краткая ссылка на работу; во втором столбце – используемый в работе метод машинного обучения, в третьем – информация об обрабатываемых данных, в четвертом – используемые метрики качества, в пятом – значения по используемой мере качества.

Табл. 1 – Сравнительная характеристика методов классификации данных о морском мусоре

Ссылка	Модели	Данные	Мера качества	Результат
Асуña-Ruz et al. (2018)	SVM, RF, LDA	144 образца	Доля верных ответов (Accuracy)	SVM:80 %, RF:77 %, LDA:70 %
Kylili et al. (2019); Kylili et al. (2021A)	VGG-16	12000 изображений	Точность (Accuracy)	86 %
Fulton et al. (2019)	TinyYOLO, YOLOv2, SSD, Faster R-CNN	5720 изображений	mAP (Mean average precision, усредненная точность)	Faster R-CNN: 81 %
Watanabe et al. (2019)	YOLOv3	189 изображений (фрагменты), 8036 изображений (биологические объекты)	mAP	Морская биота: 69.6 % Загрязнение: 77.2 %
Jakovljevic et al. (2020)	ResUNet50	3 Набора данных с 328, 434, 1846 изображениями	Средняя мера F1	0.89
Savastano et al. (2021)	RF, SVM, GNB	8395 пикселей всего, 1794 пикселей с пластиком	Сбалансированная точность (Balanced accuracy)	RF: 86 %; SVM: 86 %; GNB: 68 %
Kylili et al. (2021B)	YOLOV5, YOLACT++	1650 изображений	mAP	YOLOV5: 92.4 %; YOLACT++: 69.6 %
Xue et al. (2021)	ResNet50-, YOLOv3	10000 изображений	mAP	83.4 %
de Vries et al. (2022)	Faster R-CNN-Ultralytics, YOLOv5	18589 изображений	–	В материалах исследования не приведены оценки качества
Teng et al. (2022)	YOLOv5	2050 изображений	mAP	89.4 %
Sannigrahi et al. (2022)	SVM, RF	27 снимков со спутника Sentinel 2A/B	Доля верных ответов (Accuracy)	SVM: 88 %; RF: 94 %
Kikaki et al. (2022)	RF, U-Net	1381 образцов; 3399 пикселей с морским мусором	Доля верных ответов (Accuracy)	RF: 92 %; U-Net:70 %

Заключение

Океаны Земли в настоящее время наполнены большим количеством пластика, металла, резины, бумаги, текстиля, оставленных рыболовных снастей, заброшенных судов, отходов производства и других объектов искусственного происхождения. Морской мусор – одна из важнейших мировых проблем, ставящая под угрозу стабильность океанических экосистем и биоразнообразие.

По этой причине в последние десятилетия существенное внимание исследователей обращено на методы обнаружения, идентификации и классификации искусственных объектов на поверхности моря. В настоящем обзоре мы обсудили подходы и результаты ряда значимых работ, в которых авторами применялись различные методы машинного обучения для данной задачи. Стоит отметить, что настоящее исследование охватывает только фрагменты макромусора, то есть все частицы размером от 2.5 см.

Наиболее представленным методом решения проблемы мониторинга морского мусора следует признать обнаружение плавающих объектов и отслеживание их с помощью дистанционного зондирования, хотя существуют и другие методы, такие как визуальное наблюдение, траление. Что касается методов идентификации и классификации, то здесь лучше всего показывают себя модели сверточных искусственных нейронных сетей, такие как нейросети семейств YOLO и ResNet.

По результатам проведенного анализа следует отметить, что в литературе встречаются алгоритмы обработки двумерных данных (оптических изображений или спутниковых снимков) как из подмножества классических методов машинного обучения, так и искусственных нейронных сетей. Несмотря на успехи искусственных нейронных сетей, с 2012 г. демонстрирующих подавляющее превосходство в обработке изображений над классическими методами машинного обучения, в современных исследованиях до сих пор применяют подход машинного обучения для табличных данных (т. н. «классические» методы), в котором предполагается предварительное вычисление характеристик (признаков) идентифицируемых объектов на базе экспертного понимания решаемой задачи.

Благодарности. Исследование подходов получения данных для мониторинга загрязнения океана выполнено в рамках Госзадания № FMWE- 2022-0002. Обзор методов обработки данных выполнен при поддержке стратегического проекта «Исследовательское лидерство (от бакалавра до нобелевского лауреата)» программы «Приоритет-2030» Московского физико-технического института. Анализ методов глубокого обучения выполнен в рамках работ по Соглашению № 075-03-2024-117 от 17.01.2024.

Список литературы

1. *Гвишиани А. Д., Добровольский М. Н., Дзеранов Б. В., Дзобоев Б. А.* Большие данные в геофизике и других науках о Земле // *Физика Земли*. 2022. № 1. С. 3–34. <https://doi.org/10.31857/S0002333722010033>.
2. *Погожева М. П., Якушев Е. В., Терский П. Н., Глазов Д. М., Аляутдинов В. А., Коршенко А. Н., Ханке Г., Семилетов И. П.* Оценка загрязнения Баренцева моря плавающим морским мусором по данным судовых наблюдений в 2019 г. // *Известия Томского политехнического университета. Инжиниринг георесурсов*. 2021. Т. 332. № 2. С. 87–96. <https://doi.org/10.18799/24131830/2021/02/3045>.
3. *Acuña-Ruz T., Uribe D., Taylor R., Amezcua L., Guzman M. C., Merrill J., Martinez P., Voisin L., Cristian M. B.* Anthropogenic marine debris over beaches: Spectral characterization for remote sensing applications // *Remote Sensing of Environment*. 2018. Vol. 217. P. 309–322. <https://doi.org/10.1016/j.rse.2018.08.008>.
4. *Aliani S., Molcard A.* Hitch-hiking on floating marine debris: macrobenthic species in the western Mediterranean Sea // *Hydrobiologia*. 2003. Vol. 503. P. 59, 67. <https://doi.org/10.1023/B:HYDR.0000008480.95045.26>.
5. *Andrady A. L.* Persistence of plastic litter in the oceans // *Marine anthropogenic litter*. 2015. P. 57–72. https://doi.org/10.1007/978-3-319-16510-3_3.
6. Arctic Monitoring and Assessment Programme (AMAP). AMAP Litter and Microplastics Monitoring Guidelines. Version 1.0 // Arctic Monitoring and Assessment Programme (AMAP). 2021. P. 1–257. <http://dx.doi.org/10.25607/OBP-1667>.
7. *Arthur C., Murphy P., Opfer S., Morishige C.* Bringing together the marine debris community using “ships of opportunity” and a Federal marine debris information clearinghouse // *Technical Proceedings of the Fifth International Marine Debris Conference*. 2009. NOAA Technical Memorandum NOS-OR&R-38. P. 449–453. <https://doi.org/10.2788/92438>.
8. *Barboza L. G. A., Vethaak A. D., Lavorante B. R., Lundebye A. K., Guilhermino, L.* Marine microplastic debris: An emerging issue for food security, food safety and human health // *Marine pollution bulletin*. 2018. Vol. 133. P. 336–348. <https://doi.org/10.1016/j.marpolbul.2018.05.047>.
9. Black Sea Commission. Black Sea Marine Litter Regional Action Plan // Black Sea Commission Publications. 2018. P. 1–30.
10. *Bolya D., Zhou C., Xiao F., Lee Y. J.* Yolact: Real-time instance segmentation // *Proc. of the IEEE/CVF International Conference on Computer Vision*. 2019. P. 9157–9166. <https://doi.org/10.1109/ICCV.2019.00925>.
11. *Boerger C. M., Lattin G. L., Moore S. L., Moore C. J.* Plastic ingestion by planktivorous fishes in the North Pacific Central Gyre // *Marine Pollution Bulletin*. 2010. Vol. 60. No. 12. P. 2275–2278. <https://doi.org/10.1016/j.marpolbul.2010.08.007>.
12. *Booth H., Ma W., Karakuş O.* High-precision density mapping of marine debris and floating plastics via satellite imagery // *Sci. Rep.* 2023. Vol. 13. No. 6822. <https://doi.org/10.1038/s41598-023-33612-2>.
13. *Carney Almroth B. C., Eggert H.* Marine Plastic Pollution: Sources, Impacts, and Policy Issues // *Review of Environmental Economics and Policy*. 2019. Vol. 13 (2). P. 317–326. <https://doi.org/10.1093/reep/rez012>.
14. *de Vries R., Egger M., Mani T., Lebreton L.* Quantifying Floating Plastic Debris at Sea Using Vessel-Based Optical Data and Artificial Intelligence // *Remote Sens.* 2021. Vol. 13. No. 3401. <https://doi.org/10.3390/rs13173401>.
15. *de Vries R.* Using AI to Monitor Plastic Density in the Ocean // *The Ocean Clean Up Project*. <https://theoceancleanup.com>. 2022.

16. *Derraik J. G. B.* The pollution of the marine environment by plastic debris: a review // *Marine Pollution Bulletin*. 2002. Vol. 44 (9). P. 842–852. [https://doi.org/10.1016/S0025-326X\(02\)00220-5](https://doi.org/10.1016/S0025-326X(02)00220-5).
17. *Domènech F., Aznar F. J., Raga J. A., Tomás J.* Two decades of monitoring marine debris ingestion in loggerhead sea turtle, *Caretta caretta*, from the western Mediterranean // *Environmental Pollution*. 2019. Vol. 244. P. 367–378. <https://doi.org/10.1016/j.envpol.2018.10.047>.
18. *Ershova A., Vorotnichenko E., Gordeeva S., Ruzhnikova N., Trofimova A.* Beach litter composition, distribution patterns and annual budgets on Novaya Zemlya archipelago, Russian Arctic // *Marine Pollution Bulletin*. 2024. Vol. 204. No. 116517. <https://doi.org/10.1016/j.marpolbul.2024.116517>.
19. *Fallati L., Polidori A., Salvatore C., Saponari L., Savini A., Galli A.* Anthropogenic marine debris assessment with unmanned aerial vehicle imagery and deep learning: a case study along the beaches of the Republic of Maldives // *Sci. Total Environ*. 2019. Vol. 693. No. 133581. <https://doi.org/10.1016/j.scitotenv.2019.133581>.
20. *Fleet D., Vlachogianni T., Hanke G.* A joint list of litter categories for marine macrolitter monitoring Manual for the application of the classification system // JRC Technical Report. 2021. <https://doi.org/10.2760/127473>.
21. *Fulton M., Hong J., Islam M. J., Sattar J.* Robotic detection of marine litter using deep visual detection models // *International Conference on Robotics and Automation (ICRA)*. 2019. P. 5752–5758. <https://doi.org/10.1109/ICRA.2019.8793975>.
22. *Galgani F., Hanke G., Maes T.* Global Distribution, Composition and Abundance of Marine Litter // *Marine Anthropogenic Litter*. 2015. Heidelberg New York Dordrecht London: Springer International Publishing. P. 29–56. JRC88794. https://doi.org/10.1007/978-3-319-16510-3_2.
23. *Galgani F., Pastor R. O. S., Ronchi F., Tallec K., Fischer E., Matiddi M., Anastasopoulou A., Andresmaa E., Angiolillo M., Bakker Paiva M., Booth A. M., Buhhalko N., Cadiou B., Claro F., Consoli P., Darmon G., Deudero S., Fleet D., Fortibuoni T., Fossi M.C., Gago J., Gerigny O., Giorgetti A., Gonzalez Fernandez D., Guse N., Haseler M., Ioakeimidis C., Kammann U., Kühn S., Lacroix C., Lips I., Loza A. L., Molina Jack M. E., Noren K., Papadoyannakis M., Pragnell-Raasch H., Rindorf A., Ruiz M., Setälä O., Schulz M., Schultze M., Silvestri C., Soederberg L., Stoica E., Storr-Paulsen M., Strand J., Valente T., Van Franeker J. A., Van Loon W., Vighi M., Vinci M., Vlachogianni T., Volckaert A., Weie, S., Wenneker B., Werner S., Zeri C., Zorzo P., Hanke G.* European Commission: Joint Research Centre, Guidance on the monitoring of marine litter in European seas – An update to improve the harmonised monitoring of marine litter under the Marine Strategy Framework Directive // *Publications Office of the European Union*. 2023. JRC133594. <https://doi.org/10.2760/59137>.
24. *Gall S. C., Thompson R. C.* The impact of debris on marine life // *Marine Pollution Bulletin*. 2015. Vol. 92 (1–2). P. 170–179. <https://doi.org/10.1016/j.marpolbul.2014.12.041>.
25. *González-Fernández D., Hanke G., Pogojeva M., Machitadze N., Kotelnikova Y., Tretiak I., Savenko O., Bilashvili K., Gelashvili N., Fedorov A., Kulagin D., Terentiev A., Slobodnik J.* Floating marine macro litter in the Black Sea: Toward baselines for large scale assessment // *Environmental Pollution*. 2022. Vol. 309. 119816. ISSN 0269-7491. <https://doi.org/10.1016/j.envpol.2022.119816>.
26. *Gregory M. R.* Environmental implications of plastic debris in marine settings-entanglement, ingestion, smothering, hangers-on, hitch-hiking and alien invasions // *Phil. Trans. R. Soc. B*. 2009. Vol. 364. P. 2013–2025. <http://doi.org/10.1098/rstb.2008.0265>.
27. *Grøsvik B. E., Prokhorova T., Eriksen E., Krivosheya P., Horneland P. A., Prozorkevich D.* Assessment of Marine Litter in the Barents Sea, a Part of the Joint Norwegian–Russian Ecosystem Survey // *Frontiers in Marine Science*. 2018. No. 5. <https://doi.org/10.3389/fmars.2018.00072>.

28. Hanke G., Piha H. Large-scale monitoring of surface floating marine litter by high resolution imagery // Presentation and extended abstract, 5th International Marine DEBRIS Conference. 2011.
29. HELCOM – the Helsinki Convention Organization. HELCOM activities report for the year 2023 // Baltic Sea Environment Proceedings. 2023. No. 196.
30. Hu Ch. Remote detection of marine debris using satellite observations in the visible and near infrared spectral range: Challenges and potentials // Remote Sensing of Environment. 2021. Vol. 259 (28). No. 112414. <https://doi.org/112414.10.1016/j.rse.2021.112414>.
31. Iñiguez M. E., Conesa J. A., Fullana A. Marine debris occurrence and treatment: A review // Renewable and Sustainable Energy Reviews. 2016. Vol. 64 (C). P. 394–402. <https://doi.org/10.1016/j.rser.2016.06.031>.
32. Intergovernmental Oceanographic Commission of UNESCO. IOC Strategic Plan for Ocean Data and Information Management (2023–2029) // IOC UNESCO. 2023. P. 1–18. <https://doi.org/10.25607/OBP-1377.2>.
33. Jakovljevic G., Govedarica M., Alvarez-Taboada F. A deep learning model for automatic plastic mapping using unmanned aerial vehicle (uav) data // Remote Sensing. 2020. Vol. 12. No. 1515. <https://doi.org/10.3390/rs12091515>.
34. Jocher G., Stoken A., Borovec J., Changyu L., Hogan A., Diaconu L., Ingham F., Poznanski J., Fang J., Yu L., Wang M., Gupta N., Akhtar O., Rai P. Ultralytics/yolov5: v3.0 // Zenodo. 2020. <https://zenodo.org/records/3983579>.
35. Katsanevakis S. Marine debris, a growing problem: Sources, distribution, composition, and impacts // Open Access Library Journal. 2014. Vol. 1. No. 3.
36. Kikaki K., Kakogeorgiou I., Mikeli P., Raitzos D. E., Karantzas K. MARIDA: A benchmark for marine debris detection from sentinel-2 remote sensing data // PLoS ONE. 2022. Vol. 17 (1). <https://doi.org/10.1371/journal.pone.0262247>.
37. Kylili K., Artusi A., Hadjistassou C. A new paradigm for estimating the prevalence of plastic litter in the marine environment // Marine Pollution Bulletin. 2021. Vol. 173. No. 113127. <https://doi.org/10.1016/j.marpolbul.2021.113127>.
38. Kylili K., Hadjistassou C., Artusi A. An intelligent way for discerning plastics at the shorelines and the seas // Environmental Science and Pollution Research. 2021. Vol. 27. P. 42631–42645. <https://doi.org/10.1007/s11356-020-10105-7>.
39. Kylili K., Kyriakides I., Artusi A., Hadjistassou C. Identifying floating plastic marine debris using a deep learning approach // Environmental Science and Pollution Research. 2019. Vol. 26. P. 17091–17099. <https://doi.org/10.1007/s11356-019-05148-4>.
40. Lebreton L., Slat B., Ferrari F., Sainte-Rose B., Aitken J., Marthouse R., Hajbane S., Cunsolo S., Schwarz A., Levivier A., Noble K., Debeljak P., Maral H., Schoeneich-Argent R., Brambini R., and Reisser J. Evidence that the Great Pacific Garbage Patch is rapidly accumulating plastic. Sci. Rep. 2018. No. 8. Art. 4666. <https://doi.org/10.1038/s41598-018-22939-w>.
41. Lippiatt S., Opfer S., Arthur C. Marine Debris Monitoring and Assessment: Recommendations for Monitoring Debris Trends in the Marine Environment // NOAA Technical Memorandum NOSOR&R-46. 2013. <http://dx.doi.org/10.25607/OBP-727>.
42. Mace T. H. At-sea detection of marine debris: Overview of technologies, processes, issues, and options // Marine Pollution Bulletin. 2012. Vol. 65 (1–3). No. 23–7. <https://doi.org/10.1016/j.marpolbul.2011.08.042>.
43. Maximenko N., Corradi P., Law K., Van S., Garaba S., Lampitt R., Galgani F., Martinez-Vicente V., Goddijn-Murphy L., Veiga J., Thompson R., Maes C., Moller D., Löscher C., Addamo A., Lamson M., Centurioni L., Posth N., Lumpkin R., Vinci M., Martins A., Pieper C.,

- Isobe A., Hanke G., Edwards M., Chubarenko I., Rodriguez E., Aliani S., Arias M., Asner G., Brosich A., Carlton J., Chao Y., Cook A., Cundy A., Galloway T., Giorgetti A., Goni G., Guichoux Y., Haram L., Hardesty B.* Toward the Integrated Marine Debris Observing System // *Frontiers in Marine Science*. 2019. Vol. 6. No. 447. <https://doi.org/10.3389/fmars.2019.00447>.
44. *Meijer L. J., van Emmerik T., van der Ent R., Schmidt C., Lebreton L.* More Than 1000 Rivers Account for 80 % of Global Riverine Plastic Emissions Into the Ocean // *Science Advances*. 2021. Vol. 7. eaaz5803. <https://doi.org/10.1126/sciadv.aaz5803>.
45. *Moy K., Neilson B., Chung A., Meadows A., Castrence M., Ambagis S., Davidson K.* Mapping coastal marine debris using aerial imagery and spatial analysis // *Marine Pollution Bulletin, SI: Japanese Tsunami Debris*. 2018. Vol. 132. P. 52–59. <https://doi.org/10.1016/j.marpolbul.2017.11.045>.
46. OSPAR Commission. Finding common ground; Towards regional coherence in implementing the Marine Strategy Framework Directive in the North-East Atlantic region through the work of the OSPAR Commission // OSPAR Commission. 2012. <https://doi.org/10.1016/j.marpolbul.2018.12.038>.
47. *Pichel W. G., Veenstra T. S., Churnside J. H., Arabini E., Friedman K. S., Foley D. G., Brainard R. E., Kiefer D., Ogle S., Clemente-Colón P., Li X.* GhostNet marine debris survey in the Gulf of Alaska—Satellite guidance and aircraft observations // *Marine Pollution Bulletin*. 2012. Vol. 65. P. 28–41. <https://doi.org/10.1016/j.marpolbul.2011.10.009>.
48. *Pogojeva M., Zhdanov I., Berezina A., Lapenkov A., Kosmach D., Osadchiev A., Hanke G., Semiletov I., Yakushev E.* Distribution of floating marine macro-litter in relation to oceanographic characteristics in the Russian Arctic Seas // *Marine Pollution Bulletin*. 2021. Vol. 166. Art. 112201. <https://doi.org/10.1016/j.marpolbul.2021.112201>.
49. *Ryan P. G.* A simple technique for counting marine debris at sea reveals steep litter gradients between the Straits of Malacca and the Bay of Bengal // *Marine Pollution Bulletin*. 2010. Vol. 60. P. 128–136. <https://doi.org/10.1016/j.marpolbul.2013.01.016>.
50. *Sannigrāhi S., Basu B., Basu A. S., Pilla F.* Development of automated marine floating plastic detection system using sentinel-2 imagery and machine learning models // *Marine Pollution Bulletin*. 2022. No. 178. Art. 113527. <https://doi.org/10.1016/j.marpolbul.2022.113527>.
51. *Savastano S., Cester I., Perpinya M., Romero L.* A first approach to the automatic detection of marine litter in SAR images using artificial intelligence // *IEEE International Geoscience and Remote Sensing Symposium IGARSS*. 2021. P. 8704–8707. <https://doi.org/10.1109/IGARSS47720.2021.9737038>.
52. *Selvam K., Xavier K. A. M., Shivakrishna A., Bhutia T. P., Kamat S., Shenoy L.* Abundance, composition and sources of marine debris trawled-up in the fishing grounds along the north-east Arabian coast // *Science of The Total Environment*. 2021. No. 751. Art. 141771. <https://doi.org/10.1016/j.scitotenv.2020.141771>.
53. *Sheavly S. B., Register K. M.* Marine debris & plastics: environmental concerns, sources, impacts and solutions // *Journal of Polymers and the Environment*. 2007. Vol. 15. P. 301–305. <https://doi.org/10.1007/s10924-007-0074-3>.
54. *Teng C., Kylili K., Hadjistassou C.* Deploying deep learning to estimate the abundance of marine debris from video footage // *Marine Pollution Bulletin*. 2022. No. 183. Art. 114049. <https://doi.org/10.1016/j.marpolbul.2022.114049>.
55. *Topouzelis K., Papageorgiou D., Suaria G., Aliani S.* Floating marine litter detection algorithms and techniques using optical remote sensing data: A review // *Marine Pollution Bulletin*. 2021. No. 170. Art. 112675. <https://doi.org/10.1016/j.marpolbul.2021.112675>.
56. *Tran T. L. C., Huang Z.-C., Tseng K.-H., Chou P.-H.* Detection of Bottle Marine Debris Using Unmanned Aerial Vehicles and Machine Learning Techniques // *Drones*. 2022. Vol. 6. No. 401. <https://doi.org/10.3390/drones6120401>.

57. United Nations Environment Programme. Climate Change 1995 – A Report by the Intergovernmental Panel on Climate Change // UNEP. 1995.
58. United Nations Environment Programme, Mediterranean Action Plan, Regional Activity Centre for Specially Protected Areas (UNEP-MAP RAC/SPA). Guidelines for the Establishment and Management of Marine Protected Areas for Cetaceans // UNEP. 2011. P. 1–36.
59. United Nations Environment Programme. United Nations Environment Programme 2009 Annual Report // UNEP. 2010.
60. *Valdenegro-Toro M. A.* Deep Neural Networks for Marine Debris Detection in Sonar Images // IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). 2019. No. 00417. <https://doi.org/10.48550/arXiv.1905.05241>.
61. *van Franeker J. A., Blaize C., Danielsen J., Fairclough K., Gollan J., Guse N., Hansen P. L., Heubeck M., Jensen J.-K., Le Guillou G., Olsen B., Olsen K.-O., Pedersen J., Stienen E. W. M., Turner D. M.* Monitoring plastic ingestion by the northern fulmar *Fulmarus glacialis* in the North Sea // Environmental Pollution. 2011. Vol. 159. No. 10. P. 2609–2615. <https://doi.org/10.1016/j.envpol.2011.06.008>.
62. *Veiga J. M., Fleet D., Kinsey S., Nilsson P., Vlachogianni T., Werner S., Galgani F., Thompson R. C., Dagevos J., Gago J., Sobral P., Cronin R.* Identifying Sources of Marine Litter // MSFD GES TG Marine Litter Thematic Report; JRC Technical Report. 2016. EUR 28309. <https://doi.org/10.2788/018068>.
63. *Vighi M., Ruiz-Orejón L. F., Hanke G.* Monitoring of Floating Marine Macro Litter: State of the art and literature overview // MSFD Technical Group on Marine Litter. 2022. JRC129261. <https://doi.org/10.2760/78914>.
64. *Watanabe J. I., Shao Y., Miura N.* Underwater and airborne monitoring of marine ecosystems and debris // Journal of Applied Remote Sensing. 2019. Vol. 13. No. 1. <https://doi.org/10.1117/1.JRS.13.044509>.
65. *Xue B., Huang B., Chen G., Li H., Wei W.* Deep-Sea Debris Identification Using Deep Convolutional Neural Networks // IEEE journal of selected topics in applied Earth Observations and remote sensing. 2021. Vol. 14. P. 8909–8921. <https://doi.org/10.1109/JSTARS.2021.3107853>.

Статья поступила в редакцию 10.10.2024, одобрена к печати 25.12.2024.

Для цитирования: Белоусова О., Криницкий М. А., Погожева М. П. Современные средства и методы мониторинга плавающего морского макромусора и внедрение технологий машинного обучения // Океанологические исследования. 2024. № 52 (4). С. 243–268. [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).12](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).12).

MODERN FLOATING MARINE MACROLITTER MONITORING APPROACHES AND METHODS AND INTEGRATION OF MACHINE LEARNING TECHNIQUES

O. Bilousova^{1,2}, M. A. Krinitskiy^{1,2}, M. P. Pogojeva^{1,3}

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

² Institute of Physics and Technology (National Research University),
9, Institutskiy pereulok, Dolgoprudny, 141701, Russia;

³ N. N. Zubov's State Oceanographic Institute, Roshydromet,
6, Kropotkinsky pereulok, Moscow, 119034, Russia,
e-mail: belousova.o@phystech.edu

Marine litter pollution is currently recognized as global problem at the level of all international organizations and conventions related to the marine protection. This review examines modern methods and approaches for detecting floating marine macrolitter. The task of detecting marine litter on the water surface is complicated by a large variety of objects, various degrees of their degradation, predominantly small size, partial immersion in the subsurface layer, colorlessness, disguising within the water, difficult observation conditions. The main approaches today include visual observations (from ships, aircraft), trawling, and remote sensing, especially using radar systems. In the last decade, deep learning methods have made significant progress, which has allowed error recognition and identification to be brought to a new level due to various modifications of artificial neural networks. In this review, we analyze the main research on the presented topic and significant achievements and prospects for the application of artificial intelligence to improve methods for detecting and classifying marine litter larger than 2.5 cm.

Keywords: marine litter, marine environmental monitoring, artificial intelligence, object detection, remote sensing, data collection, machine learning, artificial neural networks

Acknowledgments: The study of approaches to obtaining data and a review of organizations involved in ocean pollution monitoring work was carried out within the framework of State Assignment No. FMWE-2022-0002. The review of data processing methods and the geographical distribution of studies was 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. The analysis of deep learning methods was carried out as part of the work under Agreement No. 075-03-2024-117 dated 01.17.2024.

References

1. Acuña-Ruz, T., D. Uribe, R. Taylor, L. Amezcuita, M. C. Guzman, J. Merrill, P. Martinez, L. Voisin, and M. B. Cristian, 2018: Anthropogenic marine debris over beaches: Spectral characterization for remote sensing applications. *Remote Sensing of Environment*, **217**, 309–322.
2. Aliani, S. and A. Molcard, 2003: Hitch-hiking on floating marine debris: macrobenthic species in the western Mediterranean Sea. *Hydrobiologia*, **503**, 59–67.

3. Andrady, A. L., 2015: Persistence of plastic litter in the oceans. *Marine anthropogenic litter*, 57–72.
4. Arctic Monitoring and Assessment Programme (AMAP), 2021 AMAP Litter and Microplastics Monitoring Guidelines. Version 1.0. *Arctic Monitoring and Assessment Programme (AMAP)*, 1–257.
5. Arthur, C., P. Murphy, S. Opfer, and C. Morishige, 2009: Bringing together the marine debris community using “ships of opportunity” and a Federal marine debris information clearinghouse. *Technical Proceedings of the Fifth International Marine Debris Conference*, 449–453.
6. Barboza, L. G. A., A. D. Vethaak, B. R. Lavorante, A. K. Lundebye, and L. Guilhermino, 2018: Marine microplastic debris: An emerging issue for food security, food safety and human health. *Marine pollution bulletin*, **133**, 336–348.
7. Black Sea Commission, 2018: Black Sea Marine Litter Regional Action Plan. *Black Sea Commission Publications*, 1–30.
8. Bolya, D., C. Zhou, F. Xiao, and Y. J. Lee, 2019: Yolact: Real-time instance segmentation. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 9157–9166.
9. Boerger, C. M., G. L. Lattin, S. L. Moore, and C. J. Moore, 2010: Plastic ingestion by planktivorous fishes in the North Pacific Central Gyre. *Marine Pollution Bulletin*, **60** (12), 2275–2278.
10. Booth, H., W. Ma, and O. Karakuş, 2023: High-precision density mapping of marine debris and floating plastics via satellite imagery. *Sci. Rep.*, **13**, 6822, <https://doi.org/10.1038/s41598-023-33612-2>.
11. Carney Almroth, B. C. and H. Eggert, 2019: Marine Plastic Pollution: Sources, Impacts, and Policy Issues. *Review of Environmental Economics and Policy*, **13** (2), 317–326.
12. de Vries, R., M. Egger, T. Mani, and L. Lebreton, 2021: Quantifying Floating Plastic Debris at Sea Using Vessel-Based Optical Data and Artificial Intelligence. *Remote Sens.*, **13**, 3401, <https://doi.org/10.3390/rs13173401>.
13. de Vries, R., 2022: Using AI to Monitor Plastic Density in the Ocean. *The Ocean Clean-Up Project*, <https://theoceancleanup.com>.
14. Derraik, J. G. B., 2002: The pollution of the marine environment by plastic debris: a review. *Marine Pollution Bulletin*, **44** (9), 842–852.
15. Domènech, F., F. J. Aznar, J. Raga, and J. Tomás, 2019: Two decades of monitoring marine debris ingestion in loggerhead sea turtle, *Caretta caretta*, from the western Mediterranean. *Environmental Pollution*, **244**, 367–378.
16. Ershova, A., E. Vorotnichenko, S. Gordeeva, N. Ruzhnikova, and A. Trofimova, 2024: Beach litter composition, distribution patterns and annual budgets on Novaya Zemlya archipelago, Russian Arctic. *Marine Pollution Bulletin*, **204**, 116517.
17. Fallati, L., A. Polidori, C. Salvatore, L. Saponari, A. Savini, and A. Galli, 2019: Anthropogenic marine debris assessment with unmanned aerial vehicle imagery and deep learning: a case study along the beaches of the Republic of Maldives. *Sci. Total Environ.*, **693**, 133581.
18. Fleet, D., T. Vlachogianni, and G. Hanke, 2021: A joint list of litter categories for marine macrolitter monitoring. Manual for the application of the classification system. *JRC Technical Report*.
19. Fulton, M., J. Hong, M. J. Islam, and J. Sattar, 2019: Robotic detection of marine litter using deep visual detection models. *International Conference on Robotics and Automation (ICRA)*, 5752–5758.
20. Galgani, F., G. Hanke, and T. Maes, 2015: Global Distribution, Composition and Abundance of Marine Litter, in: Bergmann, M., Gutow, L., Klages, M. (Eds). *Marine Anthropogenic Litter*, 29–56, JRC88794
21. Galgani, F., R. O. S. Pastor, F. Ronchi, K. Tallec, E. Fischer, M. Matiddi, A. Anastasopoulou, E. Andresmaa, M. Angiolillo, M. Bakker Paiva, A. M. Booth, N. Buhhalko, B. Cadiou, F. Claro,

- P. Consoli, G. Darmon, S. Deudero, D. Fleet, T. Fortibuoni, M. C. Fossi, J. Gago, O. Gerigny, A. Giorgetti, D. Gonzalez Fernandez, N. Guse, M. Haseler, C. Ioakeimidis, U. Kammann, S. Kühn, C. Lacroix, I. Lips, A. Loza, M. E. Molina Jack, K. Noren, M. Papadoyannakis, H. Pragnell-Raasch, A. Rindorf, M. Ruiz, O. Setälä, M. Schulz, M. Schultze, C. Silvestri, L. Soederberg, E. Stoica, M. Storr-Paulsen, J. Strand, T. Valente, J. A. Van Franeker, W. Van Loon, M. Vighi, M. Vinci, T. Vlachogianni, A. Volckaert, S. Weie, B. Wenneker, S. Werner, C. Zeri, P. Zorzo, and G. Hanke, 2023: European Commission: Joint Research Centre, Guidance on the monitoring of marine litter in European seas – An update to improve the harmonised monitoring of marine litter under the Marine Strategy Framework Directive. *Publications Office of the European Union*, JRC133594.
22. Gall, S. C. and R. C. Thompson, 2015: The impact of debris on marine life. *Marine Pollution Bulletin*, **92** (1–2), 170–179.
 23. González-Fernández, D., G. Hanke, M. Pogojeva, N. Machitadze, Y. Kotelnikova, I. Tretiak, O. Savenko, K. Bilashvili, N. Gelashvili, A. Fedorov, D. Kulagin, A. Terentiev, and J. Slobodnik, 2022: Floating marine macro litter in the Black Sea: Toward baselines for large scale assessment. *Environmental Pollution*, **309**, 119816, ISSN 0269-7491, <https://doi.org/10.1016/j.envpol.2022.119816>.
 24. Gregory, M. R., 2009: Environmental implications of plastic debris in marine settings-entanglement, ingestion, smothering, hangers-on, hitch-hiking and alien invasions. *Phil. Trans. R. Soc. B* **364**, 2013–2025, <http://doi.org/10.1098/rstb.2008.0265>.
 25. Grøsvik, B. E., T. Prokhorova, E. Eriksen, P. Krivosheya, P. A. Horneland, and D. Prozorkevich, 2018: Assessment of Marine Litter in the Barents Sea, a Part of the Joint Norwegian–Russian Ecosystem Survey. *Frontiers in Marine Science*, **5**.
 26. Gvishiani, A. D., M. N. Dobrovolskij, B. V. Dzeranov, and B. A. Dzebojev, 2022: Big Data in Geophysics and Other Earth Studies. *Earth Physics*, **1**, 3–34.
 27. Hanke, G. and H. Piha, 2011: Large-scale monitoring of surface floating marine litter by high resolution imagery. *Presentation and extended abstract, 5th International Marine DEBRIS Conference*, Hawaii, Honolulu.
 28. HELCOM – the Helsinki Convention Organization, 2023: HELCOM activities report for the year 2023. *Baltic Sea Environment Proceedings*, No. 196.
 29. Hu, Ch., 2021: Remote detection of marine debris using satellite observations in the visible and near infrared spectral range: Challenges and potentials. *Remote Sensing of Environment*, **259** (28), 112414.
 30. Iñiguez, M. E., J. A. Conesa, and A. Fullana, 2016: Marine debris occurrence and treatment: A review. *Renewable and Sustainable Energy Reviews*, **64** (C), 394–402.
 31. Intergovernmental Oceanographic Commission of UNESCO, 2023: IOC Strategic Plan for Ocean Data and Information Management (2023–2029). *IOC UNESCO*, 1–18, <https://doi.org/10.25607/OBP-1377.2>.
 32. Jakovljevic, G., M. Govedarica, and F. Alvarez-Taboada, 2020: A deep learning model for automatic plastic mapping using unmanned aerial vehicle (UAV) data. *Remote Sensing*, **12**, 1515.
 33. Jocher, G., A. Stoken, J. Borovec, L. Changyu, A. Hogan, L. Diaconu, F. Ingham, J. Poznanski, J. Fang, L. Yu, M. Wang, N. Gupta, O. Akhtar, and P. Rai, 2020: Ultralytics/yolov5: v3.0. *Zenodo*, <https://zenodo.org/records/3983579> (last accessed 26.11.2024).
 34. Katsanevakis, S., 2014: Marine debris, a growing problem: Sources, distribution, composition, and impacts. *Open Access Library Journal*, **1**, 3.
 35. Kikaki, K., I. Kakogeorgiou, P. Mikeli, D. E. Raitsos, and K. Karantzalos, 2022: MARIDA: A benchmark for marine debris detection from sentinel-2 remote sensing data. *PLoS ONE*, **17** (1).

36. Kylili, K., A. Artusi, and C. Hadjistassou, 2021: A new paradigm for estimating the prevalence of plastic litter in the marine environment. *Marine Pollution Bulletin*, **173**, 113127.
37. Kylili, K., C. Hadjistassou, and A. Artusi, 2021. An intelligent way for discerning plastics at the shorelines and the seas. *Environmental Science and Pollution Research*, **27**, 42631–42645.
38. Kylili, K., I. Kyriakides, A. Artusi, and C. Hadjistassou, 2019: Identifying floating plastic marine debris using a deep learning approach. *Environmental Science and Pollution Research*, **26**, 17091–17099.
39. Lebreton, L., B. Slat, F. Ferrari, B. Sainte-Rose, J. Aitken, R. Marthouse, S. Hajbane, S. Cunsolo, A. Schwarz, A. Levivier, K. Noble, P. Debeljak, H. Maral, R. Schoeneich-Argent, R. Brambini, and J. Reisser, 2018: Evidence that the Great Pacific Garbage Patch is rapidly accumulating plastic. *Sci. Rep.*, **8**, 4666, <https://doi.org/10.1038/s41598-018-22939-w>.
40. Lippiatt, S., S. Opfer, and C. Arthur, 2013: Marine Debris Monitoring and Assessment: Recommendations for Monitoring Debris Trends in the Marine Environment. *NOAA Technical Memorandum NOSOR&R-46*.
41. Mace, T. H., 2012: At-sea detection of marine debris: Overview of technologies, processes, issues, and options. *Marine Pollution Bulletin*, **65** (1–3), 23–7.
42. Maximenko, N., P. Corradi, K. Law, S. Van, S. Garaba, R. Lampitt, F. Galgani, V. Martinez-Vicente, L. Goddijn-Murphy, J. Veiga, R. Thompson, C. Maes, D. Moller, C. Löscher, A. Addamo, M. Lamson, L. Centurioni, N. Posth, R. Lumpkin, M. Vinci, A. Martins, C. Pieper, A. Isobe, G. Hanke, M. Edwards, I. Chubarenko, E. Rodriguez, S. Aliani, M. Arias, G. Asner, A. Brosich, J. Carlton, Y. Chao, A. Cook, A. Cundy, T. Galloway, A. Giorgetti, G. Goni, Y. Guichoux, L. Haram, and B. Hardesty, 2019: Toward the Integrated Marine Debris Observing System. *Frontiers in Marine Science*, **6** (447), <https://doi.org/10.3389/fmars.2019.00447>.
43. Meijer, L. J., T. van Emmerik, R. van der Ent, C. Schmidt, and L. Lebreton, 2021: More Than 1000 Rivers Account for 80 % of Global Riverine Plastic Emissions into the Ocean. *Science Advances*, **7**, eaaz5803.
44. Moy, K., B. Neilson, A. Chung, A. Meadows, M. Castrence, S. Ambagis, and K. Davidson, 2018: Mapping coastal marine debris using aerial imagery and spatial analysis. *Marine Pollution Bulletin*, SI: Japanese Tsunami Debris, **132**, 52–59.
45. *OSPAR Commission*, 2012: Finding common ground; Towards regional coherence in implementing the Marine Strategy Framework Directive in the North-East Atlantic region through the work of the OSPAR Commission. OSPAR Commission.
46. Pichel, W. G., T. S. Veenstra, J. H. Churnside, E. Arabini, K. S. Friedman, D. G. Foley, R. E. Brainard, D. Kiefer, S. Ogle, P. Clemente-Colón, and X. Li, 2012: GhostNet marine debris survey in the Gulf of Alaska—Satellite guidance and aircraft observations. *Marine Pollution Bulletin*, **65**, 28–41.
47. Pogojeva, M., E. Yakushev, P. Terskii, D. Glazov, V. Aliautdinov, A. Korshenko, and G. Hanke, 2021: Assessment of Barents Sea Floating Marine Macro Litter Pollution During The Vessel Survey In 2019. *Tomsk State Pedagogical University Bulletin*, **332**, 87–96, <https://doi.org/10.18799/24131830/2021/02/3045>.
48. Pogojeva, M., I. Zhdanov, A. Berezina, A. Lapenkov, D. Kosmach, A. Osadchiev, G. Hanke, I. Semiletov, and E. Yakushev, 2021: Distribution of floating marine macro-litter in relation to oceanographic characteristics in the Russian Arctic Seas. *Marine Pollution Bulletin*, **166**, 112201, ISSN 0025-326X, <https://doi.org/10.1016/j.marpolbul.2021.112201>.
49. Ryan, P. G., 2010: A simple technique for counting marine debris at sea reveals steep litter gradients between the Straits of Malacca and the Bay of Bengal. *Marine Pollution Bulletin*, **60**, 128–136.

50. Sannigrahi, S., B. Basu, A. S. Basu, and F. Pilla, 2022: Development of automated marine floating plastic detection system using sentinel-2 imagery and machine learning models. *Marine Pollution Bulletin*, **178**, 113527.
51. Savastano, S., I. Cester, M. Perpinya, and L. Romero, 2021: A first approach to the automatic detection of marine litter in SAR images using artificial intelligence. *IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 8704–8707.
52. Selvam, K., K. A. M. Xavier, A. Shivakrishna, T. P. Bhutia, S. Kamat, and L. Shenoy, 2021: Abundance, composition and sources of marine debris trawled-up in the fishing grounds along the north-east Arabian coast. *Science of The Total Environment*, **751**, 141771.
53. Sheavly, S. B. and K. M. Register, 2007: Marine debris & plastics: environmental concerns, sources, impacts and solutions. *Journal of Polymers and the Environment*, **15**, 301–305.
54. Teng, C., K. Kylili, and C. Hadjistassou, 2022: Deploying deep learning to estimate the abundance of marine debris from video footage. *Marine Pollution Bulletin*, **183**, 114049.
55. Topouzelis, K., D. Papageorgiou, G. Suaria, and S. Aliani, 2021: Floating marine litter detection algorithms and techniques using optical remote sensing data: A review. *Marine Pollution Bulletin*, **170**, 112675, <https://doi.org/10.1016/j.marpolbul.2021.112675>.
56. Tran, T. L. C., Z.-C. Huang, K.-H. Tseng, and P.-H. Chou, 2022: Detection of Bottle Marine Debris Using Unmanned Aerial Vehicles and Machine Learning Techniques. *Drones*, **6**, 401.
57. *United Nations Environment Programme*, 1995: Climate Change 1995 – A Report by the Intergovernmental Panel on Climate Change. *UNEP*.
58. *United Nations Environment Programme, Mediterranean Action Plan, Regional Activity Centre for Specially Protected Areas (UNEP-MAP RAC/SPA)*, 2011: Guidelines for the Establishment and Management of Marine Protected Areas for Cetaceans. *UNEP*, 1–36.
59. *United Nations Environment Programme*, 2010: *United Nations Environment Programme 2009. Annual Report*. *UNEP*.
60. Valdenegro-Toro, M. A., 2019: Deep Neural Networks for Marine Debris Detection in Sonar Images. *IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, No. 00417.
61. van Franeker, J. A., C. Blaize, J. Danielsen, K. Fairclough, J. Gollan, N. Guse, P.-L. Hansen, M. Heubeck, J.-K. Jensen, G. Le Guillou, B. Olsen, K.-O. Olsen, J. Pedersen, E. W. M. Stienen, and D. M. Turner, 2011: Monitoring plastic ingestion by the northern fulmar *Fulmarus glacialis* in the North Sea. *Environmental Pollution*, **159** (10), 2609–2615.
62. Veiga, J. M., D. Fleet, S. Kinsey, P. Nilsson, T. Vlachogianni, S. Werner, F. Galgani, R. C. Thompson, J. Dagevos, J. Gago, P. Sobral, and R. Cronin, 2016: Identifying Sources of Marine Litter. *MSFD GES TG Marine Litter Thematic Report; JRC Technical Report*, EUR 28309.
63. Vighi, M., L. F. Ruiz-Orejón, and G. Hanke, 2022: Monitoring of Floating Marine Macro Litter: State of the art and literature overview. *MSFD Technical Group on Marine Litter*. JRC129261.
64. Watanabe, J. I., Y. Shao, and N. Miura, 2019: Underwater and airborne monitoring of marine ecosystems and debris. *Journal of Applied Remote Sensing*, **13** (1).
65. Xue, B., B. Huang, G. Chen, H. Li, and W. Wei, 2021: Deep-Sea Debris Identification Using Deep Convolutional Neural Networks. *IEEE journal of selected topics in applied Earth Observations and remote sensing*, **14**, 8909–8921.

Submitted 10.10.2024, accepted 25.12.2024.

For citation: Bilousova, O., M. A. Krinitskiy, and M. P. Pogojeva, 2024: Modern floating marine macrolitter monitoring approaches and methods and integration of machine learning techniques. *Journal of Oceanological Research*, **52** (4), 243–268, [https://doi.org/10.29006/1564-2291.JOR-2024.52\(4\).12](https://doi.org/10.29006/1564-2291.JOR-2024.52(4).12).