

ГЕНЕРАЦИЯ СПЕКТРА ВИДИМОГО ДИАПАЗОНА ПО ОГРАНИЧЕННЫМ ДАННЫМ

А. В. Креч

*Белорусский государственный университет,
Минск, Беларусь, kreshess@mail.ru*

Генерация спектральных характеристик является одной из главных целей в мониторинге состояния растительности и решении ряда прикладных задач анализа изображений. В работе обсуждаются современные подходы к генерации спектра по ограниченными данным, позволяющие воспроизводить спектральные характеристики видимого диапазона на основе RGB-изображений, что открывает возможности для более доступного применения методов спектрального анализа.

Ключевые слова: гиперспектральные данные; сверточные нейронные сети; rgb; спектр; феномика; изображения.

GENERATION OF THE VISIBLE RANGE SPECTRUM BASED ON LIMITED DATA

A. V. Krech

*Belarusian State University,
Minsk, Belarus, kreshess@mail.ru*

The generation of spectral characteristics is one of the main goals in monitoring vegetation conditions and solving a number of applied image analysis problems. The paper discusses modern approaches to spectrum generation based on limited data, which make it possible to reproduce the spectral characteristics of the visible range based on RGB images, which opens up opportunities for a more comprehensive application of spectral analysis methods.

Keywords: hyperspectral data; convolutional neural networks; rgb; spectrum; phenomics; images.

1. Введение

Видимый спектр отражения листьев содержит богатую информацию о процессах фотосинтеза, содержании пигментов и структурных особенностях тканей [1]. Его анализ позволяет выявлять изменения, которые не

всегда заметны визуально, но имеют ключевое значение для оценки состояния растений [2]. Тем не менее, получение полного спектра из многоканальных изображений требует дорогостоящего оборудования и значительных ресурсов, что ограничивает возможности их широкого применения в полевых условиях.

В связи с этим актуальной задачей становится восстановление или генерация спектральных характеристик видимого диапазона на основе ограниченного объема данных. Данный подход открывает перспективы для создания более доступных и эффективных методов мониторинга растительности, которые могут быть применены как в научных исследованиях, так и в сельском хозяйстве, экологии и смежных областях.

2. Теоретические основы гиперспектрального анализа

Гиперспектральные изображения — это особый класс изображений, где каждому пикселю сопоставлена подробная спектральная информация, охватывающая десятки, сотни или даже тысячи узких спектральных каналов, по сравнению с традиционными RGB-изображениями, имеющими только три канала цвета [3]. Такие данные образуют трехмерную структуру — «гиперкуб», где два измерения описывают пространственные координаты, а третье — спектральные. Схематичное представление такой структуры часто иллюстрируется в виде многослойного куба, пример представлен на рис. 1, где каждый слой соответствует отдельной длине волны.

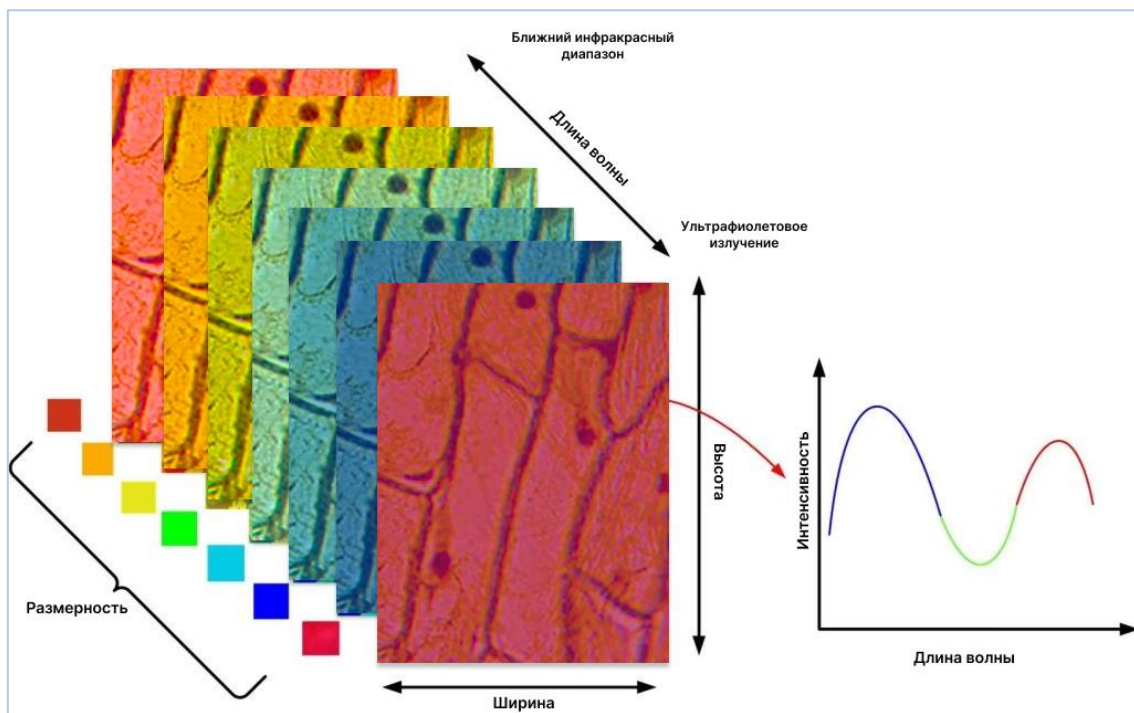


Рис. 1. Структура гиперспектрального изображения

Гиперкуб данных позволяет анализировать физико-химический состав объектов на основе спектральных подписей. Однако получение гиперспектральных данных требует дорогостоящего оборудования и зачастую оказывается затруднительным в полевых условиях.

3. Некорректность задачи восстановления спектра

Особый интерес представляет задача восстановления спектральной информации по ограниченным данным, например по обычным RGB-изображениям. Однако такая задача является некорректной по Адамару, поскольку прямое восстановление спектра из трех каналов неоднозначно: множество различных спектров может соответствовать одному и тому же цветовому восприятию.

Операцию формирования изображения в визуализирующей системе удобно описывать в виде общей математической модели.

$$y = \mathcal{H}(x), \quad (1)$$

где $y \in R^P$ — наблюдаемые данные; $x \in R^N$ — истинное или искомое изображение, которое требуется восстановить; $\mathcal{H}: R^N \rightarrow R^P$ — оператор, описывающий отображение из пространства истинных данных в пространство измерений [4, с. 14].

В большинстве практических случаев $H \in R^{P \times N}$ можно рассматривать как линейное преобразование и записывать в виде матрицы. Тогда процесс наблюдения (1) сводится к матричному уравнению.

$$y = Hx. \quad (2)$$

Из (2) видно, что в зависимости от соотношения между N и P выделяют несколько классов задач. Если $N = P$, оператор H близок к невырожденному, и задача восстановления может быть корректно поставлена (например, в задачах микроскопии). Если же $P \ll N$, как это имеет место при восстановлении гиперспектральных данных из RGB-изображений, то задача становится некорректной по Адамару: малое число наблюдений не позволяет однозначно определить истинный спектр, так как множество различных x может порождать одни и те же наблюдаемые данные y .

Классическим способом решения обратной задачи является метод регуляризации, согласно которому решение находится путем минимизации функционала.

$$\hat{x} = \arg \min_x \|Hx - y\|_2^2, \quad (3)$$

где \hat{x} — оценка истинного изображения.

Однако при недостаточности измерений (когда $P < N$) такое решение оказывается неустойчивым: небольшие изменения в y могут приводить к большому искажению в \hat{x} .

Для стабилизации решения (3) вводятся дополнительные предположения — регуляризация или априорная информация о структуре искомого спектра. Современный подход заключается в том, чтобы аппроксимировать отображение H^{-1} с помощью нейронных сетей. Обучаясь на больших выборках пар (x, y) , они восстанавливают априорные статистические зависимости между спектральным и цветовыми представлениями. Таким образом, нейронные сети фактически реализуют регуляризатор, позволяющий решать некорректную задачу и получать устойчивые оценки гиперспектральных данных, открывая возможность для генерации полного спектра без применения дорогостоящих сенсоров, делая технологию значительно более доступной для прикладных исследований и практических приложений.

4. Сверточная нейронная сеть HRNet

Сверточные нейронные сети (CNN) представляют собой класс глубоких архитектур, ориентированных на обработку данных с ярко выраженной пространственной структурой. Ключевым механизмом их работы основан на операции свертки, которая позволяет выделять информативные признаки различного уровня — от локальных текстур и границ до сложных структурных паттернов.

Для решения задачи реконструкции гиперспектральных данных в данной работе используется архитектура Hierarchical Regression Network (HRNet). HRNet реализует параллельные вычислительные потоки с многоуровневым обменом информацией между ними.

В процессе обучения в качестве критерия оптимизации используется функция потерь L_1 , направленная на повышение пикового отношения сигнал / шум.

$$L_1 = E(\|G(x) - y\|_1), \quad (4)$$

где $E(\cdot)$ — усреднение по всем объектам обучающей выборки; $G(\cdot)$ — результат работы модели; x и y — входные и выходные данные соответственно.

Математическое представление функции L_1 задается формулой (4). Для увеличения эффективности обучения применяется методика обучения на локальных фрагмента. В рамках этого подхода как входное RGB-изображение, так и соответствующее ему спектральное изображение разбиваются на одинаковые фрагменты с совпадающими пространственными координатами и разрешением. Такой способ позволяет увеличить число обучающих примеров, снизить вычислительные затраты и повысить устойчивость модели к локальным вариациям изображений.

Для компенсации потери исходной пиксельной информации, вызванной понижающей выборкой при свертке с шагом больше единицы, в работе используется метод PixelShuffle [5], который преобразует изображение с низким разрешением в высокое путем перестановки пикселей. Дополнительно используется PixelUnShuffle, выполняющий обратную операцию — снижая разрешение, он перекодирует пиксели в дополнительные каналы, предотвращая потерю информации. В сочетании с иерархической архитектурой эти методы позволяют эффективно восстанавливать детали объектов на разных масштабах [6]. Структура HRNet представлена на рис. 2.

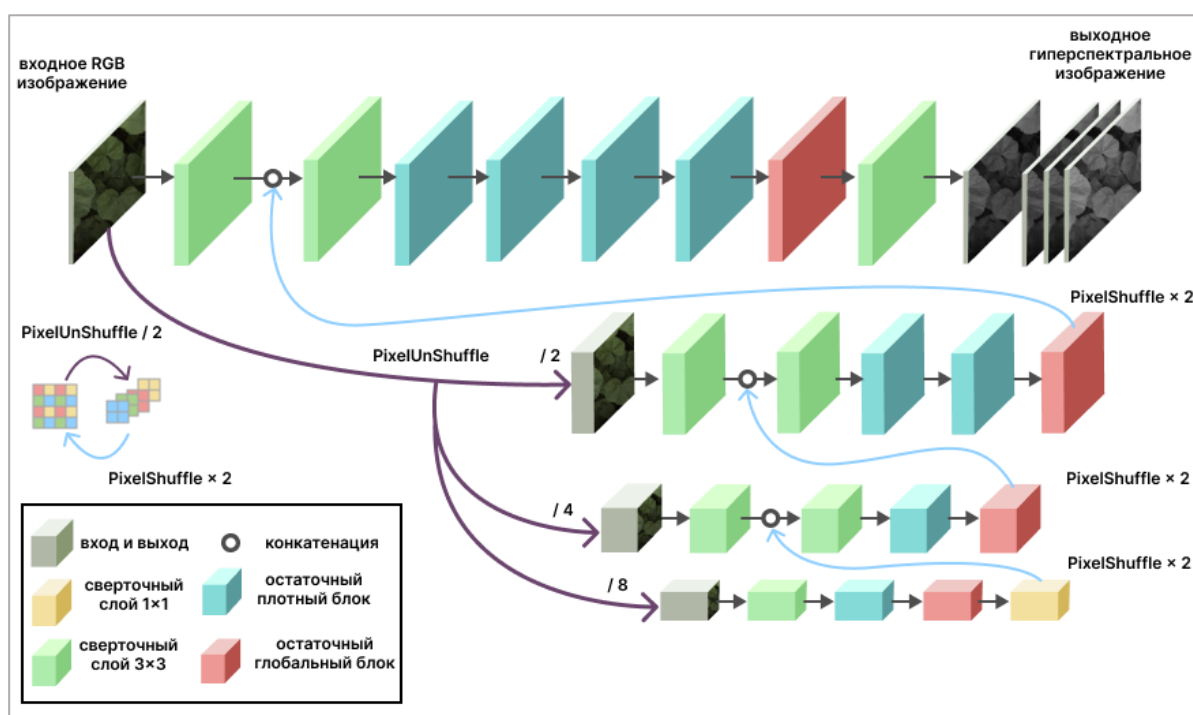


Рис. 2. Иллюстрация архитектуры HRNet

5. Анализ полученных результатов

Эффективность предложенной архитектуры HRNet оценивалась посредством сравнения с тремя широко применяемыми моделями глубокого обучения: U-Net [7], U-ResNet [8] и HSCNN-D [9]. Модели U-Net и

U-ResNet хорошо зарекомендовали себя в задачах низкоуровневой обработки изображений, включая сегментацию и восстановление, благодаря способности сохранять пространственные детали и эффективно использовать остаточные связи [7]. HSCNN-D представляет специализированную архитектуру, разработанную для гиперспектральных изображений и ориентированную на восстановление спектральной информации с минимальными искажениями.

Все модели обучались с одинаковыми гиперпараметрами, предварительно оптимизированными для HRNet, до достижения сходимости. При этом методы ансамблирования не использовались. Для анализа результатов учитывались метрики, полученные в эпоху с наилучшей производительностью модели. Результат генерации представлен на рис. 3.

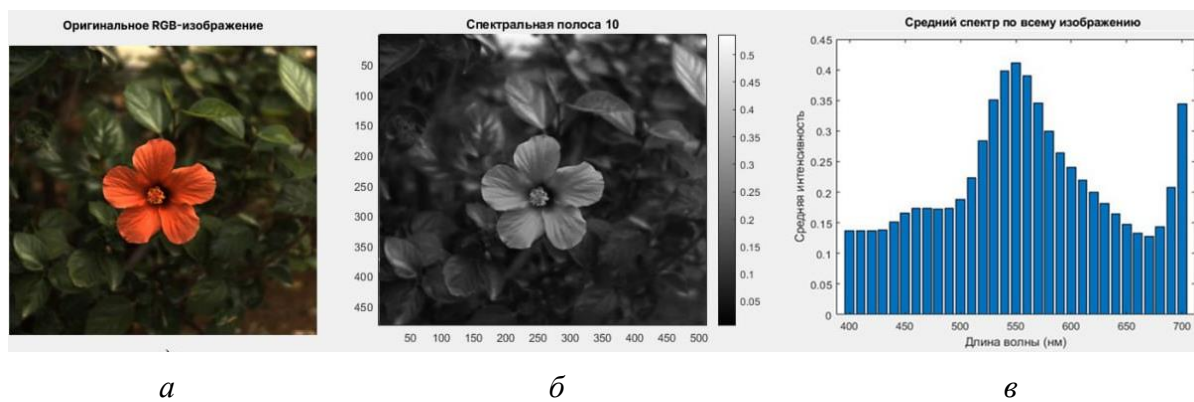


Рис. 3. Оригинальное RGB-изображение (а);
 отображение 10 полосы из полученного гиперспектрального изображения (б);
 извлеченный спектр из полученного изображения (в)

Итоговые показатели представлены в таблице, где отражены стандартные метрики оценки точности восстановления, включая среднюю квадратичную ошибку (MSE) и среднеквадратичную ошибку (RMSE).

По метрике MRAE HRNet минимальное значения достигла 0.0425, что ниже, чем у U-ResNet (0,0582) и HSCNN-D (0,0495), также существенно превосходит результат U-Net (0,0756) и разреженного кодирования (0,0816).

По метрике RMSE минимальные значения также были зафиксированы у HRNet. Также следует отметить, что при сопоставимых показателях ошибки HRNet демонстрирует значительно более высокую вычислительную эффективность. Среднее время обработки составило всего 3,748 секунд (GPU), что более чем в 20 раз быстрее по сравнению с HSCNN-D (77,962 секунд) и заметно превосходит U-Net (16,57 секунд). Что делает HRNet особенно эффективной для задач, требующих сочетания высокой точности и вычислительной эффективности, включая реальное время обработки изображений.

Сравнение рассматриваемой модели с предыдущими

Набор данных		Чистый	Реальный мир	Время выполнения (сек.)
Разреженное кодирование	MRAE	0,0816	-	112,933 (CPU)
	RMSE	49,217	-	
U-Net	MRAE	0,0756	-	16,57 (GPU)
	RMSE	17,006	-	
U-ResNet	MRAE	0,0582	0,0792	5,431 (GPU)
	RMSE	16,653	24,987	
HSCNN-D	MRAE	0,0495	0,0776	77,962 (GPU)
	RMSE	13,911	23,457	
HRNet	MRAE	0,0425	0,071152	3,748 (GPU)
	RMSE	0,013537	0,017859	

Экспериментальные результаты показывают, что предложенная архитектура HRNet обеспечивает превосходное качество реконструкции по всем ключевым метрикам. Высокая точность достигается за счет сохранения высокоразрешенных представлений на всех уровнях сети и эффективной интеграции многомасштабной информации, что позволяет одновременно учитывать глобальный контекст и локальные детали.

5. Заключение

В ходе проведенных экспериментов была получена оценка производительности различных моделей для задачи восстановления гиперспектральных изображений по ограниченному данным. Сравнительный анализ показал, что архитектура HRNet демонстрирует наилучшие результаты как по метрикам точности (MRAE и RMSE), так и по времени вычислений, значительно превосходя альтернативные методы, такие как U-Net, U-ResNet и HSCNN-D. На всем рассматриваемом диапазоне спектры модели близки к эталонному, что находит подтверждение в точном совпадении их пиков.

Таким образом, предложенный подход обеспечивает более высокую степень сохранения спектральных характеристик при существенно меньших вычислительных затратах. Это делает HRNet перспективным инструментом для решения прикладных задач, связанных с анализом гиперспектральных данных, включая мониторинг состояния сельскохозяйственных культур, раннюю диагностику заболеваний растений, оценку качества почв, а также задачи экологического и промышленного контроля.

Библиографические ссылки

1. *Pauli D. W.* The Quest for Understanding Phenotypic Variation via Integrated Approaches in the Field Environment // *Plant Physiology*. 2016. Vol. 172. P. 622–663.
2. CANNA: The solution for growth and bloom. URL: <https://www.cannagardening.com/articles/influence-colors-plants> (date of access: 27.06.2025).
3. *Ермаков В., Кузнецов М., Раменская Е.* Классификация гиперспектральных изображений с использованием кластерной структуры данных // *Современные проблемы дистанционного зондирования Земли из космоса*. 2017. Т. 14. № 7. С. 9–19.
4. *Пронина В.* Восстановление изображений с помощью обучаемых оптимизационно-нейросетевых алгоритмов // *Научная библиотека ИАиЭ СО РАН*. 2022. URL: https://scask.ru/i_book_recimg.php (дата обращения: 24.10.2024).
5. MLIFeat: Multi-level information fusion based deep local features / Y. Zhang [et al.] // *Computer Vision – ACCV 2020 : 15th Asian Conference on Computer Vision, Kyoto, Japan, November 30 – December 4, 2020, Revised Selected Papers* / eds.: H. Ishikawa [et al.]. Cham : Springer, 2021. Part III. P. 403–419. URL: https://www.researchgate.net/publication/349580000_MLIFeat_Multilevel_Information_Fusion_Based_Deep_Local_Features (date of access: 26.10.2024).
6. Hybrid Pixel-Unshuffled Network for Lightweight Image Super-Resolution / B. Sun [et al.] // *arXiv preprint*. 2022. arXiv:2203.08921.
7. U-net: Convolutional networks for biomedical image segmentation / O. Ronnenberger [et al.] // *arXiv preprint*. 2022. arXiv:1505.04597.
8. Deep residual learning for image recognition / K. He [et al.] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2016. P. 770–778. URL: <https://ieeexplore.ieee.org/document/7780459> (date of access: 22.07.2025).
9. HSCNN+: Advanced CNN-Based Hyperspectral Recovery from RGB Images / Z. Shi [et al.] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2018. P. 1052–1060. URL: https://openaccess.thecvf.com/content_cvpr_2018_workshops/papers/w13/Shi_HSCNN_Advanced_CNN-Based_CVPR_2018_paper.pdf (date of access: 03.06.2025).
10. DeblurGAN: Blind Motion Deblurring Using Conditional Adversarial Networks / O. Kupyn [et al.] // *arXiv preprint*. 2018. arXiv: 1711.07064.