

Методы интеллектуального анализа радиолокационных изображений, получаемых с бортовых авиационных систем

С. Н. Кокутин • С. А. Сергиев

В статье представлено комплексное исследование последних достижений в области интеллектуальных методов решения задач технического зрения по данным радиолокационной съемки, применимых для реализации на беспилотных воздушных платформах. Актуальность обзора обусловлена быстрым развитием беспилотных авиационных систем и растущим интересом к применению малогабаритных бортовых радиолокационных станций для оперативного мониторинга, картографирования и поиска наземных объектов в сложных условиях, недоступных для традиционных оптических средств съемки. Выполнен детальный обзор ключевых проблем, возникающих при обработке данных радиолокационного зондирования с использованием искусственных нейронных сетей. Приведено систематизированное описание известных датасетов, содержащих радарные снимки и синтетические данные, применяемые для машинного обучения при разработке нейросетевых моделей. Выполнен анализ особенностей и ограничений этих датасетов. Рассмотрен широкий спектр современных методов и алгоритмов анализа радиолокационных изображений на основе глубокого обучения, а также реализованных архитектур нейронных сетей. Представлены результаты решения различных задач технического зрения, достигнутые с применением рассматриваемых методов. Обсуждены преимущества и недостатки различных подходов, исследованы факторы, влияющие на показатели точности. Определены основные перспективные направления в развитии методов обработки радиолокационных данных применительно к реальным условиям работы бортовых радиолокационных систем, в том числе многопозиционных. Практическая ценность настоящего обзора заключается в предоставлении исследователям и разработчикам в области машинного обучения систематизированной основы для создания новых методов, направленных на решение актуальных задач радиолокационного мониторинга земной поверхности, экологического контроля и обеспечения безопасности с использованием беспилотных авиационных систем.

Беспилотная авиационная система, радиолокационное изображение, датасет, искусственная нейронная сеть, глубокое обучение, обнаружение объектов, сегментация изображений, классификация объектов, разноракурсные данные.

Цитирование: Кокутин С. Н., Сергиев С. А. Методы интеллектуального анализа радиолокационных изображений, получаемых с бортовых авиационных систем // СИИТ. 2025. Т. 7, № 4 (23). С. 124–154. EDN [TTBCME](#).

Cite: Kokutin S. N., Sergiev S. A. "Methods of intelligent analysis of radar images obtained from on-board aviation systems" // SIIT. 2025. Vol. 7, no. 4 (23), pp. 124-154. EDN [TTBCME](#).

ВВЕДЕНИЕ

Радиолокационное зондирование представляет собой один из основных методов дистанционного мониторинга, обеспечивающий всепогодное наблюдение за земной поверхностью [Кон05, Зах12, Вер14]. Принцип действия активных радиолокаторов с синтезированной апертурой (РСА) основан на облучении наземных объектов зондирующим сигналом в микроволновом диапазоне (от 0,01 до 1 м) и регистрации отражённого сигнала. В отличие от оптических систем, работающих в видимом или инфракрасном диапазонах, РСА позволяют получать данные независимо от освещенности, облачности, задымленности и осадков, что делает их незаменимыми в ряде критически важных задач мониторинга.

Хорошо известно, что основными носителями для РСА являются космические аппараты (КА) дистанционного зондирования Земли (ДЗЗ) [Вер10, Гру19]. Также широко развивается применение РСА, базирующихся на воздушных судах (ВС) [Ров21] и беспилотных воздушных судах (БВС) [Лял22]. КА ДЗЗ обеспечивают глобальный охват территории и постоянный долговременный мониторинг одних и тех же участков земной поверхности, но ограничены в предоставлении разноракурсной информации. ВС дают возможность гибкого планирования съемки на относительно больших площадях с применением различных режимов радиолокационной

съемки (телескопический, секторный, полосовой и др.), но имеют ограниченный район действия и высокую стоимость эксплуатации. БВС обладают высокой экономичностью и адаптивностью к различным условиям съемки, обеспечивая при этом локальный мониторинг с низких высот, однако имеют серьезные ограничения по полезной нагрузке и времени работы. Несмотря на это, в последнее время применение беспилотных авиационных систем (БАС) с бортовыми РЛС приобретает все большую актуальность, так как вследствие автономности, малых габаритов и высокой мобильности развертывания они позволяют выполнять оперативный сбор данных при необходимости быстрого реагирования в экстренных и чрезвычайных ситуациях, а также при необходимости взлета-посадки с необорудованных площадок или эксплуатации с использованием малоразмерных посадочных платформ (суда, морские буровые платформы).

Методы радиолокационного зондирования находят широкое применение в сельском хозяйстве (оценка состояния сельскохозяйственных посевов, определение влажности почвы), ледовой разведке (обнаружение ледовых образований, оценка состояния льда, поиск трещин), сфере охраны и безопасности (контроль периметра, распознавание техники, в том числе замаскированной), экологии (мониторинг стихийных бедствий и загрязнений), а также при чрезвычайных ситуациях (поиск объектов ночью, а также в условиях задымления и тумана).

Основные задачи в рамках всего цикла обработки радиолокационных изображений (РЛИ) включают в себя: формирование РЛИ на основе исходных голограмм, предварительную обработку данных, обнаружение, сегментацию, классификацию объектов, отслеживание движущихся целей, выявление изменений, оценку характеристик объектов [Дор21]. Задачи обнаружения, сегментации и классификации объектов имеют важное значение и занимают центральное место среди вышеперечисленных этапов обработки РЛИ, так как обеспечивают основу для дальнейшего анализа данных в ходе разработки производных продуктов более высокого уровня обработки. Кроме того, обнаружение и классификация (распознавание) физических наземных объектов, а также сегментация подстилающих поверхностей представляют собой самостоятельные задачи, решение которых требуется для многих направлений прикладного применения радиолокационного зондирования с бортовых носителей, от оперативного мониторинга и разведки до высокоточного картографирования.

Методы обработки и анализа РЛИ можно разделить на два основных направления. Прежде всего это традиционные методы, основанные на выделении признаков и статистическом анализе. Они обладают хорошей интерпретируемостью и простотой реализации, но требуют длительного экспертного выделения признаков, ручной настройки и малоприспособлены для масштабируемых сценариев с большим количеством классов объектов [Дор24]. Поэтому в последнее время наибольшее распространение получили методы машинного обучения, основанные на применении различных типов искусственных нейронных сетей (ИНС), в основном методы глубокого обучения (Deep Learning, DL) [Zhu21]. Эти интеллектуальные методы обеспечивают автоматическое выделение информативных признаков и высокую точность, показывают хорошую производительность при наличии достаточных вычислительных мощностей, однако нуждаются в больших размеченных наборах данных для обучения нейросетевых моделей.

Известен ряд публикаций обзорного характера за период 2020–2025 гг., в которых рассматриваются различные современные методы обработки РЛИ [Par20, Kec21, Don21, Jan22, Yan22, Zha22, Ove22, Pas22, Li23, Sri23, Jia23, Pas23, Li23b, Yin24, Yan24, Lan25]. На рис. 1 приведено распределение обзорных статей по годам публикаций.

Обращает внимание, что наибольший вклад в распределение публикаций вносят работы (10 статей), связанные со специфической задачей технического зрения, которая в зарубежной литературе носит название Automatic Target Recognition (ATR), то есть «автоматическое распознавание целей». Методы ATR предназначены для распознавания локальных целей (такие как бронетехника, транспортные средства, суда и самолеты) в рамках технологий дистанци-

онной разведки. При этом, как правило, обучение нейросетевых моделей происходит на небольших фрагментах РЛИ, содержащихся в таких известных базах данных, как MSTAR [Bla20], OpenSARShip [Li17] и аналогичных.




Рис. 1 Распределение статей с обзором методов интеллектуального анализа РЛИ по годам публикаций в интервале от 2020 г. до 2025 г.

Таким образом, анализ доступных обзорных работ за 2020–2025 гг., касающихся темы нашей статьи, показывает, что в них присутствует существенный дисбаланс в сторону методов АТР. Соответственно, наблюдается определенный недостаток работ, исследующих другие методы интеллектуального анализа РЛИ, такие как сегментация, особенно применительно к протяженным и сравнительно однородным наземным объектам, таким как подстилающие поверхности. Кроме того, в 2024–2025 гг. количество доступных обзоров заметно снижается, и в них присутствует ограниченное ссылок на работы, опубликованные в последние 2–3 года. Следовательно, можно отметить, что в имеющихся работах обзорного характера уделяется недостаточное внимание последним достижениям в части применения методов глубокого обучения при обработке РЛИ, в том числе новейшим архитектурам глубокого обучения. Помимо этого, упомянутые работы не рассматривают методы анализа РЛИ в контексте их применения для данных, получаемых посредством БАС. И наконец, среди статей на русском языке по данной тематике, опубликованных за последнее время, авторами не найдено ни одного комплексного обзора современных методов интеллектуального анализа РЛИ и используемых датасетов. Настоящая работа устраняет этот и другие вышеперечисленные недостатки.

Целью настоящей обзорной статьи является проведение комплексного изучения и систематизации современных методов интеллектуального анализа РЛИ, применимых к обработке данных с БАС, с фокусировкой на алгоритмах, основанных на применении методов глубокого обучения и новейших нейросетевых архитектур. Основная направленность статьи заключается в исследовании актуальных подходов к обнаружению, сегментации и классификации объектов на РЛИ, а также в определении путей повышения точности и надежности существующих методов. Рассматриваемые подходы охватывают как различные архитектуры нейросетевых моделей, предназначенные для анализа радиолокационных данных, так и датасеты, используемые для обучения и тестирования этих моделей.

Ключевыми результатами настоящей работы являются:

- обзор основных проблем при разработке эффективных и производительных методов интеллектуального анализа РЛИ;
- подробный анализ датасетов, используемых для обучения нейросетевых моделей, включая выявление основных недостатков этих датасетов;

- исследование достоинств и ограничений существующих методов интеллектуального анализа РЛИ;
- выявление перспективных направлений в развитии методов интеллектуального анализа РЛИ в условиях их применения при обработке данных съемки с БАС.

1. МАТЕРИАЛЫ И МЕТОДИКА ОБЗОРА

Методика настоящего обзора была направлена на систематическое и комплексное исследование существующих методов интеллектуального анализа РЛИ, применимых к обработке данных с БАС. Основными задачами применяемого методологического подхода являлись выявление, оценка и структурирование научных публикаций, посвящённых обнаружению, сегментации и классификации наземных объектов по радиолокационным данным, получаемым преимущественно с авиационных платформ.

Поиск научных работ охватывал временной период с 2020 по 2025 гг. В качестве основных источников использовались ведущие электронные научные базы данных, включая Российский индекс научного цитирования (РИНЦ), IEEE Xplore, ScienceDirect, MDPI, а также архивы профильных конференций, таких как IGARSS, CIE International Conference on Radar и др. Для расширения охвата применялись методы анализа обратного и прямого цитирования, извлечение информации из списков литературы ранее опубликованных обзорных и оригинальных статей, а также просмотр выпусков ключевых профильных журналов, таких как IEEE Transactions on Geoscience and Remote Sensing, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Sensors, Remote Sensing и др.

Отбор публикаций проводился в два этапа. На первом этапе (реферативный скрининг) оценивалась релевантность статьи на основе названия, аннотации и ключевых слов. На втором этапе осуществлялся полнотекстовый анализ для исключения работ, не соответствующих критериям отбора. К публикациям, отобранным в обзор, предъявлялись следующие требования: применение РЛИ, полученных с авиационных носителей (ВС, БВС) или со спутников сверхвысокого разрешения (лучше 1 м/пикс), таких как КА TerraSAR-X, использование данных с РЛС, работающих в диапазонах частот, обеспечивающих максимально детальный анализ наземных объектов (Ка-, Ку-, Х-, С-диапазоны), ориентация на задачи обнаружения, сегментации и классификации различных объектов на земной поверхности, применение методов глубокого обучения, а также научная новизна и достаточная техническая детализация. Из обзора исключались работы, в которых основное внимание уделялось интерферометрическим или поляриметрическим методам обработки РЛИ, публикации, в которых рассматривались только спутниковые данные с невысоким пространственным разрешением (КА Sentinel-1, Radarsat-2 и др.), а также комбинирование (слияние) оптических и радиолокационных данных. Указанные критерии отбора обеспечивают фокусировку на подходах, применимых к мобильным и оперативным беспилотным платформам. Помимо этого, при исследовании существующих методов из рассмотрения исключались диссертации, технические отчёты, патенты, презентации и статьи без экспертного рецензирования.

После отбора релевантных публикаций они были классифицированы и структурированы по ряду признаков: решаемая задача технического зрения, источники данных для машинного обучения (используемые датасеты), стратегия обучения и архитектура реализованной нейросетевой модели. Также были собраны и проанализированы сведения об оценке качества разработанных моделей в соответствии с применяемыми метриками.

Особенностью предложенной методики по сравнению с аналогичными обзорными работами, в которых не проводилась дифференциация между спутниковыми и авиационными источниками данных, является акцент на РЛИ с пространственным разрешением 0,1–1 м/пикс. Это позволяет более точно отразить специфические особенности геометрии съёмки, условий формирования радиолокационных сигналов и проблем достижения высоких показателей точности обработки, характерные для БАС. Также оригинальностью методики является деталь-

ный анализ датасетов, на основе которых обучались нейросетевые модели, что позволяет комплексно и с большей релевантностью оценить преимущества и недостатки, а также перспективы рассматриваемых методов интеллектуального анализа РЛИ.

2. ОСНОВНЫЕ ПРОБЛЕМЫ В ОБЛАСТИ ТЕХНИЧЕСКОГО ЗРЕНИЯ С ИСПОЛЬЗОВАНИЕМ РАДИОЛОКАЦИОННЫХ ДАННЫХ

В области технического зрения, использующей радиолокационные данные, включая получаемые с БАС, существует целый ряд фундаментальных и прикладных проблем, затрудняющих построение надежных и высокоточных систем анализа изображений. При решении задач обнаружения, сегментации и классификации объектов на РЛИ обычно выделяют следующие основные проблемы [Fra21, Dor20]: высокий уровень спекл-шумов, сложность анализа данных из-за специфического характера РЛИ, многообразие форм и размеров объектов интереса, затрудняющих разработку универсальных алгоритмов обработки, влияние угла наблюдения на точностные показатели, потребность в мощных вычислительных ресурсах, что трудно обеспечить на борту БВС, а также ограниченную доступность размеченных наборов данных (датасетов), особенно собранных с борта БВС. Далее остановимся на этих проблемах подробнее.

Одной из наиболее характерных особенностей РЛИ является наличие спекл-шума – мультипликативного шума, обусловленного когерентной природой радиолокационного сигнала. Этот шум значительно снижает визуальную чёткость сцены, затрудняет выделение границ объектов и негативно сказывается на эффективности алгоритмов сегментации и классификации. Особенно остро эта проблема проявляется при работе с объектами небольшого размера и поверхностями, имеющими низкое значение удельной эффективной поверхности рассеяния (УЭПР), которые могут быть полностью искажены шумом или подавлены фильтрацией. Другим источником возникновения шума на РЛИ являются неблагоприятные метеорологические явления (дождь, туман, снег и т. п.), в пределах которых на частицах воды происходит поглощение и рассеивание радиолокационных волн, что приводит к снижению силы отражённого сигнала, потере контрастности и смазыванию границ объектов.

Наличие шума на РЛИ является одной из основной причин появления большого количества ложноположительных результатов (False Positives) при анализе данных с использованием моделей глубокого обучения. Шумы достаточно часто создают ложные пиковые значения, которые принимаются нейросетевыми моделями за реальный объект, что приводит к ложным срабатываниям. Еще одной причиной увеличения числа ложноположительных результатов является эффект переотражения, когда радиолокационный сигнал многократно отражается от объектов и поверхностей, расположенных на пути его распространения, искажая при этом истинную картину распределения энергии и размывая границы объектов, что приводит к снижению контрастности РЛИ. В случае использования нескольких передатчиков РЛС в многопозиционных системах может возникнуть негативное явление интерференции распространяющихся от них сигналов, которое заключается в их периодическом взаимном усилении или ослаблении (в зависимости от фазы), что также ведет к радиометрическим искажениям РЛИ, появлению артефактов и ложных объектов.

Для борьбы с шумами используются следующие программно-алгоритмические методы: улучшение архитектуры нейросетей, прежде всего использование многослойных нейросетей с дополнительными уровнями обработки для подавления шума, а также подбор оптимальных наборов данных для обучения, в том числе синтетических (с известной степенью шума), создаваемых с использованием методов аугментации данных, (поворот, растяжение, сдвиги и др.), что делает модели более устойчивыми к различным шумам и помехам. Однако при этом необходимо учитывать, что агрессивное подавление шума часто приводит к потере значимой информации, особенно в областях с высокой детализацией, нарушая структуру контекста сцены и затрудняя точное распознавание объектов.

С проблемой нахождения компромисса между детализацией и шумом тесно связана задача определения оптимального пространственного разрешения РЛИ при их интеллектуальном анализе с помощью нейросетевых алгоритмов. Очень высокое разрешение может спровоцировать рост ложноположительных результатов, поскольку модель глубокого обучения склонна считать значимыми признаками мелкие детали и артефакты РЛИ, такие как небольшие изменения в структуре почвы, отдельные деревья, крупные ветви и тени от них, рябь и блики на водных поверхностях, которые при более низком разрешении выглядели бы однородно. При недостаточном разрешении небольшие объекты интереса могут иметь такой малый размер на РЛИ, что их тяжело отличить от случайных шумов или помех.

Ещё одной существенной трудностью является распознавание объектов, наблюдаемых с различных углов и высот, что характерно для авиационных платформ, где геометрия съёмки динамически изменяется. Из-за анизотропной отражательной способности объектов и зависимости радиолокационной сигнатуры от угла обзора, одни и те же цели могут выглядеть на разноракурсных снимках по-разному, что требует от алгоритмов высокого уровня инвариантности к геометрическим трансформациям.

Отдельную проблему в задачах автоматического анализа сцен составляет различение переднего плана и фона на РЛИ. Её сложность обусловлена тем, что РЛИ отражает не привычную структуру сцены, характерную для видимого диапазона электромагнитного излучения, а пространственное распределение радиолокационной отражательной способности различных поверхностей и объектов, что придаёт изображениям иной характер текстуры, контрастности и формы отображения. Эта проблема носит комплексный характер и существенным образом варьируется в зависимости от типа ландшафта. Например, в условиях урбанизированных ландшафтов эта задача усложняется наличием большого количества и плотностью антропогенных объектов, обладающих резко отличающимися свойствами отражения и рассеяния радиоволн. Здания, дороги, инфраструктура и промышленные объекты генерируют насыщенные сигнатуры, создающие сложную структуру радиолокационного сигнала. Элементы сцены сливаются в плотные кластеры отражений, где границы между объектами размыты или вообще отсутствуют из-за эффекта наложения сигналов. Дополнительно, металлические конструкции, крыши и фасады зданий могут порождать сильные зеркальные отражения, перекрывая друг друга и маскируя слабые цели, находящиеся рядом. Кроме того, городская застройка вследствие экранирующих эффектов, создаваемых зданиями и сооружениями, характеризуется наличием множественных радиолокационных теней, которые искажают восприятие объектов и ведут к возникновению ложных контуров. В случае естественных ландшафтов различение переднего плана и фона сталкивается с другими типами трудностей. Плотная лесная, луговая и сельскохозяйственная растительность характеризуются низкой контрастностью и сглаживанием деталей, вызванным эффектом рассеяния радиоволн на неоднородных покрытиях. Растительные объекты создают сложный, хаотичный и слабо структурированный низкоэнергетический фон, на котором другие объекты со слабовыраженными контурами, а также небольшие объекты (например, техника, некоторые другие естественные объекты, особенно водоемы, почти не отражающие радиоволны), часто теряются или становятся неотличимыми от естественных аномалий поверхности. Одной из таких частных, но критически важных проблем является различение границы «вода–земля», так как в местах контакта водной поверхности и суши, как правило, наблюдается постепенный переход между двумя разными типами отражений, что делает границу нечёткой и трудноразличимой. Таким образом, природа радиолокационного сигнала, который радикально меняется в зависимости от окружения (густонаселённые городские районы, природная местность и т. д.), создаёт особые трудности для реализации надежных алгоритмов обработки и анализа изображений.

Серьёзные вызовы связаны с обнаружением и распознаванием объектов разного размера, особенно в сценах, где одновременно присутствуют как крупные, так и мелкие объекты. Последние зачастую ошибочно интерпретируются как шум, особенно если их форма нерегу-

лярная или слабоконтрастная. Кроме того, модель глубокого обучения может ошибочно объединить объекты смешанного размера в единый объект, либо наоборот – посчитать отдельные небольшие объекты частями одного большого объекта. Такие объекты требуют применения архитектур нейронных сетей, поддерживающих обработку изображений на разных масштабах, либо использования специализированных архитектур, которые более чувствительны к мелким объектам на РЛИ.

Помимо проблем, связанных непосредственно с физической природой сигнала и вариативностью сцен, значительное ограничение на точность разрабатываемых алгоритмов накладывают характеристики применяемых наборов данных. Доступные датасеты, особенно на основе данных, полученных с авиационных платформ, как правило, отличаются сравнительно небольшим объёмом и выраженным дисбалансом классов: одни категории объектов представлены множеством примеров, тогда как другие – единичными изображениями. Это затрудняет обучение нейросетевых моделей и ведёт к переобучению на доминирующих классах.

Дополнительные сложности связаны с высокими вычислительными затратами на обработку РЛИ, особенно при использовании глубоких нейросетевых архитектур, требующих значительных ресурсов для обработки большого объема данных сверхвысокого разрешения. Проблема усугубляется необходимостью итеративной фильтрации, разметки и дообучения моделей на новых выборках, особенно в реальных условиях, характеризующихся сильной внутриклассовой вариативностью объектов интереса, часто одновременно с высокой степенью сходства между различными классами.

Наряду с этим, при последовательной донастройке моделей на новых данных наблюдается эффект забывания ранее усвоенной информации (Catastrophic Forgetting), характерный для нейросетевых систем. Это делает крайне актуальной задачу разработки устойчивых механизмов накопления знаний и адаптации моделей без потери ранее приобретённых способностей.

И, наконец, традиционной проблемой, присущей всем моделям глубокого обучения, является их неинтерпретируемая логика. Эта особенность, известная как проблема «черного ящика», вызванная наличием у нейросетевых моделей большого количества слоев и параметров, делает их внутренне крайне сложными, существенно влияет на точность и усложняет процесс машинного обучения, так как при возникновении ошибок достаточно трудно понять их причину и внести необходимые поправки. Отсутствие понимания внутренней логики моделей также препятствует их простому переносу на смежные задачи и другие типы данных.

В совокупности все перечисленные факторы формируют сложную и многоуровневую проблематику, требующую не только продвинутых архитектур, но и фундаментальных изменений в подходах к формированию датасетов, обучению и тестированию систем технического зрения на РЛИ. Сводка наиболее значимых проблем, возникающих при анализе РЛИ с применением методов технического зрения и глубокого обучения, представлена в табл. 1, в которой также приведены причины этих проблем и их влияние на обработку радиолокационных данных.

Таблица 1

Описание основных проблем технического зрения, возникающих при интеллектуальном анализе РЛИ

Категория проблемы	Характеристика проблемы	Причина возникновения проблемы
1. Шум на РЛИ	Появление зернистости фона на РЛИ (спекл-шум), искажения и нарушение качества РЛИ, затрудняющие его анализ.	Природа когерентного излучения РЛС, влияние атмосферы на распространение радиоволн.
2. Искажения радиолокационных образов	Ложные объекты, включая яркие артефакты вблизи крупных объектов, некорректное разделение объектов смешанного размера, искажение формы объектов на РЛИ, что ведет к значительному увеличению ложноположительных срабатываний нейросетей.	Переотражения сигналов, переналоженные сигнатур крупных и малых объектов, интерференция сигналов вследствие одновременной работы нескольких бортовых РЛС в многопозиционных системах.

Категория проблемы	Характеристика проблемы	Причина возникновения проблемы
3. Нехватка данных для обучения	Неудовлетворительные результаты на нейросетевых моделях, обученных на неполных датасетах, имеющих ограниченный состав классов и разметки.	Недостаток полигонов, высокая стоимость сбора данных (особенно разноразмерных, получаемых с авиационных платформ), трудозатратная разметка.
4. Ошибочный выбор класса	Некорректная классификация локальных и площадных объектов, трудности различения переднего плана и фона на РЛИ, снижающие надежность модели.	Низкое качество (зашумленность) исходных данных, высокая внутриклассовая вариативность объектов, перекрывающиеся информативные признаки близких классов, дисбаланс классов в обучающей выборке, неоптимальная архитектура нейросети.
5. Забывание ранних классов	Потеря информации о старых классах при появлении новых данных в процессе обучения, особенно при непрерывном обучении с использованием данных эхосигналов РЛС со сложной и специфичной структурой.	Ограничения традиционных подходов к дообучению моделей, требующих хранения большого количества предыдущих данных и высоких вычислительных затрат.
6. Неинтерпретируемая логика моделей глубокого обучения	Трудность интерпретации внутренних механизмов принятия решений нейросетями и диагностики ошибок (проблема «черного ящика»).	Высокая сложность и нелинейность архитектуры глубоких нейронных сетей, отсутствие интуитивно понятных информативных признаков у РЛИ (в отличие от оптических изображений).
7. Длительное время обработки РЛИ	Увеличенная продолжительность операций, выполняемых моделями глубокого обучения (особенно на борту БВС), значительные задержки в принятии решений, что критично для задач, требующих оперативного реагирования.	Большие объемы данных, высокая вычислительная трудоемкость операций по обработке РЛИ, сложность нейросетевых моделей, ограниченные вычислительные ресурсы бортовых систем.

3. ДАТАСЕТЫ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ, ПРИМЕНЯЕМЫЕ ДЛЯ ОБУЧЕНИЯ И ОЦЕНКИ КАЧЕСТВА НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

Стремительное развитие методов интеллектуального анализа РЛИ требует наличия обширных и репрезентативных датасетов, которые используются для обучения и тестирования моделей глубокого обучения. Эффективность этих моделей напрямую зависит от качества и количества данных, на которых они обучаются. Особенно остро эта необходимость ощущается в сегменте данных, получаемых с БАС, где съёмка ведётся на низких высотах и характеризуется переменной геометрией. Несмотря на рост числа исследований в области обработки данных, получаемых с авиационных платформ, большинство доступных открытых датасетов основаны на спутниковых снимках.

Основные проблемы, сопровождающие использование существующих датасетов при выполнении автоматической обработки РЛИ:

- нехватка данных, вызванная значительно меньшим количеством действующих РЛС активного типа как в нашей стране, так и в мире, по сравнению с бортовыми оптико-электронными системами;
- закрытость коммерческих данных, что ограничивает их доступность для широкого круга исследователей и разработчиков;
- ограниченность классов объектов, поскольку современные датасеты, как правило, сосредоточены на узком перечне классов, таких как наземная техника, транспортные средства, самолеты, суда, пренебрегая другими классами (сельскохозяйственные угодья, лесные массивы, водные объекты и прочие типы подстилающей поверхности);
- отсутствие разметки в ряде доступных датасетов, а также отсутствие единого стандарта разметки;

- слабая представленность задач, характерных для БАС с бортовыми радарными системами, таких как мониторинг стихийных бедствий, проведение поисково-спасательных операций;
- незначительное количество датасетов, содержащих данные по одним и тем же объектам, полученные в разнообразных условиях съемки (различные сезонные и погодные условия, углы съемки, значения пространственного разрешения), что ограничивает возможности по разработке моделей, устойчивых к изменению ситуации на местности.

На сегодняшний день для машинного обучения на основе РЛИ используются различные доступные датасеты, например такие известные наборы данных, как MSTAR, Sandia MiniSAR, Sandia FARAD SAR, UAVSAR, SSDD. Исследователи и разработчики активно используют указанные и другие датасеты для различных задач, таких как обнаружение объектов, сегментация изображений, классификация целей и поверхностей. Далее приведем краткое описание датасетов, пригодных для машинного обучения радиолокационных данных, получаемых с БАС.

MSTAR (Moving and Stationary Target Acquisition and Recognition)

MSTAR – наиболее распространённый датасет для задачи автоматического распознавания объектов на основе данных PCA (Synthetic Aperture Radar – Automatic Target Recognition, SAR-ATR), разработанный агентством DARPA (Defense Advanced Research Projects Agency) Министерства обороны США [Bla20]. Изначально он использовался для военного применения, но впоследствии был опубликован и стал доступным для исследователей и разработчиков по всему миру. В его состав входят снимки 10 классов военной техники, полученные в X-диапазоне при различных условиях съемки. Пространственное разрешение изображений около 0,3 м/пикс. Особенностью MSTAR являются разноразмерные серии данных – несколько снимков одной цели под близкими азимутами, а также различные конфигурации техники. Стандартный сценарий (Standard Operating Conditions, SOC) включает обучающие снимки под углом наклона цели 17° и тестовые под углом 15° ; размер изображений обычно 128×128 или 64×64 пикселей. Объём SOC-подвыборки – порядка 3,6 тыс. обучающих и 3,2 тыс. тестовых изображений. Сценарий с расширенными условиями эксплуатации (Extended Operating Conditions, EOC) усложняет задачу, включая, например, 4 класса целей при гораздо большем расхождении углов наклона цели, чем в SOC: 17° (обучающая выборка) и 30° (тестовая выборка).

MSTAR фигурирует в подавляющем большинстве исследований по SAR-ATR. Например, в работе [Gao18] описано его применение для обучения полуконтролируемой генеративно-сопоставительной сети, в [Hua20] – для изучения методов трансферного обучения вместе с другими данными, а многие работы, в том числе [Com18], используют MSTAR как основной набор при сравнении алгоритмов классификации объектов.

MSTAR стал де-факто стандартом для оценки методов SAR-ATR, хотя он узкоспециализирован, поскольку содержит только некоторые наземные объекты ограниченного набора классов. Кроме того, проблемой при использовании MSTAR для машинного обучения является то, что входящие в него РЛИ получены в идеальных условиях (содержат яркие и контрастные объекты на достаточно простом и низкоинтенсивном фоне), поэтому точность моделей, разработанных на его основе, заметно снижается в реальной обстановке.

На рис. 2, а приведен график изменения точности распознавания для задачи SAR-ATR с применением датасета MSTAR (сценарий SOC) по результатам обзора 38 работ, опубликованных с 2018 по 2025 гг. На рис. 2, б приведен график изменения точности распознавания для 3 сценариев EOC датасета MSTAR, полученный по материалам 19 публикаций, вышедших с 2020 по 2025 гг. В этих работах применялись следующие сценарии EOC: EOC-D (проверка устойчивости нейросетевой модели к изменению угла наклона цели по вертикали), EOC-C (проверка к вариациям конфигурации объекта, например используются разные модификации бронетехники), EOC-V (проверка устойчивости к изменениям версии внутри одной конкретной модели объекта, например, разные серийные варианты танка Т-72). На обоих графиках

для каждого достигнутого результата представлена доля размеченных данных MSTAR, использованных в исследованиях. По результатам анализ рисунков 3 и 4 можно сделать следующий вывод: в настоящее время из-за низкой сложности MSTAR и значительного прогресса в разработке архитектур нейросетей результаты распознавания для SAR-ATR фактически достигли максимально возможных значений как на стандартных сценариях (SOC), так и на расширенных (EOC), поэтому для дальнейшего развития и обеспечения работы моделей в реальных условиях необходимы более совершенные датасеты.




Рис. 2. График распределения по годам (2018–2025 гг.) точности распознавания наземных объектов в задаче SAR-ATR на датасете MSTAR:
а – сценарий SOC; б – 3 сценария EOC

На основе MSTAR был создан датасет SAMPLE (Synthetic and Measured Paired Labeled Experiment) [Lew19]. Ключевой особенностью SAMPLE является его парная структура, где каждое реальное изображение из MSTAR соответствует синтетическому аналогу, созданному с использованием компьютерного моделирования. Эта особенность делает датасет особенно ценным для исследований в области SAR-ATR и для разработки алгоритмов, способных работать как с реальными, так и с синтетическими данными. Публичная версия этого датасета включает данные с азимутальными углами от 10 до 80 градусов, что обеспечивает широкий спектр условий наблюдения для исследовательских целей.

MiniSAR

Датасет MiniSAR – небольшой открытый набор данных, опубликованный компанией Sandia National Labs (США) в 2006 году [San]. Это 9 реальных сцен, полученных с БВС в Ku-диапазоне, каждая размером приблизительно 1638×2510 пикселей при сверхвысоком разрешении около 0,1 м/пикс. Сцены содержат различные объекты (дороги, строения, деревья, области с травянистой растительностью), среди которых размечены цели – автомобили. Разметка представлена в виде ограничивающих рамок (bounding boxes) целей и меток наличия цели на сцене. Набор разбит на 7 изображений для обучения и 2 – для тестирования. Несмотря на небольшой объем MiniSAR ценен благодаря реалистичным сложным фонам и стал одним из первых общедоступных субметровых наборов с данными PCA.

MiniSAR часто применяется для задач обнаружения объектов в условиях сложных сцен. В частности, в работе [Wei21] датасеты MiniSAR и FARAD SAR использовались для обучения полуконтролируемого детектора с адаптацией домена. Другие исследования в области

обнаружения и адаптации, например [Lv23] также проводят эксперименты на MiniSAR, подчёркивая его сложность и реалистичность сцен.

FARAD SAR

FARAD SAR – комплементарный к MiniSAR набор, также собранный Sandia National Labs в 2015 году [San]. Он содержит 106 РЛИ сложных городских сцен (например, территория университетского кампуса) с таким же высоким разрешением $0,1 \times 0,1$ м, что и MiniSAR, но полученных в диапазонах Ка и Х. Размеры сцен варьируются примерно от 1300×580 до 1700×1850 пикселей. В каждой сцене присутствуют многочисленные объекты (машины, строения, растительность и пр.), общее число типов целей порядка 10. Данные разделены на обучающую (78 изображений) и тестовую (28 изображений) выборки. MiniSAR и FARAD SAR считаются одними из самых сложных доступных SAR-наборов с большим разнообразием данных, что делает их подходящими для разработки методов, устойчивых к фоновым помехам.

MiniSAR и FARAD SAR могут использоваться совместно. Например, в работе [Shi21] FARAD SAR задействован для оценки алгоритма адаптации «без учителя» применительно к задаче детекции объектов. Авторы исследования обучали детектор на одном из этих наборов данных и валидировали на другом, демонстрируя эффективность предложенного метода на сложных сценах адаптированного домена.

TerraSAR-X (Гуандун)

Бортовой PCA КА TerraSAR-X (работает в Х-диапазоне) также служит популярным источником данных высокого разрешения для машинного обучения. В одной из работ по классификации почвенно-растительных покровов [Liu20] использован космический снимок провинции Гуандун (Китай) в режиме Stripmap, поляризация VV. Изображение большого размера (примерно 4656×7518 пикселей, разрешение 1,25 м/пикс) датировано 2008 годом. Для задачи классификации земель сцена была размечена на 5 классов местности (включая класс «неидентифицируемый»). Разбиение: 60% пикселей – обучение, 15% – валидация, 25% – тестирование. Этот датасет представляет собой единичный, но детально размеченный снимок, полезный для оценки методов сегментации/классификации поверхностей на спутниковых РЛИ. В упомянутом исследовании [Liu20] новый метод на основе статистической сверточной нейронной сети (SCNN) для классификации типов подстилающей поверхности продемонстрировал высокую точность (около 86%) по этому набору, превосходя классические сверточные нейронные сети. В этой же работе снимок КА TerraSAR-X служил стандартизированным тестом (бенчмарком) для сравнения моделей сегментации земных покровов, разработанных на основе как стандартных (AlexNet, VGG-19), так и специализированных (A-ConvNet, C-HRNN, SPPNet, PSNet) архитектур.

UAVSAR (наводнение после урагана Харви)

UAVSAR – авиационный PCA (L-диапазон), в настоящее время используемый Национальным аэрокосмическим агентством США (NASA) для съемок с самолета Gulfstream III. Для выявления территорий штата Техас, подвергнутых катастрофическим наводнениям, вызванных ураганом Харви в 2017 году, был собран набор поляриметрических снимков UAVSAR [Den20]. Данные включают результаты съёмки участков затоплений в августе-сентябре 2017 г. Из этих снимков вручную было размечено более 10 000 областей (сегментов), что составляет около 3,5 млн пикселей, с классификацией «затоплено / не затоплено». Для независимой валидации разметки использовались внешние источники, такие как аэрофотоснимки с самолетов Национального управления океанических и атмосферных исследований США (NOAA) и карта наводнений Геологической службы США (USGS). Набор уникален наличием достоверной разметки участков, охваченных наводнением, и применением мультисенсорной проверки, что позволяет достаточно точно обучать и оценивать алгоритмы сегментации зон затопления.

В работе [Den20] данный набор впервые был применён для сегментации участков затоплений и далее было проведено сравнение точности полносверточных моделей (U-Net, SegNet) на поляриметрических данных, полученных бортовым PCA UAVSAR. Метод с U-Net показал точность до 89% и показатель F1-score, равный 0,87, превзойдя классический алгоритм Чапмена примерно на 13%. UAVSAR-набор стал эталоном для последующих исследований по обнаружению последствий стихийных бедствий на радиолокационных данных, демонстрируя преимущество глубоких сетей над традиционными подходами.

Fangchenggang

Fangchenggang – небольшой набор аэроснимков, используемый для задач сегментации [Ma19]. Он содержит 36 РЛИ местности с пространственным разрешением порядка 2 м/пикс. Каждое изображение размечено на 4 класса земного покрова: фон, река, сельскохозяйственные угодья, городская застройка. Съёмка выполнена авиационной PCA в районе Фанчэнган (Китай). Разметка проведена вручную экспертами. Набор характеризуется ограниченным числом изображений при довольно высоком разрешении, что отражает типичную ситуацию дефицита данных для обучения моделей сегментации.

В работе [Yue20] датасет Fangchenggang использован для обучения многомасштабной полносверточной сети с модулями внимания. Предложенный метод (AFCN-MANet) показал существенный выигрыш по метрикам mIoU (Mean Intersection over Union) и PA (Pixel Accuracy) на данном наборе (например, mIoU составил 73,8%, что на 5,7% выше ближайшего аналога). Кроме того, в той же работе Fangchenggang совместно с другим набором (Pucheng) применялся для оценки устойчивости алгоритмов сегментации при ограниченном объеме размеченных данных.

Pucheng

Pucheng – второй небольшой датасет с данными аэросъемки, также применяемый для задач сегментации РЛИ [Ma19]. Включает в себя 40 РЛИ с разрешением около 1 м/пикс, снятых с борта самолёта над районом Пучэн (Китай). В рамках этого датасета размечено 2 класса: городская территория и сельскохозяйственные угодья. Данный набор проще по семантике (только 2 типа подстилающей поверхности), но обеспечивает проверку нейросетевых алгоритмов на обобщаемость – он часто используется в паре с Fangchenggang для демонстрации, что метод сегментации успешно работает на разных датасетах.

В упомянутой выше работе [Yue20] сеть с вниманием, обученная на наборе данных Fangchenggang, была протестирована и на Pucheng – достигнув mIoU 85,8% и PA 95,8%, что превосходит результаты моделей DeepLab, PSPNet и др. Таким образом, Pucheng подтвердил способность модели переноситься на иной набор с минимальным снижением качества. В последующих исследованиях эти два датасета нередко фигурируют совместно для оценки методов сегментации в условиях ограниченной разметки.

OpenSARShip

OpenSARShip – открытый датасет для обнаружения и классификации судов на спутниковых радиолокационных данных [Li17]. Он собран с использованием снимков, полученных с КА Sentinel-1, и содержит 11 346 изображений судов, принадлежащих к 17 классам (танкеры, контейнеровозы, военные корабли и др.). Каждое изображение представляет собой фрагмент (чип), вырезанный вокруг судна. Аннотации включают в себя тип судна. Данные охватывают различные условия (прибрежные районы и открытое море, разный уровень шума, перекрытия и др.), что делает набор весьма разнообразным. В исследованиях часто используют упрощённые версии OpenSARShip: например, берут только 3-4 крупнейших класса судов для экспериментов, чтобы снизить дисбаланс. Существуют и обновления набора – OpenSARShip 2.0, где для нескольких ключевых классов (грузовое судно, танкер и т. д.) отобрано по 510 изображений VH/VV-поляризации с приведением к единому балансу классов.

OpenSARShip применялся во многих работах по классификации морских целей. Авторы работы [Hua20] использовали его (с тремя основными классами) для оценки моделей трансферного обучения – достигнута точность 91,0% при дообучении на SAR-специфичной модели. В этом исследовании по самообучению на частично размеченных данных OpenSARShip был задействован в паре с MSTAR.

Кроме того, OpenSARShip применяется для тестирования новых архитектур, например, сверточных нейронных сетей с полноценной интеграцией комплексных чисел [Hou25], демонстрируя их преимущество перед сетями, использующими только действительные числа.

SSDD (SAR Ship Detection Dataset)

SSDD – популярный открытый датасет для обнаружения судов на РЛИ [Zha21]. Он составлен из данных разнородных источников (КА TerraSAR-X, RadarSat-2, Sentinel-1) и включает в себя 1160 снимков со сценами в X- и C-диапазонах. Пространственное разрешение составляет от 1 до 5 м/пикс, условия съёмки – различные (спокойное/штормовое море, порты и открытый океан). В сумме размечено 2456 судов, разметка представлена в виде ограничивающих прямоугольников (в том числе вращающихся) вокруг объектов интереса. Набор разделён на обучающую и тестовую выборки (иногда с выделением части под валидационную выборку), обычно в пропорции 7:3. Датасет SSDD ценен тем, что содержит сцены с разной плотностью целей и уровнем шумов, позволяя испытывать алгоритмы детекции в условиях, приближенных к реальным.

SSDD выступает основным стандартизированным тестом (бенчмарком) для моделей, разрабатываемых для обнаружения судов. В множестве исследований ([Jia21, Yu24] и др.) с использованием SSDD обучают и тестируют сверточные детекторы объектов, такие как YOLO (You Only Look Once). Также SSDD часто используется в задачах адаптации домена. Например, в работе [Zha22b] изучался перенос детекторов между данными КА Gaofen-3 и SSDD, показывая, что даже без разметки в целевом домене можно достичь mAP (Mean Average Precision) около 74–81%. Таким образом, SSDD является ключевым набором для оценки новых методов обнаружения объектов на море.

FUSAR-Ship

FUSAR-Ship – датасет изображений судов, полученных китайским КА Gaofen-3 (C-диапазон) [Mal17]. Первоначально он включал достаточно много классов судов – до 15 типов, с крайне неравномерным числом примеров (от 2 до 1500 на класс), что делало задачу классификации очень сложной. В ряде исследований используют ограниченную версию этого датасета: 4 основных класса (например, балкер, контейнеровоз, танкер, военный корабль) и всего 2110 изображений с разрешением 10×10 м/пикс. Датасет FUSAR-Ship был представлен китайским сообществом в области компьютерного зрения в рамках конкурсов по распознаванию судов и впоследствии стал открытым. Он отличается большим разнообразием сценариев съёмки в прибрежной зоне и служит для отладки алгоритмов обнаружения/классификации судов, особенно в сочетании с методами борьбы с дисбалансом классов.

FUSAR-Ship применялся в исследованиях по классификации судов и устойчивости нейросетевых моделей. В [Liu23] использовали его вариант с 4 классами объектов для тестирования подхода по обучению на длиннохвостых (Long-Tailed) распределениях – предложенная методика дала около 89% точности против 84% у базового метода. Также FUSAR-Ship задействован в работах по защите от адверсариальных атак (злонамеренных вторжений по поиску уязвимостей в моделях): например, [Lu23] использовали его (наряду с MSTAR) при оценке ансамбля ResNet+ViT, устойчивого к атакам FGSM (метод атаки «белого ящика» на нейронные сети), BIM (метод базовой итеративной атаки) и др. Таким образом, FUSAR-Ship позволяет проверять модели на дополнительном источнике данных PCA (КА Gaofen-3) и обогащает эксперименты по сравнению с использованием наборов данных только с одного КА Sentinel-1.

SARDet-180K

SARDet-180K – крупнейший публичный набор данных для обучения моделей обнаружения целей на РЛИ [Li25]. Он объединяет 186 600 фрагментов РЛИ с разметкой из 14 открытых датасетов с радиолокационными данными для задач обнаружения и классификации различных наземных и морских объектов (автомобили, суда, самолёты, резервуары для хранения нефтепродуктов, мосты и др.). Стоит отметить разнообразие собранных сцен (города, порты, аэропорты, океаны) и сенсоров (спутниковые, авиационные, синтезированные данные) с различным разрешением (0,1–25 м/пикс) и частотными диапазонами (С-, Х-, Ku- и Ka-диапазоны). Данные сбалансированы по категориям: около 46 тыс. автомобилей, 74 тыс. судов, 36 тыс. самолётов и 47 тыс. прочих объектов. Размеры изображений варьируются от 128 до 2048 пикселей. Таким образом, SARDet-180K обеспечивает широту охвата задач обнаружения, что позволяет эффективно обучать и оценивать фундаментальные модели с учётом реальных вариаций условий съёмки и шумов радиолокационного сигнала, включая разноракурсное представление целей и разнообразие самих ракурсов.

В работе [Li25] приведены сведения о том, что SARDet-180K используется как основной масштабный предобучающий датасет для формирования базовой конфигурации модели SARATR-X, разработанной для обнаружения и классификации наземных объектов. Такой подход обеспечивает улучшенную обобщаемость и устойчивость моделей к вариациям РЛИ в задачах обнаружения и классификации.

ATRNet-STAR (ранее NUDT4MSTAR)

ATRNet-STAR – крупный датасет, созданный специалистами Национального университета оборонных технологий Китая (National University of Defense Technology, NUDT) в 2025 г. [Liu25] для преодоления проблем, свойственных ранее созданным датасетам, предназначенных для задач SAR-ATR, прежде всего MSTAR. Основными недостатками MSTAR, в частности, являлись следующие: 2) малое разнообразие объектов (всего 10 классов целей); 2) идеальные условия съёмки, характеризующиеся размещением объектов в центре снимка и минимальным воздействием окружающей среды; 3) отсутствие стандартного протокола оценки эффективности алгоритмов, используемых на MSTAR, что приводило к невозможности объективного сравнения различных методов.

Основные преимущества ATRNet-STAR: 1) новый датасет содержит более 190 000 размеченных изображений, что в 10 раз превышает размер MSTAR; 2) ATRNet-STAR включает 40 различных классов транспортных средств, собранные в рамках пяти реалистичных сцен; 3) объекты находятся в городских, заводских, каменистых, лесных и пустынных условиях, воссоздавая реальные условия использования РЛС; 4) датасет включает изображения, снятые с различных углов азимута и наклона цели, а также при нецентрированном положении цели на изображении, что стимулирует развитие более устойчивых методов; 5) наличие данных в нескольких поляризациях и диапазонах (Х и Ku), что делает датасет более универсальным; 6) ATRNet-STAR организован по принципу таксономии, разделяющий объекты на классы, подклассы и типы, что упрощает его расширение и интеграцию с другими датасетами; 7) предлагает 7 различных экспериментальных настроек и 15 базовых методов, что позволяет исследователям проверять гипотезы и проводить прямое сравнение результатов.

Таким образом, ATRNet-STAR предоставляет богатый ресурс для исследователей, развивая новые методы в области глубокого обучения для распознавания объектов на РЛИ. Так, в препринте [Xio25] описывается применение ATRNet-STAR при разработке нового подхода к решению задач SAR-ATR в сложных условиях на основе графовых нейронных сетей и трансформеров, а также дополнительного модуля для интеграции физических знаний о рассеивающих центрах и топологии наземных объектов.

Прочие датасеты и источники данных

Выше перечислены специализированные датасеты, которые являются ключевыми для настоящего обзора. Однако помимо них в публикациях по методам глубокого обучения фигурируют и другие наборы, например данные КА Gaofen-3 (С-диапазон), применяемые для различных задач, в том числе для сегментации подстилающих поверхностей. Например, известен датасет, содержащий изображения с 6 классами (горы, водные объекты, здания, дороги, лес, открытая почва) при разрешении 1 м/пикс [Liu22]. В рамках соревнований Gaofen Challenge был опубликован датасет FG-SAD, содержащий космические снимки аэропортов: 52 больших изображения КА Gaofen-3 (разрешение 1 м/пикс), из которых вырезано 3850 фрагментов размером 1024×1024 пикселей с разметкой 6 типов самолётов (6550 объектов) [Wan22].

Встречается отдельные упоминания о проприетарном датасете BSSAR, созданном Science and Technology Laboratory of U. K. Defense (Великобритания) на основе данных съемки авиационной РЛС I-Master. По данным работы [Zhu21b] этот датасет включает одну крупную сцену размером 6656×5056 пикселей, в пределах которой присутствуют различные объекты инфраструктуры (мосты, дороги, фермы), а также реки, сельскохозяйственные угодья и прочие протяженные объекты. Пространственное разрешение РЛИ является субметровым. Авторы упомянутой работы заявляют использование BSSAR совместно с MiniSAR для задачи обнаружения объектов.

Среди наборов, содержащих синтетические данные, известен SARSim [Mal17]: 21168 смоделированных изображений Х-диапазона с пространственным разрешением 0,3 м/пикс и размером 128×128 пикселей. На каждом изображении этого набора есть объект одного из 7 классов транспортных средств (грузовой автомобиль, легковой автомобиль, мотоцикл, автобус, бульдозер, пикап, танк) для каждого поворота объекта по азимуту на 2° при семи различных углах наклона цели (15°, 17°, 25°, 30°, 35°, 40° и 45°), полученный путем моделирования в системе автоматизированного проектирования (САПР).

Кроме того, в некоторых работах имитируются «радиолокационные версии» оптических данных. Например, за основу применяется поднабор NWPU-RESISC45 [Pas21, Fu24] и к его изображениям добавляется спекл-шум, чтобы протестировать методы классификации на псевдо-радарных данных.

Однако ключевыми для настоящего обзора остаются перечисленные ранее специализированные датасеты, которые охватывают широкий спектр приложений: от задач SAR-ATR до мониторинга судоходства и стихийных бедствий.

Краткие сведения об основных наборах радиолокационных данных, используемых при обучении и тестировании нейросетевых сетей, приведены в табл. 2.

Таблица 2

Описание ключевых датасетов, используемых при машинном обучении и анализе РЛИ
(задачи технического зрения: О – обнаружение, С – сегментация, К – классификация)

№ п/п	Датасет	Год	Задача	Кол-во РЛИ	Размер РЛИ	Кол-во классов (подкатегорий)	Разрешение, м	Диапазон	Описание данных
1	MSTAR	1995	К	14 577	128–193	8 (10)	0,3	Х	Транспортные средства
2	Sandia MiniSAR	2006	О	3 927	224	≥ 1	0,1	Ки	Техника и здания в урбанизированных зонах и пустынях
3	SARSim	2017	К	21 168	139	14	0,3	Х	Транспортные средства (синтетический датасет)
4	OpenSARShip	2017	К	26 679	445	16	2,7–22	С	Суда
5	SAMPLE	2019	К	5 380	128	7	0,3	Х	Транспортные средства (смешанный датасет с синтетическими и реальными РЛИ)

№ п/п	Датасет	Год	Задача	Кол-во РЛИ	Размер РЛИ	Кол-во классов (подкатегорий)	Разрешение, м	Диапазон	Описание данных
6	SAR-Ship	2019	О	39 729	256	≥ 1	3–25	С	Суда
7	AIR-SARShip	2019	О	801	512–1000	≥ 1	1–3	С	Суда
8	HRSID	2020	О	5 604	800	≥ 1	0.5–3	С/Х	Суда
9	FUSAR-Ship	2020	О	16 144	512	15 (98)	1,1–1,7	С	Суда
10	SSDD	2021	О	1 160	214–668	≥ 1	1–15	С/Х	Суда
11	WHU-OPT-SAR	2021	С	100	5556×3704	7	5	С	Объекты землепользования (смешанный датасет с оптическими и радиолокационными данными)
12	SADD	2022	О	883	224	≥ 1	0,5–3	Х	Летательные аппараты
13	MSAR	2022	О	28 499	256–2048	≥ 4	1	С	Наземная и морская техника
14	SAR-AIRcraft	2023	О	18 818	512	≥ 7	1	С	Летательные аппараты
15	SIVED	2023	О	1 044	512	≥ 1	0,1–0,3	Х/Ку/Ка	Транспортные средства (синтетический датасет)
16	OGSOD	2023	О	18 331	256	≥ 3	3	С	Мосты, резервуары нефтепродуктов и портовые сооружения
17	SARDet-180K (сборный датасет)	2024	О	186 600	128–2048	6 основных	0,1–25	С/Х/Ку/Ка	Транспортные средства, суда, летательные аппараты, др. объекты (РЛИ из 14 открытых датасетов)
18	ATRNNet-STAR	2024	К	194 324	128	21 (40)	0,12–0,15	Х/Ку	Транспортные средства

Проведённый анализ показал, что датасеты играют критическую роль в развитии методов интеллектуального анализа РЛИ. Однако имеющиеся наборы данных обладают рядом недостатков, препятствующих эффективному внедрению этих методов в различных приложениях. Дальнейшие усилия должны быть направлены на создание более полноценных и реалистичных датасетов, а также на разработку методов, позволяющих преодолевать проблемы, связанные с качеством данных.

4. ИССЛЕДОВАНИЕ СОВРЕМЕННЫХ МЕТОДОВ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ

Современные методы анализа РЛИ на основе глубокого обучения чрезвычайно разнообразны. Их можно классифицировать рядом способов:

- по типу используемых нейросетевых архитектур;
- по специфике решаемой задачи технического зрения (обнаружение, сегментация и классификация объектов и др.);
- по особым техническим приемам, таким как:
 - специфика данных и стратегия обучения;
 - методы повышения устойчивости;
 - специализированные функции потерь.

Ниже представлен многоаспектный обзор методов, применяемых для интеллектуального анализа РЛИ. Методы структурированы на основе оригинальной классификации, предлагаемой авторами настоящей статьи и разработанной с учетом того, что анализ РЛИ – сложная задача, включающая множество аспектов. Такой подход обеспечит более полное, гибкое и удобное представление методов анализа РЛИ, использующих алгоритмы глубокого обучения.

4.1 Методы по типу архитектуры нейросети

Методы с применением сверточных нейронных сетей

Преобладающее большинство работ, описывающих интеллектуальную обработку РЛИ, опирается на сверточные нейронные сети (Convolutional Neural Network, CNN) различного вида. Используются как классические архитектуры общего назначения (AlexNet, ResNet, VGG) [Hua20, Zha22b, Che21], так и архитектуры, специализированные под РЛИ. Например, для задач SAR-ATR предлагались сети на основе A-ConvNet, оптимизированные под ограниченный объем радиолокационных данных [Hua24], и рекуррентные гибриды типа MBCRN [Fen21]. При сегментации применяются полносверточные сети (Fully Convolutional Network, FCN) с модификациями: в [Yue20] внедрили в FCN модуль мультиуровневого внимания (Multi-Attention Network, MANet), усиливающий извлечение признаков на разных масштабах и в разных каналах. Современные исследования используют облегченные и эффективные варианты CNN: например, EfficientNet-B0 (около 5 млн параметров) показал сопоставимую или лучшую точность, чем более тяжелый ResNet-50 (26 млн параметров) на ATR-задаче по данным MSTAR [Zha20].

Также в эту категорию можно отнести многомасштабные сверточные сети (Multi-Scale Neural Network, MSNN): в публикациях встречается применение SPP (Spatial Pyramid Pooling) для агрегации контекстов [Jia21] и U-Net для учета поляриметрической информации [Den20]. В целом, CNN остаются базовым строительным блоком моделей глубокого обучения, обеспечивая иерархическое выделение локальных признаков из РЛИ.

Методы с применением рекуррентных нейронных сетей

В задачах, где данные представлены последовательностями (сериями) снимков с перекрытиями, сверточные нейронные сети сочетают с рекуррентными архитектурами (Recurrent Neural Networks, RNN). В задачах SAR-ATR это бывает необходимо для обработки разноракурсных данных из наборов MSTAR.

Так, в одной из работ [Zha20] сверточный экстрактор EfficientNet был объединен с двунаправленной управляемой рекуррентной (Gated Recurrent Unit, GRU) сетью, чтобы учесть временные (ракурсные) зависимости в последовательности кадров. Рекуррентная составляющая, такая как GRU или долгая краткосрочная память (Long Short-Term Memory, LSTM) позволяет нейросетевой модели запоминать и интегрировать информацию от разных ракурсов, повышая точность классификации объекта в целом.

Кроме того, двунаправленная рекуррентно-свёрточная сеть (MBCRN) применялась в работе [Fen21] для поэтапного слияния признаков от нескольких углов наблюдения за целью. Такие гибриды (CNN+RNN) показали эффективность в случаях, когда доступны последовательные данные или требуется обеспечить инвариантность модели к вращению объекта интереса.

Методы с применением генеративно-состязательных сетей

Отдельным направлением является применение генеративных моделей для анализа РЛИ. Наиболее яркий пример – генеративно-состязательные сети (Generative Adversarial Network, GAN). В [Gao18] для задачи SAR-ATR был предложен полуконтролируемый метод на базе DCGAN (модификация алгоритма GAN, в основе которых лежат CNN), при котором один генератор и два кооперативных дискриминатора обучаются одновременно. Такой подход (назван MO-DCGAN) позволяет задействовать неразмеченные данные: генератор порождает искусственные РЛИ, а два дискриминатора (с softmax-выходами для многоклассовой классификации) определяют аутентичность РЛИ и одновременно классифицируют реальные объекты, добавляя наиболее уверенные предсказания друг друга в свои обучающие выборки. Совместное обучение дискриминаторов и специальная теория обучения на зашумленных данных помогли фильтровать ошибки авторазметки и привели к высокому качеству: при 80% неразмеченных данных точность SAR-ATR превысила 95%.

GAN также применяются для задачи адаптации домена (перенос знаний из исходного домена в целевой домен). Пример: использование CycleGAN-подобного преобразования изображений MiniSAR $\leftrightarrow$ FARAD SAR для того, чтобы генерировать псевдо-изображения в целевом домене и снизить расхождения в распределении выборки в датасете [Shi21]. Генеративные сети оказались полезны и для задачи увеличения данных: в некоторых работах изображения, синтезированные при помощи GAN, включаются в обучающую выборку, что улучшает обобщение на малых наборах данных [Fu24, Zhe23].

Методы, использующие архитектуры с механизмом внимания

Последние годы в обработке изображений набирают популярность механизмы внимания (Attention Mechanism). Для задач анализа РЛИ эта тенденция также имеет место. Так, во многие CNN-модели интегрируются модули внимания [Don21b, Zha22c].

Помимо упомянутого выше MANet для задач сегментации есть примеры вложения блоков обработки нелокальной информации (Non-Local Efficient Channel Attention) в ResNet для улучшения глобального контекста [Zha21b, Wei22]. Полностью трансформерные архитектуры моделей, имеющих название «визуальные трансформеры» (Vision Transformer, ViT), пока редки для задач обработки РЛИ, однако появляются различные гибридные модели. В работе [Lu23] впервые был применен ансамбль ResNet18 + ViT-Large для защиты классификатора от adversarial-атак. Выяснилось, что такой гибридный ансамбль способен существенно снижать успешность атак (с применением этого ансамбля доля ошибочных классификаций при FGSM-атаке на наборе MSTAR упала с 81% до 10%).

Трансформеры имеют ценность благодаря наличию механизма глобального внимания и устойчивости к поворотам, но их применение при обработке РЛИ сдерживается повышенными требованиями к числу обучающих данных. Поэтому их чаще используют либо в комбинации с CNN, либо в рамках решений специфических задач, таких как обнаружение атак, инкрементное обучение и т. п.

Методы, использующие графовые нейронные сети

К менее распространенным архитектурам, нашедшим место в методах анализа РЛИ, относятся графовые нейронные сети (Graph Neural Network, GNN) и графовые сверточные сети (Graph Convolutional Networks, GCN). Методы, разрабатываемые на их основе основаны, как правило, на применении априорной информации об электромагнитном рассеянии объектов интереса, таких как самолёты, суда.

Пример разработки такого решения приведен в работе [Zhu20], в которой предложено представлять РЛИ как граф на основе упорядочения пикселей по яркости. В этом подходе пиксели разбиваются на группы по уровням градаций серого, каждая группа – вершина графа, а вершины соединяются рёбрами в порядке убывания интенсивности. Затем применяется небольшая GCN, включающая в себя пару графовых сверток и слой субдискретизации (Pooling Layer) для классификации объекта интереса по полученному графу. Эта модель смогла достичь практически 100% точности в эксперименте с использованием датасета MSTAR, хотя и на ограниченной выборке.

Графовый подход интересен тем, что учитывает физическую структуру рассеяния объекта и нетривиальные связи между пикселями на РЛИ. Однако пока данная техника используется редко, ограничиваясь экспериментальными работами.

Гибридные методы, основанные на комбинировании с классическими методами

Некоторые исследования стремятся объединить преимущества алгоритмов глубокого обучения и традиционных алгоритмов. Например, в [Wei22] предложили архитектуру DDPL (Deep Dictionary Pair Learning), в которой общий CNN-экстрактор (ResNet50 с Non-Local блоками) сочетается с двумя обучаемыми словарями для анализа и синтеза признаков. По сути, сеть одновременно учится извлекать признаки и аппроксимировать извлеченный набор признаков линейными комбинациями базисов ранее изученных классов. Такой гибридный подход обеспечивает интерпретируемость и, как показали эксперименты, универсальность, поскольку

одна модель успешно работает на разных по природе задачах (классификация судов, сегментация подстилающих поверхностей, океанических явлений). Другим примером является объединение моментных инвариантов с признаками CNN. Так, в [He20] извлекали из изображения глобальные моментные признаки (Цернике, Ху и др.) и объединяли их с выходами сверточной сети, добиваясь более устойчивой классификации в задаче SAR-ATR в условиях поворотов и шума. Таким образом, комбинированные архитектуры достаточно перспективны, поскольку стремятся получить лучшее из двух областей: производительность глубоких нелинейных представлений и устойчивость/интерпретируемость математических признаков.

4.2 Методы по стратегии обучения и используемым данным

Полностью контролируемое обучение

Изначально практически все алгоритмы обучались на размеченных данных «с учителем» (Supervised Learning). Для решения задач SAR-ATR многие классические сети (LeNet, AlexNet и другие) дорабатывались и обучались с нуля на датасете MSTAR или похожих, и до сих пор в ряде работ соблюдается этот подход. Например, сравнительные эксперименты [Com18] показали преимущество глубокой CNN над моделью машинного обучения, основанной на методе опорных векторов (Support Vector Machines, SVM), при обучении только на амплитудных РЛИ из набора MSTAR. Однако существенной проблемой подхода обучения «с учителем» является требование большого числа размеченных данных, которое применительно к данным радиолокационного зондирования часто бывает трудновыполнимо. Поэтому в настоящее время обучение «с учителем» обычно дополняется либо другими стратегиями обучения, либо тонко настроенными процедурами регуляризации, чтобы избежать переобучения на малых выборках. Тем не менее, методы на основе Supervised Learning до последнего времени остаются базовыми, и практически каждая новая архитектура сначала проверяется в полностью контролируемом режиме на эталонном наборе (MSTAR, OpenSARShip и т. д.) для сравнения с предыдущими результатами.

Полуконтролируемое обучение

Компромиссом между полностью контролируемыми и неконтролируемыми подходами является использование частично размеченных данных. В задачах SAR-ATR проблема нехватки размеченных данных стимулировала появление методов полуконтролируемого обучения (Semi-Supervised Learning). Рассмотренный выше метод MO-DCGAN [Gao18] – это как раз пример полуконтролируемого подхода, при котором 80% данных не имели разметки, но генеративная модель позволила эффективно их задействовать.

Другой вариант – самообучение модели на псевдоразметке (Pseudo-Labeling), когда модель, обученная на небольшом размеченном множестве, помечает часть неразмеченных данных, добавляет их в обучающее множество и переобучается. Однако без специальных мер это может приводить к накоплению ошибок. Поэтому современные реализации концепции Pseudo-Labeling комбинируют самообучение с продвинутыми техниками. Примером является метод с двумя дискриминаторами в работе [Gao18], при котором вводилось «строгое правило уверенности» для отбора только надежных псевдо-меток. Ещё один пример – работа [Wan22b], в которой исследовались контрастные самообучающиеся схемы (SimCLR, MoCo) для извлечения признаков на неразмеченных РЛИ. Авторы сначала обучили энкодер на неразмеченных изображениях, оптимизируя контрастивную функцию потерь (InfoNCE), а затем немного дообучили классификатор на нескольких размеченных примерах. В эксперименте с применением датасета MSTAR, используя всего 1–5 размеченных изображений на класс, удалось достичь точности свыше 90% при правильном самообучении.

Методы со слабым контролем также включают подходы, при которых используются виды меток, не предназначенные для требуемой задачи. Например, при выполнении сегментации РЛИ могут быть доступны только метки «Присутствие/Отсутствие» (Presence/Absence) на уровне сцен, полученные по результатам бинарной классификации изображений. В этом случае для выполнения сегментации РЛИ применяют многовариантное обучение (Multiple

Instance Learning, MIL) или генерируют искусственные маски. Так, в [Fen22] сеть ACM-Net сегментировала цели на данных MSTAR, вообще не имея подготовленных вручную масок — вместо этого маски автоматически получались из физической модели рассеяния (Attribute Scattering Center Model). Подобные приемы позволяют обучаться с минимальным привлечением ручной разметки, что крайне актуально для задач интеллектуального анализа РЛИ.

Обучение без учителя и адаптация домена

В ряде задач удаётся обходиться без наличия разметки на целевом наборе, используя либо суррогатные задачи (такие как восстановление изображения по перемешанной сетке его фрагментов), либо разметку из другого домена. Извлечение признаков без учителя (Unsupervised Learning) обычно выполняется с помощью автокодировщиков. Так, в [Qin20] сверточный автоэнкодер (Convolutional AutoEncoder, CAE) был обучен на неразмеченных РЛИ, чтобы получить векторные представления изображений, а затем его вес использовался для инициализации классификатора.

Еще одним методом является неконтролируемая адаптация домена (Unsupervised Domain Adaptation, UDA), который целесообразно применять в ситуациях, когда имеются размеченные данные из одной обстановки (Source), а тестировать надо на другой (Target), для которой отсутствует разметка. При работе с РЛИ такая ситуация возникает, например, при переносе нейросетевого детектора, обученного на синтетических данных или данных, полученных с помощью одного вида сенсора, на реальные данные другого сенсора. Подходящим решением является комбинация adversarial-подходов и инвариантных признаков.

Как пример такого подхода, в [Shi21] предложена полностью неконтролируемая схема адаптации для детектора, при этом были совмещены сразу три техники:

- GAN-переход изображений из домена A в домен B (чтобы генератор GAN подгонял стиль изображений);
- многоуровневая адаптация признаков (Multi-Level Feature Domain Adaptation) через дискриминатор, распознающий домен по признакам на разных слоях;
- итеративное саморазмечивание Target-данных, с постепенным добавлением самых уверенных предсказаний модели в обучающее множество.

В результате, предложенная модель (с полным отсутствием разметки из целевого домена) продемонстрировала успешное детектирование объектов в новом наборе данных, приближаясь по качеству к контролируемому обучению. Были достигнуты значения F1-score, равные 0,8 (с использованием данных набора FARAD) и 0,85 (на данных MiniSAR). Соответствующие результаты с применением контролируемого обучения составили 0,87 (FARAD) и 0,86 (MiniSAR).

Также популярным является подход к обучению посредством общих скрытых представлений. Например, можно обучить автоэнкодер, который через составительную функцию потерь (Adversarial Loss) подменяет принадлежность исходному домену, формируя таким образом признаки, одинаково пригодные для двух разных наборов.

Методы обучения без учителя особенно востребованы при совмещении данных разных радаров (например, спутникового и наземного) или данных разных спектральных диапазонов (оптического и микроволнового), где ручная разметка одного из доменов отсутствует. Эти методы демонстрируют, что для улучшения качества моделей можно использовать весь массив доступных радиолокационных данных, даже без наличия разметки.

Обучение на малых выборках

В отдельное направление исследований выделяют методы, рассчитанные на экстремально малый объем обучающих примеров (Few-Shot Learning). Это критически важно для ряда приложений радиолокационного зондирования (прежде всего в сфере обороны и безопасности), где обычно для обучения модели распознавания доступно незначительное количество размеченных изображений. Few-Shot подходы обычно строятся либо на мета-обучении (Meta-Learning), либо на прототипных сетях (Prototypical Networks).

В 2023 г. в работе [Lv23] был предложен фреймворк FASAR-Net, который впервые объединил мета-обучение и генеративно-состязательную адаптацию для задач SAR-ATR. Суть предложенного подхода заключалась в том, что сеть обучается быстро адаптироваться к новому классу, имея лишь несколько его примеров, при этом одновременно пытаясь через доменно-состязательное обучение (Adversarial Domain Learning) сократить расхождение между распределениями признаков, получаемых с разных углов обзора, и использовать априорные знания о рассеянии целей. В частности, FASAR-Net включает модуль извлечения УЭПР-признаков, который оценивает отражательные характеристики цели на основе САПР-модели, чтобы помочь задаче классификации даже при сильной деформации изображения цели под большим углом ее наклона. Мета-сеть тренируется на задачах «извлечение по 1–2 примерам» и успешно распознаёт деформированные и малоразмерные цели, достигая высокой точности (около 90%) на датасете MSTAR при использовании лишь 2% от исходных данных.

Другой подход Few-Shot Learning – это прототипные сети, когда для каждого класса в пространстве признаков вычисляется усреднённый эталон, и новые примеры сравниваются с прототипами. Тем не менее, для РЛИ прототипные методы сложны из-за вариативности ракурсов, так как прототип может оказаться нечувствительным к существенным изменениям. Поэтому последние работы (например, [Zha21b]) вводят продвинутые меры расстояния и агрегации, чтобы прототипы учитывали внутриклассовую вариативность и межклассовые сходства.

В целом, несмотря на то, методы обучения на малых выборках применительно к РЛИ только развиваются, уже очевидно, что комбинация подходов мета-обучения, адаптации и физических знаний (рассеяние, модели сигнала) позволяет добиваться внушительных результатов в ситуациях, когда почти нет исходных данных для машинного обучения.

Трансферное обучение и дообучение

Поскольку собрать большие размеченные корпуса данных радиолокационной съемки достаточно сложно, то активно используется перенос знаний из других источников (Transfer Learning). Ранние работы пробовали применять модели, предобученные на ImageNet (натурные изображения, полученные в оптическом диапазоне) и дообучать их на доступных РЛИ. Однако прямое трансферное обучение с использованием оптических изображений не всегда эффективно из-за существенного разрыва доменов, вызванного различной физической основой сигналов, принимаемых в оптическом и микроволновом диапазонах.

Авторы работы [Hua20] провели масштабный анализ следующих аспектов Transfer Learning для РЛИ: 1) что переносить (какие слои), 2) откуда переносить (какие исходные домены) и как лучше адаптировать под задачи SAR-ATR. Они выяснили, что более глубокие и широкие сети дают более универсальные признаки; но для узкоспециализированного ATR лучше исходить из смешанных источников: например, сочетать предобучение на ImageNet с дальнейшим использованием данных по различным типам почвенно-растительного покрова (РЛИ, полученные с КА TerraSAR-X) и по объектам техники (набор MSTAR). В работе предложен транзитивный перенос (Transitive Transfer Learning) – поэтапное многократно перенаправленное дообучение через цепочку задач с постепенно уменьшающимся отличием от целевой задачи. В рамках исследования [Hua20] также внедрялся компонент адаптации доменов с использованием метрики многоядерного максимального среднего расхождения (Multi-kernel Maximum Mean Discrepancy, МК-MMD) между признаками исходных и целевых данных. Итогом стало построение улучшенных моделей, которые на MSTAR достигли точности свыше 99% без обучения, а на другом наборе (OpenSARShip) – около 91%. Более того, авторы выложили в открытый доступ модели, предобученные на задачи радиолокационного зондирования, что может облегчить дальнейшие исследования.

В целом, трансферное обучение на сегодняшний день используется повсеместно: новые нейронные сети часто инициализируют либо весами ImageNet (с последующей адаптацией первых слоев к специфике РЛИ), либо используют экзотические трансферы, такие как перенос

знаний с задач сегментации на классификацию, с поляриметрических данных на одном расстоянии (высот) съемки на другие и т.п. Правильная стратегия дообучения существенно повышает результат на малых выборках.

Инкрементное обучение

Методы инкрементного обучения (Incremental Learning) близки к подходам, рассчитанным на малые выборки, поскольку позволяют модели постепенно осваивать новые классы без потери уже приобретённых знаний. Это особенно важно в задачах SAR-ATR, где появление нового типа объекта не должно снижать точность распознавания ранее известных. Так, в [Li23c] был предложен метод на основе метрического обучения с функцией потерь SACS-Loss, которая способствует тому, чтобы в пространстве признаков объекты разных классов располагались ближе к центрам своего класса. Для предотвращения забывания старых классов также был разработан алгоритм выбора якорных образцов – небольшого, но информативного поднабора, который обеспечивает сохранность знаний при дообучении.

Также применяют подход распознавания открытого набора (Open Set Recognition) для обнаружения «неизвестных» классов. В одной из работ [Ove23] предлагалось модифицировать выход сети (OpenMax) и анализировать разделимость признаков, чтобы идентифицировать объекты, не принадлежащие ни к одному из обученных классов. Такие расширяемые и открытые модели позволяют приблизиться к реализации прикладных систем, которые смогут эффективно работать в реальных условиях с заранее неизвестным множеством встречающихся объектов интереса.

4.3 Методы по типу решаемой задачи технического зрения при дистанционном зондирования Земли

Обнаружение объектов на изображении

Задачи обнаружения (детекции) предполагают автоматическое нахождение объектов интереса на РЛИ и выделение их положения (например, прямоугольными рамками).

Выделяют два вида задач обнаружения:

- обнаружение неподвижных объектов, заключающееся в поиске на радарном снимке различных статичных целей, например здания, наземная техника, суда на воде. Обычно для детектирования объектов на фоне по яркости и контрасту применяются сверточные нейросети: например, одностадийные детекторы на основе YOLO [Jia21, Gro22, Zha24] или двухстадийные на основе R-CNN, адаптированные под спекл-шум РЛИ [Shi21, Zha22c];
- обнаружение движущихся объектов, т. е. детекция целей (наземный транспорт, морские и речные суда, самолеты), смещающихся за время съемки. Такая задача сложнее из-за наличия размытости и доплеровских сдвигов движущихся целей на РЛИ. Используются специальные подходы, например, обработка серии РЛИ [Wen21] или создание дополнительных каналов на анализируемом изображении [Yan24], а также глубокие нейросети, такие как Faster R-CNN, обученные для выявления характерных следов движения на снимке (размытости, «двойники») [Wen21, Yan24].

Сегментация изображения

Задача сегментации заключается в разделении РЛИ на отдельные области (маски) таким образом, чтобы каждому пикселю был присвоен класс объекта. Результатом является сегментированная карта, отображающая границы областей различного класса.

Различают следующие виды сегментации:

- семантическая сегментация (классификация каждого пикселя изображения на основе его принадлежности к определенному семантическому классу объектов, при этом все пиксели, относящиеся к одному классу, рассматриваются как единое целое). Для семантической сегментации используются как сверточные нейросети – U-Net и ее варианты [Den20, Ni24], так и сети на основе механизма внимания (Visual Transformer, ViT) [Sin23, Zha24b]. Первые учитывают контекст окружающих пикселей для более точного разделения областей на РЛИ, вторые лучше захватывают глобальный контекст. Для объединения сильных сторон каждой

из этих архитектур в работе [Liu22] используют сеть слияния на основе свёрточных слоёв и взвешенной суммы CNN и ViT;

- инстанс-сегментация или сегментация экземпляров (выделение каждого отдельного экземпляра объекта, принадлежащего к определенному классу – сочетание детекции и сегментации). Алгоритмы инстанс-сегментации позволяют разделять и идентифицировать отдельные объекты одного класса. При обработке РЛИ применяются модификации Mask R-CNN и аналогичных моделей [Fen22, Yuy20], например, для обнаружения и контурного выделения каждого отдельного судна на изображении участка моря [Nie20].

Классификация объектов на изображениях

Задачи классификации объектов на изображении подразумевают определение принадлежности конкретного объекта на РЛИ к одному из заранее определенных классов (категорий).

В контексте актуальных применений радиолокационных данных в задаче классификации объектов на изображении можно выделить следующие предметные области:

- классификация типов объектов военной и гражданской техники. Выше эта задача рассматривалась как «автоматическое распознавание целей» (ATR). Для ее решения обычно применяются глубокие сверточные нейронные сети, такие как ConvNext, MobileNetV3, ResNet-50, обученные на образцах целей (танк, БТР, грузовик и т.п.) с учетом изменений ракурса наблюдения объекта интереса [Hou25, Hua24, Ai24, Rah24];

- классификация антропогенных поверхностей. В рамках этой задачи нейросетевые модели (например, на основе ResNet) обучаются различать особенности радиолокационного эхосигнала (УЭПР, диэлектрическая проницаемость, шероховатость и другие характеристики), отраженного от разных типов застройки, дорог, сельскохозяйственных территорий и др. [Lia21]. Эта задача схожа с задачей семантической сегментации. Ключевое отличие от сегментации заключается в том, что методы классификации антропогенных поверхностей определяют принадлежность всего изображения одному классу, а не принадлежность каждого пикселя. В таком сценарии оригинальное РЛИ нарезают на фрагменты, размер которых определяется в зависимости от специфики целевой задачи. Такой подход оправдан в ситуациях, когда требуется определить наличие целевого типа антропогенной поверхности только в области соответствующего фрагмента, то есть осуществить приблизительную локализацию поверхности того или иного класса, без уточнения ее границ до пиксельного уровня.

5. ПЕРСПЕКТИВНЫЕ НАПРАВЛЕНИЯ РАЗВИТИЯ МЕТОДОВ ОБРАБОТКИ РЛИ

Современные исследования в области интеллектуального анализа РЛИ, получаемых с помощью БАС, сфокусированы на преодолении ограничений существующих методов, связанных с недостатком обучающих данных, влиянием шумов и помех, сложностью интерпретации РЛИ, а также с необходимостью адаптации к меняющимся условиям окружающей среды и геометрическим условиям съемки. К ключевым направлениям, которые определяют прогресс в этой области, можно отнести следующие новые подходы:

- повышение точности семантической сегментации подстилающих поверхностей и классификации физических наземных объектов с помощью многопозиционной съемки;
- физически информированное машинное обучение (Physics-Informed Learning) с использованием априорных знаний о физических процессах, лежащих в основе формирования РЛИ;
- специализированные архитектуры нейронных сетей, обеспечивающие выполнение обработки РЛИ в условиях ограниченных вычислительных ресурсов и в режиме, близком к реальному, в том числе непосредственно на борту БВС;
- современные архитектурные решения на системном уровне, дающие возможность существенно повысить эффективность и скорость обработки данных за счет распределения вычислительных задач глубокого обучения между бортовой аппаратурой БВС и наземными облачными платформами.

5.1 Использование разноракурсных РЛИ

Одним из наиболее перспективных направлений повышения информативности радиолокационной съемки с БВС является развитие методов получения, комплексной обработки и анализа разноракурсных данных, получаемых от многопозиционных РЛС. Разноракурсный подход подразумевает обработку последовательностей РЛИ одного объекта, снятых под разными азимутальными углами и углами наклона. При стандартной моностатической съемке проблемой является сходство радиолокационных откликов от различных типов подстилающей поверхности, особенно имеющих низкую интенсивность (например, плотные почвы, мокрый песок, густая растительность). Использование разноракурсных РЛИ и их комплексирование позволяет получить дополнительные информационные признаки, обусловленные угловой зависимостью ЭПР, что способствует лучшей дифференциации классов и помогает повысить точность семантической сегментации поверхностей и классификации объектов. Для улучшения семантической сегментации подстилающих поверхностей может быть реализовано преобразование РЛИ, полученных при разных углах наблюдения, в единое трехканальное RGB-изображение [Dub06]. Указанный метод использования разноракурсных РЛИ является альтернативой классификации земных покровов на основе данных, получаемых при разных поляризациях, и обладает при этом следующими преимуществами: 1) меньшая чувствительность к шероховатости поверхности; 2) лучшая идентификация объектов с низкой отражательной способностью за счёт комплексирования РЛИ разных ракурсов, что повышает отношение «сигнал/шум»; 3) два или более ракурса позволяют получить изображение поверхности с разных направлений, что значительно увеличивает объем информации о ее форме, текстуре и структуре. Кроме того, вследствие сложной конструкции, больших габаритов и веса, многополяризационные РЛС в основном используются на спутниках или пилотируемых самолетах, их установка возможна только на достаточно крупные БВС с большой допустимой массой полезной нагрузки, что ограничивает их широкое применение. Этих недостатков лишены двух- и многопозиционные системы, которые могут быть созданы на основе малогабаритных бортовых РЛС. Также на основе дополнительной обработки разноракурсных данных могут быть определены диэлектрическая проницаемость и влажность сельскохозяйственных почв [Lin24], а также другие геофизические параметры земной поверхности. Однако обработка и синтез данных, получаемых с разных ракурсов, предъявляют новые требования к алгоритмам, так как сигнатуры объектов значительно меняются между соседними изображениями. Поэтому необходимы специальные методы объединения и анализа разноракурсных РЛИ.

В работе [Zha20] предложена нейросетевая архитектура, объединяющая сверточную сеть EfficientNet и двунаправленную сеть с управляемыми рекуррентными блоками (BiGRU). Авторы показали, что такая модель достигает почти 100% точности распознавания при небольшом объеме обучающих данных.

Для задач с ограниченной разметкой используется обучение «с малыми выборками» (Few-Shot Learning). Так, в [Zha21b] применена прототипная сеть с многоуровневым объединением признаков. Это позволило приблизить качество распознавания к уровню полностью размеченной выборки, используя лишь несколько процентов исходных данных.

Также были предложены модели на основе механизмов самовнимания (Self-Attention). В [Li22] описан метод, сочетающий свёрточный автокодировщик и трансформер-энкодер. Он позволяет находить корреляции между разноракурсными РЛИ без строгой зависимости от порядка изображений, что повышает устойчивость модели к шуму на входе. В [Zho23] используется блок самовнимания, способный учитывать глобальный контекст (Non-Local подход для учета связей между пикселями, находящимися далеко друг от друга) и контрастивное предобучение. Благодаря этому подходу точность распознавания остаётся высокой даже при очень малом объеме обучающих данных (например, при 2% выборки достигается более 91% точности).

Таким образом, развитие методов интеграции информации из разноракурсных последовательностей РЛИ представляет собой одно из перспективных направлений применения алгоритмов глубокого обучения. К нему относятся гибридные нейросетевые модели (CNN + RNN), подходы Few-Shot (прототипные сети, многокритериальное обучение), механизмы внимания, а также адаптивные алгоритмы предобработки (кластеризация пикселей по характеру рассеяния). Все эти подходы показывают, что использование разноракурсных данных может значительно повысить точность и надёжность анализа РЛИ.

5.2. Интеграция физических моделей

Одно из ключевых ограничений современных ИИ-систем для эффективной обработки РЛИ – недостаточное использование знаний о физических принципах формирования радиолокационного сигнала и особенностях его рассеяния. В этой связи весьма перспективным является направление развития нейросетей со встроенными физическими моделями, которые учитывают комплексность сигнала, фазовые сдвиги, многолучевые эффекты и физическую структуру рассеяния объекта. Такие системы будут комбинировать обучаемые модули с детерминированными уравнениями распространения радиолокационных волн, что повысит объяснимость и устойчивость решений, особенно при ограниченном объёме данных для обучения.

В [Gao18] частично реализована идея использования генеративных моделей с учётом физической структуры данных. С ростом подобных исследований становится все более очевидным, что будущее – за более тесно интеграцией физических знаний и машинного обучения.

5.3. Коллаборативные распределённые системы и Edge-Cloud гибриды

Для задач реального времени и обработки больших потоков радиолокационных данных на борту БВС и в распределённых вычислительных сетях большим потенциалом обладает использование гибридных архитектур, объединяющих Edge-вычисления (периферийные вычисления на конечных устройствах) и облачные мощности. Такой подход позволяет минимизировать задержки при локальной предобработке и обнаружении объектов интереса, одновременно используя для глубокого анализа и переобучения нейросетевых моделей мощность облачных платформ.

Работы, подобные [Lu23], показывают, что ансамбли моделей и коллаборативные решения на борту БВС и в облаке позволяют значительно повысить надёжность и безопасность системы интеллектуального анализа РЛИ. Таким образом, применение гетерогенных вычислительных экосистем, способных адаптироваться к различным условиям и задачам с учётом ограничений по энергопотреблению, пропускной способности и безопасности, является перспективным способом повысить оперативность и производительность обработки РЛИ, получаемых с беспилотных авиационных носителей.

ЗАКЛЮЧЕНИЕ

Настоящий обзор современного состояния в области методов анализа РЛИ на основе глубокого обучения представляет актуальность в связи со стремительным развитием беспилотных технологий. На сегодняшний день БАС становятся ключевым элементом распределённых интеллектуальных систем мониторинга, однако для успешной реализации их потенциала в радиолокационном зондировании требуется разработка специализированных методов обработки данных, адаптированных к особенностям радиолокационной информации, различным условиям съёмки и ограничениям вычислительных ресурсов на борту носителя.

Поскольку реализация эффективных методов и подходов требует наличия полноценных наборов данных для обучения и оценки качества нейросетевых моделей, в рамках настоящего обзора была выполнена систематизация информации о существующих датасетах, содержащих радиолокационные данные. Анализ характеристик датасетов показал, что большинство из них содержат ограниченное разнообразие сцен, имеют несбалансированное распределение классов и недостаточный объём разметки. Поэтому первоочередным шагом при разработке новых

нейросетевых архитектур должно являться создание специализированных обучающих наборов с необходимой полнотой данных, соответствующих реальным условиям и конкретным задачам, для которых предназначена модель. С целью обеспечения полноты данных для обучения в последнее время активно развиваются подходы по расширению датасетов за счет создания синтетических РЛИ, имитирующих реальные условия съемки или содержащих объекты интереса, полученные путем моделирования в САПР.

Обзор методов интеллектуального анализа РЛИ был организован на основе структурирования этих методов по трем независимым таксономиям: исходя из типа архитектуры нейросети, типа стратегии обучения и типа решаемой задачи технического зрения.

В части применяемого типа архитектуры нейросети доминирующим остается использование сверточных нейронных сетей, демонстрирующих высокую эффективность в разнообразных задачах обработки РЛИ. Однако для ряда специфических задач хорошие результаты показывают рекуррентные (при обработке последовательностей разноракурсных РЛИ) и графовые (для распознавания объектов техники и транспорта на основе априорной информации об их ЭПР) нейронные сети. Большой потенциал для анализа РЛИ имеют нейронные сети с механизмом внимания, но пока преимущественно в рамках гибридных архитектур совместно со сверточными сетями. В задачах, характеризующихся дефицитом данных для обучения, успешно применяются генеративно-состязательные сети, поскольку позволяют создавать реалистичные синтетические РЛИ. Перспективными также являются комбинированные архитектуры, которые сочетают высокую производительность методов глубокого обучения с устойчивостью и интерпретируемостью, присущими традиционным методам обработки РЛИ.

Рассмотрение используемых стратегий обучения показало, что методы, основанные на обучении с использованием малых выборок и на трансферном обучении, позволяют преодолеть проблему нехватки данных при обеспечении высокой точности результатов. Находят свое решение проблемы забывания ранних классов (путем инкрементного обучения) и ограниченности размеченных данных (на основе адаптации домена), хотя эти вопросы все еще остаются открытыми для дальнейших исследований.

Для основных задач технического зрения, решаемых с применением интеллектуальных методов анализа РЛИ, наибольшую эффективность продемонстрировали свёрточные нейронные сети и сети на основе механизма внимания, обеспечивающие высокую точность и устойчивость к шумам. Для задач обнаружения неподвижных объектов наиболее распространены архитектуры на основе YOLO, Detection Transformer (одностадийные детекторы) и Faster R-CNN (двухстадийные детекторы), а для движущихся целей – Faster R-CNN. Сегментацию РЛИ наиболее успешно проводят с помощью модификаций U-Net (семантическая сегментация) и Mask R-CNN (инстанс-сегментация), а классификацию (автоматическое распознавание целей) – на основе различных модификаций ResNet.

Проведенный анализ современных методов интеллектуального анализа РЛИ позволил выявить несколько ключевых направлений развития этих методов, перспективных для использования на БАС, включая:

- подходы, основанные на обработке разноракурсных РЛИ с целью получения дополнительных информационных признаков, обусловленных угловой зависимостью ЭПР;
- способы интеграции нейросетей и физических моделей;
- распределенные (Edge-Cloud) архитектуры, позволяющие повысить оперативность и производительность обработки РЛИ, получаемых с БВС.

Прикладное значение выполненного обзора заключается в том, что он предоставляет разработчикам своего рода «дорожную карту» для создания эффективных систем интеллектуального анализа РЛИ. Предложенная таксономия методов позволяет осознанно выбирать архитектуры глубокого обучения под конкретные практические задачи радиолокационного зондирования с беспилотных носителей.

Перспективы дальнейших исследований лежат прежде всего в разработке новых методов надежной семантической сегментации подстилающих поверхностей и классификации объектов в режиме, близком к реальному времени, с использованием разноракурсных РЛИ, получаемых многопозиционной бортовой РЛС. Это позволит открыть новые возможности для оперативного мониторинга с использованием БАС.

БЛАГОДАРНОСТИ И ПОДДЕРЖКА

Работа выполнена на средства гранта, предоставленного по договору от 30.10.2024 № 70-2024-001319 между АНО ВО «Университет Иннополис» и Фондом поддержки проектов Национальной технологической инициативы.

СПИСОК ЛИТЕРАТУРЫ

- [Ai24] Ai J. et al. An SAR Target Classification Algorithm Based on the Central Coordinate Attention Module // IEEE Sensors Journal. 2024. Vol. 24. no. 2. pp. 1941-1952. EDN: [ZNZDJQ](#).
- [Bla20] Blasch E. et al. Review of recent advances in AI/ML using the MSTAR data // Proc. SPIE 11393, Algorithms for Synthetic Aperture Radar Imagery XXVII, 113930C (19 May 2020), 2020. pp. 53-63. DOI: [10.1117/12.2559035](#).
- [Che21] Chen J. et al. Airborne SAR Autofocus Based on Blurry Imagery Classification // Remote Sensing. 2021. Vol. 13. no. 19. 3872. EDN: [CRJWUQ](#).
- [Com18] Coman C., Thaens R. A Deep Learning SAR Target Classification Experiment on MSTAR Dataset // 19th International Radar Symposium (IRS) '18, Bonn, Germany, 2018. pp. 1-6. DOI: [10.23919/IRS.2018.8448048](#).
- [Den20] Denbina M. et al. Flood Mapping Using UAVSAR and Convolutional Neural Networks // IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium '20, Waikoloa, HI, USA, 2020. pp. 3247-3250. DOI: [10.1109/IGARSS39084.2020.9324379](#).
- [Don21] Dong G., Liu H., Chanussot J. Keypoint-Based Local Descriptors for Target Recognition in SAR Images: A Comparative Analysis // IEEE Geoscience and Remote Sensing Magazine. 2021. Vol. 9. no. 1. pp. 139-166. EDN: [NOOYSM](#).
- [Don21b] Dongdong L. et al. Improved S2ANet based on attention mechanism for small target detection in remote sensing images // CIE International Conference on Radar (Radar) '21, Haikou, Hainan, China, 2021. pp. 942-945. DOI: [10.1109/Radar53847.2021.10028564](#).
- [Dub06] Dubois-Fernandez P. et al. ONERA-DLR bistatic SAR campaign: Planning, data acquisition, and first analysis of bistatic scattering behavior of natural and urban targets // IEEE Proceedings - Radar Sonar and Navigation. 2006. Vol. 153. no. 3. pp. 214-223. DOI: [10.1049/ip-rsn:20045117](#).
- [Fen21] Feng S. et al. SAR Target Classification Based on Integration of ASC Parts Model and Deep Learning Algorithm // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2021. Vol. 14. pp. 10213-10225. EDN: [NEJTUQ](#).
- [Fen22] Feng S. et al. Target Region Segmentation in SAR Vehicle Chip Image with ACM Net // IEEE Geoscience and Remote Sensing Letters. 2022. Vol. 19. pp. 1-5. EDN: [WRJIYG](#).
- [Fra21] Fracastoro G. et al. Deep Learning Methods for Synthetic Aperture Radar Image Despeckling: An Overview of Trends and Perspectives // IEEE Geoscience and Remote Sensing Magazine. 2021. Vol. 9. no. 2. pp. 29-51. EDN: [SYTVTQ](#).
- [Fu24] Fu N., Wang Q., Cai F. Research on Speckle Filtering Method for Synthetic Aperture Radar Images Based on Deep Learning // 2024 6th International Conference on Frontier Technologies of Information and Computer (ICFTIC) '24, Qingdao, China, 2024. pp. 680-684. DOI: [10.1109/ICFTIC64248.2024.10913265](#).
- [Gao18] Gao F. et al. A Deep Convolutional Generative Adversarial Networks (DCGANs)-Based Semi-Supervised Method for Object Recognition in Synthetic Aperture Radar (SAR) Images // Remote Sensing. 2018. Vol. 10. no. 6. 846. DOI: [10.3390/rs10060846](#).
- [Gro22] Gromada K. et al. Real-Time Object Detection and Classification by UAV Equipped with SAR // Sensors. 2022. Vol. 22. no. 5. 2068. EDN: [IYROAK](#).
- [He20] He C., Li D., Gao Y. Improved SAR feature fusion with convolutional neural networks and moment methods // ESS Open Archive. July 31, 2020. DOI: [10.1002/essoar.10503842.1](#).
- [Hou20] Hou X. et al. FUSAR-Ship: building a high-resolution SAR-AIS matchup dataset of Gaofen-3 for ship detection and recognition // Sci. China Inf. Sci. 2020. Vol. 63. no. 4. 140303. EDN: [SCYNHC](#).
- [Hou25] Hou G. et al. A Multiscale Convolution SAR Image Target Recognition Method Based on Complex-Valued Neural Networks // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2025. Vol. 18. pp. 10657-10673. DOI: [10.1109/JSTARS.2025.3559656](#).
- [Hua20] Huang Z., Pan Z., Lei B. What, Where, and How to Transfer in SAR Target Recognition Based on Deep CNNs // IEEE Transactions on Geoscience and Remote Sensing. 2020. Vol. 58. no. 4. pp. 2324-2336. EDN: [CXBJNG](#).
- [Hua24] Huang L., Liu G. Convolutional Feature Aggregation Network with Self-Supervised Learning and Decision Fusion for SAR Target Recognition // IEEE Transactions on Instrumentation and Measurement. 2024. Vol. 73. pp. 1-14. DOI: [10.1109/TIM.2024.3443349](#).
- [Jan22] Jang O., Jo S., Kim S. A comparative survey on SAR image segmentation using deep learning // 22nd International Conference on Control, Automation and Systems (ICCAS) '22, Jeju, Korea, 2022. pp. 1292-1296. DOI: [10.23919/ICCAS55662.2022.10003707](#).
- [Jia21] Jiang J. et al. High-Speed Lightweight Ship Detection Algorithm Based on YOLO-V4 for Three-Channels RGB SAR Image // Remote Sensing. 2021. Vol. 13. no. 10. 1909. EDN: [QPAMAG](#).

- [Jia23] Jiang W. et al. Radar Target Characterization and Deep Learning in Radar Automatic Target Recognition: A Review // *Remote Sensing*. 2023. Vol. 15. no. 15. 3742. EDN: [HSOJSB](#).
- [Kec21] Kechagias-Stamatis O., Aouf N. Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey // *IEEE Aerospace and Electronic Systems Magazine*. 2021. Vol. 36. no. 3. pp. 56-81. EDN: [ZBINAA](#).
- [Lan25] Lang P. et al. Recent Advances in Deep-Learning-Based SAR Image Target Detection and Recognition // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2025. Vol. 18. pp. 6884-6915. EDN: [UBPVZG](#).
- [Lew19] Lewis B. et al. A SAR dataset for ATR development: the Synthetic and Measured Paired Labeled Experiment (SAMPLE) // *Proc. SPIE 10987, Algorithms for Synthetic Aperture Radar Imagery XXVI, 109870H* (14 May 2019), 2019. pp. 39-54. DOI: [10.1117/12.2523460](#).
- [Li17] Li B. et al. OpenSARShip 2.0: A large-volume dataset for deeper interpretation of ship targets in Sentinel-1 imagery // *SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA) '17*, Beijing, China, 2017. pp. 1-5. DOI: [10.1109/BIGSAR-DATA.2017.8124929](#).
- [Li22] Li S., Pan Z., Hu Y. Multi-Aspect Convolutional-Transformer Network for SAR Automatic Target Recognition // *Remote Sensing*. 2022. Vol. 14. no. 16. 3924. EDN: [CYNEUQ](#).
- [Li23] Li J. et al. A Comprehensive Survey on SAR ATR in Deep-Learning Era // *Remote Sensing*. 2023b. Vol. 15. no. 5. 1454. EDN: [BBBKRI](#).
- [Li23b] Li J. et al. A Survey on Deep-Learning-Based Real-Time SAR Ship Detection *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2023. Vol. 16. pp. 3218-3247. EDN: [HVXVOU](#).
- [Li23c] Li B. et al. Density Coverage-Based Exemplar Selection for Incremental SAR Automatic Target Recognition // *IEEE Transactions on Geoscience and Remote Sensing*. 2023. Vol. 61. pp. 1-13. DOI: [10.1109/TGRS.2023.3293509](#).
- [Li25] Li W. et al. SARATR-X: Toward Building a Foundation Model for SAR Target Recognition // *IEEE Transactions on Image Processing*. 2025. Vol. 34. pp. 869-884. EDN: [TKYODP](#).
- [Lia21] Liao N. et al. Analyzing the Separability of SAR Classification Dataset in Open Set Conditions // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. Vol. 14. pp. 7895-7910. EDN: [HOQCGZ](#).
- [Lin24] Linets G. et al. Method for remote measurement of specific conductivity and moisture of subsurface soil horizons // *Smart Agricultural Technology*. 2024. Vol. 8. 100503. EDN: [WCLMLX](#).
- [Liu20] Liu X. et al. Statistical Convolutional Neural Network for Land-Cover Classification from SAR Images // *IEEE Geoscience and Remote Sensing Letters*. 2020. Vol. 17, no. 9, pp. 1548-1552. EDN: [KLDUKL](#).
- [Liu22] Liu X. et al. High Resolution SAR Image Classification Using Global-Local Network Structure Based on Vision Transformer and CNN // *IEEE Geoscience and Remote Sensing Letters*. 2022. Vol. 19. pp. 1-5. EDN: [WRJIYG](#).
- [Liu23] Liu Y. et al. Long-Tailed SAR Target Recognition Based on Expert Network and Intraclass Resampling // *IEEE Geoscience and Remote Sensing Letters*. 2023. Vol. 20, pp. 1-5. DOI: [10.1109/LGRS.2023.3312274](#).
- [Liu25] Liu Y. et al. ATRNet-STAR: A Large Dataset and Benchmark Towards Remote Sensing Object Recognition in the Wild // *arXiv preprint*. 2025. [Online]. Available: [Accessed Jun. 16, 2025]. DOI: [10.48550/arXiv.2501.13354](#).
- [Lu23] Lu Z., Sun H., Xu Y. Adversarial Robustness Enhancement of UAV-Oriented Automatic Image Recognition Based on Deep Ensemble Models // *Remote Sensing*. 2023. Vol. 15, no. 12. 3007. EDN: [FGOJKC](#).
- [Lv23] Lv J. et al. Recognition of Deformation Military Targets in the Complex Scenes via MiniSAR Submeter Images With FASAR-Net // *IEEE Transactions on Geoscience and Remote Sensing*. 2023. Vol. 61, pp. 1-19. DOI: [10.1109/TGRS.2023.3280946](#).
- [Ma19] Ma F. et al. Attention Graph Convolution Network for Image Segmentation in Big SAR Imagery Data // *Remote Sensing*. 2019. Vol. 11, no. 21. 2586. DOI: [10.3390/rs11212586](#).
- [Mal17] Malmgren-Hansen D. et al. Improving SAR Automatic Target Recognition Models with Transfer Learning from Simulated Data // *IEEE Geoscience and Remote Sensing Letters*. 2017. Vol. 14. no. 9. pp. 1484-1488. DOI: [10.1109/LGRS.2017.2717486](#).
- [Ni24] Ni K. et al. DPGUNet: A Dynamic Pyramidal Graph U-Net for SAR Image Classification // *IEEE Transactions on Aerospace and Electronic Systems*. 2024. Vol. 60. no. 4. pp. 5247-5263. DOI: [10.1109/TAES.2024.3388373](#).
- [Nie20] Nie X. et al. Attention Mask R-CNN for Ship Detection and Segmentation from Remote Sensing Images // *IEEE Access*. 2020. Vol. 8. pp. 9325-9334. EDN: [QYEHBC](#).
- [Ove22] Oveis A. H. et al. A Survey on the Applications of Convolutional Neural Networks for Synthetic Aperture Radar: Recent Advances // *IEEE Aerospace and Electronic Systems Magazine*. 2022. Vol. 37. no. 5. pp. 18-42. EDN: [JUYISI](#).
- [Ove23] Oveis A. H. et al. Incremental Learning in Synthetic Aperture Radar Images Using Openmax Algorithm // *IEEE Radar Conference (RadarConf23)*, San Antonio, TX, USA, 2023. pp. 1-6. DOI: [10.1109/RadarConf2351548.2023.10149627](#).
- [Par20] Parikh H., Patel S., Patel V. Classification of SAR and PolSAR images using deep learning: a review // *International Journal of Image and Data Fusion*. 2020. Vol. 11. no. 1. pp. 1-32. EDN: [UANCDF](#).
- [Pas21] Passah A., Amitab K., Kandar D. SAR image despeckling using deep CNN // *IET image processing*. 2021. Vol. 15. no. 6. pp. 1285-1297. EDN: [IKNACD](#).
- [Pas22] Passah A. et al. SAR Image Classification: A Comprehensive Study and Analysis // *IEEE Access*. 2022. Vol. 10. pp. 20385-20399. EDN: [DMOMQC](#).
- [Pas23] Passah A. et al. Synthetic Aperture Radar image analysis based on deep learning: A review of a decade of research // *Engineering Applications of Artificial Intelligence*. 2023. Vol. 123. 106305. EDN: [PIZNYV](#).
- [Qin20] Qin R. et al. A semi-greedy neural network CAE-HL-CNN for SAR target recognition with limited training data // *International Journal of Remote Sensing*. 2020. Vol. 41. no. 20. pp. 7889-7911. EDN: [VVXIKM](#).
- [Rah24] Rahman N. et al. A Novel Lightweight CNN for Constrained IoT Devices: Achieving High Accuracy with Parameter Efficiency on the MSTAR Dataset // *IEEE Access*. 2024. Vol. 12. pp. 160284-160298. EDN: [RMNEXT](#).
- [San] Sandia National Laboratories, "Complex SAR Data". [Online]. Available: <https://www.sandia.gov/radar.pathfinder-radar-isr-and-synthetic-aperture-radar-sar-systems/complex-data>. [Accessed Jun. 16, 2025].

- [Shi21] Shi Y., Du L., Guo Y. Unsupervised Domain Adaptation for SAR Target Detection // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2021. Vol. 14. pp. 6372-6385. EDN: [GEHHQG](#).
- [Sin23] Singh A., Singh V. K. Exploring Deep Learning Methods for Classification of SAR Images: Towards NextGen Convolutions via Transformers // Advanced Network Technologies and Intelligent Computing Conference. ANTIC 2022, Varanasi, India: Cham Springer Nature Switzerland, 2023. pp. 249-260. DOI: [10.48550/arXiv.2303.15852](#).
- [Sri23] Srinitya G. et al. Automated SAR Image Segmentation and Classification Using Modified Deep Learning // Int. J. Patt. Recogn. Artif. Intell. 2023. Vol. 37. no. 01. 2252027. EDN: [KEQIHP](#).
- [Wan22] Wang Z. et al. SCFNet: Semantic Condition Constraint Guided Feature Aware Network for Aircraft Detection in SAR Images // IEEE Transactions on Geoscience and Remote Sensing. 2022b. Vol. 60. pp. 1-20. DOI: [10.1109/TGRS.2022.3224599](#).
- [Wan22b] Wang W. et al. Explorations of Contrastive Learning in the Field of Small Sample SAR ATR // Procedia Computer Science. 2022. Vol. 208. pp. 190-195. EDN: [LBSGSC](#).
- [Wei21] Wei D. et al. Target Detection Network for SAR Images Based on Semi-Supervised Learning and Attention Mechanism // Remote Sensing. 2021. Vol. 13. no. 14. 2686. EDN: [WRMYAD](#).
- [Wei22] Wei K. et al. Deep Dictionary Pair Learning for SAR Image Classification // Artificial Neural Networks and Machine Learning - ICANN 2022 / E. Pimenidis et al. (eds). Lecture Notes in Computer Science, vol 13531. Cham: Springer Nature Switzerland, 2022. pp. 87-100. DOI: [10.1007/978-3-031-15934-3_8](#).
- [Wen21] Wen L., Ding J., Loffeld O. Video SAR Moving Target Detection Using Dual Faster R-CNN // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2021. Vol. 14. pp. 2984-2994. EDN: [HMRXFS](#).
- [Xio25] Xiong X. et al. SAR-GTR: Attributed Scattering Information Guided SAR Graph Transformer Recognition Algorithm // arXiv preprint. 2025. [Online]. Available: [Accessed Jun. 16, 2025]. DOI: [10.48550/arXiv.2505.08547](#).
- [Yan22] Yang Y., Zhu W., Li J. A Review of SAR Images Target Recognition Based on Few-shot // EMIE 2022; The 2nd International Conference on Electronic Materials and Information Engineering, Hangzhou, China, 2022. pp. 1-5. DOI: [10.1109/TGRS.2023.3325988](#).
- [Yan24] Yang X., Jiao L., Pan Q. Transfer Adaptation Learning for Target Recognition in SAR Images: A Survey // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2024. Vol. 17. pp. 13577-13601. EDN: [LDPTME](#).
- [Yan24b] Yan H. et al. A New Method of Robust Ground Moving Target Detection Under Different Backgrounds of Airborne SAR Based on Spatial Deformable Module // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2024. Vol. 17. pp. 13000-13015. EDN: [CACMVO](#).
- [Yay20] Yayla R., Sen B. A New Classification Approach with Deep Mask R-CNN for Synthetic Aperture Radar Image Segmentation // Elektronika ir Elektrotehnika. 2020. Vol. 26. no. 6. pp. 52-57. EDN: [YVDPBL](#).
- [Yin24] Yin J. et al. A Review on the Few-Shot SAR Target Recognition // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2024. Vol. 17. pp. 16411-16425. EDN: [CWLPUQ](#).
- [Yu24] Yu C., Shin Y. An efficient YOLO for ship detection in SAR images via channel shuffled reparameterized convolution blocks and dynamic head // ICT Express. 2024. Vol. 10. no. 3. pp. 673-679. EDN: [ESRDIL](#).
- [Yue20] Yue Z. et al. A Novel Attention Fully Convolutional Network Method for Synthetic Aperture Radar Image Segmentation // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2020. Vol. 13. pp. 4585-4598. EDN: [WGZHLV](#).
- [Zha20] Zhao P., Huang L. Multi-Aspect SAR Target Recognition Based on EfficientNet and GRU // IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium '20, Waikoloa, HI, USA, 2020. pp. 1651-1654. DOI: [10.1109/IGARSS39084.2020.9323422](#).
- [Zha21] Zhang T. et al. SAR Ship Detection Dataset (SSDD): Official Release and Comprehensive Data Analysis // Remote Sensing. 2021. Vol. 13. no. 18. 3690. EDN: [ERYFPO](#).
- [Zha21b] Zhao P. et al. Multi-Aspect SAR Target Recognition Based on Prototypical Network with a Small Number of Training Samples // Sensors. 2021. Vol. 21. no. 13. 4333. EDN: [BFKJKM](#).
- [Zha22] Zhang Y., Hao Y. A Survey of SAR Image Target Detection Based on Convolutional Neural Networks // Remote Sensing. 2022. Vol. 14, no. 24. 6240. EDN: [PWUYLV](#).
- [Zha22b] Zhao S. et al. A Feature Decomposition-Based Method for Automatic Ship Detection Crossing Different Satellite SAR Images // IEEE Transactions on Geoscience and Remote Sensing. 2022. Vol. 60. pp. 1-15. EDN: [QWZKPD](#).
- [Zha22c] Zhao Y. et al. Attentional Feature Refinement and Alignment Network for Aircraft Detection in SAR Imagery // IEEE Transactions on Geoscience and Remote Sensing. 2022c. Vol. 60. pp. 1-16. DOI: [10.1109/TGRS.2021.3139994](#).
- [Zha22d] Zhao S. et al. An Automatic Ship Detection Method Adapting to Different Satellites SAR Images with Feature Alignment and Compensation Loss // IEEE Transactions on Geoscience and Remote Sensing. 2022. Vol. 60. pp. 1-17. DOI: [10.1109/TGRS.2022.3160727](#).
- [Zha24] Zhang X., Li R., He X. Multi-feature fusion ship target detection based on improved YOLOv5s // 7th International Conference on Communication Engineering and Technology (ICCET) '24, Tokyo, Japan, 2024. pp. 76-80. DOI: [10.1109/ICCET62255.2024.00020](#).
- [Zha24b] Zhao G. et al. Towards SAR Automatic Target Recognition: Multi-Category SAR Image Classification Based on Light Weight Vision Transformer // 21st Annual International Conference on Privacy, Security and Trust (PST) '24, Sydney, Australia, 2024. pp. 1-6. DOI: [10.1109/PST62714.2024.10788067](#).
- [Zhe23] Zheng S. et al. Towards Lightweight Deep Classification for Low-Resolution Synthetic Aperture Radar (SAR) Images: An Empirical Study // Remote Sensing. 2023. Vol. 15. no. 13. 3312. EDN: [TMGOBN](#).
- [Zho23] Zhou X. et al. Multi-Aspect SAR Target Recognition Based on Non-Local and Contrastive Learning // Mathematics. 2023. Vol. 11. no. 12. 2690. EDN: [SSAEMS](#).
- [Zhu20] Zhu H. et al. Target Classification from SAR Imagery Based on the Pixel Grayscale Decline by Graph Convolutional Neural Network // IEEE Sensors Letters. 2020. Vol. 4. no. 6. pp. 1-4. DOI: [10.1109/LENS.2020.2995060](#).
- [Zhu21] Zhu X. X. et al. Deep Learning Meets SAR: Concepts, models, pitfalls, and perspectives // IEEE Geoscience and Remote

- Sensing Magazine. 2021. Vol. 9. no. 4. pp. 143-172. EDN: [OQMGSE](#).
- [Zhu21b] Zhu H. Dark Area Classification from Airborne SAR Images Based on Deep Margin Learning // IEEE Access. 2021. Vol. 9. pp. 139823-139841. EDN: [TTMUGI](#).
- [Вер10] Верба В. С., Неронский Л. Б., Осипов И. Г., Турук В. Э. Радиолокационные системы землеобзора космического базирования. М: Радиотехника, 2010. 680 с. EDN: [QKJNFV](#).
- [Вер14] Верба В. С. и др. Радиолокационные системы авиационно-космического мониторинга земной поверхности и воздушного пространства. М: Радиотехника, 2014. 576 с.
- [Гру19] Груздов В. В., Колковский Ю. В., Криштопов А. В., Кудря А. И. Новые технологии дистанционного зондирования Земли из космоса. М: Техносфера, 2019. 482 с. EDN: [OPPIWE](#).
- [Дор20] Доросинский Л. Г., Виноградова Н. С. Теория и практика обработки сигналов в многопозиционных космических РСА. М: Изд. дом Академии Естествознания, 2020. 271 с. EDN: [DYELZE](#).
- [Дор21] Доросинский Л. Г., Виноградова Н. С., Иванов О. Ю. Обработка радиолокационных изображений. М: Изд. дом Академии Естествознания, 2021. 334 с. DOI: [10.17513/np.503](#). EDN: [CCXNPT](#).
- [Дор24] Доросинский Л. Г., Виноградова Н. С. Радиолокация сложных целей. Обнаружение и распознавание. М: Издательский дом Академии Естествознания, 2024. 244 с. DOI: [10.17513/np.609](#). EDN: [KCEFYW](#).
- [Зах12] Захаров А. И., Яковлев О. И., Смирнов В. М. Спутниковый мониторинг Земли: Радиолокационное зондирование поверхности. М: КРАСАНД, 2012. 248 с. EDN: [QKKWIX](#).
- [Кон05] Кондратенков Г. С., Фролов А. Ю. Радиовидение. Радиолокационные системы дистанционного зондирования Земли. М: Радиотехника, 2005. 368 с. EDN: [QKFBNT](#).
- [Лял22] Лялин К. С. Модульная многодиапазонная радиолокационная платформа дистанционного зондирования Земли с летательных аппаратов // Сб. докл. науч.-практ. спец. конф. в рамках Международного военно-технического форума (Кубинка, 16-18 авг. 2022). М: НПО "Специальная техника и связь" МВД РФ, 2022. С. 42-45. EDN: [FNJPXI](#).
- [Ров21] Ровкин М. Е. и др. Экспериментальная двухчастотная РСА ДЗЗ высокого разрешения: технический облик и результаты летных испытаний // Всероссийские открытые Арmandовские чтения: Современные проблемы дистанционного зондирования, радиолокации, распространения и дифракции волн. 2021. № 1. С. 437-445. EDN: [VEPPWD](#).

ОБ АВТОРАХ

КОКУТИН Сергей Николаевич

Университет Иннополис, Россия.

Вед. науч. сотр. отдела систем видеоаналитики Инст-та искусств. интеллекта. Дипл. инж. оптик-конструктор (Казанск. гос. техн. ун-т, 1996). Канд. геол.-мин. наук по геоэкологии (Уральск. гос. горный ун-т, 2010). Иссл. в обл. дистанц. зондирования Земли.

E-mail: s.kokutin@innopolis.ru

ORCID: [0009-0007-6474-2838](#)

СЕРГИЕВ Семен Александрович

Университет Иннополис, Россия.

Гл. программист-математик лаборатории развития продукта в сфере искусств. интеллекта, Ин-т искусств. интеллекта. Дипл. программист-математик (С.-Петерб. гос. ун-т, 2021). Иссл. в обл. компьютерного зрения и глубокого обучения.

E-mail: s.sergiev@innopolis.ru

ORCID: [0000-0002-4649-905X](#)

ABOUT THE AUTHORS

KOKUTIN Sergey Nikolaevich

Innopolis University, Russia.

Lead. Researcher, Dept. of Video Analytics Systems, Institute of AI. Dipl. Optical engineer-designer (Kazan State Technical University, 1996). Cand. of Tech. Sci. on Geo-Ecology (Ural State Mining Univ., 2010). Research in Earth Remote Sensing methods.

E-mail: s.kokutin@innopolis.ru

ORCID: [0009-0007-6474-2838](#)

SERGIEV Semen Aleksandrovich

Innopolis University, Russia.

Sr. Programmer-mathematician, Lab of Product Devel., Institute of AI. Dipl. Programmer-mathematician (Saint-Petersburg State Univ., 2021). Research in the field of computer vision and deep learning.

E-mail: s.sergiev@innopolis.ru

ORCID: [0000-0002-4649-905X](#)

МЕТАДАННЫЕ

Заглавие: Методы интеллектуального анализа радиолокационных изображений, получаемых с бортовых авиационных систем.

Аннотация: В статье представлено комплексное исследование последних достижений в области интеллектуальных методов решения задач технического зрения по данным радиолокационной съемки, применимых для реализации на беспилотных воздушных платформах. Актуальность обзора обусловлена быстрым развитием беспилотных авиационных систем и растущим интересом к применению малогабаритных бортовых радиолокационных станций для оперативного мониторинга, картографирования и поиска наземных объектов в сложных условиях, недоступных для традиционных оптических средств съемки. Выполнен детальный обзор ключевых

METADATA

Title: Methods of intelligent analysis of radar images obtained from on-board aviation systems.

Abstract: The article presents a comprehensive study of the latest advances in the field of intelligent methods for solving machine vision problems based on radar survey data, applicable for implementation on unmanned aerial platforms. The relevance of the review is due to the rapid development of unmanned aircraft systems and the growing interest in the use of small-sized airborne radar stations for operational monitoring, mapping and searching for ground objects in difficult conditions inaccessible to traditional optical survey tools. A detailed review of the key problems arising in processing radar sounding data using artificial neural networks is provided. A systematized description of

проблем, возникающих при обработке данных радиолокационного зондирования с использованием искусственных нейронных сетей. Приведено систематизированное описание известных датасетов, содержащих радарные снимки и синтетические данные, применяемые для машинного обучения при разработке нейросетевых моделей. Выполнен анализ особенностей и ограничений этих датасетов. Рассмотрен широкий спектр современных методов и алгоритмов анализа радиолокационных изображений на основе глубокого обучения, а также реализованных архитектур нейронных сетей. Представлены результаты решения различных задач технического зрения, достигнутые с применением рассматриваемых методов. Обсуждены преимущества и недостатки различных подходов, исследованы факторы, влияющие на показатели точности. Определены основные перспективные направления в развитии методов обработки радиолокационных данных применительно к реальным условиям работы бортовых радиолокационных систем, в том числе многопозиционных. Практическая ценность настоящего обзора заключается в предоставлении исследователям и разработчикам в области машинного обучения систематизированной основы для создания новых методов, направленных на решение актуальных задач радиолокационного мониторинга земной поверхности, экологического контроля и обеспечения безопасности с использованием беспилотных авиационных систем

Ключевые слова: Беспилотная авиационная система, радиолокационное изображение, датасет, искусственная нейронная сеть, глубокое обучение, обнаружение объектов, сегментация изображений, классификация объектов, разноразмерные данные.

Язык статьи: Русский.

Статья поступила в редакцию 20 июня 2025 г.

known datasets containing radar images and synthetic data used for machine learning in the development of neural network models is provided. The analysis of the features and limitations of these datasets is performed. A wide range of modern methods and algorithms for analyzing radar images based on deep learning, as well as implemented neural network architectures, is considered. The results of solving various problems of machine vision, achieved using the methods under consideration, are presented. The advantages and disadvantages of various approaches are discussed, and the factors affecting the accuracy indicators are investigated. The main promising areas in the development of radar data processing methods are determined in relation to the real operating conditions of airborne radar systems, including multi-position ones. The practical value of this review lies in providing researchers and developers in the field of machine learning with a systematic basis for creating new methods aimed at solving urgent problems of radar monitoring of the earth's surface, environmental control and ensuring safety using unmanned aircraft systems.

Key words: Unmanned aerial system, radar image, dataset, artificial neural network, deep learning, object detection, image segmentation, object classification, multi-aspect data.

Language: Russian.

The article was received by the editors on 20 June 2025