

25. Gehrman S., Strobelt H., & Rush A.M. GLTR: Statistical detection and visualization of generated text, *In Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, 2019, July, pp. 111-116.
26. Hans A., Schwarzschild A., Cherepanova V., Kazemi H., Saha A., Goldblum M., Geiping J., and Goldstein T. Spotting LLMs With Binoculars: Zero-Shot Detection of Machine-Generated Text, *In International Conference on Machine Learning*, 2024, pp. 17519-17537. PMLR.
27. Zhang S., Song Y., Yang J., Li Y., Han B., and Tan M. Detecting Machine-Generated Texts by MultiPopulation Aware Optimization for Maximum Mean Discrepancy, *In The Twelfth International Conference on Learning Representations*, 2024.

Румянцев Константин Евгеньевич – Южный федеральный университет; e-mail: rke2004@mail.ru; г. Ростов-на-Дону, Россия; тел.: 89281827209; кафедра информационной безопасности телекоммуникационных систем; д.т.н.; профессор; зав. кафедрой.

Котенко Владимир Владимирович – Южный федеральный университет; e-mail: kotenkovv@sfedu.ru; г. Таганрог, Россия; тел.: 89043468665; кафедра информационной безопасности телекоммуникационных систем; к.т.н.; доцент.

Хаджиева Лаура Куираевна – Грозненский государственный нефтяной технический университет имени М.Д. Миллионщикова; e-mail: laura.hadjieva3009@mail.ru; г. Грозный, Россия; тел.: 89380230505; кафедра информатики и вычислительной техники; старший преподаватель.

Rumyantsev Konstantin Yevgenievich – Southern Federal University; e-mail: rke2004@mail.ru; Rostov-on-Don, Russia; phone: +79281827209; the Department of Information Security of Telecommunication Systems; dr. of eng. sc.; professor; head of department.

Kotenko Vladimir Vladimirovich – Southern Federal University; e-mail: kotenkovv@sfedu.ru; Taganrog, Russia; phone: +79043468665; the Department of Information Security of Telecommunication Systems; cand. of eng. sc.; associate professor.

Khadzhieva Laura Kuyraevna – Grozny State Petroleum Technical University named after M.D. Millionshchikova; e-mail: laura.hadjieva3009@mail.ru; Grozny, Russia; phone: +79380230505; the Department of Informatics and Computer Science; senior lecturer.

УДК 004.932.2

DOI 10.18522/2311-3103-2026-3-188-208

М.А. Филонова, С.Н. Широкова

СОВРЕМЕННЫЕ МЕТОДЫ ОБРАБОТКИ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ: СИСТЕМНЫЙ АНАЛИЗ, АЛГОРИТМЫ И ПЕРСПЕКТИВЫ ПРИМЕНЕНИЯ В СТРОИТЕЛЬНОЙ ДИАГНОСТИКЕ

Актуальность исследования обусловлена ростом интереса к гиперспектральным изображениям как инструменту неразрушающего контроля строительных материалов и конструкций, а также недостаточной систематизацией современных методов их обработки. Цель работы состоит в системном анализе алгоритмов обработки HSI, выявлении их преимуществ, ограничений и перспектив применения в задачах строительной диагностики. В исследовании рассмотрены особенности гиперспектральных данных, включая высокую размерность, шумы, калибровочные погрешности, атмосферные искажения и дефицит размеченных выборок. Показана эволюция подходов от классических методов машинного обучения и ручного конструирования признаков к глубоким нейронным сетям. Проанализированы методы снижения размерности, классификаторы kNN, байесовские модели, логистическая регрессия, Random Forest, SVM и MLP, а также способы учета спектрально-пространственного контекста. Особое внимание уделено современным архитектурам глубокого обучения: 1D-, 2D- и 3D-CNN, RNN, LSTM/GRU, гибридным CNN-RNN-моделям, трансформерам и CNN-Transformer-схемам. Отдельно рассмотрены transfer learning, semi-supervised learning, self-supervised learning, few-shot learning, meta-learning и domain adaptation как способы преодоления ограниченности разметки. Выполнено сопоставление подходов по требованиям к данным, вычислительной сложности, устойчивости к шумам, способности учитывать спектральные и пространственные зависимости. Показано, что наиболее перспективными для строительной диагностики являются гибридные модели, сочетающие локальные признаки сверток, глобальный контекст внимания и

возможность дообучения на малых специализированных выборках. Работа обобщает современное состояние области и формирует основу для выбора методов обнаружения дефектов, оценки влажности, коррозии и деградации строительных конструкций. Сформулированные выводы могут использоваться при проектировании экспериментальных протоколов и выборе архитектур для последующих прикладных исследований в области мониторинга зданий.

Гиперспектральные изображения; обработка данных; машинное обучение; глубокое обучение; сверточные нейронные сети (CNN); трансформеры; классификация; снижение размерности; перенос обучения; самообучение.

M.A. Filonova, S.N. Shirobokova

MODERN METHODS OF HYPERSPECTRAL IMAGE PROCESSING: SYSTEM ANALYSIS, ALGORITHMS AND PROSPECTS FOR APPLICATION IN CONSTRUCTION DIAGNOSTICS

The relevance of this study is determined by the growing interest in hyperspectral imaging as a tool for non-destructive testing of building materials and structures, as well as by the insufficient systematization of modern methods for processing such data. The aim of the work is to provide a systematic analysis of HSI processing algorithms, identify their advantages and limitations, and determine the prospects for their application in construction diagnostics. The study examines the specific features of hyperspectral data, including high dimensionality, noise, calibration errors, atmospheric distortions, and the shortage of labeled datasets. The evolution of approaches is shown: from classical machine learning methods and manual feature engineering to deep neural networks. Dimensionality reduction methods, kNN classifiers, Bayesian models, logistic regression, Random Forest, SVM, and MLP are analyzed, along with methods for incorporating spectral-spatial context. Special attention is paid to modern deep learning architectures: 1D, 2D, and 3D CNNs, RNNs, LSTM/GRU models, hybrid CNN-RNN models, transformers, and CNN-Transformer schemes. Transfer learning, semi-supervised learning, self-supervised learning, few-shot learning, meta-learning, and domain adaptation are considered separately as ways to overcome the limited availability of labeled data. The approaches are compared in terms of data requirements, computational complexity, robustness to noise, and their ability to account for spectral and spatial dependencies. It is shown that the most promising models for construction diagnostics are hybrid models that combine local convolutional features, the global context of attention mechanisms, and the possibility of fine-tuning on small specialized datasets. The paper summarizes the current state of the field and forms a basis for selecting methods for defect detection, moisture assessment, corrosion analysis, and evaluation of degradation in building structures. The conclusions formulated in the study can be used when designing experimental protocols and selecting architectures for further applied research in the field of building monitoring.

Hyperspectral images, data processing, machine learning, deep learning, convolutional neural networks (CNN), transformers, classification, dimensionality reduction, transfer learning, self-supervised learning.

Введение. Гиперспектральные изображения (HSI) являются мощным инструментом компьютерного зрения, позволяющим получать подробную спектральную информацию о материалах сцены. В отличие от обычных RGB-изображений с тремя широкими каналами, гиперспектральная съемка предоставляет сотни узких, непрерывных спектральных полос, формируя *спектральный отпечаток* каждого пикселя [1]. Благодаря этому HSI позволяют выявлять тонкие различия в свойствах материалов, которые незаметны в видимом диапазоне, преодолевая ограничения мультиспектральных систем с дискретными диапазонами [2]. Например, объекты, выглядящие одинаково на RGB-снимке, могут быть различимы на гиперспектральном изображении по характерным особенностям отражения на определенных длинах волн [3]. Эти преимущества открывают большой потенциал применения HSI в высокоуровневых задачах – от точного картографирования земной поверхности и агромониторинга до детектирования минеральных пород и пород деревьев [3].

Особый интерес представляют гиперспектральные методы в сфере строительной диагностики и мониторинга материалов. Гиперспектральная съемка обеспечивает бесконтактный и неразрушающий контроль состояния объектов, фиксируя спектральные признаки, связанные с физико-химическими параметрами материалов [4]. Например, в работах по мониторингу бетона показано, что HSI успешно выявляют различия в спектральных характеристиках цементного камня при различном режиме твердения и гидратации, что напрямую влияет на прочность конструкций [4]. Таким образом, гиперспек-

тральные данные способны предоставить инженерам-строителям уникальную информацию о *внутреннем состоянии* материалов – влажности, наличии трещин, химических изменениях – без необходимости разрушать образцы.

Основная цель данного исследования заключается в проведении системного анализа и сравнительной оценки современных методов обработки HSI – от классических алгоритмов снижения размерности до моделей глубокого обучения и трансформерных архитектур – с целью выявления их эффективности, применимости и ограничений в задачах компьютерного зрения и инженерной диагностики строительных конструкций.

Рассматриваются как классические алгоритмы обработки HSI, так и новейшие подходы на основе глубинного обучения. Отдельное внимание уделено сравнению эффективности разных методов и их перспективам применения для автоматизированного мониторинга строительных объектов. В статье обобщены результаты исследований за 2015–2025 гг., проанализированы достоинства и недостатки методов, а также даны рекомендации по выбору оптимальных алгоритмов для практических задач.

Методика обзора. Настоящее исследование представляет собой систематический обзор методов обработки гиперспектральных изображений для решения задач классификации и сегментации, сфокусированный на применении в диагностике строительных материалов, таких как бетон, сталь и защитные покрытия. Хронологический охват анализа ограничен периодом с 2015 по 2025 год; при этом для обеспечения исторического контекста привлекались ключевые более ранние публикации.

Поиск литературы осуществлялся в электронных базах данных IEEE Xplore, Scopus, Web of Science, MDPI, Elsevier ScienceDirect и Springer. Также учитывались соответствующие препринты с платформы arXiv при условии наличия у них постоянного идентификатора DOI. Использовались следующие поисковые запросы: «классификация гиперспектральных изображений», «трехмерные сверточные и рекуррентные нейронные сети для гиперспектральных данных», «трансформеры для гиперспектральных данных», «самообучение, обучение на малом количестве примеров (few-shot обучение)», «адаптация домена для гиперспектральных данных», «гиперспектральный анализ бетона и стали».

К критериям включения публикаций относились: наличие рецензирования (или существенного научного вклада для препринтов), работа с реальными гиперспектральными изображениями либо признанными открытыми наборами данных, наличие сопоставимых метрик оценки (общая точность, усредненная точность, F-мера, каппа Коэна). Для прикладных исследований обязательной была явная релевантность изучаемым строительным материалам и условиям их эксплуатации. Из рассмотрения исключались работы, посвященные узкоспециальной спектроскопии без формирования изображений, публикации без количественных результатов, а также нерецензируемая «серая» литература, за исключением технических описаний эталонных наборов данных.

Процедура отбора включала последовательные этапы: удаление дубликатов, скрининг по заголовкам и аннотациям, полный текстовый анализ и последующую тематическую категоризацию. Выделенные категории охватывали классические методы и снижение размерности, одномерные, двумерные и трехмерные сверточные нейронные сети, рекуррентные нейронные сети и сети типа ConvLSTM, архитектуры трансформеров и гибридные модели, а также режимы обучения, включая трансферное обучение, самообучение, частичное и few-shot обучение, и адаптацию домена. Для каждой отобранной работы фиксировались архитектура модели, используемые данные, протокол валидации, метрики качества и, при наличии, вычислительные характеристики. Отдельно отмечались потенциальные риски, связанные с утечкой данных при разделении на обучающую и тестовую выборки в пределах одной сцены.

Процесс отбора в соответствии с сокращенной методикой PRISMA был следующим: на начальных этапах было идентифицировано 527 источников, после удаления дубликатов осталось 342 записи. После скрининга к полному текстовому анализу было допущено 168 работ, из которых в окончательную выборку вошло 65 исследований. Из них 44 работы были сведены в сводную таблицу. Межэкспертная согласованность на этапе отбора составила $\kappa = 0,81$. Синтез результатов проведен с учетом баланса между точностью методов, их вычислительной сложностью и объемом требуемых размеченных данных.

Особенности гиперспектральных данных. *Структура и свойства HSI.* Гиперспектральное изображение обычно представляют в виде трехмерного куба данных: две оси соответствуют пространственным координатам (строки и столбцы изображения), а третья ось – спектральному измерению, содержащему сотни полос в непрерывном диапазоне длин волн. Такое представление означает, что каждый пиксель HSI содержит **спектр отражения** объекта сцены, измеренный в узких спектральных каналах, часто от видимого до ближнего инфракрасного диапазонов [5]. В результате гиперспектральные данные крайне информативны – по сути, это набор совмещенных изображений на множестве длин волн, позволяющий проводить детальную идентификацию материалов по их спектральным «подписям» [5]. Непрерывность спектральных полос отличает HSI от мультиспектральных снимков, где обычно регистрируется лишь несколько разрозненных диапазонов; HSI предоставляют практически непрерывный спектр, что дает возможность фиксировать тонкие характеристики материалов (например, узкие линии поглощения), недоступные для мультиспектральных сенсоров [2].

Основные проблемы HSI. Высокая информативность гиперспектральных данных сопряжена с целым рядом вычислительных и алгоритмических трудностей, общая схема представлена на рис. 1.




Рис. 1. Основные проблемы HSI

Во-первых, это проклятие размерности: каждое наблюдение (пиксель) задается сотнями признаков (спектральных каналов), тогда как число доступных размеченных образцов обычно невелико [2]. Классические алгоритмы машинного обучения испытывают проблемы в таких условиях – например, методы k -ближайших соседей или логистической регрессии, работая напрямую с высокоразмерными спектральными векторами, сталкиваются с деградацией качества из-за избыточности и мультиколлинеарности данных. Для успешной классификации требуется снизить размерность или иметь очень большие обучающие выборки, что в задачах HSI обычно недостижимо [6].

Во-вторых, гиперспектральные изображения часто содержат значительный уровень шума и искажений. Узкие спектральные каналы могут иметь низкий сигнал/шум, страдать от калибровочных погрешностей и атмосферных эффектов. Это требует специальных методов предобработки и повышения устойчивости алгоритмов к шумам [6].

В-третьих, дефицит обучающих данных – типичная ситуация для HSI. Разметка пикселей гиперспектрального снимка – трудоемкий и затратный процесс, требующий либо полевых измерений, либо привлечения экспертов. Количество размеченных образцов невелико, и зачастую они представлены всего на нескольких снимках, что затрудняет обобщение модели на новые сцены [6, 7]. В совокупности, высокая размерность признакового пространства, ограниченность обучающей выборки и наличие шума формируют сложный сценарий для анализа HSI, требующий разработки особых подходов [2].

Несмотря на сложности, за прошедшие годы было сформировано несколько открытых гиперспектральных наборов данных, ставших *де-факто* стандартом для тестирования новых алгоритмов. Наиболее известны классические наборы: Indian Pines, Salinas Valley, Pavia University и Pavia Centre (город Павия), а также Cuprite (гиперспектральная сцена месторождения минералов) [7]. Например, датасет Indian Pines представляет сцену сельскохозяйственных угодий с размерами 145×145 пикселей при 220 спектральных каналах (после отсеивания шумовых полос остается ~ 200 каналов), для части пикселей известна принадлежность к 16 наземным классам.

Набор Pavia University (городская сцена) содержит изображение 610×340 пикселей, 103 спектральных признака и 9 классов (городские материалы). Salinas Valley – сцена сельхозполей (512×217 , 204 полосы, 16 классов сельскохозяйственных культур).

Эти датасеты широко использовались в литературе, однако они относительно небольшие по размеру и охватывают ограниченное число классов. Например, из ~ 21 тыс. пикселей Indian Pines только порядка 10 тыс. размечены, и то они распределены всего по 16 классам; при разделении на обучение/тест в каждом классе остаются считанные сотни образцов. Такая ситуация, когда обучение и тестирование зачастую проводятся на одном и том же снимке (соседние пиксели могут попадать и в обучение, и в тест), отчасти объясняет высокие показатели качества, декларируемые многими методами – они могут частично подстраиваться под конкретное изображение.

Осознавая ограниченность этих наборов, международное сообщество инициировало создание новых бенчмарков. Один из них – HyRANK, представленный ISPRS в 2017 г. как ответ на дефицит разнообразных гиперспектральных данных [8]. В рамках HyRANK были собраны изображения гиперспектрометра Hyperion (спутник EO-1) с пространственным охватом значительно больше, чем у Indian Pines, и 14 классами покрытий поверхности. Появление таких данных позволяет более объективно сравнивать алгоритмы и оценивать их применимость к крупномасштабным задачам.

Классические методы анализа HSI. Под классическими методами здесь подразумеваются подходы, не основанные на глубоком обучении, которые доминировали в анализе гиперспектральных данных до середины 2010-х годов. Как правило, классический конвейер обработки HSI включает предварительное сокращение размерности, извлечение признаков и применение традиционных алгоритмов классификации или кластеризации.

Снижение размерности. Чтобы преодолеть проблему высокоразмерности гиперспектральных признаков, повсеместно используются методы сокращения размерности и *обобщенного отбора признаков*. Цель – удалить избыточную и скоррелированную информацию, сохранив при этом основные различительные черты спектров. Наиболее известен метод главных компонент (PCA) – линейное ортогональное преобразование исходных спектральных признаков в новое пространство меньшей размерности, ранжированное по доле дисперсии данных [9]. Даже выделив первые несколько главных компонент, можно объяснить 85–95% вариации спектров, существенно сократив размерность без заметной потери информации. Другой распространенный линейный метод – линейный дискриминантный анализ (LDA), в котором поиск проекций оптимизируется не по общей дисперсии, а по критерию разделения известных классов [9]. LDA находит подпространство, где межклассовая вариабельность максимальна, а внутриклассовая минимальна, что повышает разделимость данных. В работе с гиперспектральными данными LDA применим, если априори известны классы материалов и необходимо сжать спектры до размерности, меньшей числа классов.

Помимо линейных подходов, активно применяются нелинейные методы снижения размерности, основанные на принципах обучения многообразий (Manifold Learning): например, *независимый компонентный анализ (ICA)* – для выделения статистически независимых компонент спектров [9], *анализ факторов (FA)* и *сингулярное разложение (SVD)* – как обобщения PCA [9], а также современные методы выявления низкоразмерной многообразной структуры данных: локально-линейное вложение (LLE), *t*-распределенное стохастическое соседнее вложение (t-SNE) и унифицированное аппроксимирование и проекция на многообразие (UMAP) [10, 11]. LLE сохраняет локальные расстояния между

близкими спектрами, формируя представление, отражающее внутреннюю кривизну многообразия спектральных признаков. *t-SNE* стремится спроецировать спектральные точки в пространство низкой размерности так, чтобы близкие точки оставались близки, а далекие – разнесены (для этого в высокоразмерном пространстве задается распределение Гаусса расстояний, а в низкоразмерном – распределение Стьюдента с "длинными хвостами"). *UMAP* – более новый алгоритм, сочетающий сохранение локальной и глобальной структуры: он строит взвешенный *k*-ближайший граф в исходном пространстве и настраивает точки проекции, минимизируя расхождение расстояний с помощью стохастического градиентного спуска. Преимущество *UMAP* – высокая скорость и способность удерживать глобальные отношения данных (например, кластеры) при больших объемах данных. На практике при анализе HSI часто применяют комбинацию методов: например, линейный PCA для грубого сжатия до нескольких десятков компонент, а затем нелинейный *t-SNE* для визуализации или кластеризации сложной структуры данных. Все перечисленные методики – PCA, ICA, LDA, LLE, *t-SNE*, *UMAP* и др. – прочно вошли в арсенал анализа гиперспектральных данных, позволяя эффективно бороться с *проклятием размерности* перед применением классификаторов.

Классификация и сегментация. После этапа извлечения признаков или сокращения размерности применяется собственно метод классификации либо сегментации изображения на однородные области. К числу популярных алгоритмов относятся несколько методов. На рис. 2 показана дискретная тепловая карта соответствия классических методов классификации HSI выбранным критериям: по строкам – методы (kNN, Наивный Байес, логистическая регрессия, Random Forest, SVM, неглубокие MLP), по столбцам – критерии (малые выборки, нелинейные границы, интерпретируемость, устойчивость к шуму, скорость применения, снижение размерности, пространственный контекст). Значения в ячейках кодируются числами –1 / 0 / 1 (соответственно: «обычно не подходит», «зависит от условий», «обычно подходит») и окрашены в темно-/средне-/светло-серый для наглядности; числа продублированы внутри ячеек.



Рис. 2. Дискретная тепловая карта соответствия классических методов классификации HSI выбранным критериям

Метод *k*-ближайших соседей (*kNN*). Один из простейших методов: класс пикселя определяется по большинству среди *k* ближайших обучающих примеров в пространстве признаков. Для гиперспектральных данных *kNN* использует полные спектральные векторы (или их сжатые представления) и страдает от высокой размерности, но при должном сокращении признаков работает достаточно быстро и даёт приемлемые оценки, особенно при небольшом числе классов. Его преимущество – простота и отсутствие параметров, а также высокая скорость на этапах применения; недостаток – чувствительность к нерепрезентативности обучающей выборки и шумам [12].

Байесовские классификаторы (например, наивный байесовский) и логистическая регрессия. Эти методы предполагают определенную вероятностную модель данных. В гиперспектральной классификации они применимы, если спектральные признаки поддаются нормализации и удовлетворяют предположениям модели (например, многомер-

ное нормальное распределение классов). Байесовский подход и логистическая регрессия хорошо работают при *линейно разделимых* классах и часто используются в качестве бенчмарка. Их эффективность падает, если классы сложно разделить в исходном спектральном пространстве без учета нелинейных границ [13].

Деревья решений и ансамбли деревьев. Деревья решений рекурсивно расщепляют пространство признаков на основе пороговых правил, стремясь максимизировать чистоту классов в листьях. Для гиперспектральных данных деревья привлекательны способностью обрабатывать непрерывные признаки и совмещать спектральные и пространственные атрибуты. Одно дерево, впрочем, нестабильно и склонно к переобучению; гораздо лучше показал себя ансамблевый метод [14]. Случайный лес (Random Forest) – это ансамблевый метод, объединяющий прогнозы множества решающих деревьев, обученных на различных подвыборках признаков. Данный алгоритм успешно применяется для классификации гиперспектральных изображений, демонстрируя высокую точность и устойчивость к шумам благодаря процедуре усреднения прогнозов отдельных деревьев. Его ключевыми преимуществами являются способность эффективно работать с высокоразмерными данными, автоматический выбор информативных признаков на каждом узле разбиения, а также высокая степень распараллеливания вычислительного процесса. Как отмечалось в классических обзорах, деревья и леса эффективно классифицируют гиперспектральные пиксели, учитывая интенсивности множества спектральных каналов одновременно [15].

Метод опорных векторов (SVM). Это, пожалуй, самый популярный классификатор для гиперспектральных данных в 2000-х и начале 2010-х годов [16]. SVM ищет оптимальную гиперплоскость, разделяющую классы с максимальным зазором, что обеспечивает хорошую способность к обобщению. Важное достоинство SVM – применение ядерных функций, позволяющих эффективно проводить нелинейную классификацию в исходном пространстве спектров. Алгоритм SVM для HSI оказался мало чувствителен к высокой размерности спектральных признаков и малому числу образцов, превосходя по точности ранее применявшиеся подходы [17]. Действительно, SVM способен работать в режиме малых выборок, поскольку опирается лишь на опорные вектора, и обладает сильной теоретической гарантией обобщающей способности. Даже по состоянию на конец 2010-х SVM часто выступает как базовый бенчмарк (широко используемый в сравнениях с нейросетями). К его недостаткам относят вычислительную сложность при очень больших объемах данных и необходимость подбора гиперпараметров (параметра регуляризации, типа ядра, ширины ядра и др.). Тем не менее в большинстве работ SVM фигурирует как надежный «классический» метод классификации гиперспектральных изображений.

Нейронные сети прямого распространения. Еще до эры глубокого обучения пробовали применять многослойные перцептроны (MLP) для классификации HSI, подавая на вход спектральные векторы пикселей. Небольшие сети с 1-2 скрытыми слоями могли аппроксимировать сложные границы раздела лучше, чем линейные методы [18, 19]. Однако из-за риска переобучения (большое число параметров при малом числе образцов) и отсутствия механизмов извлечения пространственных признаков, классические MLP не получили широкого распространения в гиперспектральных задачах до появления более сложных архитектур и методов регуляризации. Тем не менее уже тогда отмечалось, что нейросети способны добиваться высокой точности, поскольку обучаются непосредственному распознаванию образов спектров на основе многомерных нелинейных преобразований [20].

Спектрально-пространственные признаки. Классические алгоритмы изначально оперируют индивидуальными пикселями, учитывая только их спектры. Однако известно, что соседние пиксели на изображении, как правило, относятся к одному классу (например, растительность, здание, водная поверхность образуют связанные области). Поэтому ещё подходы, предшествовавшие глубокому обучению, стали пытаться использовать пространственный контекст для улучшения классификации [21]. Один из распространённых приёмов – рассчитывать на изображении фильтры или статистические признаки в локальных окнах и добавлять их к спектральному признаку пикселя. Например, можно посчитать среднее или дисперсию отражения в каждом канале по окрестности 3×3 вокруг пикселя и тем самым охарактеризовать локальную текстуру [21]. Более продвинутый

метод – морфологические профили: к гиперспектральному кубу применяются морфологические операции (расширение, сужение и др.) с различными структурными элементами, формируя для каждого пикселя вектор морфологических признаков, отражающих форму и размеры объектов в его окрестности; расширенные морфологические профили строятся на нескольких первых главных компонентах HSI [22]. Другой подход – марковские случайные поля (MRF) как пост-обработка: сначала каждый пиксель классифицируется по спектральному признаку (например, SVM/MLR), а затем результат сглаживается методом MRF, поощряющим однородность соседних пикселей [23]. Это значительно снижает «шум соли и перца» в карте классификации и даёт прирост точности на типичных наборах данных порядка 5–10 пунктов относительно чисто спектральных схем [24]. В целом, комбинация спектральных и пространственных признаков доказала свою эффективность, но требует ручного конструирования признаков или априорных предположений о пространственной структуре [21]; классические алгоритмы хуже извлекают сложные многоуровневые признаки, и их возможности по учёту контекста ограничены.

Ограничения классических подходов. Несмотря на множество разработанных методов, у традиционного подхода к анализу HSI есть принципиальные недостатки.

Во-первых, каждый его этап требует ручной настройки и экспертизы. Необходимо выбрать метод снижения размерности, определить число компонент или параметр соседства в нелинейном методе, затем подобрать оптимальный классификатор и его гиперпараметры. От исследователя требуется глубокое понимание данных, чтобы решить, какие признаки оставлять, как устранить шум и т.д. [25].

Во-вторых, классические методы зачастую не в полной мере используют всю информацию гиперспектрального куба. Разделение на этапы (сначала спектральное сжатие, потом классификация) может приводить к потере важных деталей. Например, PCA ориентирована на максимальную дисперсию, но не обязательно на лучшую разделимость классов; важные для классификации узкополосные спектральные особенности могут быть смазаны в первых главных компонентах [26].

В-третьих, при росте сложности задач (большее число классов, более разнообразные условия съемки) классические алгоритмы начинают *упираться в потолок качества*. Они имеют ограниченную модельную мощность (неглубокие модели), поэтому не всегда способны учесть тонкие нелинейные зависимости в гиперспектральных данных. Например, SVM отлично работает при небольшом числе спектрально-различимых классов, но если классы имеют сложную внутреннюю структуру или сильно пересекаются в исходном пространстве, требуются более сложные архитектуры [27].

В-четвертых, традиционные подходы чувствительны к шуму и артефактам: если данные содержат полосы с низким SNR или калибровочные погрешности, метод снижения размерности может их не отфильтровать полностью, и классификатор будет дезориентирован [28].

Подводя итог, классические методы заложили основу для анализа HSI и до сих пор применяются (особенно когда объем данных и число классов невелики), однако в сложных сценариях они начинают испытывать трудности с точностью и устойчивостью. Это стимулировало переход к более гибким и мощным методам – глубоким нейронным сетям.

Современные методы на основе глубокого обучения. С середины 2010-х годов в анализе изображений произошел рывок, связанный с развитием глубокого обучения. В гиперспектральной тематике эта тенденция проявилась чуть позже, но сегодня нейросетевые подходы уже стали основным фокусом исследований. Глубокие нейронные сети способны самостоятельно извлекать сложные признаки из данных, комбинируя спектральную и пространственную информацию, и показывают рекордные результаты в классификации HSI [10]. Рассмотрим основные архитектуры, применяемые для гиперспектральных данных: сверточные сети (CNN), рекуррентные сети (RNN) и трансформеры, а также новые парадигмы обучения моделей.

1D-CNN для спектральных данных. Одним из первых направлений было применение одномерных сверточных сетей (1D-CNN) к анализу *спектров* отдельных пикселей. Идея состоит в том, чтобы рассматривать спектральный вектор (последовательность отражений на разных длинах волн) как вход, аналогичный одномерному сигналу, и обучить

сеть выявлять в нем характерные шаблоны. 1D-CNN сканирует спектр сверточным ядром фиксированной ширины (например, охватывающим несколько соседних каналов) и учитывает фильтры, реагирующие на определенные комбинации полос – например, на резкие падения или пики, соответствующие линиям поглощения материалов. По сути, 1D-CNN автоматически выделяет информативные спектральные признаки (наборы соседних длин волн), которые помогают различать классы. Практические реализации таких сетей появились примерно в 2016–2017 гг. и показали преимущество перед чисто пиксельными методами: за счет сглаживания шума и учета корреляций между соседними полосами 1D-CNN классифицировали пиксели точнее, чем, скажем, SVM на сырых спектрах. Однако исключительно спектрального анализа недостаточно – не учитывается информация о текстуре и форме объектов на изображении. Кроме того, оказалось, что модели, использующие только спектр каждого пикселя по отдельности, существенно уступают тем, которые интегрируют пространственный контекст [29]. Исследования показывают: сети, обучающиеся на единичных спектрах (включая 1D-CNN, а также простые полносвязные сети и RNN), значительно проигрывают методам, которые рассматривают сразу регион изображения вокруг пикселя [30]. Это объяснимо, ведь без учета соседей трудно разрешить спектральные неоднозначности (разные материалы могут иметь похожие спектры, но обычно образуют различные по форме объекты).

2D-CNN для пространственных признаков. Другой подход – использовать сверточные сети по двумерному изображению, чтобы извлекать пространственные признаки гиперспектральной сцены, то есть использовать двумерные сверточные сети (2D-CNN). Поскольку HSI – это набор согласованных изображений в разных спектрах, можно агрегировать информацию из нескольких спектральных каналов и подать ее в стандартную 2D-CNN, аналогично тому, как обрабатываются RGB-картинки. Один из первых вариантов – взять лишь некоторые комбинированные спектральные каналы. Например, в работе [31] использовали первую главную компоненту гиперспектрального куба как монохромное изображение и пропустили его через сверточную сеть для выделения текстурных признаков. Такая двумерная CNN способна распознавать формы объектов, границы, паттерны на изображении – например, сеть может выучить фильтры, реагирующие на «края» полей или крыш зданий, видимые на снимке. В отличие от обычных цветных снимков, одноканальное (или трехканальное) изображение, сконструированное из HSI, теряет спектральную детализацию – фактически, 2D-CNN «видит» только обобщенную интенсивность. Поэтому чисто 2D-подход может упустить критически важные спектральные различия (скажем, два объекта могут выглядеть одинаково на первой главной компоненте, но различаются в узком инфракрасном диапазоне). Тем не менее, добавление 2D-CNN для анализа локальной окрестности доказало свою пользу: даже если на вход подавались 3–7 отобранных каналов (или PCA-компонент), сети выявляли текстурные особенности, которые улучшали классификацию по сравнению с одной спектральной информацией. Главное ограничение – правильный выбор спектральных каналов для такой сети; часто брали либо три канала (имитируя RGB), либо первые компоненты PCA. Но такой эвристический выбор не оптимален, и информация многих полос не используется полностью.

3D-CNN для спектрально-пространственного анализа. Наиболее естественным решением стало объединить оба типа сведений – и спектральные, и пространственные – в рамках единой архитектуры. Так появились трехмерные сверточные сети (3D-CNN), которые воспринимают на вход фрагмент гиперспектрального куба размером $W \times H \times B$ (небольшое окно $W \times H$ пикселей и все B спектральных полос) и используют 3D-свертки, то есть фильтры, распространяющиеся по двум пространственным и одной спектральной размерности сразу. 3D-CNN извлекает совместные спектрально-пространственные признаки – например, фильтр может откликаться на одновременное наличие определенного спектрального паттерна в пикселях, расположенных линейно (что может соответствовать краю определенного материала). Первые же работы с 3D-CNN на HSI показали прорыв в точности классификации. Так, была предложена модель, где входным «образцом» служит кубик 5×5 пикселей по 200 спектральным каналам (окно вокруг классифицируемого

пикселя) [29]. Сеть выполняла последовательность 3D-сверток, постепенно агрегируя информацию: первые слои вычленили локальные спектральные особенности в каждом пикселе, далее – более высокоуровневые признаки региона, учитывая спектральные закономерности соседних пикселей, и т.д. В рассматриваемой архитектуре вместо классического пулинга применялась сверточная операция по спектральной оси для уменьшения размерности, а финальным классификатором служила 1D-свертка по спектру [29]. Такой гибрид позволил избежать потерь информации, присущих жесткому пулингу, и задействовать максимум данных. Результаты превзошли все классические алгоритмы: 3D-CNN достигает точности 95.2-97.8% ОА на Indian Pines для различных классов и 98.1-99.3% ОА на Pavia University, что на 8-12% превышает показатели классических методов, особенно на классах с малым числом образцов, где традиционные методы сильно переобучались или не справлялись [29].

Преимущество 3D-CNN – в их автоматическом обучении оптимальных признаков. В то время как раньше исследователи вручную придумывали, как сочетать спектры и фильтры, нейросеть сама находит нужные комбинации. Например, в первом сверточном слое 3D-CNN могут выучиваться фильтры, распознающие характерные спектральные кривые в каждом пикселе, во втором – фильтры, реагирующие на контраст этих кривых между центральным пикселем и окрестными, и т.д.

На практике трёхмерные архитектуры демонстрируют рекордные показатели точности. Однако достижение таких результатов сопряжено с существенными вычислительными затратами: типичная 3D-CNN может содержать от 5 до 15 свёрточных уровней и насчитывать несколько миллионов обучаемых параметров. Для обучения модели такого масштаба требуется значительный объём размеченных данных – как правило, не менее 15–20% от общего числа пикселей в сцене. В противном случае высока вероятность переобучения.

Сегодня 3D-сверточные сети и их усовершенствования (например, *спектрально-пространственные сети* с раздельными блоками 2D- и 1D-сверток, глубинные ансамбли 3D-CNN и др.) являются одним из стандартов гиперспектральной классификации. Они эффективны в сценариях, где требуются высокоточные карты материалов и есть возможность обучения на представительной выборке.

Рекуррентные нейронные сети (RNN). *Спектральные последовательности и RNN.* Рекуррентные нейронные сети (RNN) традиционно применяются для работы с последовательными данными – текстом, аудио, временными рядами. Гиперспектральный спектр можно трактовать как последовательность значений отражательной способности, упорядоченных по возрастанию длины волны, что позволяет привлекать RNN для моделирования спектральных зависимостей [32]. В отличие от свёрточных сетей, которые используют фиксированные фильтры и локальные рецептивные поля, рекуррентные нейронные сети обходятся последовательным просмотром входных данных, обновляя своё скрытое состояние. Классическая RNN на каждом шаге принимает значение очередного канала (полосы) и обновляет внутреннюю память; после просмотра всех каналов скрытое состояние содержит «свёрнутую» информацию обо всём спектре. Прямое применение базовой RNN сталкивается с проблемами затухания/взрыва градиентов на длинных последовательностях, поэтому на практике используют сети с долгой краткосрочной памятью (LSTM) или управляемые рекуррентные блоки (GRU) [33]. LSTM включает специальные ячейки памяти и управляющие «входные/выходные/забывающие» ворота, позволяя сохранять информацию на долгих интервалах и избегать деградации обучения [33]. Проще говоря, LSTM способна запоминать важные спектральные особенности, даже если они разделены десятками узких полос, и игнорировать менее значимые вариации спектра.

Применение LSTM к спектрам пикселей было активно исследовано с 2017 г. и далее: пиксель рассматривался как последовательность, и LSTM обучали предсказывать его класс по значениям отражения от первой до последней полосы [34], см. также улучшения с рекуррентно-свёрточными и двунаправленными вариантами [35, 36]. Выяснилось, что LSTM действительно моделирует дальние спектральные зависимости: для материалов с «разнесёнными» спектральными признаками это даёт выигрыш по сравнению с простыми 1D-CNN и MLP [36], а включение пространственного контекста в спектрально-пространственных LSTM дополнительно повышает точность [35].

Гибриды CNN–RNN. Хотя RNN эффективно анализирует последовательности, ей не хватает учёта пространственного контекста. Логичным шагом стало комбинировать свёрточные и рекуррентные сети: CNN извлекает локальные пространственные признаки, а RNN – спектральные зависимости [37]. Существует несколько вариантов таких гибридных архитектур. В одном подходе сначала из окрестности пикселя извлекаются пространственные признаки (например, 3D-CNN по спектрально-пространственным патчам), после чего последовательность спектральных «срезов» обрабатывается моделью ConvLSTM/GRU, что позволяет учитывать длинные зависимости по спектру [38]. Другой подход – двухэтапный: отдельная CNN формирует компактные спектрально-пространственные представления, а затем двунаправленная LSTM бежит по спектральной оси, уточняя классификацию [39]. Экспериментально показано, что такие CNN–RNN-гибриды превосходят сопоставимые по глубине чисто CNN-модели при задачах, где важны дальние спектральные связи; при этом модель ConvLSTM/Bi-LSTM помогают удерживать глобальные спектральные шаблоны без потери локальной структуры [39, 40].

Трансформеры. Трансформеры – модели на механизме самовнимания – изначально разрабатывались для последовательностей и затем были адаптированы для зрения. В Vision Transformer (ViT) изображение режется на патчи (например, 16×16), которые подаются в трансформер, где матрицы внимания связывают любые участки изображения, обеспечивая учёт глобального контекста. ViT показал, что трансформеры соперничают с глубокими CNN при обучении на масштабных датасетах; при этом отсутствие индуктивных ограничений (типа трансляционной инвариантности) ведет к переобучению на малых выборках. Успех ViT стимулировал исследования трансформеров для работы с гиперспектральными данными [41, 42].

В HSI патчи содержат десятки/сотни спектральных каналов, поэтому механизм self-attention становится ресурсоёмким и обычно требует спектрального сжатия или группировки. Ранние специализированные варианты моделей включают подход HSI-BERT, переносящий идеи BERT на HSI-классификацию [43]; последующие работы отмечали устойчивый прирост точности относительно CNN-базовых базовых линий (на единицы процентов) у трансформерных архитектур, например у MSTNet [44]. SpectralFormer достигает 99.46% на отдельных классах на Pavia University, что на 2.3-3.7% выше CNN-аналогов [3]. Прямая адаптация ViT к HSI использует 2D-свёртки для уменьшения пространственного размера перед подачей патчей, но слабее учитывает спектральные корреляции [45]. Более прогрессивные спектрально-пространственные трансформеры, такие как S2Former, явно разделяют обработку по спектральной и по пространственной осям, что помогает одновременно ловить дальние зависимости в спектрах и глобальные связи между объектами [46].

Чистые трансформеры хорошо моделируют глобальные связи, но хуже извлекают мелкие локальные признаки, которые эффективно ловят свёртки; поэтому активно развиваются гибриды CNN–Transformer [47, 48, 49]. Пример – DBCTNet с параллельными ветвями свёрток и трансформера [50]. Также предлагаются 3D-CNN–Transformer-модели, где 3D-свёртки извлекают локальные спектрально-пространственные признаки, а механизм self-attention связывает удалённые регионы [51]. В целом гибридные архитектуры демонстрируют высокую точность (в задачах классификации и сверхразрешения), совмещая устойчивость свёрток к шумам с глобальным контекстом трансформеров [52].

Специализированные трансформеры для HSI. В гиперспектральных изображениях есть два естественных измерения, по которым можно применять механизмы внимания: спектральное и пространственное. Появился ряд работ, предлагающих адаптировать архитектуру трансформера под трехмерный характер HSI. Один из подходов – SpectralFormer [3]. В этой модели гиперспектральный пиксель трактуется как последовательность спектральных признаков, и трансформер обучается извлекать из этой последовательности информативное представление [3]. Авторы отметили, что классические трансформеры оперируют «плоскими» эмбедингами для каждого канала, игнорируя локальную группировку спектральных полос [3]. Работа модели SpectralFormer основывается на формировании групповых спектральных эмбедингов: разбиении спектра на группы соседних полос и использовании их как единицы внимания, благодаря чему становится возможным сохранить локальный спектральный контекст. Кроме того, был вве-

ден механизм кросс-слоного обучения (skip connections), переносящий «память» из нижних слоев трансформера в верхние, чтобы уменьшить потери информации при последовательной многослойной обработке. Модель SpectralFormer сумела достичь заметного прироста точности по сравнению с прежними трансформерными подходами и даже превзошел глубокие CNN на ряде наборов данных, показав примерно 2–5% улучшения по общей точности классификации [3]. Существенно, что SpectralFormer обучался без использования сверточных или рекуррентных блоков, то есть чисто attention-архитектура справилась с задачей классификации, что было первым подтверждением жизнеспособности трансформеров для HSI [3].

Другой пример – HyperSpectral Transformer и гибриды на его основе. Некоторые работы комбинируют идеи: например, используют 2D-свёртки для уменьшения размерности и получения патчей, а затем применяют трансформер по пространственным позициям. Так, модель HSI-ViT (первая прямая адаптация Vision Transformer) работает с гиперспектральным снимком как с набором патчей, но каждый патч представлен не тремя каналами, а полным спектром [45]. Такой трансформер мог глобально моделировать отношения между разными областями изображения, но едва ли учитывал спектральные корреляции. Поэтому более прогрессивные модели – спектрально-пространственные трансформеры – содержат два ветвления: одно ветвление применяет слои самовнимания по спектральной оси (для каждого пикселя, связывая разные длины волн), другое – по пространственной (между пикселями или патчами). Например, архитектура SST (Spectral-Spatial Transformer) использует каскад: сначала спектральный трансформер обрабатывает каждый пиксель (его спектр) и выдает сжатое спектральное представление, затем пространственный трансформер обменивается информацией между этими представлениями соседних пикселей по изображению [53]. Такой двухуровневый трансформер способен одновременно улавливать длинноволновые зависимости в спектрах и дальнедействующие пространственные взаимосвязи между объектами. Результаты демонстрируют высокую точность классификации, особенно на сложных сценах, где присутствуют как спектрально близкие классы, так и классы, различимые только по текстуре [54].

Гибриды CNN-Transformer. Несмотря на потенциал трансформеров, исследования показывают, что полностью трансформерные сети могут упускать локальные детали, которые успешно ловят сверточные фильтры [3]. Трансформер хорошо моделирует глобальные зависимости (например, учет отдаленные связи спектральных полос или удаленных регионов изображения), но у него нет «врожденного» механизма фокусироваться на маленьких локальных признаках (края, мелкие особенности спектра) [55]. Поэтому возник тренд на гибридные архитектуры, совмещающие сверточные и трансформерные слои. В таких моделях CNN отвечает за извлечение базовых локальных признаков (временами ее даже называют «*локальным encoder*»), а трансформер оперирует уже более абстрактными признаками, устанавливая между ними дальние связи. Пример – модель HyFormer для сверхразрешения HSI, но ее подход показателен и для классификации: HyFormer содержит две параллельные ветви – широкую CNN и трансформер, причем трансформер обеспечивает взаимодействие между спектральными каналами, улавливая тонкие детали в каждом спектре, а CNN обеспечивает непрерывность пространственных структур и сглаживает шум [55]. Авторы прямо отмечают, что HyFormer «*объединяет сильные стороны CNN и трансформера*»: ветвь трансформера осуществляет внутриспектральное взаимодействие (capturing fine-grained spectral details), а ветвь CNN – извлечение признаков в широкой окрестности, сохраняя целостность форм [55].

Для задач классификации разрабатываются схожие гибриды: 3D-CNN – Transformer (3D-CmT), где 3D-свёртки сначала агрегируют локальные спектрально-пространственные признаки, а трансформер на их основе выясняет глобальные отношения между разными частями изображения [56]. Гибридный подход позволяет компенсировать взаимные недостатки: свёртки приносят инвариантность и устойчивость к мелким сдвигам/шумам, а самовнимание добавляет глобальный контекст и селективность по важности признаков. В итоге, наиболее перспективными сегодня считаются именно гибридные архитектуры для HSI, объединяющие глубокие сверточные и трансформерные блоки.

Современные парадигмы обучения. Помимо архитектурных новшеств, за последние годы появились методики, позволяющие эффективнее обучать модели на гиперспектральных данных, особенно в условиях ограниченной разметки.

Transfer learning (перенос обучения). Перенос обучения предполагает использование модели, предварительно обученной на крупном датасете (например, ImageNet), для решения задач анализа гиперспектральных изображений [57]. Общий принцип работы transfer learning представлен на рис. 3. Поскольку HSI содержат десятки и сотни спектральных каналов, исходные архитектуры (например, ResNet) адаптируются к многоканальному входу (в т. ч. через модификацию первого свёрточного слоя); показано, что низкоуровневые признаки, полученные при предобучении на RGB-изображениях, обладают достаточной универсальностью и ускоряют/улучшают обучение на HSI [58], а также в специализированных HSI-схемах с переносом (включая лёгкие 3D-CNN) [59]. Помимо этого, применяется междоменный перенос: модель сначала обучают на данных одной предметной области (например, агросцены), а затем дообучают на другой (городская среда); такие подходы реализуются как перенос глубинных спектрально-пространственных признаков или как адаптация доменов (domain adaptation) с учётом сдвигов распределений [59, 60]. На практике даже базовая инициализация весов предобученной моделью заметно улучшает сходимость и итоговую точность классификации HSI [57], а также даёт выигрыш при ограниченной разметке в сценариях переноса с RGB/HSI и между сенсорами [61]. Предложенный метод значительно превзошел ранее опубликованные лучшие результаты, улучшив общую точность классификации (Overall Accuracy) на бенчмарке UCML с 83,1% до 92,4%. Дополнительно подтверждается обобщаемость «глубоких» признаков, извлечённых на естественных изображениях, к задачам дистанционного зондирования, что объясняет эффективность предобучения на ImageNet как стартовой точки для HSI-пайплайнов [57].




Рис. 3. Принцип работы трансферного обучения

Самообучение (Self-Supervised Learning, SSL). Методы SSL нацелены на извлечение осмысленных признаков из неразмеченных данных путём решения так называемой претекстовой задачи. Для HSI классические подходы, такие как контрастивное обучение [62] или маскированное моделирование [63], требуют адаптации, поскольку их прямое применение не учитывает спектральную специфику и особенности дистанционного зондирования [64]. В качестве специализированной претекстовой задачи предлагается, например, предсказание порядка случайно перемешанных сегментов спектра (Spectral Band Permutation Prediction) [65]. Для решения этой задачи модель вынуждена изучать глобальную структуру спектральной кривой и характерные спектральные признаки материалов. Модели, обученные таким образом, при последующей тонкой настройке на небольшом количестве размеченных примеров демонстрируют высокое качество классификации: коэффициент детерминации составил 94,56% [65]. Применение SSL актуально в строительном мониторинге, так как позволяет накапливать обширные массивы неразмеченных наблюдений и в дальнейшем быстро адаптировать модель для выявления дефектов.

Semi-supervised и few-shot методы. Полуобучение (semi-supervised learning) и обучение на малом количестве примеров (few-shot learning) – это методы, предназначенные для эффективной работы при ограниченном количестве размеченных данных: первый сочетает небольшое число размеченных примеров с большим объёмом неразмеченных, а второй

решает задачу классификации новых классов всего по нескольким образцам. Распространённый приём – итеративная генерация псевдометок, когда модель постепенно добавляет в обучающую выборку свои наиболее уверенные прогнозы по неразмеченным данным; применяются и semi-supervised-свёрточные архитектуры (Semi-CNN) с регуляризацией согласованности [66], а также графовые методы, такие как распространение меток (label propagation) [67], обеспечивающее согласованность предсказаний в пространственных окрестностях. В рамках few-shot learning решается задача классификации новых классов по нескольким примерам (например, 5–10 эталонных спектров); для этого используются, в частности, прототипные сети, которые формируют опорные представления классов и относят объекты по расстоянию до этих прототипов [68]. Комбинация few-shot и самообучения дополнительно улучшает переносимость и устойчивость при дефиците разметки [69].

Таким образом, современные парадигмы обучения – перенос знаний, самообучение, полуобучение – нацелены на преодоление *фундаментального ограничения гиперспектральных данных*: небольшого объема размеченных выборок на фоне высокой сложности данных. Совмещение этих подходов с мощными архитектурами (CNN, RNN, Transformer) обеспечивает все более высокую точность анализа HSI даже в ранее тупиковых сценариях.

Сравнительный анализ методов. Современное многообразие методов обработки гиперспектральных изображений требует их сопоставления по ключевым критериям. В табл. 1 представлено обобщенное сравнение трех групп подходов – классических алгоритмов, глубоких сверточных сетей (CNN) и трансформерных моделей – с точки зрения их особенностей, достоинств и недостатков применительно к задачам гиперспектральной классификации.

Таблица 1

**Сравнение методов анализа гиперспектральных изображений
(классические, CNN и Transformer-подходы)**

Подход	Ключевая идея	Достоинства	Недостатки	Сфера применения
Классические (PCA-SVM, kNN, RF)	Ручные признаки – отдельный классификатор; обычно спектральный пиксель, контекст через пост-обработку	Работают при малых выборках; интерпретируемы; быстры в применении	«Проклятие размерности» без снижения; много ручной настройки; слабый учёт контекста; чувствительны к шуму	Пилоты, малые датасеты, быстрый базовый ориентир
Глубокие CNN (1D/2D/3D)	Автоизвлечение спектрально-пространственных признаков; локальный контекст через свёртки	Высокая точность; устойчивость к частичному шуму; естественное объединение спектра и пространства	Нужны метки (риск переобучения); локальность свёрток; ресурсоёмкость (особенно 3D); чувствительность к калибровке	Средние/крупные датасеты; производственные пайплайны
Трансформеры (ViT/SpectralFormer, гибриды)	Самовнимание, глобальные зависимости; требуется позиционное/спектральное кодирование	Глобальный контекст; гибкость; высокий потолок при предобучении/SSL	Требовательны к данным и вычислениям ($O(n^2)$); могут терять локальные детали без модификаций; тонкая настройка	Крупные датасеты или предобучение; задачи с дальними зависимостями

Как видно из табл. 1, каждая группа методов имеет свою нишу. Классические алгоритмы удобны, когда данных мало и нужно быстро получить базовый результат, либо когда важна интерпретируемость (напрямую понять, какие спектральные признаки используются). Однако их потенциал ограничен – они не извлекают высокоуровневые структуры, чувствительны к шуму и требуют ручного выбора признаков [27]. Сверточные нейронные сети стали основным подходом в гиперспектральном анализе. Они существенно повысили точность и автоматизировали выделение спектрально-пространственных шаблонов [28]. CNN обеспечивают хорошую устойчивость к шумам – например, свёртки могут

усреднять случайные флуктуации яркости по соседним каналам – и относительно просто обучаются на средних массивах данных (с аугментациями, инициализацией от ImageNet и т.д.). Их ограничение – локальный взгляд: если задача требует учесть, скажем, корреляции полос через весь спектр или сопоставить разрозненные регионы изображения, CNN приходится наращивать область восприятия или глубину, что не всегда эффективно. Трансформеры же предлагают сразу учитывать глобальные связи, что особенно ценно для гиперспектральных данных, где, к примеру, узкие спектральные особенности материалов могут появляться в далеких друг от друга участках спектра [3]. Трансформер «видит» весь спектр целиком и может концентрироваться на наиболее информативных его частях, игнорируя избыточные полосы. Это позволяет лучше работать с задачами, где много коррелированных каналов и нужен «интеллектуальный отбор» спектральных признаков – по сути, механизм самовнимания выполняет адаптивный отбор признаков, который усиливает важные спектральные полосы и подавляет малозначимые [3]. Однако плата за это – необходимость очень хорошего обучения. Без больших данных или предварительной тренировки трансформерные модели могут показывать результат хуже, чем тщательно настроенная CNN, особенно в условиях небольших выборок (что как раз частый случай в гиперспектральных приложениях) [70]. Гибридные подходы (CNN–Transformer), появившиеся совсем недавно, стремятся объединить достоинства обоих подходов: например, HyFormer успешно применяет CNN для локального сглаживания и внимания – для спектральной детализации, что обеспечивает превосходство в качестве для задач суперразрешения HSI [55]. Подобные гибриды и в классификации демонстрируют высокую точность при умеренной сложности. Существующие подходы к работе с HSI представлены на рис. 4.




Рис. 4. Подходы – масштаб и годы реализации

Результаты и их обсуждение. *Применимость к строительному мониторингу.* К задачам диагностики строительных конструкций (поиск дефектов, оценка прочности материалов, мониторинг износа) наиболее целесообразно подходить комплексно. Если имеющихся данных мало (например, гиперспектральные снимки нескольких зданий с отмеченными повреждениями), разумно начать с классических методов или простых CNN, используя перенос обучения с других доменов (например, с промышленных материалов). Для более продвинутых систем, где планируется длительный мониторинг и накопление данных, стоит закладывать глубокие модели – сверточные или гибридные CNN-Transformer. Они обещают более надежное распознавание едва заметных спектральных признаков деградации материалов (коррозия, влагосодержание, микротрещины) в шумном уличном окружении [4]. Также трансформеры могут быть полезны для *универсализации* модели под разные типы объектов: внимание может адаптивно переключаться на разные наборы спектральных признаков для бетона, металла, отделочных материалов и т.д. Однако это преимущество проявится, если модель обучена на действительно разнообразном корпусе данных. В текущей практике мониторинга, где датасеты невелики, оптимальным выглядит компромисс – использование относительно компактных 3D-CNN, возможно, с элементами внимания на спектральные каналы, обученных с применением подходов transfer learning и self-supervised на обширной неразмеченной подборке гиперспектральных наблюдений строительной инфраструктуры.

Перспективы развития и научная новизна. Анализ современных тенденций позволяет выделить ряд перспективных направлений развития методов гиперспектральной обработки изображений, обладающих высоким научным и прикладным потенциалом, особенно в контексте автоматизированного мониторинга состояния строительных объектов.

Гибридные архитектуры, комбинирующие сверточные нейронные сети (CNN) и трансформеры, демонстрируют значительный потенциал для обработки гиперспектральных изображений, эффективно преодолевая ограничения отдельных подходов. Модели, такие как DBCTNet и 3D-CmT, в которых 3D-CNN извлекают локальные спектрально-пространственные признаки, а трансформеры моделируют глобальные зависимости, показывают исключительно высокую точность (ОА до 99.88% на Salinas) даже при малой доле обучающих данных (10%). Эти решения остаются вычислительно эффективными (порядка 7.5 млн параметров) и устойчивы к спектральной вариабельности, превосходя чисто CNN и трансформерные подходы. Для строительной диагностики ключевое преимущество гибридов заключается в возможности мультисенсорной интеграции данных (HSI, LiDAR, SAR), что позволяет одновременно детектировать локальные дефекты (трещины, коррозию) и оценивать глобальное состояние конструкций, что подтверждается прикладными исследованиями по мониторингу инфраструктуры [50, 56].

Одной из ключевых проблем HSI остаётся ограниченность размеченных данных. Это особенно актуально в строительной сфере, где сложно собрать репрезентативные выборки дефектов. Перспективными являются методы метаобучения и few-shot классификации, позволяющие распознавать новые классы материалов или повреждений по нескольким примерам [70]. Комбинация с self-supervised обучением позволяет сначала выучить универсальные спектральные представления, а затем быстро адаптироваться к новой задаче с минимальным числом аннотированных данных [2].

В настоящее время активное развитие технологий гиперспектральной съёмки (ГСС) во многом сосредоточено на интеграции моделей глубокого обучения (DL), которые обеспечивают автоматизированное извлечение информативных признаков и поддержку принятия решений, что особенно важно для преодоления барьеров, связанных с высокой стоимостью оборудования и вычислительной сложностью обработки больших объёмов спектрально-пространственных данных; наиболее заметные результаты получены в медицинской диагностике и задачах классификации, где ГСС ценится за неинвазивность и отсутствие необходимости в маркировке: так, при диагностике рака сочетание ГСС и искусственных нейронных сетей позволяет различать колоректальный рак (CRC) с чувствительностью 86% и специфичностью 95%, при интраоперационном обнаружении опухолей головного мозга слияние данных в диапазонах видимого/ближнего инфракрасного (VNIR) и ближнего инфракрасного (NIR) повышает точность классификации на 21%, обеспечивая потенциал навигации в реальном времени во время операции, а в дерматологии диагностика рака кожи достигает 87% чувствительности и 88% специфичности; при этом в других прикладных областях. В сельском хозяйстве DL-модель HSI-TransUNet достигает 86,05% общей точности при идентификации типов сельскохозяйственных культур, а модель CropdocNet – 98,09% точности при автоматическом обнаружении фитофтороза картофеля, тогда как в экологическом мониторинге ГСС обеспечивает высокую результативность при оценке концентрации загрязнения PM_{2.5} (85,93% точности) и обнаружении микропластика в кишечнике рыб (точность более 96,22% и полнота более 98,80%) [5].

Помимо алгоритмических достижений, большое значение имеет технический прогресс в области сенсоров. Ожидается, что в будущем развитие миниатюрных, портативных систем ГСС и методов обработки данных в реальном времени повысит доступность технологии для полевых и промышленных приложений [5]. Это позволит проводить регулярный съём спектральных данных без сложной логистики. Совместно с нейросетевыми алгоритмами такие системы смогут осуществлять непрерывный мониторинг, выявляя изменения спектральных характеристик, указывающие на начальные стадии разрушений, например, раннюю коррозию металлоконструкций.

С ростом количества алгоритмов возрастает потребность в систематизации выбора оптимальных решений. Использование AutoML и NAS (поиск архитектур нейросетей) позволяет автоматизировать подбор моделей и их параметров для конкретных HSI-задач [70]. Это снижает требования к квалификации пользователя и повышает воспроизводимость решений, что особенно важно в инженерных приложениях.

Выводы (значимость, новизна, рекомендации). В статье представлен обзор современных методов обработки HSI с акцентом на их применение в строительной диагностике. Гиперспектральные данные, обладая высокой спектральной разрешающей способностью, позволяют идентифицировать материалы по характерным спектральным признакам, что выгодно отличает их от традиционных RGB- и мультиспектральных снимков [1]. Вместе с тем, их анализ сопряжён с трудностями: высокой размерностью, шумами, ограниченностью размеченных данных [7].

Классические методы, такие как PCA и SVM, остаются полезными в условиях ограниченного числа примеров, но уступают глубоким моделям в точности и гибкости [27]. С появлением сверточных нейросетей (CNN), особенно 3D-CNN, стало возможным автоматически извлекать спектрально-пространственные признаки, значительно повысив качество классификации [30]. Рекуррентные и трансформерные модели позволили учитывать дальние зависимости в спектре, расширяя возможности анализа [32].

Исследования демонстрируют, что нейронные сети и модели глубокого обучения превосходят традиционные классификаторы при работе со сложными HSI, обеспечивая значительно более высокую точность классификации. В ранних работах гибридный классификатор, использующий полное спектральное разрешение (194 полосы) данных для картирования 23 типов геологического покрытия, показал общую точность (OA) 88,71%, при этом превзойдя классификатор минимального Евклидова расстояния (MED), который достиг 82,04% [20]. В более современных исследованиях, направленных на решение проблемы высокой размерности и нехватки размеченных данных с помощью DL, была предложена новая модель ESFNet (Enhanced Spectral Fusion Network), которая продемонстрировала наилучшие результаты среди всех сравниваемых моделей – она достигла общей точности 96,1% с коэффициентом 0,948 на наборе данных Pavia (датасете из материалов городской среды) и [29]. Это подтверждает практическую применимость HSI в задачах неразрушающего контроля.

Для инженерного применения рекомендуется пошаговый подход: от базовых методов (PCA–SVM) к более сложным CNN и трансформерам по мере роста объема данных. Важным аспектом остаётся наличие качественных размеченных выборок и валидация моделей на новых условиях. Использование предобученных моделей и методов переноса обучения существенно снижает порог внедрения [28].

Рекомендации включают: проведение пилотных испытаний; формирование эталонных датасетов; использование полуавтоматической разметки и интерпретируемых моделей; проверку устойчивости к изменяющимся условиям.

Научная новизна представленного исследования заключается в комплексном системном анализе эволюции методов обработки HSI – от классических алгоритмов машинного обучения до современных архитектур глубокого обучения, включая гибридные CNN-Transformer модели. Проведена тематическая категоризация методов с учётом их применимости в диагностике строительных материалов, таких как бетон и сталь, что ранее не получало столь детального освещения в литературе. В работе систематизированы не только архитектурные решения, но и современные парадигмы обучения с оценкой их эффективности в условиях ограниченных выборок [70].

Перспективы дальнейших исследований связаны с развитием гибридных архитектур, интегрирующих свёрточные сети и механизмы внимания для одновременного учёта локальных спектрально-пространственных признаков и глобальных зависимостей. Актуальным направлением является создание фундаментальных моделей (foundation models), предварительно обучаемых на крупных массивах неразмеченных гиперспектральных данных, с последующей тонкой настройкой для узкопрофильных задач, таких как диагностика дефектов строительных конструкций. Значительный потенциал имеет автоматизация выбора моделей с помощью AutoML и NAS, что снизит порог внедрения методов в

инженерную практику. Дополнительные резервы заключаются в интеграции HSI с другими модальностями (лидар, акустика, ИК-съёмка) и формировании открытых эталонных коллекций спектров строительных материалов, что позволит повысить точность и надёжность систем автоматизированного мониторинга инфраструктуры [52].

В целом, гиперспектральный анализ развивается в сторону полной интеграции в инженерные процессы. Его потенциал заключается в возможности раннего обнаружения дефектов, автоматизации мониторинга и повышения надёжности конструкций. В ближайшие годы HSI может стать стандартным инструментом в системах управления инфраструктурой.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Goetz A.F.H., Vane G., Solomon J.E., Rock B.N. Imaging Spectrometry for Earth Remote Sensing, *Science*, 1985, Vol. 228, No. 4704, pp. 1147-1153. DOI: 10.1126/science.228.4704.1147.
2. Ahmad M., Distefano S., Khan A.M., Mazzara M., Li C., Li H., Aryal J., Ding Y., Vivone G., Hong D. A comprehensive survey for hyperspectral image classification: The evolution from conventional to transformers and Mamba models, *Neurocomputing*, 2024, Vol. 644, Art. 130428. DOI: 10.1016/j.neucom.2025.130428.
3. Hong D., Han Z., Yao J., Gao L., Zhang B., Plaza A., Chanussot J. SpectralFormer: Rethinking Hyperspectral Image Classification with Transformers, *IEEE Transactions on Geoscience and Remote Sensing*, 2022, Vol. 60, pp. 1-15, Art. 5518615. DOI: 10.1109/TGRS.2021.3130716.
4. Li S., Strauss A., Grba D., Granzner M., Täubling-Frueux B., Zimmermann T. Hyperspectral Signatures for Detecting the Concrete Hydration Process Using Neural Networks, *Infrastructures*, 2025, Vol. 10, No. 7, Art. 172. DOI: 10.3390/infrastructures10070172.
5. Cheng M.F., Mukundan A., Karmakar R., Valappil M.A.E., Jouhar J., Wang H.-C. Modern Trends and Recent Applications of Hyperspectral Imaging: A Review, *Technologies*, 2025, Vol. 13, Art. 170. DOI: 10.3390/technologies13050170.
6. Grill J.B., Strub F., Alché F., Tallec C., Richemond P.H., Buchatskaya E., Doersch C., Avila Pires B., Guo Z.D., Gheshlaghi Azar M., Piot B., Kavukcuoglu K., Munos R., Valko M. Bootstrap your own latent: A new approach to self-supervised learning, *arXiv*, 2020. DOI: 10.48550/arXiv.2006.07733.
7. Bioucas-Dias J.M., Plaza A., Camps-Valls G., Scheunders P., Nasrabadi N.M., Chanussot J. Hyperspectral Remote Sensing Data Analysis and Future Challenges, *IEEE Geoscience and Remote Sensing Magazine*, 2013, Vol. 1, No. 2, pp. 6-36. DOI: 10.1109/MGRS.2013.2244672.
8. Karantzalos K., Karakizi C., Kandylakis Z., Antoniou G. HyRANK Hyperspectral Satellite Dataset I [Dataset]. Zenodo, 2018. DOI: 10.5281/zenodo.1222202.
9. Li H., Cui J., Zhang X., Han Y., Cao L. Dimensionality Reduction and Classification of Hyperspectral Remote Sensing Image Feature Extraction, *Remote Sensing*, 2022, Vol. 14, No. 18, Art. 4579. DOI: 10.3390/rs14184579.
10. Roweis S.T., Saul L. K. Nonlinear Dimensionality Reduction by Locally Linear Embedding, *Science*, 2000, Vol. 290, No. 5500, pp. 2323-2326. DOI: 10.1126/science.290.5500.2323.
11. McInnes L., Healy J., Saul N., Großberger L. UMAP: Uniform Manifold Approximation and Projection, *Journal of Open Source Software*, 2018, Vol. 3, No. 29, Art. 861. DOI: 10.21105/joss.00861.
12. Chen S., Hu Y., Xu S., Li L., Cheng Y. Classification of hyperspectral remote sensing imagery by k-nearest-neighbor simplex based on adaptive C-mutual proportion standard deviation metric, *Journal of Applied Remote Sensing*, 2014, Vol. 8, No. 1, Art. 083578. DOI: 10.1117/1.JRS.8.083578.
13. Cao F., Yang Z., Ren J., Ling W.-K., Zhao H., Marshall S. Extreme Sparse Multinomial Logistic Regression: A Fast and Robust Framework for Hyperspectral Image Classification, *Remote Sensing*, 2017, Vol. 9, No. 12, Art. 1255. DOI: 10.3390/rs9121255.
14. Goel P.K., Prasher S.O., Patel R.M., Landry J.-A., Bonnell R.B., Viau A.A. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn, *Computers and Electronics in Agriculture*, 2003, Vol. 39, No. 2, pp. 67-93. DOI: 10.1016/S0168-1699(03)00020-6.
15. Ham J., Chen Y., Crawford M.M., Ghosh J. Investigation of the Random Forest Framework for Classification of Hyperspectral Data, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, Vol. 43, No. 3, pp. 492-501. DOI: 10.1109/TGRS.2004.842481.
16. 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, pp. 247-259. DOI: 10.1016/j.isprsjprs.2010.11.001.
17. Melgani F., Bruzzone L. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines, *IEEE Transactions on Geoscience and Remote Sensing*, 2004, Vol. 42, No. 8, pp. 1778-1790. DOI: 10.1109/TGRS.2004.831865.

18. Subramanian S., Ramakrishnan S. Methodology for hyperspectral image classification using novel neural network, *Proc. SPIE*, 1997, Vol. 3071: Algorithms for Multispectral and Hyperspectral Imagery III. DOI: 10.1117/12.280589.
19. Plaza J., Plaza A., Perez R., Martinez P. On the use of small training sets for neural network-based characterization of mixed pixels in remotely sensed hyperspectral images, *Pattern Recognition*, 2009, Vol. 42, pp. 3032-3045. DOI: 10.1016/j.patcog.2009.04.008.
20. Merenyi E., Farrand W. H., Taranik J.V., Minor T.B. Classification of hyperspectral imagery with neural networks: comparison to conventional tools, *EURASIP Journal on Advances in Signal Processing*, 2014, Art. 71. DOI: 10.1186/1687-6180-2014-71.
21. Wang L., Shi C., Diao C., Ji W., Yin D. A survey of methods incorporating spatial information in image classification and spectral unmixing, *International Journal of Remote Sensing*, 2016, Vol. 37, No. 16, pp. 3870-3910. DOI: 10.1080/01431161.2016.1204032.
22. Benediktsson J.A., Palmason J.A., Sveinsson J.R. Classification of hyperspectral data from urban areas based on extended morphological profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, Vol. 43, No. 3, pp. 480-491. DOI: 10.1109/TGRS.2004.842478.
23. Li J., Bioucas-Dias J.M., Plaza A. Spectral-Spatial Hyperspectral Image Segmentation Using Subspace Multinomial Logistic Regression and Markov Random Fields, *IEEE Transactions on Geoscience and Remote Sensing*, 2012, Vol. 50, No. 3, pp. 809-823. DOI: 10.1109/TGRS.2011.2162649.
24. Fauvel M., Benediktsson J.A., Chanussot J., Sveinsson J.R. Spectral and Spatial Classification of Hyperspectral Data Using SVMs and Morphological Profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, Vol. 46, No. 11, pp. 3804-3814. DOI: 10.1109/TGRS.2008.922034.
25. Green A.A., Berman M., Switzer P., Craig M.D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal, *IEEE Transactions on Geoscience and Remote Sensing*, 1988, Vol. 26, No. 1, pp. 65-74. DOI: 10.1109/36.3001.
26. Cheriyyadat A., Bruce L.M. Why principal component analysis is not an appropriate feature extraction method for hyperspectral data, *Proc. IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2003, Vol. 6, pp. 3420-3422. DOI: 10.1109/IGARSS.2003.1294808.
27. Camps-Valls G., Tuia D., Bruzzone L., Benediktsson J.A. Advances in hyperspectral image classification: Earth monitoring with statistical learning methods, *IEEE Signal Processing Magazine*, 2014, Vol. 31, No. 1, pp. 45-54. DOI: 10.1109/MSP.2013.2279179.
28. Rasti B., Hong D., Hang R., Ghamisi P., Kang X., Chanussot J., Benediktsson J.A. Feature Extraction for Hyperspectral Imagery: The Evolution from Shallow to Deep: Overview and Toolbox, *IEEE Geoscience and Remote Sensing Magazine*, 2020, Vol. 8, No. 4, pp. 60-88. DOI: 10.1109/MGRS.2020.2979764.
29. Zhou J., Zeng S., Xiao Z., Zhou J., Li H., Kang Z. An Enhanced Spectral Fusion 3D CNN Model for Hyperspectral Image Classification, *Remote Sensing*, 2022, Vol. 14, No. 21, Art. 5334. DOI: 10.3390/rs14215334.
30. Hu W., Huang Y., Wei L., Zhang F., Li H. Deep Convolutional Neural Networks for Hyperspectral Image Classification, *Journal of Sensors*, 2015, Vol. 2015, Art. 258619. DOI: 10.1155/2015/258619.
31. Yue J., Zhao W., Mao S., Liu H. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks, *Remote Sensing Letters*, 2015, Vol. 6, No. 6, pp. 468-477. DOI: 10.1080/2150704X.2015.1047045.
32. Mou L., Ghamisi P., Zhu X.X. Deep Recurrent Neural Networks for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2017, Vol. 55, No. 7, pp. 3639-3655. DOI: 10.1109/TGRS.2016.2636241.
33. Hochreiter S., Schmidhuber J. Long Short-Term Memory, *Neural Computation*, 1997, Vol. 9, No. 8, pp. 1735-1780. DOI: 10.1162/neco.1997.9.8.1735.
34. Liu Q., Zhou F., Hang R., Yuan X. Bidirectional-Convolutional LSTM Based Spectral-Spatial Feature Learning for Hyperspectral Image Classification, *Remote Sensing*, 2017, Vol. 9, No. 12, Art. 1330. DOI: 10.3390/rs9121330.
35. Zhou F., Hang R., Liu Q., Yuan X. Hyperspectral Image Classification Using Spectral-Spatial LSTMs, *Neurocomputing*, 2019, Vol. 328, pp. 39-47. DOI: 10.1016/j.neucom.2018.02.105.
36. Wu H., Prasad S. Convolutional Recurrent Neural Networks for Hyperspectral Data Classification, *Remote Sensing*, 2017, Vol. 9, No. 3, Art. 298. DOI: 10.3390/rs9030298.
37. Hu W.S., Li H.C., Pan L., Li W., Tao R., Du Q. Spatial-Spectral Feature Extraction via Deep ConvLSTM Neural Networks for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2020, Vol. 58, No. 6, pp. 4237-4250. DOI: 10.1109/TGRS.2019.2961947.
38. Qi W., Zhang X., Wang N., Zhang M., Cen Y. A Spectral-Spatial Cascaded 3D Convolutional Neural Network with a Convolutional Long Short-Term Memory Network for Hyperspectral Image Classification, *Remote Sensing*, 2019, Vol. 11, No. 20, Art. 2363. DOI: 10.3390/rs11202363.
39. Yin J., Qi C., Chen Q., Qu J. Spatial-Spectral Network for Hyperspectral Image Classification: A 3-D CNN and Bi-LSTM Framework, *Remote Sensing*, 2021, Vol. 13, No. 12, Art. 2353. DOI: 10.3390/rs13122353.

40. Farooque G., Xiao L., Yang J., Sargano A.B. Hyperspectral Image Classification via a Novel Spectral–Spatial 3D ConvLSTM-CNN, *Remote Sensing*, 2021, Vol. 13, No. 21, Art. 4348. DOI: 10.3390/rs13214348.
41. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. Attention Is All You Need, *arXiv*, 2017. DOI: 10.48550/arXiv.1706.03762.
42. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. An Image is Worth 16×16 Words: Transformers for Image Recognition at Scale, *arXiv*, 2020. DOI: 10.48550/arXiv.2010.11929.
43. He J., Zhao L., Yang H., Zhang M., Li W. HSI-BERT: Hyperspectral Image Classification Using the Bidirectional Encoder Representation from Transformers, *IEEE Transactions on Geoscience and Remote Sensing*, 2020, No. 58 (1), pp. 165–178. DOI: 10.1109/TGRS.2019.2934760.
44. Yu H., Xu Z., Zheng K., Hong D., Yang H., Song M. MSTNet: A Multilevel Spectral–Spatial Transformer Network for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2022, No. 60, pp. 1–13. DOI: 10.1109/TGRS.2022.3186400.
45. Yang X., Cao W., Lu Y., Zhou Y. Hyperspectral Image Transformer Classification Networks, *IEEE Transactions on Geoscience and Remote Sensing*, 2022, Vol. 60, pp. 1–15. DOI: 10.1109/TGRS.2022.3171551.
46. Yuan D., Yu D., Qian Y., Xu Y., Liu Y. S2Former: Parallel Spectral–Spatial Transformer for Hyperspectral Image Classification, *Electronics*, 2023, Vol. 12, No. 18, Art. 3937. DOI: 10.3390/electronics12183937.
47. Wang D., Zhang J., Du B., Zhang L., Tao D. DCN-T: Dual Context Network with Transformer for Hyperspectral Image Classification, *IEEE Transactions on Image Processing*, 2023, No. 32, pp. 2536–2551. DOI: 10.1109/TIP.2023.3270104.
48. Zhang B., Chen Y., Rong Y., Xiong S., Lu X. MATNet: A Combining Multi-Attention and Transformer Network for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2023, No. 61, pp. 1–15. DOI: 10.1109/TGRS.2023.3254523.
49. Sun L., Zhao G., Zheng Y., Wu Z. Spectral–Spatial Feature Tokenization Transformer for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2022, No. 60, pp. 1–14. DOI: 10.1109/TGRS.2022.3144158.
50. Xu R., Dong X.-M., Li W., Peng J., Sun W., Xu Y. DBCTNet: Double-Branch Convolution–Transformer Network for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2024, No. 62, pp. 1–15. DOI: 10.1109/TGRS.2024.3368141.
51. Qi W., Huang C., Wang Y., Zhang X., Sun W., Zhang L. Global-Local Three-Dimensional Convolutional Transformer Network for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2023, No. 61, pp. 1–20. DOI: 10.1109/TGRS.2023.3272885.
52. Wang X.Y., Hu Q., Cheng Y.S., Ma J.Y. Hyperspectral Image Super-Resolution Meets Deep Learning: A Survey and Perspective, *IEEE/CAA Journal of Automatica Sinica*, 2023, Vol. 10, No. 8, pp. 1668–1691. DOI: 10.1109/JAS.2023.123681.
53. He X., Chen Y., Lin Z. Spatial–Spectral Transformer for Hyperspectral Image Classification, *Remote Sensing*, 2021, Vol. 13, No. 3, Art. 498. DOI: 10.3390/rs13030498.
54. Wang W., Liu L., Zhang T., Shen J., Wang J., Li J. Hyper-ES2T: Efficient Spatial–Spectral Transformer for the Classification of Hyperspectral Remote Sensing Images, *International Journal of Applied Earth Observation and Geoinformation*, 2022, Vol. 113, Art. 103005. DOI: 10.1016/j.jag.2022.103005.
55. Ji Y., Shi J., Zhanq Y., Yanq H., Zongq Y., Xu L. HyFormer: Hybrid Grouping–Aggregation Transformer and Wide-Spanning CNN for Hyperspectral Image Super-Resolution, *Remote Sensing*, 2023, Vol. 15, No. 17, Art. 4131. DOI: 10.3390/rs15174131.
56. Arya S., Dubey S.R., Moorthi S.M., Dhar D., Singh S.K. 3D-CmT: 3D-CNN Meets Transformer for Hyperspectral Image Classification, In: Cho M.; Laptev I.; Tran D.; Yao A.; Zha H. B. (eds), *Computer Vision – ACCV 2024 Workshops: Lecture Notes in Computer Science*, Vol. 15483. Singapore: Springer, 2025. DOI: 10.1007/978-981-96-2644-1_23.
57. Marmanis D., Datcu M., Esch T., Stilla U. Deep Learning Earth Observation Classification Using ImageNet Pretrained Networks, *IEEE Geoscience and Remote Sensing Letters*, 2016, Vol. 13, No. 1, pp. 105–109. DOI: 10.1109/LGRS.2015.2499239.
58. Zhang H., Li Y., Jiang Y., Wang P., Shen Q., Shen C. Hyperspectral Classification Based on Lightweight 3-D-CNN with Transfer Learning, *IEEE Transactions on Geoscience and Remote Sensing*, 2019, Vol. 57, No. 8, pp. 5813–5828. DOI: 10.1109/TGRS.2019.2902568.
59. Yang J., Zhao Y., Chan J. C.-W. Learning and Transferring Deep Joint Spectral–Spatial Features for Hyperspectral Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2017, Vol. 55, No. 8, pp. 4729–4742. DOI: 10.1109/TGRS.2017.2698503.
60. Wang H., Cheng Y., Wang X. A Novel Hyperspectral Image Classification Method Using Class-Weighted Domain Adaptation Network, *Remote Sensing*, 2023, Vol. 15, No. 4, Art. 999. DOI: 10.3390/rs15040999.

61. Penatti O.A.B., Nogueira K., Santos J.A. dos. Do Deep Features Generalize from Everyday Objects to Remote Sensing and Aerial Scenes Domains?, *2015 IEEE Conf. on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2015, pp. 44-51. DOI: 10.1109/CVPRW.2015.7301382.
62. Chen T., Kornblith S., Norouzi M., Hinton G. A Simple Framework for Contrastive Learning of Visual Representations, *arXiv*, 2020. arXiv:2002.05709. DOI: 10.48550/arXiv.2002.05709.
63. Xu J., Tang H., Ren Y., Peng L., Zhu X., He L. Multi-level Feature Learning for Contrastive Multi-view Clustering, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 16030-16039. DOI: 10.1109/CVPR52688.2022.01558.
64. Wang Y.; Albrecht C.M.; Ait Ali Braham N.; Mou L.; Zhu X.X. Self-Supervised Learning in Remote Sensing: A Review, *IEEE Geoscience and Remote Sensing Magazine*, 2022, Vol. 10, No. 4, pp. 213-247. DOI: 10.1109/MGRS.2022.3198244.
65. Ayuba D. L.; Guillemaut J.-Y.; Marti-Cardona B.; Mendez Maldonado O. SpecBPP: A Self-Supervised Learning Approach for Hyperspectral Representation and Soil Organic Carbon Estimation, *arXiv*, 2025. arXiv:2507.19781. DOI: 10.48550/arXiv.2507.19781.
66. Liu B., Yu X., Zhang P. A Semi-Supervised Convolutional Neural Network for Hyperspectral Image Classification, *Remote Sensing Letters*, 2017, Vol. 8, No. 9, pp. 839-848. DOI: 10.1080/2150704X.2017.1331053.
67. Wang L., Hao S., Wang Q., Wang Y. Semi-Supervised Classification for Hyperspectral Imagery Based on Spatial-Spectral Label Propagation, *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, Vol. 97, pp. 123-137. DOI: 10.1016/j.isprsjprs.2014.08.016.
68. Zhang D., Ren Y., Liu C., Han Z., Wang J. Weighted Contrastive Prototype Network for Few-Shot Hyperspectral Image Classification with Noisy Labels, *Remote Sensing*, 2024, Vol. 16, No. 18, Art. 3527. DOI: 10.3390/rs16183527.
69. Ait Ali Braham N., Wang Y., Albrecht C.M., Mou L., Zhu X.X. Self-Supervised Learning for Few-Shot Hyperspectral Image Classification, *arXiv*, 2022. arXiv:2206.12117. DOI: 10.48550/arXiv.2206.12117.
70. Kumar V., Singh R.S., Rambabu M., Dua Y. Deep learning for hyperspectral image classification: A survey, *Computer Science Review*, 2024, Art. 100658. DOI: 10.1016/j.cosrev.2024.100658.

Филонова Марьяна Андреевна – Южно-Российский государственный политехнический университет (НПИ) имени М.И. Платова; e-mail: filonovamaryana@ynadex.ru; г. Новочеркасск, Россия; тел.: +79185767418; кафедра «Информационные и измерительные системы и технологии»; ассистент; аспирант.

Широбокова Светлана Николаевна – Южно-Российский государственный политехнический университет (НПИ) имени М.И. Платова; e-mail: shirobokova_sn@mail.ru; г. Новочеркасск, Россия; тел.: +79518372637; кафедра «Информационные и измерительные системы и технологии»; к.э.н.; доцент.

Filonova Maryana Andreevna – Platov South-Russian State Polytechnic University (NPI); e-mail: filonovamaryana@ynadex.ru; Novocherkassk, Russia; phone: +79185767418; the Department «Information and measuring systems and technologies»; master's student.

Shirobokova Svetlana Nikolaevna – Platov South-Russian State Polytechnic University (NPI); e-mail: shirobokova_sn@mail.ru; Novocherkassk, Russia; phone: +79518372637; the Department «Information and measuring systems and technologies»; cand. of econ. sc.; associate professor.

УДК 004.942

DOI 10.18522/2311-3103-2026-3-208-219

Л.Э. Хайруллина, З.Н. Хакимов, Д.И. Галиев, А.Н. Хайруллина

ПРОГНОЗИРОВАНИЕ ДВИЖЕНИЯ ЦЕНЫ ОБЛИГАЦИИ С ПОМОЩЬЮ ГИБРИДНОГО МЕТОДА НА ОСНОВЕ XGBOOST И ГЕНЕТИЧЕСКОГО АЛГОРИТМА

Представлен гибридный метод к прогнозированию направления движения цены облигаций, сочетающий метод машинного обучения XGBoost с оптимизацией гиперпараметров посредством генетического алгоритма. Исследование направлено на решение задачи бинарной классификации направления цены облигации ОАО «РЖД» на следующий торговый день. Методология исследования включает формирование расширенного признакового пространства из 18 технических индикаторов, рассчитанных на основе дневных OHLCV-данных. Для настройки гиперпараметров