



Алгоритм предварительной подготовки оптических обучающих данных, повышающий эффективность их использования в задачах нейросетевой обработки радиолокационных изображений

В. А. Павлов^а, канд. техн. наук, доцент, orcid.org/0000-0003-0726-6613, pavlov_va@spbstu.ru

А. А. Белов^а, ведущий инженер, orcid.org/0000-0003-0617-4514

Ф. Шариати^а, старший преподаватель, orcid.org/0000-0002-7060-8826

С. В. Волвенко^а, старший научный сотрудник, orcid.org/0000-0001-7726-8492

Л. Гу^а, канд. техн. наук, инженер-исследователь, orcid.org/0000-0003-1105-5835

^аСанкт-Петербургский политехнический университет Петра Великого, Политехническая ул., 29, Санкт-Петербург, 195251, РФ

Введение: несмотря на продемонстрированную в последние годы в ряде исследований возможность применения оптических изображений для обучения нейронных сетей, предназначенных для обработки данных радиолокаторов с синтезированной апертурой, существующие подходы все еще характеризуются недостаточно высокой эффективностью. Это связано с различиями в физической природе формирования изображений и, как следствие, с существенными отличиями классификационных признаков объектов, выделяемых нейронной сетью в процессе обучения. **Цель:** разработать алгоритм специализированной предварительной обработки оптических изображений для использования в трансферном междоменном обучении нейросетей, обрабатывающих радиолокационные изображения, а также оценить эффективность такой обработки по стандартным метрикам нейросетевого детектора. **Результаты:** разработан алгоритм специализированной предварительной обработки оптических снимков, включающий преобразование в полутоновое изображение, низкочастотную гауссовскую фильтрацию, выделение границ на основе лапласиана и последующее сглаживание для формирования псевдорadiолокационного представления. В экспериментах детектор YOLO11х обучался на преобработанных оптических изображениях, валидация проводилась на оптических изображениях, а тестирование – на реальных радиолокационных изображениях с видами морских судов. По сравнению с обучением на необработанных оптических изображениях лучшая конфигурация обработки повысила Precision с 0,675 до 0,813, Recall с 0,464 до 0,517, mAP50 с 0,518 до 0,613 и mAP50-95 с 0,202 до 0,342. Полученные результаты показывают, что подавление яркостно-цветовой информации, характерной для оптического диапазона, и выделение признаков, связанных с формой и границами объектов, повышают эффективность переноса между оптическим и радиолокационным доменами в рассмотренных условиях эксперимента. **Практическая значимость:** результаты работы позволяют использовать широкодоступные размеченные оптические изображения для обучения нейросетей, решающих задачи классификации, сегментации или детектирования объектов на радиолокационных изображениях.

Ключевые слова – радиолокатор с синтезированной апертурой, оптические изображения, радиолокационные изображения, обработка изображений, нейронная сеть, обучение, обнаружение объектов.

Для цитирования: Павлов В. А., Белов А. А., Шариати Ф., Волвенко С. В., Гу Л. Алгоритм предварительной подготовки оптических обучающих данных, повышающий эффективность их использования в задачах нейросетевой обработки радиолокационных изображений. *Информационно-управляющие системы*, 2026, № 3, с. 14–22. doi:10.31799/1684-8853-2026-3-14-22, EDN: ZWXEEH

For citation: Pavlov V. A., Belov A. A., Shariaty F., Volvenko S. V., Gu L. Algorithm for preprocessing optical training data that improves the efficiency of their use in neural network processing tasks of radar images. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2026, no. 3, pp. 14–22 (In Russian). doi:10.31799/1684-8853-2026-3-14-22, EDN: ZWXEEH

Введение

Значительная часть информации, получаемой средствами дистанционного зондирования Земли, формируется на основе результатов анализа изображений оптического диапазона, собранных спутниками и летательными аппаратами. Оптические изображения (ОИ) имеют высокое качество, их анализ и интерпретация опираются на отработанные методики, однако недостатком является невозможность их съемки ночью и при наличии облачности. Это приводит к проблемам

с надежностью и оперативностью получения информации, важными при анализе быстро меняющихся событий, например при реагировании на стихийные бедствия.

Технология получения радиолокационных изображений (РЛИ) с помощью радиолокаторов с синтезированной апертурой также известна давно. Важнейшим преимуществом РЛИ по сравнению с ОИ является существенно меньшая зависимость их информационных характеристик от времени суток и метеорологических условий в районе съемки. Однако в течение длительного

времени широкодоступные РЛИ, как правило, уступали ОИ по пространственному разрешению, которое для массово используемых данных часто составляло десятки метров против единиц метров у оптических снимков. Такие разрешения были достаточны для анализа крупных площадных объектов типа сельскохозяйственных угодий, лесов, разливов нефти и т. п., но недостаточны для надежного обнаружения и анализа состояния более мелких объектов, в первую очередь искусственного происхождения: зданий и других сооружений, линий электропередач, кораблей и т. п.

В последнее время ситуация меняется: широкодоступными становятся РЛИ с разрешением порядка одного метра, близким к разрешению оптических снимков. Такие РЛИ предоставляют несколько компаний: «Роскосмос» (<https://gptl.ru/>), Capella Space (<https://www.capellaspace.com/>), ICEYE (<https://www.iceye.com/>) и др. Более высокое разрешение существенно повышает информационную ценность радиолокационных данных. Однако применение современных методов машинного обучения, особенно нейросетевых, к автоматизированной обработке РЛИ высокого разрешения осложняется рядом факторов, в частности: относительно малым количеством качественно аннотированных обучающих данных для РЛИ по сравнению с ОИ, их высокой стоимостью, а также специфическими особенностями формирования и интерпретации РЛИ.

Нехватка размеченных данных является одним из ключевых факторов, сдерживающих развитие нейросетевых методов обнаружения объектов в радиолокационном диапазоне. В связи с этим в последние годы активно развиваются подходы, позволяющие переносить знания, полученные при анализе ОИ (где аннотированных наборов данных существенно больше [1, 2]), на задачи обработки РЛИ. Этот вектор исследований направлен на сокращение междоменного разрыва и учет специфики РЛИ через многоуровневое согласование доменов и прогрессивный перенос на уровнях пикселей, признаков и предсказаний [3–5]. Наибольший практический интерес представляет сценарий, когда «источник» (ОИ) содержит достаточно большое количество качественно размеченных данных, а «цель» (РЛИ) представлена ограниченным числом размеченных примеров либо вовсе недоступна для обучения, что делает актуальными методы междоменного обучения и доменной адаптации.

В рамках перехода ОИ к РЛИ можно выделить несколько устойчивых направлений. Первое – это методы доменного выравнивания и адаптации, которые уменьшают расхождения распределений ОИ и РЛИ на разных уровнях представления данных. Достигается это за счет применения пиксельных преобразований, выравнивания признаковых

пространств и калибровки предсказаний, как правило, в сочетании со схемами «учитель–ученик» (teacher–student) и другими методами полуконтролируемого обучения, включая самообучение (self-training) [3, 4, 6, 7]. Второе направление делает акцент на структурно-текстурных признаках как наиболее стабильных при переходе между оптическим и радиолокационным доменами. Здесь используются архитектурные и алгоритмические приемы, направленные на сохранение геометрии объектов, усиление границ и текстур при подавлении модально-специфичных артефактов, что позволяет эффективнее «совмещать» оптические и радиолокационные представления [6, 7].

Отдельно развивается направление синтетической генерации РЛИ-подобных данных из ОИ. В нем применяются генеративно-состязательные сети и более современные генеративные подходы для построения «промежуточного домена» или прямого перехода ОИ к РЛИ в целях расширения обучающих выборок [8, 9]. Однако в ряде обзоров подчеркивается, что такая трансляция часто является более неоднозначной, чем обратная задача, поскольку один и тот же оптический вид может соответствовать множеству РЛИ-проявлений в зависимости от геометрии съемки и характеристик рассеяния [10, 11]. Альтернативой генеративным подходам является физическое моделирование радиолокационных сигнатур с использованием электромагнитного численного анализа и их внедрение в статистически сгенерированный фон, что позволяет создавать неограниченное количество реалистичных обучающих примеров с контролируемыми параметрами [12]. Такой подход, включающий извлечение сигнатур из реальных снимков с неполной информацией автоматической идентификационной системы судов и синтез новых по 3D-моделям, продемонстрировал повышение точности обнаружения (mAP) на 15–20 % при ограниченной обучающей выборке [12]. Поэтому наряду с генеративными моделями сохраняют актуальность стратегии, основанные на переносе через представления (representation learning) и специализированное предобучение, ориентированное на повышение переносимости признаков между оптическим и радиолокационным доменами [13].

В статьях [14, 15] в целях обучения сверточной нейронной сети для работы с РЛИ (на примере обнаружения морских судов) использовались цветные ОИ, переведенные в градации серого. Однако очевидно, что такой простейший метод адаптации не является оптимальным.

Исследование нацелено на разработку алгоритма специализированной предварительной обработки ОИ для применения в междоменном обучении нейросетевого детектора РЛИ и на оценку его эффективности с помощью стандартных метрик обнаружения объектов.


Описание предлагаемого алгоритма

Для сравнения на рис. 1, *а* и *б* представлены оптическое и радиолокационное изображения, содержащие один класс объекта, — морское судно. Сопоставление и анализ оптических и радиолокационных сходных объектов позволяет сделать следующие выводы. В настоящее время типичные данные дистанционного зондирования Земли, получаемые с помощью оптических и радиолокационных средств, уже имеют сравнимое разрешение (порядка одного метра или более высокое). Соответственно, структурные особенности многих объектов (размеры, форма контуров, взаимная ориентация составных частей объекта) одинаково проявляются в обоих случаях. С другой стороны, яркостная (амплитудная) информация отличается существенно. Например, плоские поверхности типа дорожного покрытия, плоской крыши здания, поверхности водоема на РЛИ всегда имеют малую амплитуду (яркость). Яркость таких объектов, в зависимости от их материала и условий освещенности, на ОИ может быть практически произвольной.

Эти наблюдения подтверждаются анализом физических механизмов формирования отражений в оптическом и радиодиапазонах длин волн, связанных в основном с большим различием в длине волны. Известно, что характер рассеяния от неровной поверхности определяется отношением среднего размера ее неровностей (в первую очередь их высоты) к длине волны и может иметь диффузный или зеркальный характер [17]. Соответственно, многие поверхности, шероховатые и диффузно рассеивающие в оптическом диапазоне, являются гладкими и зеркально отражаю-

щими в радиодиапазоне, поскольку из-за различия длин волн в оптическом и радиодиапазоне одна и та же поверхность по критериям шероховатости может рассматриваться как шероховатая для ОИ и как гладкая для РЛИ.

Таким образом, при трансформации ОИ в РЛИ-подобные изображения следует ориентироваться на преобразования, сохраняющие структурную информацию и снижающие влияние яркостной и цветовой компонент ОИ. Для удаления цветовой информации могут использоваться известные методы перевода цветных изображений в оттенки серого. Однако они не решают проблему несоответствия поведения яркостных компонент РЛИ и ОИ. Как уже обсуждалось, практически все однородные гладкие поверхности на РЛИ имеют малую амплитуду отражений, а на ОИ — произвольную, и часто достаточно большую. Спектр однородных гладких участков на изображении сконцентрирован в зоне низких пространственных частот, амплитуда которых зависит от яркости данной зоны. Преобразование, сводящее яркость (амплитуду) любой однородной области на изображении к малой яркости, — это подавление низких пространственных частот изображения, достигаемое использованием двумерных фильтров верхних частот (ФВЧ), в частности дифференциаторов. ФВЧ обычно применяется после обработки изображения специально подобранным фильтром низких частот (ФНЧ). Это делается для снижения влияния шума на результаты фильтрации, так как ФВЧ будет дополнительно подчеркивать имеющиеся высокочастотные (ВЧ) компоненты шума. В качестве ФНЧ часто используется фильтр с конечной импульсной характеристикой с ядром Гаусса.



■ **Рис. 1.** Оптическое (<https://www.kaggle.com/competitions/airbus-ship-detection>) (*а*) и радиолокационное (*б*) изображения [16]

■ **Fig. 1.** Optical (<https://www.kaggle.com/competitions/airbus-ship-detection>) (*a*) and radar (*b*) images [16]

В соответствии с вышеизложенным можно предложить следующий алгоритм преобразования ОИ в псевдо-РЛИ.

1. Предварительная НЧ-фильтрация ОИ. Для снижения влияния шума перед дифференцированием цветное изображение поканально сворачивается с ядром Гаусса.

Пусть $G_{\sigma_1}(x, y)$ – ядро Гаусса с параметром σ_1 (стандартное отклонение):

$$G_{\sigma_1}(x, y) = \frac{1}{2\pi\sigma_1^2} e^{-\frac{x^2+y^2}{2\sigma_1^2}},$$

где x, y – целочисленные координаты, изменяющиеся в пределах $[-r_1, r_1]$, а размер ядра $k_1 = 2r_1 + 1$ выбирается как $k_1 = 2[3\sigma_1] + 1$ (что охватывает практически всю энергию гауссианы).

Ядро нормируется таким образом, чтобы сумма всех его элементов равнялась единице: $\sum \sum G_{\sigma_1}(x, y) = 1$, что гарантирует сохранение средней яркости однородных областей. Тогда сглаженное изображение $I_{smooth}(x, y)$ (цветное) представляет собой результат свертки (обозначается *) исходного изображения с этим ядром:

$$I_{smooth}(x, y) = G_{\sigma_1}(x, y) * I(x, y).$$

Обработка границ изображения осуществляется методом дополнения нулями (zero-padding), т.е. пиксели, выходящие за пределы исходного изображения, считаются равными нулю.

2. Преобразование цветного ОИ в уровни серого. Полученное сглаженное цветное изображение путем поканального усреднения преобразуется в полутоновое:

$$I_{gray}(x, y) = \frac{1}{3} (I_{smooth}^R(x, y) + I_{smooth}^G(x, y) + I_{smooth}^B(x, y)).$$

3. ВЧ-фильтрация полученного изображения (выделение границ). Детектор границ реализован на основе лапласиана:

$$I_{edge}[i, j] = \sum_{m=-2}^2 \sum_{n=-2}^2 L[m, n] I_{gray}[i-m, j-n],$$

где L – ядро лапласиана. В работе использовалось ядро 5×5

$$L = \begin{bmatrix} -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & 24 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \end{bmatrix}.$$

4. Дополнительная НЧ-фильтрация изображения. Пусть $G_{\sigma_2}(x, y)$ – ядро Гаусса с параметром σ_2 :

$$G_{\sigma_2}(x, y) = \frac{1}{2\pi\sigma_2^2} e^{-\frac{x^2+y^2}{2\sigma_2^2}}.$$

Размер ядра $k_2 = 2[3\sigma_2] + 1$, нормировка: $\sum \sum G_{\sigma_2}(x, y) = 1$. Тогда сглаженное изображение представляет собой результат свертки исходного изображения с этим ядром с заполнением нулями на границах:

$$I_{smooth}^{edge}(x, y) = G_{\sigma_2}(x, y) * I_{edge}(x, y).$$


Стоит отметить, что порядок выполнения пп. 1 и 2 не является существенным. Алгоритм выглядит несложным, но для его эффективного использования важен правильный подбор параметров фильтров, т.е. необходимо оценить влияние параметров применяемых фильтров на качество обнаружения объектов.

Ниже приведены примеры изображений, полученных в результате применения алгоритма с тремя различными наборами фильтров (рис. 2, а–г).

Комбинация фильтров 1: последовательное применение низкочастотной гауссовской фильтрации с параметром ядра $\sigma = 3$, преобразование в градации серого методом усреднения каналов, ВЧ-фильтрации детектором границ на основе лапласиана и финального низкочастотного гауссовского сглаживания с параметром $\sigma = 20$. Результат предобработки представлен на рис. 2, б.

Комбинация фильтров 2: предварительная низкочастотная гауссовская фильтрация с параметром $\sigma = 20$, преобразование в градации серого методом усреднения каналов, ВЧ-фильтрация детектором границ на основе лапласиана и финальное НЧ-сглаживание с параметром $\sigma = 20$. Таким образом, оба этапа НЧ-обработки выполняются с одинаковым и значительным радиусом размытия, что обеспечивает интенсивное сглаживание как исходного, так и промежуточного изображения. Результат предобработки представлен на рис. 2, в.

Комбинация фильтров 3: преобразование в градации серого методом усреднения каналов, ВЧ-фильтрация детектором границ на основе лапласиана и последующее низкочастотное гауссовское сглаживание с параметром $\sigma = 20$. В отличие от предыдущих вариантов, здесь отсутствует предварительная НЧ-фильтрация, что позволяет сохранить более мелкие детали исходного изображения перед выделением границ, однако финальное размытие со значительным радиусом обеспечивает итоговую «радароподобную» сглаженность. Результат предобработки представлен на рис. 2, г.



■ **Рис. 2.** Примеры оптических изображений: *a* – исходные; *б* – обработанные комбинацией фильтров 1; *в* – обработанные комбинацией фильтров 2; *г* – обработанные комбинацией фильтров 3

■ **Fig. 2.** Examples of optical images: *a* – originals; *б* – processed by a combination of filters 1; *в* – processed by a combination of filters 2; *г* – processed by a combination of filters 3

Результаты и обсуждение

При визуальном анализе наиболее соответствующим реальным РЛИ представляется набор, полученный комбинацией фильтров 2. Однако визуальная оценка результатов предварительной обработки позволяет судить только о внешнем сходстве полученных псевдо-РЛИ с реальными РЛИ и не является достаточным критерием эффективности подготовки обучающих данных. Поэтому в работе эффективность предварительной обработки оценивалась косвенно — по результатам обнаружения морских судов на тестовой выборке реальных РЛИ. Для этого нейросетевой детектор обучался на ОИ, обработанных различными комбинациями фильтров, а затем тестировался на реальных РЛИ; в качестве показателей эффективности использовались стандартные метрики детекторов объектов.

Для проведения экспериментов был выбран нейросетевой детектор YOLO11x [18], обладающий высокой точностью обнаружения объектов на ОИ. Для каждого набора фильтров выполнялось обучение YOLO11x: длительность 30 эпох, размер батча 8, входное разрешение 640×640 . Обучение и валидация проводились на предобработанных ОИ, тестирование — на РЛИ. Размер наборов данных: обучающий — 1610 ОИ, валидационный — 403 ОИ, тестовый — 5604 РЛИ с изображениями видов морских судов. В качестве метрик качества обнаружения использовались стандартные показатели машинного обучения [19, 20]: точность (Precision), полнота (Recall), mAP50, mAP50-95. Указанные метрики применялись в качестве показателей эффективности предварительной обработки; более высокие значения этих метрик соответствуют лучшему переносу признаков с ОИ на РЛИ.

Обучающая и валидационная выборки сформированы из ОИ конкурса Airbus Ship Detection (источник — спутники Airbus SPOT 6/7, цветные изображения, разрешение 1,5 м) (<https://www.kaggle.com/competitions/airbus-ship-detection>). Тестовая выборка РЛИ взята из общедоступного набора данных HRSID [16], содержащего снимки со спутников Sentinel-1B (С-диапазон, разрешение 1,7–4,9 м, поляризации HH, HV, VV), TerraSAR-X и TanDEM-X (X-диапазон, разрешение 0,25–3 м, поляризации HH, VV). Все РЛИ имеют пространственное разрешение от одного до 5 м, представлены в виде кополяризационных (116 снимков) и кросс-поляризационных (20 снимков) режимов. Подробные характеристики исходных панорамных снимков (углы падения, режимы съемки, количество судов) приведены в [16]. Оба набора содержат изображения с видами морских судов.

■ **Таблица 1.** Результаты обнаружения морских судов на тестовой выборке РЛИ

■ **Table 1.** Ship detection results on the radar-image test set

Тип обработки	Precision	Recall	mAP50	mAP50-95
Без обработки	0,675	0,464	0,518	0,202
Комбинация фильтров 1	0,785	0,492	0,563	0,250
Комбинация фильтров 2	0,821	0,517	0,608	0,313
Комбинация фильтров 3	0,786	0,484	0,569	0,321

Результаты тестирования на реальных РЛИ, приведенные в табл. 1, показывают повышение значений метрик при использовании предложенной предварительной обработки. Все комбинации фильтров демонстрируют более высокие значения метрик по сравнению с базовым вариантом (без обработки) по всем метрикам. Наилучший баланс точности и полноты обеспечивает комбинация фильтров 2, увеличивающая Precision с 0,675 до 0,821, Recall с 0,464 до 0,517, а ключевую метрику mAP50 с 0,518 до 0,608. Это свидетельствует о том, что предварительная обработка ОИ, учитывающая отдельные характеристики РЛИ, повышает эффективность обучения сверточной нейронной сети при переносе на реальные радиолокационные данные. Модель, обученная на необработанных ОИ, демонстрирует более низкие значения метрик при переносе на целевую предметную область.

Исследование влияния размера ядра предварительной гауссовской фильтрации (табл. 2) позволило определить значение параметра, при котором в проведенных экспериментах были получены наибольшие значения метрик для настройки алгоритма преобразования. Увеличение размера ядра с 10 до 20 практически не влияет на Precision и Recall, но повышает mAP50-95 с 0,312 до 0,313. Дальнейшее увеличение до 30 пикселей приводит к росту обобщающей способности модели (mAP50-95 до 0,342) при сохранении высокой точности (0,813). При размере ядра 40 наблюдается резкое ухудшение всех метрик, что, вероятно, связано с чрезмерным сглаживанием и потерей мелких, но важных для обнаружения объектов деталей. Таким образом, размер ядра 30 пикселей является наиболее предпочтительным выбором для данного набора данных.

■ **Таблица 2.** Результаты тестирования на РЛИ при изменении размера гауссовского ядра предварительной НЧ-фильтрации

■ **Table 2.** Radar-image test results for different Gaussian kernel sizes of the preliminary low-pass filtering in filter combination 2

Размер ядра	Precision	Recall	mAP50	mAP50-95
10	0,803	0,518	0,607	0,312
20	0,821	0,517	0,608	0,313
30	0,813	0,517	0,613	0,342
40	0,805	0,488	0,580	0,317


Два примера обнаружения морских судов на реальных тестовых РЛИ с использованием YOLOv11x, обученного на предобработанных ОИ, представлены на рис. 3, а и б.

Таким образом, проведенные эксперименты подтверждают, что предложенная методика предварительной обработки ОИ, адаптированная к характеристикам РЛИ, повышает эффективность переноса признаков при обучении нейросетевого детектора. Наилучшие результаты достигаются при использовании комбинации фильтров 2 с размером гауссовского ядра 30 пикселей, что обеспечивает оптимальный баланс между сглаживанием шумов и сохранением значимых деталей объектов. Полученные значения метрик Precision, Recall и mAP50 свидетельствуют

о практической применимости подхода для решения задачи обнаружения морских судов на реальных РЛИ, в том числе в условиях прибрежной зоны и открытого моря.

Заключение

В ходе проведенного исследования было показано, что применение специализированной предварительной обработки ОИ позволяет повысить значения метрик обнаружения при обучении сверточных нейронных сетей, предназначенных для анализа реальных РЛИ, в рассмотренных условиях эксперимента. Поскольку физические механизмы формирования отражений в оптическом и радиодиапазонах существенно различаются, простой перевод цветных оптических снимков в градации серого является нерациональным подходом, не позволяющим нейронной сети эффективно переносить знания на целевую предметную область. Во всех рассмотренных экспериментальных случаях предложенный алгоритм, направленный на имитацию характеристик РЛИ путем подавления несущественных яркостных компонент и подчеркивания структурной информации об объектах, продемонстрировал значительное улучшение качества обнаружения морских судов по сравнению с использованием немодифицированных ОИ. Наилучший баланс метрик (включая Precision, Recall и mAP) был достигнут при использовании комбинации фильтров с интенсивным сглаживанием, где оптимальный размер ядра предварительной низкочастотной гауссовской фильтрации составил



■ **Рис. 3.** Примеры обнаружения морских судов на реальных тестовых РЛИ в открытом море (а) и в прибрежной зоне (б)

■ **Fig. 3.** Examples of ship detection on real test radar images: in open sea (а) and in a coastal area (б)

30 пикселей, что обеспечило высокую точность и рост обобщающей способности модели. Таким образом, в работе продемонстрирована практическая возможность эффективного вовлечения обширных наборов предварительно обработан-

ных ОИ как непосредственно для процесса обучения нейронных сетей, так и в качестве инструмента аугментации уже имеющихся, но немногочисленных радиолокационных обучающих данных.

Литература

1. **Li K., Wan G., Cheng G.** DIOR: A large-scale dataset for object detection in optical remote sensing images. *IEEE Dataport*, April 12, 2025. doi:10.21227/tq1e-nx82
2. **Xia G. S., Bai X., Ding J., Zhu Z.** DOTA: A large-scale dataset for object detection in aerial images. *IEEE Dataport*, April 12, 2025. doi:10.21227/wwrj-3d46
3. **Jeong S., Kim Y., Kim S., Sohn K.** Enriching SAR ship detection via multistage domain alignment. *IEEE Geoscience and Remote Sensing Letters*, 2021, vol. 19, pp. 1–5. doi:10.1109/LGRS.2021.3115498
4. **Shi Y., Du L., Guo Y., Du Y.** Unsupervised domain adaptation based on progressive transfer for ship detection: From optical to SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, vol. 60, pp. 1–17. doi:10.1109/TGRS.2022.3185298
5. **Liu S., Wang Z., Wang R., Chen Y., Fan X., Li W.** SAR ship detection based on deep domain adaptation with limited samples. *Procedia Computer Science*, 2023, vol. 221, pp. 378–385. doi:10.1016/j.procs.2023.07.051
6. **Zhu Y., Ai J., Xue W., Wang Z., Zhao Z.** Cross-modal ship detection from optical to SAR images based on pixel-level and feature-level progressive transfer. *IEEE Sensors Journal*, 2025, vol. 25, no. 8, pp. 13344–13356. doi:10.1109/JSEN.2025.3543520
7. **Luo C., Zhang Y., Guo J., Hu Y., Zhou G., You H., Ning X.** SAR-CDSS: A semi-supervised cross-domain object detection from optical to SAR domain. *Remote Sensing*, 2024, vol. 16, no. 6, p. 940. doi:10.3390/rs16060940
8. **Wu B., Wang H., Zhang C., Chen J.** Optical-to-SAR translation based on CDA-GAN for high-quality training sample generation for ship detection in SAR amplitude images. *Remote Sensing*, 2024, vol. 16, no. 16, p. 3001. doi:10.3390/rs16163001
9. **Luo X., Lin Y., Xu K., Nam H., Peng D.** OS-Ship-1K: A CycleGAN-Based Optical-SAR Multimodal Ship Detection Dataset. 2025. <https://openreview.net/forum?id=a1B8eQc9Au> (дата обращения: 01.02.2026).
10. **Huang Z., Zhang X., Tang Z., Xu F., Dacu M., Han J.** Generative artificial intelligence meets synthetic aperture radar: A survey. *IEEE Geoscience and Remote Sensing Magazine*, 2024, vol. 14, no. 1, pp. 6–48. doi:10.1109/MGRS.2024.3483459
11. **Wang Z., Zhang Z., Shan X., Wei H. A., Tang P.** Generative models for SAR-optical image translation: A systematic review. *International Journal of Applied Earth Observation and Geoinformation*, 2026, vol. 146, Article 105009. doi:10.1016/j.jag.2025.105009
12. **Lee S.-J., Lee K.-J.** Efficient generation of artificial training DB for ship detection using satellite SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, vol. 14, pp. 11764–11774. doi:10.1109/JSTARS.2021.3128184
13. **Bao W., Huang M., Zhang Y., Xu Y., Liu X., Xiang X.** Boosting ship detection in SAR images with complementary pretraining techniques. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, vol. 14, pp. 8941–8954. doi:10.1109/JSTARS.2021.3109002
14. **Павлов В. А., Белов А. А., Волвенко С. В., Рашич А. В.** Применение обученных на оптических изображениях сверточных нейронных сетей для обнаружения объектов на радиолокационных изображениях. *Компьютерная оптика*, 2024, т. 48, № 2, с. 253–259. doi:10.18287/2412-6179-CO-1316, EDN: RJDCTL
15. **Павлов В. А., Белов А. А.** Использование оптических изображений в обучении нейронных сетей, обрабатывающих радиолокационные изображения. *Радиотехника*, 2025, т. 89, № 3, с. 98–108. doi:https://doi.org/10.18127/j00338486-202503-09, EDN: XLSHRP
16. **Wei S., Zeng X., Qu Q., Wang M., Su H., Shi J.** HRSID: A high-resolution SAR images dataset for ship detection and instance segmentation. *IEEE Access*, 2020, vol. 8, pp. 120234–120254. doi:10.1109/ACCESS.2020.3005861
17. **Верба В. С., Неронский Л. Б., Осипов И. Г., Турук В. Э.** Радиолокационные системы землеобзора космического базирования. М., Радиотехника, 2010. 680 с.
18. **Khanam R., Hussain M.** YOLOv11: An overview of the key architectural enhancements. *arXiv preprint*, 2024. doi:10.48550/arXiv.2410.17725
19. **Everingham M., Van Gool L., Williams C. K. I., Winn J., Zisserman A.** The Pascal Visual Object Classes (VOC) challenge. *International Journal of Computer Vision*, 2010, vol. 88, no. 2, pp. 303–338. doi:10.1007/s11263-009-0275-4
20. **Lin T.-Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Dollár P., Zitnick C. L.** Microsoft COCO: Common Objects in Context. *Computer Vision – ECCV 2014: Proceedings of the 13th European Conference on Computer Vision*. Cham: Springer International Publishing, 2014, vol. 8693, pp. 740–755. doi:10.1007/978-3-319-10602-1_48

UDC 004.932.72

doi:10.31799/1684-8853-2026-3-14-22

EDN: ZWXEEH

Algorithm for preprocessing optical training data that improves the efficiency of their use in the tasks for neural network processing of radar imagesV. A. Pavlov^a, PhD, Tech., Associate Professor, orcid.org/0000-0003-0726-6613, pavlov_va@spbstu.ruA. A. Belov^a, Leading Engineer, orcid.org/0000-0003-0617-4514F. Shariaty^a, Senior Lecturer, orcid.org/0000-0002-7060-8826S. V. Volvenko^a, Senior Researcher, orcid.org/0000-0001-7726-8492L. Gu^a, PhD, Tech., Research Engineer, orcid.org/0000-0003-1105-5835^aPeter the Great St. Petersburg Polytechnic University, 29, Politekhnikheskaia St., 195251, Saint-Petersburg, Russian Federation

Introduction: Although several studies have demonstrated in recent years the possibility of using optical images to train neural networks designed for processing synthetic aperture radar data, existing approaches still show limited efficiency. This is due to differences in the physical nature of image formation and, consequently, to substantial differences in the classification features extracted by a neural network during training. **Purpose:** To develop an algorithm for specialized preprocessing of optical images which can be used in cross-domain transfer learning of neural networks for radar image processing, and to evaluate the effectiveness of this preprocessing using standard object-detection metrics. **Results:** We develop an algorithm for specialized preprocessing of optical images. It includes grayscale conversion, low-frequency Gaussian filtering, boundary extraction using the Laplacian operator, and subsequent smoothing to form a pseudo-radar representation. In the experiments, YOLO11x has been trained on preprocessed optical images, validated on optical images, and tested on real radar images containing ships. Compared with training on raw optical images, the best preprocessing configuration increases Precision from 0.675 to 0.813, Recall from 0.464 to 0.517, mAP50 from 0.518 to 0.613, and mAP50-95 from 0.202 to 0.342. These results indicate that suppressing brightness and color information specific to the optical domain and emphasizing features related to object shape and boundaries improve transfer efficiency between the optical and radar domains under the considered experimental conditions. **Practical relevance:** The results of this work enable the use of widely accessible labeled optical images for training neural networks tasked with classifying, segmenting, or detecting objects in radar images.

Keywords – synthetic aperture radar, optical images, radar images, image processing, neural network, training, object detection.

For citation: Pavlov V. A., Belov A. A., Shariaty F., Volvenko S. V., Gu L. Algorithm for preprocessing optical training data that improves the efficiency of their use in neural network processing tasks of radar images. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2026, no. 3, pp. 14–22 (In Russian). doi:10.31799/1684-8853-2026-3-14-22, EDN: ZWXEEH

References

- Li K., Wan G., Cheng G. DIOR: A large-scale dataset for object detection in optical remote sensing images. *IEEE Dataport*, April 12, 2025. doi:10.21227/tqle-nx82
- Xia G. S., Bai X., Ding J., Zhu Z. DOTA: A large-scale dataset for object detection in aerial images. *IEEE Dataport*, April 12, 2025. doi:10.21227/wvrj-3d46
- Jeong S., Kim Y., Kim S., Sohn K. Enriching SAR ship detection via multistage domain alignment. *IEEE Geoscience and Remote Sensing Letters*, 2021, vol. 19, pp. 1–5. doi:10.1109/LGRS.2021.3115498
- Shi Y., Du L., Guo Y., Du Y. Unsupervised domain adaptation based on progressive transfer for ship detection: From optical to SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, vol. 60, pp. 1–17. doi:10.1109/TGRS.2022.3185298
- Liu S., Wang Z., Wang R., Chen Y., Fan X., Li W. SAR ship detection based on deep domain adaptation with limited samples. *Procedia Computer Science*, 2023, vol. 221, pp. 378–385. doi:10.1016/j.procs.2023.07.051
- Zhu Y., Ai J., Xue W., Wang Z., Zhao Z. Cross-modal ship detection from optical to SAR images based on pixel-level and feature-level progressive transfer. *IEEE Sensors Journal*, 2025, vol. 25, no. 8, pp. 13344–13356. doi:10.1109/JSEN.2025.3543520
- Luo C., Zhang Y., Guo J., Hu Y., Zhou G., You H., Ning X. SAR-CDSS: A semi-supervised cross-domain object detection from optical to SAR domain. *Remote Sensing*, 2024, vol. 16, no. 6, p. 940. doi:10.3390/rs16060940
- Wu B., Wang H., Zhang C., Chen J. Optical-to-SAR translation based on CDA-GAN for high-quality training sample generation for ship detection in SAR amplitude images. *Remote Sensing*, 2024, vol. 16, no. 16, p. 3001. doi:10.3390/rs16163001
- Luo X., Lin Y., Xu K., Nam H., Peng D. *OS-Ship-1K: A CycleGAN-Based Optical-SAR Multimodal Ship Detection Dataset*. 2025. Available at: <https://openreview.net/forum?id=a1B8eQc9Au> (accessed 01 February 2026).
- Huang Z., Zhang X., Tang Z., Xu F., Dacu M., Han J. Generative artificial intelligence meets synthetic aperture radar: A survey. *IEEE Geoscience and Remote Sensing Magazine*, 2024, vol. 14, no. 1, pp. 6–48. doi:10.1109/MGRS.2024.3483459
- Wang Z., Zhang Z., Shan X., Wei H. A., Tang P. Generative models for SAR-optical image translation: A systematic review. *International Journal of Applied Earth Observation and Geoinformation*, 2026, vol. 146, Article 105009. doi:10.1016/j.jag.2025.105009
- Lee S.-J., Lee K.-J. Efficient generation of artificial training DB for ship detection using satellite SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, vol. 14, pp. 11764–11774. doi:10.1109/JSTARS.2021.3128184
- Bao W., Huang M., Zhang Y., Xu Y., Liu X., Xiang X. Boosting ship detection in SAR images with complementary pre-training techniques. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, vol. 14, pp. 8941–8954. doi:10.1109/JSTARS.2021.3109002
- Pavlov V. A., Belov A. A., Volvenko S. V., Rashich A. V. Application of convolutional neural networks trained on optical images for object detection in radar images. *Computer Optics*, 2024, vol. 48, no. 2, pp. 253–259 (In Russian). doi:10.18287/2412-6179-CO-1316, EDN: RJDCTL
- Pavlov V. A., Belov A. A. On using optical images in training of neural networks for radar image processing. *Radioengineering*, 2025, vol. 89, no. 3, pp. 98–108 (In Russian). doi:10.18127/j00338486-202503-09, EDN: XLSHRP
- Verba V. S., Neronskiy L. B., Osipov I. G., Turuk V. E. *Radiolokacionnye sistemy zemleobzora kosmicheskogo bazirovaniya* [Space-based radar systems for land survey]. Moscow, Radiotekhnika Publ., 2010. 680 p. (In Russian).
- Wei S., Zeng X., Qu Q., Wang M., Su H., Shi J. HRSID: A high-resolution SAR images dataset for ship detection and instance segmentation. *IEEE Access*, 2020, vol. 8, pp. 120234–120254. doi:10.1109/ACCESS.2020.3005861
- Khanam R., Hussain M. YOLOv11: An overview of the key architectural enhancements. *arXiv preprint*, 2024. doi:10.48550/arXiv.2410.17725
- Everingham M., Van Gool L., Williams C. K. I., Winn J., Zisserman A. The Pascal Visual Object Classes (VOC) challenge. *International Journal of Computer Vision*, 2010, vol. 88, no. 2, pp. 303–338. doi:10.1007/s11263-009-0275-4
- Lin T.-Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Dollár P., Zitnick C. L. *Microsoft COCO: Common Objects in Context*. In: *Computer Vision – ECCV 2014: Proceedings of the 13th European Conference on Computer Vision*. Cham, Springer International Publishing, 2014, vol. 8693, pp. 740–755. doi:10.1007/978-3-319-10602-1_48