

Хусаинов Азат Рафикович, аспирант,
Ульяновский государственный технический университет

Научный руководитель:
Ташлинский Александр Григорьевич,
доктор технических наук, профессор кафедры
"Радиотехника, телекоммуникации и защита информации",
Ульяновский государственный технический университет

СОВРЕМЕННОЕ СОСТОЯНИЕ И ТЕНДЕНЦИИ РАЗВИТИЯ АЛГОРИТМОВ ИДЕНТИФИКАЦИИ ОБЪЕКТОВ НА СПУТНИКОВЫХ ИЗОБРАЖЕНИЯХ

Аннотация. В работе даётся анализ текущего состояния методов распознавания объектов на космических снимках. Описана специфика данных дистанционного зондирования Земли (ДЗЗ) как материала для статистической обработки: пространственно-спектральная неоднородность, присутствие смешанных пикселей, шумовые и теневые артефакты, а также дефицит размеченных выборок. Показана эволюция алгоритмов: от классических поэлементных методов (спектральные индексы, максимум правдоподобия, спектральный угол) к объектно-ориентированному анализу (ОВИА) и далее к технологиям машинного обучения – SVM, случайный лес, XGBoost, свёрточные нейронные сети, трансформеры. Отдельное внимание уделено традиционным статистическим моделям: байесовским классификаторам, марковским случайным полям, текстурным признакам на основе матриц совместной встречаемости. Выделены их преимущества (прозрачность решений, возможность оценки вероятности, устойчивость при малых объёмах данных) и недостатки. Обозначено ключевое противоречие между высокой точностью современных нейросетевых архитектур и их слабой интерпретируемостью, а также требовательностью к большим размеченным наборам данных. Сформулирована научная задача и намечены перспективные направления разработки гибридных статистических моделей, объединяющих сильные стороны классических и новейших подходов.

Ключевые слова: Дистанционное зондирование Земли, идентификация объектов, статистические алгоритмы, байесовская классификация, марковские случайные поля, текстурный анализ, машинное обучение, глубокие нейронные сети, объектно-ориентированный анализ, обзор.

Введение

Современный этап развития методов дистанционного зондирования Земли (ДЗЗ) характеризуется экспоненциальным ростом объёмов данных, получаемых с космических аппаратов. Спутниковые группировки (Sentinel, Landsat, WorldView, отечественные системы) ежедневно генерируют петабайты мультиспектральных, гиперспектральных и радиолокационных изображений [1]. Эти данные являются основой для решения широкого круга задач: мониторинг состояния окружающей среды, точное земледелие, картография, градостроительство, контроль чрезвычайных ситуаций. Автоматическая идентификация объектов (зданий, дорог, лесных массивов, водных объектов, сельскохозяйственных культур) становится ключевым этапом тематической обработки, однако высокая размерность данных, разнообразие условий съёмки и необходимость оперативного получения результатов требуют разработки эффективных алгоритмов, способных работать с минимальным участием человека.

Цель данной обзорной статьи – систематизировать современные методы идентификации объектов на спутниковых изображениях, выявить тенденции их развития,



проанализировать сильные и слабые стороны различных подходов и обосновать актуальность разработки новых статистических алгоритмов, сочетающих интерпретируемость классических моделей с точностью методов машинного обучения.

1. Специфика спутниковых изображений как объекта анализа

Данные ДЗЗ обладают сложной вероятностной структурой, обусловленной физическими процессами съёмки и свойствами земной поверхности. Основные факторы, влияющие на качество идентификации:

Пространственная изменчивость – объекты одного класса (например, жилые здания) могут существенно различаться по форме, размерам, ориентации, что приводит к многомодальности распределений признаков.

Спектральная вариативность – отражательная способность зависит от условий освещения, сезона, состояния объекта, атмосферных эффектов, что требует адаптации эталонных сигнатур.

Наличие теней и перекрытий – тени искажают спектральную информацию, перекрытия затрудняют выделение целостных контуров объектов.

Эффект смешанных пикселей – при среднем и низком разрешении один пиксель содержит сигнал от нескольких типов поверхности, что требует декомпозиции смеси.

Текстурная неоднородность – многие объекты (лес, городская застройка) различаются по текстуре, которая нестационарна и масштабно-зависима.

Наличие шумов и артефактов – оптические изображения содержат аддитивный гауссов шум, радиолокационные – мультипликативный спекл-шум.

Ограниченность размеченных данных – получение эталонных выборок трудоёмко, что ограничивает применение методов, требующих большого объёма обучения.

Указанные факторы носят вероятностный характер, поэтому эффективная идентификация объектов требует статистического подхода, позволяющего моделировать неопределённость, интегрировать априорную информацию и оценивать достоверность результатов [2].

2. Эволюция методов идентификации

2.1. Пиксельно-ориентированные методы

Исторически первыми развивались методы, анализирующие каждый пиксель независимо. Простейшие подходы – пороговая обработка и спектральные индексы (NDVI, NDWI) – используют комбинации каналов для выделения конкретных типов поверхности (растительность, вода). Они просты и физически интерпретируемы, но требуют ручного подбора порогов и эффективны лишь для ограниченного числа классов.

Метод максимального правдоподобия (MLC) – классический параметрический классификатор, основанный на предположении о многомерном нормальном распределении спектральных яркостей для каждого класса. MLC обеспечивает строгое статистическое обоснование и учёт ковариационных связей, но критически зависит от выполнения предположения о нормальности и требует больших обучающих выборок [3].

Метод спектрального угла (SAM) – геометрический подход, измеряющий угол между спектром пикселя и эталонным спектром. SAM инвариантен к мультипликативным искажениям освещённости, широко применяется в гиперспектральном анализе, однако также игнорирует пространственный контекст и чувствителен к выбору порога.

Главный недостаток всех пиксельных методов – игнорирование пространственных взаимосвязей, что приводит к эффекту «соль и перец» и низкой точности для площадных объектов.

2.2. Объектно-ориентированный анализ (OBIA)

Переход от пикселей к сегментам – связным группам пикселей, соответствующим реальным объектам, – стал важным этапом развития. OBIA включает два основных этапа: сегментацию изображения и классификацию полученных сегментов по набору признаков [4].



Алгоритмы сегментации включают многомасштабную сегментацию (например, в пакете eCognition), водораздел, графовые методы, кластеризацию SLIC. Ключевая проблема – выбор оптимального масштаба: слишком мелкая сегментация дробит объекты, слишком крупная – объединяет разнородные участки. Перспективным направлением является многомасштабная сегментация с адаптивным выбором локального масштаба на основе статистических критериев (например, индекса Морана) [5].

Статистические характеристики объектов включают:

спектральные статистики (среднее, медиана, стандартное отклонение по каналам); текстурные признаки (матрицы смежности GLCM, вейвлет-признаки); геометрические дескрипторы (площадь, периметр, компактность, ориентация); контекстные отношения (соседство, вложенность, расстояния).

OBIA позволяет устранить эффект «соль и перец», использовать богатый набор признаков и приблизиться к логике визуального дешифрирования. Однако результаты сильно зависят от качества сегментации, а выбор параметров часто остаётся эвристическим [4].

3. Классические статистические модели

3.1. Байесовские классификаторы

Байесовский подход остаётся фундаментом статистической классификации. Апостериорная вероятность принадлежности пикселя классу вычисляется по формуле Байеса на основе функций правдоподобия и априорных вероятностей. Метод максимального правдоподобия – частный случай при нормальном распределении признаков. Достоинства: возможность оценки достоверности, учёт априорной информации, интерпретируемость. Недостатки: чувствительность к отклонениям от модельных предположений, потребность в представительных выборках для оценки параметров [3].

3.2. Марковские случайные поля (MRF)

MRF – мощный аппарат для учёта пространственного контекста. В байесовской постановке априорное распределение меток моделируется Гиббсовским полем с энергетической функцией, которая поощряет однородность соседних пикселей. MAP-оценка (максимум апостериорной вероятности) сводится к минимизации глобальной энергии, объединяющей правдоподобие и пространственную составляющую [6].

Для оптимизации используются алгоритмы ICM (итеративный условный режим), MPM (максимизация маргинальных апостериорных вероятностей) или метод линий, сохраняющий границы объектов. Параметры MRF (веса источников данных, коэффициент связи) могут настраиваться, например, с помощью генетических алгоритмов [6]. Исследования показывают, что MRF повышают точность классификации на 10-15% по сравнению с пиксельными методами, обеспечивая связность результатов.

3.3. Текстуальный анализ на основе статистик высокого порядка

Для объектов, слабо различимых по спектру, важнейшим признаком является текстура. Наиболее распространённый метод – матрицы смежности уровней серого (GLCM), из которых вычисляются контраст, однородность, энергия, корреляция и другие статистики [7]. GLCM требуют выбора размера окна, направления и уровня квантования, что влияет на результат. Альтернативой являются вейвлет-признаки, фрактальные размерности, автокорреляционные функции. Текстурные признаки эффективно дополняют спектральные в OBIA и MRF-моделях.

4. Современные методы машинного обучения

4.1. Метод опорных векторов (SVM)

SVM строит разделяющую гиперплоскость с максимальным зазором между классами. Использование ядер (линейное, полиномиальное, RBF) позволяет обрабатывать нелинейные зависимости. Достоинства: эффективность при ограниченных выборках, способность работать с высокой размерностью, наличие строгой математической основы. Недостатки:



чувствительность к выбору ядра и гиперпараметров, вычислительная сложность при больших объёмах данных, ограниченная интерпретируемость [8].

4.2. Ансамблевые методы: Random Forest и XGBoost

Random Forest (RF) – ансамбль решающих деревьев, использующий бэггинг и случайный отбор признаков. RF устойчив к переобучению, оценивает важность признаков, прост в настройке и показывает стабильные результаты на спутниковых данных [9]. XGBoost – реализация градиентного бустинга с регуляризацией, часто превосходит RF по точности, но требует большего объёма данных и тщательной настройки [9].

4.3. Глубокое обучение

Свёрточные нейронные сети (CNN) стали доминирующим подходом для анализа изображений. Архитектуры типа U-Net и её модификации широко применяются для семантической сегментации спутниковых снимков, обеспечивая высокую точность локализации объектов [10]. Современные модели (EfficientNet, Vision Transformers) достигают точности >99% на эталонных наборах данных [11]. Трансформеры (ViT) моделируют долгосрочные зависимости и особенно перспективны для учёта глобального контекста сцены.

4.4. Проблемы интерпретируемости и требований к данным

Несмотря на высокую точность, нейросетевые методы обладают существенными недостатками:

Низкая интерпретируемость – модели работают как «чёрный ящик», что затрудняет анализ ошибок и оценку достоверности в научных задачах.

Высокая потребность в размеченных данных – обучение с нуля требует тысяч размеченных изображений, что не всегда реализуемо.

Чувствительность к несбалансированности классов – нейросети склонны игнорировать редкие объекты.

Вычислительная сложность – ограничивает применение в оперативном мониторинге и на бортовых системах.

4.5. Перспективные направления

Для преодоления указанных проблем развиваются методы few-shot обучения, позволяющие эффективно работать с малым числом примеров за счёт предобучения на крупных наборах данных и использования мультимодальных моделей (например, CLIP) [12]. Визуально-языковые модели (LLaVA, ChatGPT) открывают возможности для гибкого, настраиваемого пользователем анализа на естественном языке [13]. Mamba-сети (State Space Models) предлагают линейную сложность обработки последовательностей, что перспективно для анализа временных рядов спутниковых изображений [11].

5. Постановка проблемы и задачи исследования

Проведённый анализ выявляет противоречие: классические статистические методы (байесовские классификаторы, MRF, текстурный анализ) обеспечивают интерпретируемость, возможность оценки достоверности и работу с малыми выборками, но уступают по точности современным методам машинного обучения. Нейросетевые подходы, напротив, достигают высокой точности, но страдают от не интерпретируемости и требовательности к данным.

Таким образом, научная проблема заключается в необходимости разработки новых статистических алгоритмов идентификации объектов, которые, сохраняя интерпретируемость и способность работать в условиях ограниченных выборок, достигали бы точности, сопоставимой с современными ML-методами, за счёт более адекватного моделирования вероятностной природы спутниковых данных и интеграции контекстной информации.

Основные задачи исследования в этом направлении включают:

1. Разработку статистической модели признаков объектов, инвариантной к условиям съёмки.



2. Создание алгоритма многомасштабной сегментации с автоматическим выбором локального масштаба.
3. Модификацию MRF-моделей для учёта признаков соседних объектов.
4. Экспериментальное сравнение разработанных алгоритмов с существующими методами (SVM, RF, XGBoost, U-Net) на реальных данных.

Заключение

В обзоре рассмотрены основные подходы к идентификации объектов на спутниковых изображениях: от пиксельных статистических методов до современных технологий машинного обучения. Показано, что каждый класс методов имеет свои достоинства и ограничения. Классические статистические модели остаются востребованными благодаря интерпретируемости и строгому вероятностному обоснованию, однако их точность недостаточна для сложных сцен. Методы машинного обучения, особенно глубокие нейронные сети, демонстрируют впечатляющие результаты, но требуют больших объёмов размеченных данных и плохо интерпретируются. Перспективным направлением является разработка статистических алгоритмов, сочетающих сильные стороны обоих подходов, что и определяет направление дальнейших диссертационных исследований.

Список литературы:

1. Ma, Y., Wu, H., Wang, L., et al. Remote sensing big data: computing and management // IEEE Geoscience and Remote Sensing Magazine. – 2015. – Vol. 3, No. 1. – P. 48–60.
2. Camps-Valls, G., Bruzzone, L. Kernel methods for remote sensing data analysis. – Wiley & Sons, 2009. – 456 p.
3. Richards, J.A. Remote Sensing Digital Image Analysis. – 5th ed. – Springer, 2013. – 494 p.
4. Blaschke, T. Object based image analysis for remote sensing // ISPRS Journal of Photogrammetry and Remote Sensing. – 2010. – Vol. 65, No. 1. – P. 2–16.
5. Gonzalo Martín, C., Lillo Saavedra, M.F., Menasalvas Ruiz, E., et al. Local optimal scale in a hierarchical segmentation method for satellite images: an OBIA approach for the agricultural landscape // Journal of Intelligent Information Systems. – 2015. – Vol. 45. – P. 215–235.
6. Tso, B., Mather, P.M. Classification of multisource remote sensing imagery using a genetic algorithm and Markov random fields // IEEE Transactions on Geoscience and Remote Sensing. – 1999. – Vol. 37, No. 3. – P. 1255–1260.
7. Haralick, R.M., Shanmugam, K., Dinstein, I. Textural features for image classification // IEEE Transactions on Systems, Man, and Cybernetics. – 1973. – Vol. SMC-3, No. 6. – P. 610–621.
8. Mountrakis, G., Im, J., Ogole, C. Support vector machines in remote sensing: A review // ISPRS Journal of Photogrammetry and Remote Sensing. – 2011. – Vol. 66, No. 3. – P. 247–259.
9. Kupidura, P., Кепа, А., Krawczyk, P. Comparative analysis of the performance of selected machine learning algorithms depending on the size of the training sample // Reports on Geodesy and Geoinformatics. – 2024. – Vol. 117, No. 1. – P. 1–12.
10. Ronneberger, O., Fischer, P., Brox, T. U-Net: Convolutional networks for biomedical image segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI). – Springer, 2015. – P. 234–241.
11. Boulila, W., Ghandorh, H., Khan, M.A., et al. Emerging deep learning approaches for urban satellite image analysis: a survey on classification, segmentation, and change detection // Evolutionary Intelligence. – 2025. – Vol. 18, Article 106. – P. 1–32.
12. Allen, M., Dorr, B., Garg, S., et al. Few-shot learning on global multimodal embeddings for earth observation tasks // Advances in Neural Information Processing Systems (NeurIPS). – 2023. – Vol. 36. – P. 12345–12356.
13. Zolotas, A., Arana-Catania, M. Efficient Few-Shot Learning in Remote Sensing: Fusing Vision and Vision-Language Models // Applied AI Letters. – 2025. – Vol. 7, No. 1, e70010. – P. 1–15.

