

## Усовершенствованный метод распознавания объектов морских и прибрежных систем на основе комбинации метода локальных бинарных шаблонов и нейросетевых технологий

**А. И. Сухинов**

Донской государственный технический университет,  
Ростов-на-Дону, Российская Федерация

ORCID: 0000-0002-5875-1523, e-mail: [sukhinov@gmail.com](mailto:sukhinov@gmail.com)

**Д. А. Соломаха**

Донской государственный технический университет,  
Ростов-на-Дону, Российская Федерация

ORCID: 0009-0005-4670-1210, e-mail: [solomakha.05@yandex.ru](mailto:solomakha.05@yandex.ru)

**Аннотация:** В работе предложена гибридная модель LBP+PSPNet для повышения точности сегментации нефтяных разливов на RGB-снимках дистанционного зондирования Земли, особенно в условиях низкой контрастности между загрязнениями и морским фоном. Модель объединяет извлечение локальных текстурных признаков (LBP) с глобальным контекстным анализом на основе Pyramid Scene Parsing Network (PSPNet). LBP усиливает детализацию текстурных особенностей нефтяной пленки, которые часто маскируются солнечными бликами или мелкими пятнами. PSPNet обеспечивает многомасштабный анализ изображения, что позволяет точно сегментировать как крупные разливы, так и слабо выраженные загрязнения. Эксперименты показали, что интеграция LBP увеличивает метрику IoU на 4.6% по сравнению с базовой PSPNet-архитектурой. Предложенная модель достигает F1-меры 0.85 при тестировании на низкоконтрастных сценариях, демонстрируя устойчивость к шумам и атмосферным искажениям. Результаты подтверждают эффективность синтеза классических методов анализа текстур и глубокого обучения для задач экологического мониторинга.

**Ключевые слова:** PSPNet, LBP, обнаружение разлива нефти, сегментация изображений.

**Благодарности:** Исследование выполнено за счет гранта Российского научного фонда № 22-11-00295-П, <https://rscf.ru/project/22-11-00295/>.

**Для цитирования:** Сухинов А.И., Соломаха Д.А. Усовершенствованный метод распознавания объектов морских и прибрежных систем на основе комбинации метода локальных бинарных шаблонов и нейросетевых технологий // Вычислительные методы и программирование. 2025. 26, № 3. 366–379. doi 10.26089/NumMet.v26r324.



## Improved method of recognizing marine and coastal system objects based on combination of local binary pattern method and neural network technologies

**Alexander I. Sukhinov**

Don State Technical University, Rostov-on-Don, Russia  
ORCID: 0000-0002-5875-1523, e-mail: [sukhinov@gmail.com](mailto:sukhinov@gmail.com)

**Denis A. Solomakha**

Don State Technical University, Rostov-on-Don, Russia  
ORCID: 0009-0005-4670-1210, e-mail: [solomakha.05@yandex.ru](mailto:solomakha.05@yandex.ru)

**Abstract:** The work proposes a hybrid model LBP+PSPNet to increase the accuracy of oil spill segmentation on RGB-images of remote sensing of the Earth, especially in conditions of low contrast between pollution and marine background. The model combines local texture feature extraction (LBP) with global context analysis based on Pyramid Scene Parsing Network (PSPNet). LBP enhances the detail of the texture features of oil film, which are often masked by solar flares or small spots. PSPNet provides large-scale image analysis, which allows for the precise segmentation of both large spills and low-level pollution. Experiments showed that LBP integration increases the IoU metric by 4.6% compared to the basic PSPNet architecture. The proposed model reaches F1-measure 0.85 when tested on low contrast scenarios, demonstrating resistance to noise and atmospheric distortions. The results confirm the effectiveness of synthesis of classical methods of texture analysis and deep learning for environmental monitoring tasks.

**Keywords:** PSPNet, LBP, oil spill detection, image segmentation.

**Acknowledgements:** The study was supported by the Russian Science Foundation grant No. 22-11-00295-II, <https://rscf.ru/en/project/22-11-00295/>.

**For citation:** A. I. Sukhinov, D. A. Solomakha, “Improved method of recognizing marine and coastal system objects based on combination of local binary pattern method and neural network technologies,” *Numerical Methods and Programming*. 25 (3), 366–379 (2025). doi 10.26089/NumMet.v26r324.

**1. Введение.** Нефтяные разливы остаются одной из наиболее острых экологических проблем, связанных с добычей и транспортировкой углеводородов. Эти инциденты оказывают разрушительное воздействие на морские экосистемы, пагубное влияние на состояние рекреационных систем и экономику прибрежных регионов. Токсичные компоненты нефти, попадая в водную среду, нарушают процессы фотосинтеза, вызывают гипотермию у морских животных и деградацию прибрежных экосистем [1–3]. Особенно критичны морские разливы, которые распространяются с высокой скоростью, создавая значительный финансовый и экологический ущерб. Согласно исследованиям, даже небольшие утечки, происходящие гораздо чаще крупных аварий, остаются недостаточно документированными, однако при этом оказывают долгосрочное негативное воздействие [4–6].

Для минимизации ущерба критически важно оперативное обнаружение и локализация разливов. Традиционные методы, такие как отбор проб и использование контактных исследований, сталкиваются с ограниченностью исследуемых акваторий, потерей оперативности обнаружения разливов, а иногда — высокой стоимостью [7]. Альтернативой становится дистанционное зондирование, основанное на спутниковых снимках, радарных данных и аэрофотосъемке. Так, в работе [8] использовались спутники Landsat-5 и Landsat-8 для оценки степени выгорания леса. Однако точность таких подходов зависит от сложности формы, размеров и направления распространения нефтяного пятна, особенно для удаленных районов моря [9, 10].

С развитием технологий искусственного интеллекта и машинного обучения появилась возможность автоматизировать процесс обнаружения и идентификации границ нефтяных загрязнений. Алгоритмы глубокого обучения, использующие сверточные нейронные сети (CNN), автоэнкодеры (АЕ) и условные генеративные состязательные сети (CGAN), демонстрируют высокую эффективность в обработке изображений, выявлении паттернов и прогнозировании зон загрязнения [11, 12]. Модели, ориентированные на классификацию типов нефтяных загрязнений (например, легкие, средние и тяжелые загрязнения), достигают точности до 89% при использовании размеченных оптических снимков [13, 14]. Однако ключевой проблемой остается недостаток крупных обучающих выборок, связанный с относительной редкостью зарегистрированных случаев разливов [15].

В исследовании предложена интеграция двух подходов — классической архитектуры PSPNet [16] и метода LBP [17] для обнаружения и идентификации границ нефтяных загрязнений. Модель PSPNet, известная своей способностью анализировать изображения на разных масштабах благодаря пирамидальной структуре, дополнена LBP — алгоритмом выделения текстурных признаков, который повышает чувствительность к характерным особенностям нефтяных пятен, таким как нерегулярные границы и контраст с фоном. Такое сочетание позволяет улучшить точность обнаружения и идентификации границ нефтяных загрязнений на спутниковых изображениях даже при сложных погодных условиях, в том числе облачности и/или волнении, а также при неоднородном рельефе земной суши.

## 2. Обзор результатов.

**2.1. Традиционные методы анализа спутниковых изображений.** Традиционные подходы к обнаружению нефтяных разливов, основанные на статистических классификаторах и анализе спутниковых изображений, демонстрируют ограниченную применимость в условиях сложного фона и низкого разрешения. В работе [18] отмечается, что методы, использующие гауссовы модели и адаптивные пороги для разделения нефтяных пятен на SAR-изображениях, сталкиваются с трудностями при интерпретации сложных океанологических явлений, таких как ветровые шумы и динамика волн, что снижает их точность до 70–85% в реальных сценариях. Однако эти методы сталкиваются с рядом дополнительных ключевых ограничений: высокой вычислительной сложностью и неспособностью дифференцировать нефть от других фоновых объектов, таких как лед или почва, а также недостаточной точностью определения границ.

**2.2. Глубокое обучение и CNN-архитектуры.** С внедрением алгоритмов глубокого обучения эффективность сегментации нефтяных пятен значительно возросла [7]. Так, применение нейросетей типа Fully Convolutional Networks (FCN) на основе архитектур GoogleNet и ResNet для анализа Landsat-изображений позволило достигнуть точности 88.25% и 89.65% соответственно. В исследовании [19] использована нормализованная пространственно-спектральная сверточная нейронная сеть N3D-CNN в сочетании с ансамблем бинарных классификаторов для уточнения результатов классификации. Данный подход обеспечил точность многоклассовой классификации на уровне 0.96, что превышает эффективность традиционных методов (1D-CNN и  $k$ -ближайших соседей) за счет интеграции спектрально-пространственных признаков и компенсации неоднородности освещения. Эти результаты превзошли классические методы, такие как SVM и алгоритмы, основанные на деревьях решений. В работе [20] был предложен двухэтапный метод с использованием трех пар CNN для детекции нефти, кораблей и береговой линии, который обеспечил общую точность 98%. В работе [21] использована ResNet-архитектура [22] для семантической сегментации SAR-изображений (Sentinel-1). В публикации [12] предложена FCN-модель на основе U-Net [23] сети для анализа RGB-изображений, при этом достигнута точность 89% в F1-мере. В работе [24] показан вариант модификации сети BiSeNetV2 за счет добавления модулей внимания и Ghost-GE-слоев, что позволило повысить вероятность распознавания алгоритма mIoU для тепловизионных изображений. Однако ключевым ограничением указанных подходов остается зависимость от качества и объема размеченных данных, которые часто ограничены из-за относительной редкости инцидентов загрязнения нефтепродуктами.

**2.3. Современные архитектуры и их эффективность.** Интеграция механизмов внимания и мультимодальных данных позволяет повысить точность сегментации. ResNet101V1c в комбинации с Dual Attention Network (DaNet), предложенная в [3], демонстрирует mIoU 72.49% на тестовом наборе данных. Использование AdamW-оптимизатора повысило точность на 7.84% по сравнению с SGD. При этом для редких типов нефти (например, черной) точность снижается на 0.3% из-за несбалансированности данных.

Современные методы анализа нефтяных разливов сталкиваются с рядом взаимосвязанных вызовов, которые ограничивают их практическую применимость. Одной из ключевых проблем остается дефицит качественных обучающих данных, обусловленный редкостью зарегистрированных инцидентов и недоста-

точной детализацией доступных снимков. Еще одним критическим фактором становится необходимость обработки данных в режиме реального времени. Большинство существующих алгоритмов требуют значительных вычислительных ресурсов и времени на анализ изображений, что противоречит требованиям оперативного реагирования при ликвидации экологических аварий.

**3. Описание датасета для задачи сегментации нефтяных разливов.** Для реализации задачи сегментации нефтяных разливов в настоящей работе использовался открытый датасет, представленный в исследовании [3]. Данные включают RGB-изображения с разрешением  $1920 \times 1080$  пикселей морской поверхности с нефтяными пятнами различной конфигурации, а также соответствующие им бинарные маски сегментации, где пиксели классифицированы как “нефть” (1) или “фон” (0). Общее количество изображений составляло 2908, разделенных на обучающую (2792), валидационную (41) и тестовую (75) выборки. Такое соотношение обеспечивало достаточную вариативность данных для обучения, при этом сохраняя строгость оценки эффективности модели.

Аннотация данных выполнялась в формате семантической сегментации, что обеспечило точное выделение границ объектов с учетом их сложной геометрии и нечетких краев. Для упрощения задачи все типы нефти были объединены в единый класс, что соответствовало бинарной постановке задачи.

**4. Усовершенствованный алгоритм и сравнительный анализ.** Современные технологии обработки данных дистанционного зондирования Земли в сочетании с методами глубокого обучения демонстрируют высокую эффективность в решении задач мониторинга экологических чрезвычайных ситуаций, включая обнаружение нефтяных разливов. Однако точная сегментация масштабных загрязнений остается нетривиальной задачей, особенно в условиях слабой визуальной контрастности между нефтяной пленкой и однородным морским фоном. Существующие подходы, основанные на классических методах компьютерного зрения или одноуровневых архитектурах глубокого обучения, часто сталкиваются с ограничениями, связанными с неспособностью адекватно учитывать как локальные текстурные особенности, так и глобальную пространственную структуру сцен.

Для преодоления указанных ограничений в работе предложена гибридная архитектура (рис. 1), объединяющая извлечение локальных бинарных паттернов с многоуровневым контекстным анализом на основе PSPNet (рис. 2). Предложенный подход реализует двухэтапную обработку: на первом этапе вычисляются инвариантные к освещению текстурные признаки с помощью LBP, которые обеспечивают устойчивость к вариациям отражательной способности поверхностей, на втором этапе модифицированная PSPNet-архитектура выполняет семантическую сегментацию с учетом иерархического контекста, включая агрегацию признаков на разных пространственных масштабах. Интеграция LBP в конвейер глубокого обучения позволяет компенсировать недостаток данных о текстуре, характерных для однородных морских сцен, и повышает точность локализации границ загрязнений.




Рис. 1. Схема работы архитектуры LBP + PSPNet

Fig. 1. Architecture diagram of LBP + PSPNet

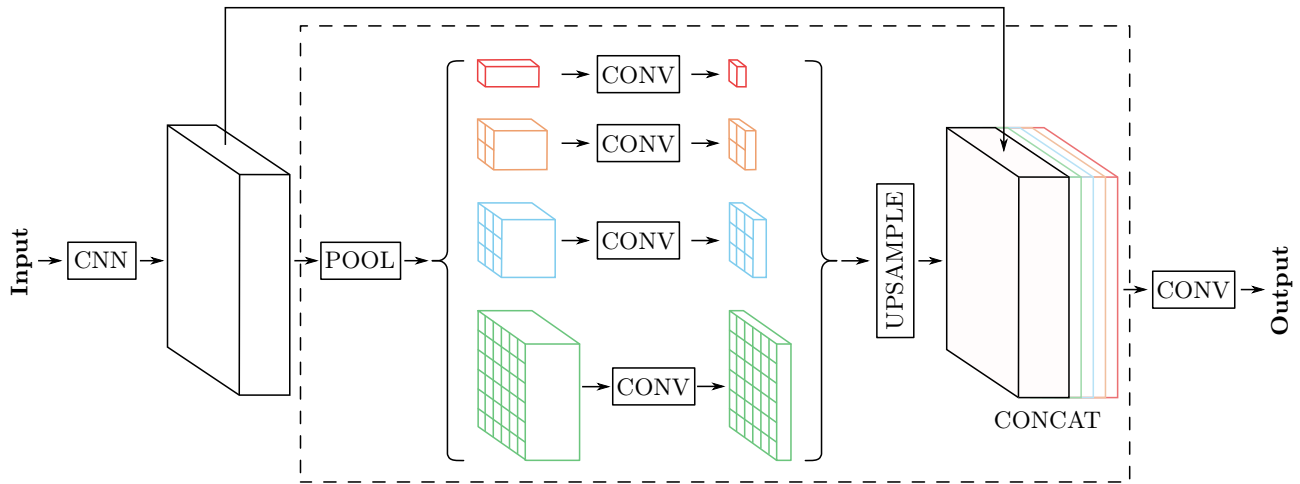


Рис. 2. Схема работы PSPNet [16]

Fig. 2. PSPNet architecture diagram [16]

## 5. Архитектура модели.

**5.1. Модуль LBP для извлечения текстурных признаков.** Модуль LBP реализован как сверточный слой, преобразующий входное RGB-изображение в нормализованную карту текстурных признаков.

Алгоритм включает следующие этапы:

1. Преобразование в градации серого: входное изображение преобразуется в одноканальное представление с использованием весовых коэффициентов для RGB-компонентов.
2. Бинаризация локальных паттернов: применяется сверточный фильтр с ядром  $3 \times 3$ , сравнивающим центральный пиксель с его окрестностью. Результат бинаризуется:

$$\text{LBP}(i, j) = \sum_{k=1}^8 s(p_k - p_c) 2^{k-1}, \quad s(x) = \begin{cases} 1, & x > 0, \\ 0, & x \leq 0, \end{cases}$$

где  $p_c$  — значение центрального пикселя с координатами  $(i, j)$ ,  $p_k$  — значения соседних пикселей.

3. Нормализация и взвешивание: полученные бинарные паттерны умножаются на матрицу весов  $3 \times 3$  (веса соответствуют степеням двойки) и нормализуются в диапазоне  $[0, 1]$ .

Выход модуля LBP ( $B \times 1 \times H \times W$ ), где  $B$  — размер батча, 1 — число каналов LBP,  $H$  и  $W$  — высота и ширина изображения, конкатенируется с входным изображением ( $B \times 3 \times H \times W$ ), формируя четырехканальный тензор ( $B \times 4 \times H \times W$ ) для последующих слоев нейронной сети. Это позволяет модели использовать как спектральные, так и текстурные признаки для сегментации.

**5.2. Модифицированная ResNet-50 для извлечения признаков.** Для извлечения высокоуровневых признаков используется модифицированная ResNet-50, адаптированная для работы с четырехканальным входом. Параметры первого сверточного слоя изменены: 4 входных канала, 64 выходных канала, размер ядра  $7 \times 7$ , шаг 2. Оставшиеся слои (BatchNorm, ReLU, MaxPool, residual-блоки) сохранены без изменений. Выход ResNet-50 ( $B \times 2048 \times H/32 \times W/32$ ) представляет собой многоканальную карту признаков, содержащую информацию о пространственных структурах и спектральных характеристиках разливов.

**5.3. Pyramid Pooling Module (PPM).** Для агрегации контекстуальной информации на разных масштабах используется Pyramid Pooling Module (PPM). Входной тензор ( $B \times 2048 \times H/32 \times W/32$ ) подвергается адаптивному среднему пулингу с размерами (1, 2, 3, 6), формируя четыре уровня иерархии. Каждый уровень обрабатывается последовательно свертка–нормализация–ReLU:

$$\text{Stage}(x) = \text{Conv1} \times 1(\text{AvgPool}(x)) \uparrow \text{Bilinear}(H, W),$$

где  $\uparrow$  обозначает интерполяцию до исходного размера  $H \times W$ . Результирующие карты и входной тензор конкатенируются по каналам ( $B \times 4096 \times H/32 \times W/32$ ), обеспечивая интеграцию локальной и глобальной информации.



**5.4. Финальный классификатор.** Конкатенированный тензор обрабатывается последовательно свертка-нормализация-ReLU с Dropout (0.1) для уменьшения размерности до 512 каналов ( $B \times 512 \times H/32 \times W/32$ ). Далее применяется билинейная интерполяция до исходного размера  $H \times W$  и свертка  $1 \times 1$  для получения карты логитов ( $B \times C \times H \times W$ ), где  $C$  — количество классов (например, типы нефти или фон).

**5.5. Адаптация к условиям низкой контрастности.** Ключевой особенностью архитектуры является интеграция LBP для усиления текстурных признаков, что критично при минимальных визуальных различиях между нефтяной пленкой и морским фоном. Модуль PPM обеспечивает устойчивость к солнечным бликам и перекрытиям типов загрязнений за счет иерархического анализа контекста.

**5.6. Обучение и оптимизация.** Модель обучается с использованием функции потерь CrossEntropyLoss и оптимизатора AdamW. Для повышения обобщающей способности применяются аугментации, имитирующие реальные условия дистанционного зондирования: случайное отражение, повороты и шум.

**6. Сравнение моделей LBP+PSPNet и U-Net.** U-Net, основанная на энкодер-декодерной структуре со skip-соединениями, демонстрирует высокую эффективность в задачах медицинской визуализации и сегментации объектов с четко выраженными границами. Однако ее применение для анализа спутниковых изображений с низкоконтрастными нефтяными разливами сопряжено с рядом ограничений. Skip-соединения фокусируются на локальных деталях, что затрудняет различение однородного морского фона и слабо выраженных нефтяных пленок, поскольку модель не учитывает широкий контекст сцены. Кроме того, U-Net полагается на спектральные данные RGB, но не выделяет текстурные особенности, такие как волнообразные узоры или радужные оттенки нефтяной пленки, что снижает точность в условиях солнечных бликов или мелких пятен. Отсутствие механизмов нормализации текстурных характеристик делает модель уязвимой к атмосферным искажениям и артефактам датчиков, характерным для спутниковых данных, что дополнительно ограничивает ее применимость в сложных сценариях.

Предложенная архитектура сочетает извлечение текстурных признаков (LBP) с многомасштабным контекстным анализом (PSPNet), обеспечивая повышение точности сегментации в условиях низкой контрастности. Добавление текстурного канала ( $B \times 1 \times H \times W$ ) позволяет явно выделять тонкие различия между нефтяной пленкой и фоном, например, уникальную текстуру узора, которая отличает серебристый оттенок пленки от солнечных бликов. Модуль пирамидального пулинга (PPM) агрегирует информацию на разных уровнях абстракции (от  $1 \times 1$  до  $6 \times 6$ ), что повышает точность сегментации как крупных разливов, так и мелких пятен, особенно в сценариях со смешанными типами загрязнений (тонкая пленка + плотные скопления нефти).

Для повышения устойчивости к шуму и вариациям освещения применяется нормализация текстурных признаков и использование Dropout в декодере, что снижает влияние атмосферных искажений и шума датчиков. Интеграция глобального контекста позволяет модели различать регулярные структуры (например, солнечные блики) и хаотичную текстуру нефтяной пленки. Вычислительная эффективность достигается за счет реализации текстурного модуля как фиксированного сверточного слоя, что снижает нагрузку по сравнению с оптимизацией skip-соединений в U-Net.

Гибридная модель LBP+PSPNet предлагает методологические инновации, заключающиеся в синтезе локальных текстурных признаков (через LBP) и глобального контекстного анализа (через PPM), что критично для разделения слабо контрастирующих объектов. В отличие от U-Net, ориентированной на медицинские изображения с высоким контрастом, модель адаптирована к специфике спутниковых данных, включая низкую контрастность, солнечные блики и шумы. Ее архитектура обладает масштабируемостью, позволяя адаптировать модель для других задач экологического мониторинга (обнаружение ледяных покровов, цветения водорослей) благодаря универсальности LBP и гибкости PPM.

**7. Выбор LBP для извлечения текстурных признаков.** Для повышения точности сегментации нефтяных разливов на спектральных изображениях дистанционного зондирования Земли в данной работе был выбран метод LBP. Этот выбор обусловлен спецификой задачи, включающей низкую контрастность между загрязнениями и фоном, а также необходимость эффективного извлечения локальных текстурных характеристик, характерных для нефтяной пленки. Ниже представлены ключевые аргументы в пользу применения LBP по сравнению с альтернативными методами, такими как HOG (Histogram of Oriented Gradients) и SIFT (Scale-Invariant Feature Transform), подкрепленные ссылками на научные исследования.

**7.1. Эффективность извлечения локальных текстур.** Нефтяные разливы на спутниковых изображениях часто проявляются в виде тонких пленок с неоднородной текстурой, которая определяется взаимодействием нефти с поверхностью воды и атмосферными условиями (например, солнечными бликами). Метод LBP, основанный на сравнении яркости центрального пикселя с его окрестностью, позволяет точно кодировать такие локальные паттерны [25]. В отличие от HOG, фокусирующегося на градиентах ориентации для выделения краев [26], и SIFT, ориентированного на обнаружение масштабно-инвариантных ключевых точек [27], LBP напрямую моделирует микротекстуры, что критически важно для разделения слабоконтрастных участков разлива и фона.

**7.2. Вычислительная легкость и интеграция в нейросетевую архитектуру.** LBP реализуется через простые операции сравнения и свертки, что делает его вычислительно эффективным [25]. В рамках предложенной модели LBP модулирован как сверточный слой с фиксированными весами, что позволяет интегрировать его в конец-в-конец обучение без значительного увеличения вычислительной нагрузки. Напротив, HOG требует вычисления градиентов и построения гистограмм на блоках изображения, а SIFT — детекции и описания ключевых точек, что значительно замедляет обработку больших спутниковых сцен [26]. Кроме того, HOG и SIFT обычно применяются как ручную построенные LBP-признаки, тогда как LBP легко адаптируется под требования глубокого обучения [28].

**7.3. Устойчивость к изменениям освещения.** Спутниковые изображения часто содержат артефакты, такие как солнечные блики и облачные покровы, которые создают неравномерное освещение. LBP демонстрирует устойчивость к монотонным изменениям яркости, так как оперирует относительными значениями пикселей в локальной окрестности [29]. HOG и SIFT, напротив, чувствительны к таким перепадам: градиенты в HOG могут быть искажены, а ключевые точки SIFT — потеряны из-за насыщения пикселей в областях с высокой яркостью [26, 27].

**7.4. Совместимость с контекстным анализом PSPNet.** Модуль LBP дополняет PPM, обеспечивая детализацию локальных текстур, которые PPM может упускать из-за агрегации информации на разных масштабах. HOG и SIFT, будучи ориентированными на глобальные структуры (края и объекты), менее эффективно взаимодействуют с пирамидальным анализом, так как их признаки не всегда коррелируют с иерархическими контекстуальными зависимостями, извлекаемыми PPM.

Метод LBP был выбран как оптимальное решение для извлечения текстурных признаков в задаче сегментации нефтяных разливов. Его способность эффективно кодировать локальные паттерны, совместимость с глубокими архитектурами и устойчивость к шумам и перепадам освещения делают его предпочтительным по сравнению с HOG и SIFT, особенно в сложных условиях дистанционного зондирования Земли [25, 29, 30].

**8. Обучение модели.** Для обучения гибридной архитектуры LBP+PSPNet использовался датасет спутниковых изображений дистанционного зондирования Земли, предварительно преобразованный к разрешению  $512 \times 512$  пикселей. Для расширения вариативности выборки применялись аугментации: случайное горизонтальное и вертикальное отражение, повороты на  $90^\circ$ , а также добавление гауссова шума с параметром  $\sigma=0.01$ , имитирующего атмосферные искажения. Эти меры позволили повысить устойчивость модели к реальным условиям съемки, таким как облачность и солнечные блики.

Оптимизация модели проводилась с использованием AdamW-оптимизатора с начальным темпом обучения  $10^{-4}$ . Обучение выполнялось на мини-пакетах размером 16 образцов в течение 50 эпох. Для компенсации дисбаланса классов (фон vs нефтяные разливы) в функцию потерь CrossEntropyLoss были введены весовые коэффициенты, пропорциональные частоте встречаемости каждого класса в обучающей выборке. Регуляризация осуществлялась через Dropout-слой (0.1) в декодере и Weight Decay ( $10^{-5}$ ), что позволило снизить риск переобучения.

Анализ графика функции потерь (рис. 3) показал стабильное снижение значений на обучающей и валидационной выборках, что свидетельствует о корректной сходимости модели. Разница между трениро-




Рис. 3. График функции потерь

Fig. 3. Graph of the loss function



точной и валидационной потерями не превышала 2%, что подтверждает эффективность выбранных мер регуляризации.

**9. Метрики оценки качества.** Введем следующие обозначения:  $TP$  (*True Positive*),  $TN$  (*True Negative*),  $FP$  (*False Positive*),  $FN$  (*False Negative*) — количество истинно положительных, истинно отрицательных, ложно положительных и ложно отрицательных предсказаний соответственно. Для количественной оценки производительности модели применялись следующие метрики:

1. *Precision* — доля истинно положительных предсказаний среди всех положительных:

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

2. *Recall* — доля истинно положительных предсказаний среди всех реальных положительных:

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

3. *F1-score* — гармоническое среднее *Precision* и *Recall*:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}.$$

4. *IoU* (*Intersection over Union*) — мера точности сегментации:

$$IoU = \frac{TP}{TP + FP + FN}.$$

5. *DiceLoss* — функция потерь, основанная на коэффициенте Серенсена–Дайса:

$$DiceLoss = 1 - \frac{2TP}{2TP + FP + FN}.$$

**10. Результаты модели.** Результаты, достигнутые моделью LBP+PSPNet на тестовом датасете, представлены в табл. 1.

Анализ визуальных результатов (рис. 4) демонстрирует высокую точность сегментации: модель корректно выделяет границы нефтяных разливов даже в условиях низкой контрастности между пленкой и морским фоном.

Сравнение с базовыми архитектурами показало (табл. 2), что интеграция LBP в PSPNet повысила метрики IoU на 4.6% и F1-score на 3.9% по сравнению с оригинальной PSPNet. Особенно значимый прирост наблюдается в сценариях с низкой контрастностью, где текстурные признаки LBP компенсируют недостаток спектральной информации. Модель LBP+U-Net также демонстрирует улучшение по сравнению с U-Net, однако уступает LBP+PSPNet из-за ограниченного контекстного анализа.

Таблица 1. Результаты модели LBP+PSPNet на тестовых данных

Table 1. Results of the LBP+PSPNet model on test data

Metric	Value, %
<i>IoU</i>	82.78
<i>DiceLoss</i>	89.11
<i>F1-score</i>	85.23

Таблица 2. Сравнение моделей на тестовых данных

Table 2. Comparison of models on a test data

Model	<i>IoU</i> , %	<i>F1-score</i> , %
U-Net	74.5	79.5
PSPNet	78.2	81.3
LBP+U-Net	79.9	80.8
LBP+PSPNet	<b>82.8</b>	<b>85.2</b>



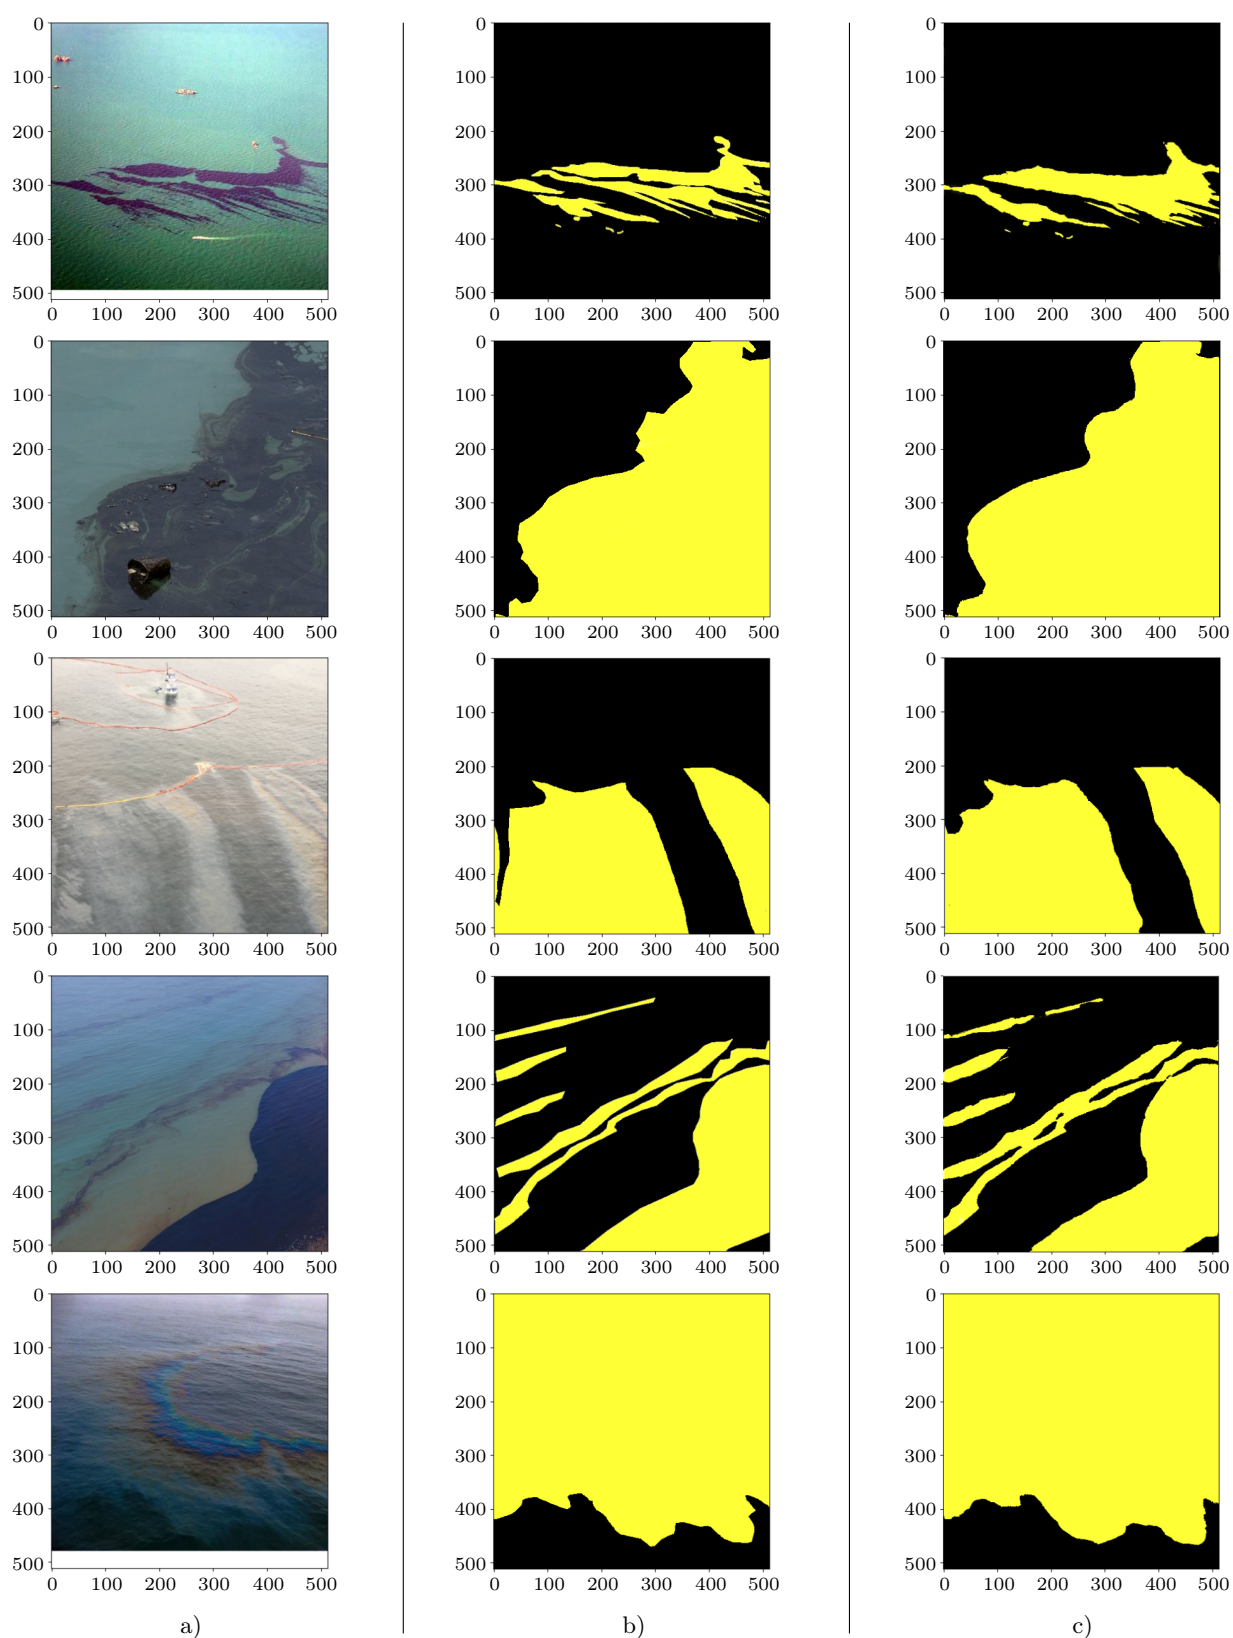


Рис. 4. Результаты модели LBP + PSPNet на тестовых данных: а) входное изображение; б) маска изображения; в) результаты сегментации. Черным цветом показана вода, желтым — нефть

Fig. 4. Results of LBP + PSPNet model on test data: a) input image; b) image mask; c) segmentation results. Black color shows water, yellow color shows oil

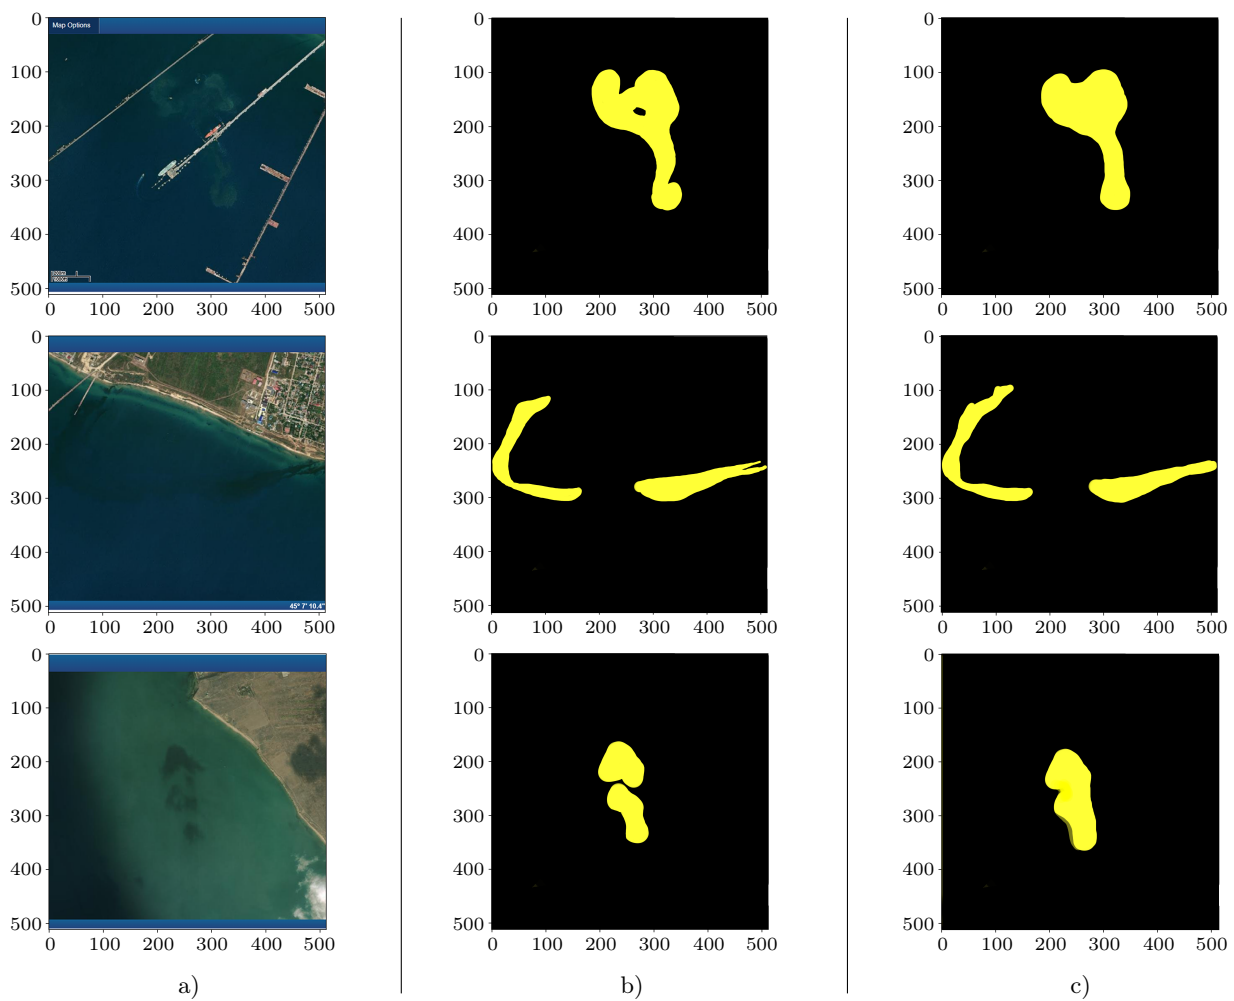


Рис. 5. Результаты модели LBP+PSPNet и PSPNet на реальных данных загрязнения в Керченском проливе (24.12.2024): а) входное изображение; б) результат LBP+PSPNET; в) результат PSPNet. Черным цветом показана вода, желтым — нефть

Fig. 5. Results of LBP+PSPNet and PSPNet models on real pollution data in the Kerch Strait (24.12.2024): a) input image; b) LBP+PSPNET result; c) PSPNet result. Black color shows water, yellow color shows oil

Результаты на реальных данных (Керченский пролив, 24.12.2024; рис. 5) подтверждают практическую применимость модели. В отличие от PSPNet (рис. 5 в), LBP+PSPNet (рис. 5 б) точнее воспроизводит форму и размер загрязнения, исключая ложные срабатывания на облачных покровах и волновых структурах. Разница в  $IoU$  (4.6%) указывает на важность синтеза локальных текстурных паттернов и глобального контекста для анализа сложных сцен.

Эти данные подтверждают гипотезу о том, что гибридная архитектура LBP+PSPNet обеспечивает устойчивую сегментацию нефтяных разливов на RGB-снимках, даже при наличии атмосферных искажений и слабой визуальной выраженности загрязнений.

**11. Заключение.** Предложенная модель LBP+PSPNet демонстрирует высокую эффективность в сегментации нефтяных разливов на RGB-снимках дистанционного зондирования, особенно в сложных условиях минимальной контрастности между загрязнениями и фоном. Интеграция текстурных признаков через LBP позволяет модели явно выделять уникальные узоры нефтяной пленки, которые U-Net и другие одноуровневые архитектуры упускают из-за фокусировки на спектральных данных RGB. Модуль PPM обеспечивает устойчивость к солнечным бликам и перекрытиям типов загрязнений за счет иерархического анализа контекста. Эксперименты показали, что модель достигает  $IoU$  82.8% и  $F1$ -меры 85.2%, превосходя базовые методы на 4–7%. Вычислительная легкость LBP открывает перспективы для

оперативного экологического мониторинга. В дальнейшем планируется адаптация модели для обработки мультиспектральных данных и интеграция с реальными системами предупреждения о чрезвычайных ситуациях.

### Список литературы

1. Beyer J., Trannum H.C., Bakke T., et al. Environmental effects of the Deepwater Horizon oil spill: a review // *Marine Pollution Bulletin*. 2016. **110**, N 1. 28–51. doi [10.1016/j.marpolbul.2016.06.027](https://doi.org/10.1016/j.marpolbul.2016.06.027).
2. Farrington J.W. Oil pollution in the marine environment II: fates and effects of oil spills // *Environment: Science and Policy for Sustainable Development*. 2014. **56**, N 4. 16–31. doi [10.1080/00139157.2014.922382](https://doi.org/10.1080/00139157.2014.922382).
3. Bui N.A., Oh Y., Lee I. Oil spill detection and classification through deep learning and tailored data augmentation // *International Journal of Applied Earth Observation and Geoinformation*. 2024. **129**, N 3–4. Article Number 103845. doi [10.1016/j.jag.2024.103845](https://doi.org/10.1016/j.jag.2024.103845).
4. Pangilinan M.N., Anacan R., Garcia R. Design and development of an oil spill detection and transmission system using artificial illumination using LEDs // *Proceedings of the 2016 7th International Conference on Intelligent Systems, Modelling and Simulation (ISMS)*, Bangkok, Thailand, 2016, pp. 407–412. doi [10.1109/ISMS.2016.61](https://doi.org/10.1109/ISMS.2016.61).
5. Gershenzon O.N., Gershenzon V.E., Osheyko S.V. Integral solution for oil spill detection using SAR data // *Proceedings of the 2007 3rd International Conference on Recent Advances in Space Technologies (RAST 2007)*. 2007. 361–365. doi [10.1109/RAST.2007.4284013](https://doi.org/10.1109/RAST.2007.4284013).
6. Shin D.-W., Yang C.-S., Choi W.-J. Oil spill detection technique with automatic updating using deep learning and oil spill index // *Proceedings of the 2023 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2023)*. 2023. 4019–4022. doi [10.1109/IGARSS52108.2023.10281425](https://doi.org/10.1109/IGARSS52108.2023.10281425).
7. Ghorbani Z., Behzadan A.H. Monitoring offshore oil pollution using multi-class convolutional neural networks // *Environmental Pollution*. 2021. **289**. Article Number 117884. doi [10.1016/j.envpol.2021.117884](https://doi.org/10.1016/j.envpol.2021.117884).
8. Bondur V., Chimtdorzhiev T., Kirbizhekova I., Dmitriev A. A novel method of boreal zone reforestation/afforestation estimation using PALSAR-1,2 and Landsat-5,8 data // *Forests*. 2024. **15**, N 1. Article Number 132. doi [10.3390/f15010132](https://doi.org/10.3390/f15010132).
9. Guo H., Wei G., An J. Dark spot detection in SAR images of oil spill using segnet // *Applied Sciences*. 2018. **8**, N 12. Article Number 2670. doi [10.3390/app8122670](https://doi.org/10.3390/app8122670).
10. Pisano A., Bignami F., Santoleri R. Oil spill detection in glint-contaminated near-infrared MODIS imagery // *Remote Sensing*. 2015. **7**, N 1. 1112–1134. doi [10.3390/rs70101112](https://doi.org/10.3390/rs70101112).
11. Kitajima N., Seto R., Yamazaki D., et al. Potential of a SAR small-satellite constellation for rapid monitoring of flood extent // *Remote Sensing*. 2021. **13**, N 10. Article Number 1959. doi [10.3390/rs13101959](https://doi.org/10.3390/rs13101959).
12. Сидорякина В.В., Соломаха Д.А. Идентификация морских разливов нефти на основе нейросетевых технологий // *Computational Mathematics and Information Technologies*. 2024. **8**, № 4. 43–48. doi [10.23947/2587-8999-2024-8-4-43-48](https://doi.org/10.23947/2587-8999-2024-8-4-43-48).
13. Pan S.J., Yang Q. A survey on transfer learning // *IEEE Transactions on Knowledge and Data Engineering*. 2010. **22**, N 10. 1345–1359. doi [10.1109/TKDE.2009.191](https://doi.org/10.1109/TKDE.2009.191).
14. Kitajima N., Seto R., Yamazaki D., et al. Potential of a SAR small-satellite constellation for rapid monitoring of flood extent // *Remote Sensing*. 2021. **13**, N 10. Article Number 1959. doi [10.3390/rs13101959](https://doi.org/10.3390/rs13101959).
15. Ahmed S., ElGharbawi T., Salah M., El-Mewafi M. Deep neural network for oil spill detection using Sentinel-1 data: application to Egyptian coastal regions // *Geomatics, Natural Hazards and Risk*. 2022. **14**, N 1. 76–94. doi [10.1080/19475705.2022.2155998](https://doi.org/10.1080/19475705.2022.2155998).
16. Zhao H., Shi J., Qi X., Wang X., Jia J. Pyramid scene parsing network // *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017. 6230–6239. doi [10.1109/CVPR.2017.660](https://doi.org/10.1109/CVPR.2017.660).
17. Ojala T., Pietikäinen M., Harwood D. A comparative study of texture measures with classification based on featured distributions // *Pattern Recognition*. 1996. **29**, N 1. 51–59. doi [10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4).
18. Brekke C., Solberg A.H.S. Oil spill detection by satellite remote sensing // *Remote Sensing of Environment*. 2005. **95**, N 1. 1–13. doi [10.1016/j.rse.2004.11.015](https://doi.org/10.1016/j.rse.2004.11.015).
19. Фирсов Н.А., Подлипнов В.В., Ивлиев Н.А., Рыськова Д.Д., Пирогов А.В., Музыка А.А., Макаров А.Р., Лобанов В.Е., Платонов В.И., Бабичев А.Н., Монастырский В.А., Ольгаренко В.И., Николаев П.П., Скиданов Р.В., Никоноров А.В., Казанский Н.Л., Соифер В.А. Ансамбли спектрально пространственных сверточных нейросетевых моделей для задачи классификации типов почв на гиперспектральных изображениях // *Компьютерная оптика*. 2023. **47**, № 5. 795–805. doi [10.18287/2412-6179-CO-1260](https://doi.org/10.18287/2412-6179-CO-1260).
20. Whetten A.B., Demler H.J. Detection of multidecadal changes in vegetation dynamics and association with intra-annual climate variability in the Columbia River Basin // *Remote Sensing*. 2022. **14**, N 3. Article Number 569. doi [10.3390/rs14030569](https://doi.org/10.3390/rs14030569).



21. Yekeen S.T., Balogun A.-L. Automated marine oil spill detection using deep learning instance segmentation model // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2020. **XLIII-B3-2020**. 1271–1276. doi [10.5194/isprs-archives-XLIII-B3-2020-1271-2020](https://doi.org/10.5194/isprs-archives-XLIII-B3-2020-1271-2020).
22. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // arXiv:1512.03385 [cs.CV]. 2015. doi [10.48550/arXiv.1512.03385](https://doi.org/10.48550/arXiv.1512.03385).
23. Ronneberger O., Fischer P., Brox T. U-Net: convolutional networks for biomedical image segmentation // Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015, in *Lecture Notes in Computer Science* **9351**, pp. 234–241 (2015) doi [10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28).
24. Chen Y., Sun Y., Yu W., Liu Y., Hu H. A novel lightweight bilateral segmentation network for detecting oil spills on the sea surface // Marine Pollution Bulletin. 2022. **175**, N 1. Article Number 113343. doi [10.1016/j.marpolbul.2022.113343](https://doi.org/10.1016/j.marpolbul.2022.113343).
25. Ojala T., Pietikainen M., Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2002. **24**, N 7. 971–987. doi [10.1109/TPAMI.2002.1017623](https://doi.org/10.1109/TPAMI.2002.1017623).
26. Dalal N., Triggs B. Histograms of oriented gradients for human detection // Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). 2005. **1**. 886–893. doi [10.1109/CVPR.2005.177](https://doi.org/10.1109/CVPR.2005.177).
27. Lowe D.G. Distinctive image features from scale-invariant keypoints // International Journal of Computer Vision. 2004. **60**, N 2. 91–110. doi [10.1023/B:VISI.0000029664.99615.94](https://doi.org/10.1023/B:VISI.0000029664.99615.94).
28. Bouwmans T. Traditional and recent approaches in background modeling for foreground detection: an overview // Computer Science Review. 2014. **11–12**. 31–66. doi [10.1016/j.cosrev.2014.04.001](https://doi.org/10.1016/j.cosrev.2014.04.001).
29. Brahmam S., Jain L.C., Nanni L., Lumini A. Local binary patterns: new variants and applications. Studies in computational intelligence. Berlin: Springer. 2014. doi [10.1007/978-3-642-39289-4](https://doi.org/10.1007/978-3-642-39289-4).
30. Heikkilä M., Pietikainen M. A texture-based method for modeling the background and detecting moving objects // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2006. **28**, N 4. 657–662. doi [10.1109/TPAMI.2006.68](https://doi.org/10.1109/TPAMI.2006.68).

Получена  
31 июля 2025 г.

Принята  
25 августа 2025 г.

Опубликована  
21 сентября 2025 г.

### Информация об авторах

Александр Иванович Сухинов — чл.-корр. РАН, д.ф.-м.н., профессор; Донской государственный технический университет, пл. Гагарина, 1, 344002, Ростов-на-Дону, Российская Федерация.

Денис Анатольевич Соломаха — студент, Донской государственный технический университет, пл. Гагарина, 1, 344002, Ростов-на-Дону, Российская Федерация.

### References

1. J. Beyer, H. C. Trannum, T. Bakke, et al., “Environmental Effects of the Deepwater Horizon Oil Spill: A Review,” *Marine Pollution Bulletin* **110** (1), 28–51. (2016). doi [10.1016/j.marpolbul.2016.06.027](https://doi.org/10.1016/j.marpolbul.2016.06.027).
2. J. W. Farrington, “Oil Pollution in the Marine Environment II: Fates and Effects of Oil Spills,” *Environment: Science and Policy for Sustainable Development* **56** (4), 16–31 (2014). doi [10.1080/00139157.2014.922382](https://doi.org/10.1080/00139157.2014.922382).
3. N. A. Bui, Y. Oh, I. Lee, “Oil Spill Detection and Classification through Deep Learning and Tailored Data Augmentation,” *International Journal of Applied Earth Observation and Geoinformation* **129** (3–4), Article Number 103845. (2024). doi [10.1016/j.jag.2024.103845](https://doi.org/10.1016/j.jag.2024.103845).
4. M. N. Pangilinan, R. Anacan, and R. Garcia, “Design and Development of an Oil Spill Detection and Transmission System Using Artificial Illumination Using LEDs,” in *Proceedings of the 2016 7th International Conference on Intelligent Systems, Modelling and Simulation (ISMS)*, Bangkok, Thailand, 2016, pp. 407–412. doi [10.1109/ISMS.2016.61](https://doi.org/10.1109/ISMS.2016.61).
5. O. N. Gershenzon, V. E. Gershenzon, and S. V. Osheyko, “Integral Solution for Oil Spill Detection Using SAR Data,” *Proceedings of the 2007 3rd International Conference on Recent Advances in Space Technologies (RAST 2007)*, 361–365 (2007). doi [10.1109/RAST.2007.4284013](https://doi.org/10.1109/RAST.2007.4284013).

6. D.-W. Shin, C.-S. Yang, and W.-J. Choi, “Oil Spill Detection Technique with Automatic Updating Using Deep Learning and Oil Spill Index,” *Proceedings of the 2023 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2023)*, 4019–4022 (2023). doi [10.1109/IGARSS52108.2023.10281425](https://doi.org/10.1109/IGARSS52108.2023.10281425).
7. Z. Ghorbani and A. H. Behzadan, “Monitoring Offshore Oil Pollution Using Multi-Class Convolutional Neural Networks,” *Environmental Pollution* **289**, Article Number 117884 (2021). doi [10.1016/j.envpol.2021.117884](https://doi.org/10.1016/j.envpol.2021.117884).
8. V. Bondur, T. Chimitdorzhev, I. Kirbizhekova, and A. Dmitriev, “A Novel Method of Boreal Zone Reforestation/Afforestation Estimation Using PALSAR-1,2 and Landsat-5,8 Data,” *Forests* **15** (1), Article Number 132 (2024). doi [10.3390/f15010132](https://doi.org/10.3390/f15010132).
9. H. Guo, G. Wei, and J. An, “Dark Spot Detection in SAR Images of Oil Spill Using Segnet,” *Applied Sciences* **8** (12), Article Number 2670 (2018). doi [10.3390/app8122670](https://doi.org/10.3390/app8122670).
10. A. Pisano, F. Bignami, and R. Santoleri, “Oil Spill Detection in Glint-Contaminated Near-Infrared MODIS Imagery,” *Remote Sensing* **7** (1), 1112–1134 (2015). doi [10.3390/rs70101112](https://doi.org/10.3390/rs70101112).
11. N. Kitajima, R. Seto, D. Yamazaki, et al., “Potential of a SAR Small-Satellite Constellation for Rapid Monitoring of Flood Extent,” *Remote Sensing* **13** (10), Article Number 1959 (2021). doi [10.3390/rs13101959](https://doi.org/10.3390/rs13101959).
12. V. V. Sidoryakina and D. A. Solomakha, “Identification of Marine Oil Spills Using Neural Network Technologies,” *Computational Mathematics and Information Technologies* **8** (4), 43–48 (2024). doi [10.23947/2587-8999-2024-8-4-43-48](https://doi.org/10.23947/2587-8999-2024-8-4-43-48).
13. S. J. Pan and Q. Yang, “A Survey on Transfer Learning,” *IEEE Transactions on Knowledge and Data Engineering* **22** (10), 1345–1359 (2010). doi [10.1109/TKDE.2009.191](https://doi.org/10.1109/TKDE.2009.191).
14. N. Kitajima, R. Seto, D. Yamazaki, et al., “Potential of a SAR Small-Satellite Constellation for Rapid Monitoring of Flood Extent,” *Remote Sensing* **13** (10), Article Number 1959 (2021). doi [10.3390/rs13101959](https://doi.org/10.3390/rs13101959).
15. S. Ahmed, T. ElGharbawi, M. Salah, and M. El-Mewafi, “Deep Neural Network for Oil Spill Detection Using Sentinel-1 Data: Application to Egyptian Coastal Regions,” *Geomatics, Natural Hazards and Risk* **14** (1), 76–94 (2022). doi [10.1080/19475705.2022.2155998](https://doi.org/10.1080/19475705.2022.2155998).
16. H. Zhao, J. Shi, X. Qi, X. Wang, and J. Jia, “Pyramid Scene Parsing Network,” *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 6230–6239 (2017). doi [10.1109/CVPR.2017.660](https://doi.org/10.1109/CVPR.2017.660).
17. T. Ojala, M. Pietikäinen, and D. Harwood, “A Comparative Study of Texture Measures with Classification Based on Featured Distributions,” *Pattern Recognition* **29** (1), 51–59 (1996). doi [10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4).
18. C. Brekke and A. H. S. Solberg, “Oil Spill Detection by Satellite Remote Sensing,” *Remote Sensing of Environment* **95** (1), 1–13 (2005). doi [10.1016/j.rse.2004.11.015](https://doi.org/10.1016/j.rse.2004.11.015).
19. N. A. Firsov, V. V. Podlipnov, N. A. Ivliev, et al., “Ensembles of Spectral-Spatial Convolutional Neural Network Models for Classifying Soil Types in Hyperspectral Images,” *Computer Optics* **47** (5), 795–805 (2023). doi [10.18287/2412-6179-CO-1260](https://doi.org/10.18287/2412-6179-CO-1260).
20. A. B. Whetten and H. J. Demler, “Detection of Multidecadal Changes in Vegetation Dynamics and Association with Intra-Annual Climate Variability in the Columbia River Basin,” *Remote Sensing* **14** (3), Article Number 569 (2022). doi [10.3390/rs14030569](https://doi.org/10.3390/rs14030569).
21. S. T. Yekeen and A.-L. Balogun, “Automated Marine Oil Spill Detection Using Deep Learning Instance Segmentation Model,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* **XLIII-B3-2020**, 1271–1276 (2020). doi [10.5194/isprs-archives-XLIII-B3-2020-1271-2020](https://doi.org/10.5194/isprs-archives-XLIII-B3-2020-1271-2020).
22. K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” *arXiv:1512.03385 [cs.CV]* (2015). doi [10.48550/arXiv.1512.03385](https://doi.org/10.48550/arXiv.1512.03385).
23. O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” *Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015*, in *Lecture Notes in Computer Science* **9351**, pp. 234–241 (2015). doi [10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28).
24. Y. Chen, Y. Sun, W. Yu, Y. Liu, and H. Hu, “A Novel Lightweight Bilateral Segmentation Network for Detecting Oil Spills on the Sea Surface,” *Marine Pollution Bulletin* **175** (1), Article Number 113343 (2022). doi [10.1016/j.marpolbul.2022.113343](https://doi.org/10.1016/j.marpolbul.2022.113343).
25. T. Ojala, M. Pietikainen, and T. Maenpaa, “Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns,” *IEEE Transactions on Pattern Analysis and Machine Intelligence* **24** (7), 971–987 (2002). doi [10.1109/TPAMI.2002.1017623](https://doi.org/10.1109/TPAMI.2002.1017623).
26. N. Dalal and B. Triggs, “Histograms of Oriented Gradients for Human Detection,” *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)* **1**, 886–893 (2005). doi [10.1109/CVPR.2005.177](https://doi.org/10.1109/CVPR.2005.177).
27. D. G. Lowe, “Distinctive Image Features from Scale-Invariant Keypoints,” *International Journal of Computer Vision* **60** (2), 91–110 (2004). doi [10.1023/B:VISI.0000029664.99615.94](https://doi.org/10.1023/B:VISI.0000029664.99615.94).





28. T. Bouwmans, “Traditional and Recent Approaches in Background Modeling for Foreground Detection: An Overview,” *Computer Science Review* **11–12**, 31–66 (2014). doi [10.1016/j.cosrev.2014.04.001](https://doi.org/10.1016/j.cosrev.2014.04.001).
29. S. Brahmam, L. C. Jain, L. Nanni, and A. Lumini, *Local Binary Patterns: New Variants and Applications. Studies in Computational Intelligence*. (Springer, Berlin, 2014). doi [10.1007/978-3-642-39289-4](https://doi.org/10.1007/978-3-642-39289-4).
30. M. Heikkilä and M. Pietikäinen, “A Texture-Based Method for Modeling the Background and Detecting Moving Objects,” *IEEE Transactions on Pattern Analysis and Machine Intelligence* **28** (4), 657–662 (2006). doi [10.1109/TPAMI.2006.68](https://doi.org/10.1109/TPAMI.2006.68).

*Received*  
July 31, 2025

*Accepted*  
August 25, 2025

*Published*  
September 21, 2025

### Information about the authors

*Alexander I. Sukhinov* — Corr. Member of RAS, Dr. Sci., Professor; Don State Technical University, Gagarina ploshchad', 1, 344002, Rostov-on-Don, Russia.

*Denis A. Solomakha* — Student, Don State Technical University, Gagarina ploshchad', 1, 344002, Rostov-on-Don, Russia.