

## Нейросетевой метод коррекции пространственно–спектральной чувствительности щелевого гиперспектрометра

А.Р. Макаров<sup>1</sup>, А.В. Никоноров<sup>1</sup>

<sup>1</sup> Самарский национальный исследовательский университет имени академика С.П. Королёва, 443086, Россия, г. Самара, Московское шоссе, д. 34;

### Аннотация

Предложен нейросетевой метод обучаемой пространственно–спектральной коррекции чувствительности щелевого гиперспектрометра. В отличие от традиционных подходов к калибровке, основанных на выравнивании регистрируемого сигнала, отраженного от однородно освещенного «эталонного» объекта (имеющего ламбертовскую поверхность), вдоль направления длины щелевой диафрагмы прибора с использованием заранее рассчитанных коэффициентов, предлагаемый подход к калибровке реализован в виде слоёв нейронной сети, параметры которых оптимизируются совместно с моделью классификации в процессе обучения. Разработаны три типа обучаемых калибровочных слоёв, с использованием обучаемой матрицы калибровочных коэффициентов, ее частичной полиномиальной аппроксимации и векторной факторизации. Экспериментальная оценка проведена на гиперспектральных изображениях, зарегистрированных при близких, но не идентичных условиях съёмки. Калибровочные слои интегрированы в 3D–свёрточную сеть и пространственно–спектральный трансформер. Эксперименты показали устойчивое повышение качества классификации относительно базовых моделей без калибровки: прирост точности для метрики accuracy составил от 0,59 % до 14,27 %, а для F1–score – от 0,17 % до 10,98 %. Также разработан алгоритм применения калибровочных слоёв для предобработки данных с последующим обучением немодифицированных базовых моделей, что существенно расширяет применимость предложенного подхода.

**Ключевые слова:** гиперспектрометр, параметрические слои коррекции, глубокое обучение, классификация, позиционно–зависимая коррекция чувствительности гиперспектрометра.

**Цитирование:** Макаров, А.Р. Нейросетевой метод коррекции пространственно–спектральной чувствительности щелевого гиперспектрометра / А.Р. Макаров, А.В. Никоноров // Компьютерная оптика. – 2025. – Т. 49, № 6. – С. 947–960. – DOI: 10.18287/COJ1812.

**Citation:** Makarov AR, Nikonorov AV. Neural-based spatial-spectral sensitivity correction for pushbroom hyperspectral cameras. Computer Optics 2025; 49(6): 947–960. DOI: 10.18287/COJ1812.

### Введение

Сканирующие щелевые гиперспектрометры широко применяются в различных областях, таких как: точное земледелие, мониторинг окружающей среды, экологическое наблюдение, геология и т.д. [1 – 7]. Рассмотрим модель гиперспектрометра, состоящего из объектива, узла с щелевой диафрагмой, спектрального блока с диспергирующим элементом и кадровым фотоприемником (или фотоприемной матрицей). Изображение снимаемой поверхности проецируется объективом в область щелевой диафрагмы. Далее изображение, вырезанное щелевой диафрагмой, раскладывается спектральным блоком с формированием пространственной спектрограммы в области фотоприемника. Цель является одним из основных элементов оптической схемы гиперспектрометров подобного типа, обеспечивающим пространственное ограничение входного потока излучения и формирование линии наблюдения сцены [8 – 10]. Подобные гиперспектрометры могут обладать искажениями типа «smile», «keystone». При искажениях типа «smile» у

пространственной спектрограммы смещаются положения длин волн, в зависимости от позиции проекции спектрограммы вдоль длины щелевой диафрагмы. У искажений типа «keystone» наблюдается несовпадение пространственного положения начала и конца спектральных диапазонов вдоль длины щелевой диафрагмы, т.е. появляется наклон проекции спектра, регистрируемого фотоприемником [11 – 13].

Существуют различные методы коррекции подобных искажений гиперспектральной аппаратуры (ГСА). В работе [14] предложен подход, основанный на использовании кубической сплайн–интерполяции для автоматической компенсации искажений типа «smile» и «keystone» на борту космического аппарата. В [15] предложен лабораторный метод измерения и коррекции искажений «smile» и «keystone» на основе нормализованной кросс–корреляции и субпиксельной интерполяции. В [16] предложен программный метод коррекции искажений типа «smile» (и сопутствующего наклона «slit», обозначенного как «tilt»), основанный на поиске эмиссионных линий во флуоресцентном спектре, аппроксимации их дугами окружностей

и последующем построении матрицы сдвигов, выравнивающей спектральные линии без использования оптической лаборатории или монохроматора.

Также для компенсации подобных искажений у ГСА используют «эталонные» объекты. В [17] описывается лабораторная система на основе гиперспектрометров «Specim» (FX10 и FX17) с использованием белого эталона объекта «spectralon» для радиометрической калибровки, а также методов аппаратной и программной коррекции искажений типа «smile» и «keystone». Также, существуют закрытые алгоритмы компенсации трапециевидных искажений «AIE» коммерческого гиперспектрометра Specim серии FX [18], и исследования их эффективности, проводимые как самой компанией Specim, так и сторонними группами ученых [19–20].

Помимо искажений «smile» и «keystone» существуют радиометрические искажения. В работе [21] рассмотрена проблема радиометрической неравномерности отклика пикселей инфракрасной ПЗС-матрицы, проявляющаяся в виде «полос» вдоль направления сканирования. Предложен сценно-зависимый метод коррекции неравномерности (scene-based NUC), основанный на автоматическом выделении однородных областей с близкой отражательной способностью и вычислении коэффициентов коррекции для каждого пикселя щели. В работе [22] предложена методика радиометрической калибровки сканирующего гиперспектрометра с использованием недорогого белого эталона из политетрафторэтилена (PTFE), обеспечивающего корректное измерение относительной отражательной способности независимо от распределения освещения и чувствительности сенсора. В том числе на однородность полученных данных, влияет спектрально и пространственно-зависимая функция рассеяния точки (ФРТ) у сканирующих гиперспектрометров как показано в [23]. Также в работах [25–29] упоминается использование «эталонных» объектов для исправления искажений ГСА упомянутых выше.

Описанные выше подходы калибровки эффективно устраняют искажения у ГСА при заранее известных условиях эксплуатации. В лабораторных условиях это характеристики используемого источника освещения и заранее подобранные параметры выдержки и усиления у ГСА. Также в лабораторных условиях зачастую обеспечен стабильный температурный режим. При съемках вне лаборатории дополнительно приходится учитывать следующие факторы: погодные условия (наличие облаков), положение источника освещения (т.е. Солнца) и температурный режим. В [30] подтверждается необходимость проведения регулярных процедур калибровки из-за изменяющихся условий освещения сцены, чтобы избежать искажений получаемых данных.

Следовательно, калибровочные коэффициенты, рассчитанные в лабораторных условиях под определенные профили освещенности (облачно/ясно),

определенные параметры съемки у ГСА (время выдержки, «gain» т.е. усиление), определенный температурный режим – могут оказаться недостаточно подходящими для полноценной компенсации искажений, которые вносят узлы ГСА в регистрируемые гиперспектральные данные (ГСИ).

Параллельно с алгоритмами калибровки ГСА развиваются методы анализа ГСИ. В том числе методы машинного обучения, включающие применение глубоких нейросетевых архитектур. Среди современных методов поэлементной классификации особый интерес представляют подходы на основе 3D-свёрточных сетей и трансформеров, учитывающие пространственно-спектральные зависимости в данных [31–35]. Несмотря на наличие моделей демонстрирующих высокую эффективность при решении задач поэлементной классификации объектов на гиперспектральных изображениях (ГСИ) [36], существующие нейросетевые архитектуры не принимают во внимание особенности регистрации сигнала в сканирующих гиперспектрометрах, которые были рассмотрены выше. Существуют нейросетевые методы коррекции неоднородной функции рассеивания точки (ФРТ) в микроскопии [37] и астрофизических спектрографах [38], но данные решения не адаптированы к особенностям сканирующих гиперспектрометров.

В настоящей работе предлагается подход, при котором коррекция искажений используемого в работе сканирующего щелевого гиперспектрометра реализуется в виде обучаемых слоёв, интегрированных непосредственно в архитектуру нейросети. Предложенные слои позволяют не только компенсировать пространственную неравномерность отклика вдоль щели сканирующего гиперспектрометра, но и выделять спектральные признаки, наиболее значимые для повышения точности классификации.

В данной работе:

1. Предложены четыре варианта обучаемых слоёв для компенсации пространственно-спектральных искажений сканирующего гиперспектрометра;
2. Реализована интеграция этих слоёв в две архитектуры – 3D-свёрточную (NM3DCNN) и пространственно-спектральный трансформер (SSFTT);
3. Проведён сравнительный анализ различных комбинаций слоёв на гиперспектральных данных, полученных в полевых условиях при варьирующихся параметрах съёмки. Выявлены наиболее эффективные конфигурации для каждой из исследуемых архитектур.

### **1. Формирование изображения сканирующим гиперспектрометром**

#### **1.1. Используемые представления гиперспектральных изображений**

В [39] ГСИ представляется в виде матрицы гиперпикселей, каждый гиперпиксел – это вектор, элементы которого содержат зарегистрированную

спектральную интенсивность в заданном диапазоне длин волн, с определенным спектральными разрешением (интервал между узкими поддиапазонами спектральной интенсивности). Такое векторное представление удобно для решения задач поэлементной классификации объектов на ГСИ. Однако для задач калибровки, рассматриваемых в настоящей статье, более удобной является тензорное представление ГСИ, аналогично тому, как это сделано в ряде работ, посвященных алгоритмам оптимизации обработки ГСИ [40–43] или синтеза ГСИ [42]. Представим ГСИ в виде тензора третьего порядка:

$$S(i, j, k): 1 \leq i \leq I, 1 \leq j \leq J, 1 \leq k \leq K, \quad (1)$$

где  $i$  и  $j$  это соответствующие индексы строки и столбца вектора, который является спектром первого порядка,  $k$  – индекс спектрального канала (см. рис. 1).



Рис. 1. Пример ГСИ (1) с отсчетами  $i, j, k$

При описании алгоритмов калибровки гиперспектральной аппаратуры (ГСА) будем использовать понятие двумерного или одномерного среза (субтензора) [44]. Так, в частности  $k$ -тый канал ГСИ представляется следующим срезом тензора (1):

$$S_{k_0}(i, j) = S(i, j, k_0), 1 \leq i \leq I, 1 \leq j \leq J. \quad (2)$$

Отметим, что зафиксированный индекс среза (субтензора) указывается нижним индексом, а свободные индексы указываются в скобках. Так же будем рассматривать срезы по строке  $i$  и по столбцу  $j$ ,  $S_i(j, k)$  и  $S_j(i, k)$  соответственно.

### 1.2. Пространственно-спектральные искажения сканирующего гиперспектрометра

Рассмотрим формирование  $i$ -й строки (пространственной spectroграммы) гиперспектрального изображения  $S_i(j, k)$ . Оптической системой гиперспектрометра в плоскости площадок фотоприемной матрицы формируется непрерывное распределение освещенности  $E(\lambda, x, y)$ . Здесь координаты  $(x, y)$  направлены вдоль отсчетов  $j$  и  $k$  соответственно матричного фотоприемника (которые соответствуют столбцам и каналам формируемого ГСИ). Элементы матричного фотоприемника за время формирования  $i$ -й строки ГСИ (1) интегрируют падающий на него диапазон длин волн  $\Delta\lambda$ , а также проводят пространственную дискретизацию оптического изображения по массиву  $j \times k$

светочувствительных площадок с размером стороны  $\delta$  и с шагом между их центрами  $b$ . Тогда, на основании [45] запишем:

$$S_i(j, k) = \int_{j \cdot b - 0.5\delta}^{j \cdot b + 0.5\delta} \int_{k \cdot b - 0.5\delta}^{k \cdot b + 0.5\delta} \int_{\Delta\lambda} E(\lambda, x, y) G(\lambda) d\lambda dx dy, \quad (3)$$

где  $G(\lambda)$  – спектральная чувствительность фотоприемника.

Однако в реальном приборе обычно присутствует неоднородность чувствительности  $W(x, y)$ , которую зададим как произведение двух функций:

$$W(x, y) = V(x)T(x, y), \quad (4)$$

где  $V(x)T(x, y)$  – описывают неоднородность пропускания вдоль направлений длины щелевой диафрагмы и дисперсии гиперспектрометра. Тогда

$$S_i^1(j, k) = \int_{j \cdot b - 0.5\delta}^{j \cdot b + 0.5\delta} \int_{k \cdot b - 0.5\delta}^{k \cdot b + 0.5\delta} \int_{\Delta\lambda} E(\lambda, x, y) \times G(\lambda) V(x)T(x, y) d\lambda dx dy \quad (5)$$

где  $S_i^1(j, k)$  – кадр изображения с учетом неоднородности чувствительности прибора.

Примем следующее приближение, пусть функции  $V(x)$  и  $T(x, y)$  локально не изменяются для выбранной координаты пикселя  $j, k$ , тогда можно записать

$$S_i^1(j, k) = v(j)t(j, k) \times \int_{j \cdot b - 0.5\delta}^{j \cdot b + 0.5\delta} \int_{k \cdot b - 0.5\delta}^{k \cdot b + 0.5\delta} \int_{\Delta\lambda} E(\lambda, x, y) G(\lambda) d\lambda dx dy = v(j)t(j, k)S_i(j, k), \quad (6)$$

Сопоставление длин волн и каналов ГСИ, выполняется на первом этапе спектральной калибровки гиперспектрометра. Такая калибровка как правило выполняется в предположении линейной зависимости положения центральной длины волны от номера спектрального канала ГСИ [44].

Рассматриваемая в настоящей работе ГСА свободна от искажений типа «smile» [36, 46–47]. Однако, как показано в предыдущей работе [36] присутствуют искажения подобные искажениям «keystone». Экспериментальное подтверждение наличия подобных искажений получено при формировании спектра точечного источника (см. рис. 2а). Явно наблюдается изменение формы ФРТ и отклонение расположения центров ФРТ от прямой (см. на индексы  $j$  рис. 2а, индексы столбца  $j$  spectroграмм точечного источника в начале и конце диапазона должны совпадать), аналогичная ситуация для эффекта «keystone» (см. рис. 2б).

Также подтверждается наличие дополнительных искажений, которые могут визуально напоминать эффект «smile». Были проведены съемки равномерно освещенного солнечным светом белого тест объекта и съемки тест объекта освещенным монохроматическим источником (640 нм). На полученных spectroграммах выявлена зависимость позиций локальных экстремумов вдоль отсчетов  $k$  (максимумов/минимумов) у проекций спектров от отсчетов  $j$ , но в [36] показано что

позиции вдоль отсчетов  $k$  локальных максимумов у монохромного источника не изменяются и не имеют зависимости от отсчетов  $j$ . Следовательно данные искажения не являются эффектом «smile», а скорее связаны с неравномерной чувствительностью ГСА, зависящей от отсчетов  $j$  и  $k$ .

На практике это приводит к сдвигу позиций локальных экстремумов у спектров в зависимости от позиции источника света вдоль щелевой диафрагмы с отсчетами

$j$ , расположенных от 60 до 160 каналов (см. рис. 3 и 4). В красных областях рис. 3 сдвиг значительный (10–12 нм), в зеленой области – минимален, до 2,5 нм.

Данный эффект можно обозначить как «сдвиг спектральных пиков», который тоже характерен для коммерческих гиперспектрометров типа «Specim» [18–20], но подобный «сдвиг спектральных пиков» у «Specim» возникает из-за искажения типа «smile».

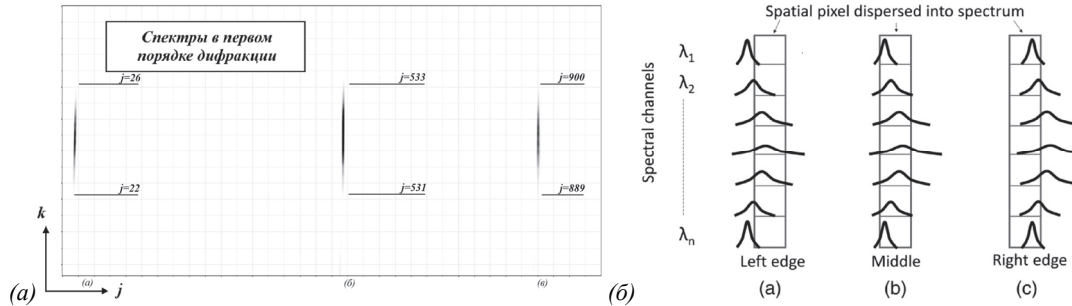


Рис. 2. ФРТ точечного источника на разных отсчетах  $j$  измерения тензора ГСИ (1). (а) Экспериментальное подтверждение искажений ФРТ, наблюдается изменение формы ФРТ и отклонение расположения центров ФРТ от прямой, (б) рис. «б» работы [11], с характерным для эффекта «keystone» распределением ФРТ по плоскости кадра сканирующего гиперспектрометра

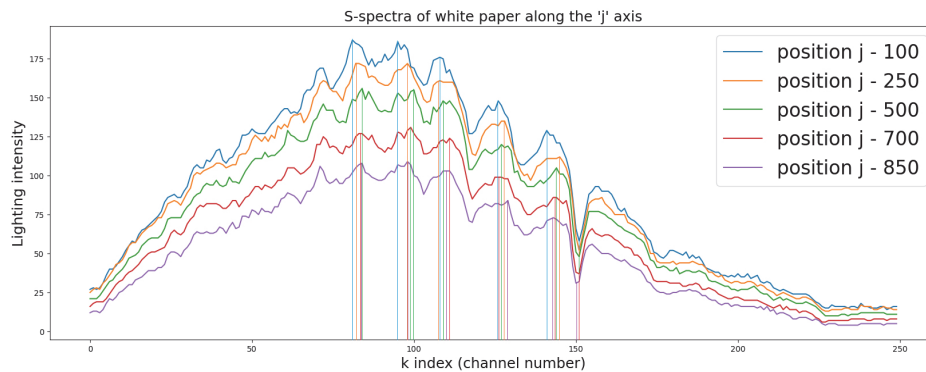


Рис. 3. Спектры белого тест объекта вдоль оси  $i$  в зависимости от номера столбца  $j$  среза  $S_i(j, k)$ , отмечены локальные экстремумы (усреднены 50 строчных срезов однородного белого объекта (ось с отсчетами  $i$ ), для компенсации шумов) [36]

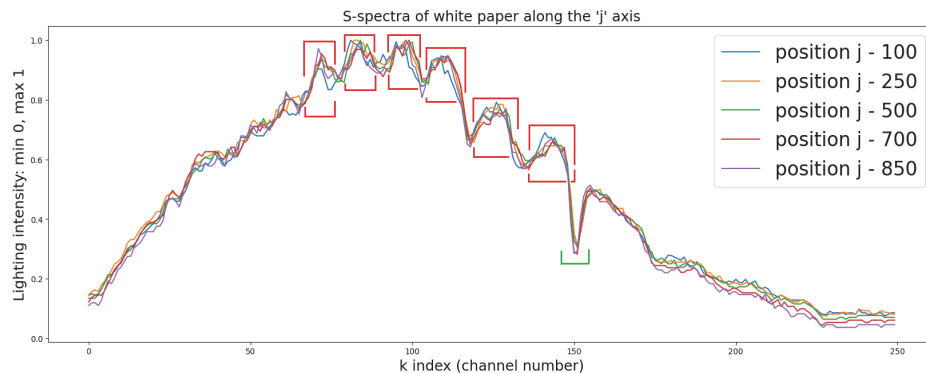


Рис. 4. Нормализованный от 0 до 1 спектр белого тест объекта в различных столбцах среза  $S_i(j, k)$ . (а) красным цветом выделены области, с значительным смещением локальных экстремумов (60–145 каналы ГСИ), (б) зеленым цветом выделена область линии Фраунгофера «А» (760 нм) позиция локального минимума меняется минимально (150 канал ГСИ) [36]

В [36] был предложен подход к компенсации указанных искажений, на основе предварительной калибровки при помощи белого эталонного объекта. В настоящей работе этот подход развивается и предлагается обучаемая версия в виде калибровочных слоев нейросети.

Используемая в настоящей работе модель искажений основана на предположении, что искажения интенсивности регистрируемого ГСИ  $S(i, j, k)$  зависят как от индекса столбца  $j$  и от индекса канала среза  $k$  (2):

$$S_i^1(j, k) = S_0(i, j)t_k(j)v(j), \tag{7}$$

где  $S_i^1(j, k)$  – строчный срез гиперспектрального изображения с искажениями,  $S_0(i, j)$  – строчный срез гиперспектрального изображения без искажений,  $v(j)$  – изменения пропускной способности вдоль щелевой диафрагмы, обусловленные изменением ширины щелевой диафрагмы, зависящие от номера столбца  $j$  ГСИ (1), при этом  $t_k(j)$  – коэффициенты, характеризующие искажение интенсивности сигнала, которое предположительно может быть связано с изменением формы ФРТ оптической системы (в зависимости позиции  $j, k$ ), с наличием виньетирования, спектрального пропускания оптической системы, спектральной чувствительности фотоприёмника и т.д. (см. рис 2–4).

**2. Калибровочная процедура для компенсации искажений**

Искажения (5) на этапе калибровки ГСА компенсируются функцией  $l_k(j)$ . Таким образом, можно получить близкое к неискаженному ГСИ:

$$\hat{S}_k(i, j) = S_k(i, j) \odot l_k(j). \tag{8}$$

Функция коррекции  $l_k(j)$  (см. рис. 6) может быть представлена в следующем виде:

$$l_k(j) = l_k^{(t)}(j) \odot l_k^{(v)}(j), \tag{9}$$

где  $l_k^{(t)}(j)$  (см. рис. 7) учитывает искажения интенсивности сигнала зависящей от  $j$  и  $k$ , представлена компонентом  $t_k$  в (7), а  $l_k^{(v)}(j)$  устраняет искажения пропускной способности щели, возникающие из-за наличия зависимости ширины щели от отсчетов  $j$ . Данные искажения представлены компонентом  $v$  в (7) (см. рис. 7).




Рис. 5. Строчный срез гиперспектрального изображения, однородного белого объекта, освещенного солнечным светом [36]

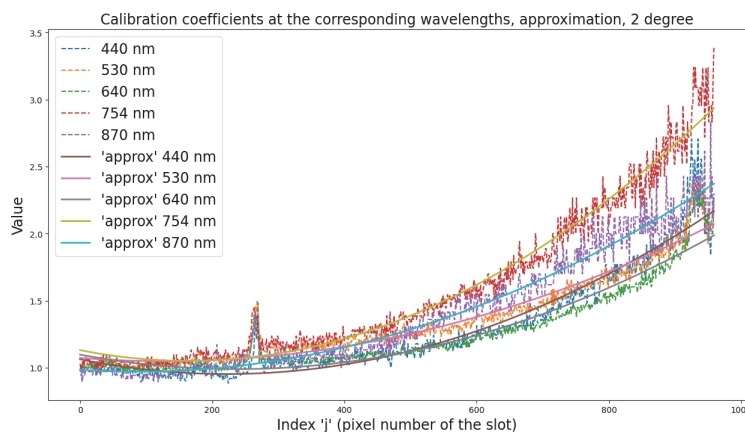


Рис. 6. Функция коррекции  $l_k(j)$  и калибровочные полиномы  $l_k^{(t)}(j)$  на каждой длине волны [36]

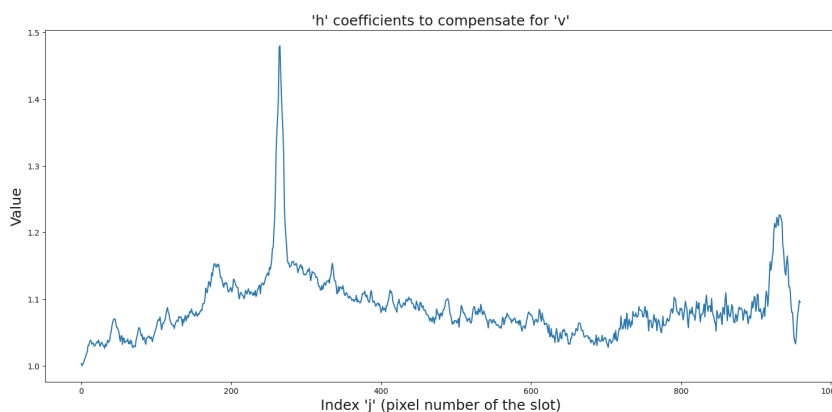


Рис. 7. Калибровочные коэффициенты  $l_k^{(v)}(j)$ , для компенсации зависимой пропускной способности щелевой диафрагмы от  $j$  у ГСА [36]

Определение  $l_k(j)$  может быть выполнено по эталонному спектру  $W_k^0(i_w, j)$  белого объекта (см. рис. 8), предварительно расположенного на снимаемой сцене, регистрируемой в строке  $i_w$ :

$$l_{k,j} = \frac{W_k(i_w, j)}{W_k^0(i_w, j)} = \frac{W_{k, i_w, j}}{W_{k, i_w, j}^0}. \tag{10}$$

Для определения  $l_k(j)$ , необходимо определить эталонный спектр  $W_k^0(i_w, j)$  белого объекта. Поскольку модель (8) предполагает мультипликативные искажения, считаем, что спектр белого объекта имеет одинаковую форму во всех столбцах  $j$  строки  $i_w$ , а амплитудные искажения определяются коэффициентами  $t_k(j)$  и  $v(j)$ . Следовательно, для определения эталонного спектра

необходимо выделить гиперпиксел с максимальной суммарной спектральной яркостью по каналам  $k$ , так как предполагается, что самый яркий спектр минимально искажен:

$$j_{\text{ref}} = \operatorname{argmax}_{1 \leq j \leq J} \sum_{k=1}^K W_k(i_w, j). \quad (11)$$



Рис. 8. Пространственная спектрограмма однородного белого тест-объекта после процедуры калибровки коэффициентами  $l_k(j)$  (без аппроксимации) (до калибровки см. рис. 5) [36]

С учетом (9) считаем спектр  $W_k^0(i_w, j)$  эталонным:

$$W_k^0(i_w, j) = W_k(i_w, j_{\text{ref}}). \quad (12)$$

Таким образом, итоговая  $l_k(j)$  определяется как:

$$l_k(j) = \frac{W_k(i_w, j_{\text{ref}})}{W_k(i_w, j)}. \quad (13)$$

Задание полиномиальной аппроксимации позволяет построить малопараметрическую модель коррекции искажений, менее чувствительную к шуму (см. рис. 6):

$$\sum_{j=1}^J [l_k(j) - l_k^{(t)}(j)]^2 \rightarrow \min, \quad (14)$$

$$l_k^{(t)}(j) = a_{k,2}j^2 + a_{k,1}j + a_{k,0}. \quad (15)$$

После процедуры коррекции искажений с использованием однородного белого объекта при помощи  $l_k(j)$  или  $l_k^{(t)}(j)$ ,  $l_k^{(v)}(j)$ , все  $S_k(i, j)$  из (8) практически совпадают с эталонным сигналом по всем координатам  $\hat{S}_k(i, j)$  в (8) (см. рис. 8 и 9).

### 3. Ограничения процедур калибровки чувствительности

Предложенная в предыдущем разделе процедура калибровки, выполняемая на этапе предобработки ГСИ накладывает ряд ограничений на сценарии прикладного применения ГСА. Можно выделить три типовых сценария получения данных при помощи ГСА:

1. Съёмка в помещении [48–49];
2. Наземная съёмка вне помещения [50–51];
3. Съёмка с борта авиационных и космических платформ [52–53].




Рис. 9. Пространственная спектрограмма однородного белого тест-объекта после процедуры калибровки коэффициентами  $l_k^{(t)}(j)$  и  $l_k^{(v)}(j)$  (с аппроксимацией) (до калибровки см. рис. 5) [36]

При съёмке в помещениях с искусственным освещением, заранее рассчитанные профили калибровки

чувствительности гиперспектрометра позволяют компенсировать искажения полученных данных.

При съёмке с космических платформ основным источником искажений является атмосфера. Её влияние обычно учитывают с помощью моделей переноса излучения и калибровочных данных. Сама платформа при этом работает в относительно стабильных условиях: орбита обеспечивает устойчивое положение, а также соблюдается равномерный температурный режим аппаратуры из-за наличия активных и пассивных устройств для регулировки температуры платформы [52].

При съёмке сцен с неконтролируемым освещением [36, 48, 54] предварительная калибровка недостаточно эффективна. В условиях, где недоступны заранее известные, стабильные и контролируемые условия съёмки, снижается эффективность предварительной калибровки, описанной в разделе 4. Следовательно, необходимо рассмотреть альтернативные методы компенсации искажений интенсивности ГСИ (1). В настоящей работе предлагается нейросетевой метод компенсации искажений, не использующий белый эталонный объект для предварительной компенсации искажений вносимых ГСА (7), тем самым учитывая аппаратные искажения без жёсткой привязки к освещению сцены.

### 4. Нейросетевая коррекция чувствительности сканирующего гиперспектрометра

#### 4.1. Обучаемая калибровочная матрица

Для компенсации искажений ГСА  $t_k(j)v(j)$  из (7) предлагается использовать обучаемую модель (калибровочные обучаемые слои), свободную от недостатков, перечисленных в предыдущем разделе. В данном случае матрицу коррекции искажений ГСА представим в виде обучаемых параметров  $M \in R^{J \times K}$  (16), где каждому сочетанию координат  $(j, k)$  у субтензора сопоставляется индивидуальный корректирующий коэффициент:

$$S_m(i, j, k) = S(i, j, k) \odot M(j, k), \quad (16)$$

где  $M(j, k)$  – коэффициент коррекции, соответствующий спектральному каналу  $k$  и позиции вдоль измерения  $j$ .

На этапе подготовки данных для обучения нейросети исходное ГСИ, ранее представленное тензором  $S(i, j, k)$  (1), разбивается на набор фрагментов, каждый из которых интерпретируется как отдельный подтензор фиксированного размера:

$$S_p(i', j', k) \in R^{H_p \times W_p \times K}, \quad (17)$$

где  $H_p, W_p$  – пространственные размеры исходного тензора  $S$  (1) вдоль измерений с индексами  $i$  и  $j$ ,  $K$  – число спектральных каналов, индекс  $k$  исходного тензора.

Калибровочные слои используют координаты вдоль измерения  $j$  исходного тензора  $S(i, j, k)$ , осуществляя позиционно-зависимую коррекцию зарегистрированных спектральных интенсивностей. Для этого каждому подтензору  $S_p \in R^{H_p \times W_p \times K}$  (17) сопоставляется вектор  $j_{pos} \in N^{H_p}$ , содержащий

координаты столбцов подтензора вдоль измерения  $j$  в исходном тензоре  $S(i, j, k)$  (1). Координаты  $j_{pos}$  используются калибровочными слоями для обращения к соответствующим обучаемым параметрам, как в матричных слоях, так и в представленных далее слоях калибровки. Коррекция осуществляется путём поэлементного умножения:

$$S_m(i', j', k) = S_p(i', j', k) \odot M(j_{pos}, k), \quad (18)$$

После применения калибровочных слоев, значения подтензора  $S_m(i, j_{pos}, k)$  дополнительно нормализуются по методу RMS-нормализации (Root Mean Square), аналогично подходу, описанному в [54]. Нормализованное значение спектрального отклика вычисляется по формуле:

$$\hat{S}_{rms}(i', j', k) = \frac{S_m(i', j', k)}{\sqrt{\frac{1}{H_p W_p K} \sum_{i', j', k} S_m(i', j', k)^2 + \varepsilon}}, \quad (19)$$

где  $\hat{S}_{rms}(i', j', k)$  – скорректированное значение интенсивности, соответствующее  $\hat{S}$  из (8);  $H_p W_p K$  – размеры подтензора;  $\varepsilon$  – малая положительная константа ( $\varepsilon = 10^{-6}$ ), предотвращающая деление на ноль.

RMS-нормализация выполняет выравнивание амплитудного масштаба подтензора, снижая чувствительность модели к абсолютному уровню яркости. Такая нормализация позволяет модели фокусироваться на форме спектрального отклика, а не на амплитуде.

#### 4.2. Полиномиальная аппроксимация калибровочной матрицы

Как описано в (14) и (15) полиномами второй степени корректируются искажения ГСА. Данный слой является полиномиальной аппроксимацией матрицы корректирующих коэффициентов (16). Для каждого спектрального канала  $k \in \{1, \dots, K\}$  вводится набор обучаемых параметров  $a_k, b_k, c_k \in R$ , определяющих форму параболы у полинома:

$$y_k(j) = a_k j^2 + b_k j + c_k, \quad (20)$$

где  $y_k(j)$  – корректирующий множитель в позиции  $j$  канала  $k$ ;  $j \in \{0, 1, \dots, J - 1\}$  – индекс вдоль измерения  $j$  в исходном тензоре (1), соответствующего координате щели ГСА;  $a_k, b_k, c_k$  – обучаемые параметры, оптимизируемые совместно с остальными параметрами нейросетевой модели.

На этапе корректирования интенсивностей подтензора (13) для каждой координаты  $j_{pos}$  вычисляется значение корректирующего коэффициента (множителя)  $y_k(j_{pos})$  где  $j_{pos}$  – глобальная координата вдоль измерения  $j$ , соответствующая позиции  $j'$  внутри подтензора. При вычислении корректирующего коэффициента  $y_k(j)$  индексы  $j$  приводятся к диапазону от 0 до 1. Коррекция осуществляется путём поэлементного умножения:

$$\hat{S}_{p,k}(i', j') = S_{p,k}(i', j') \odot y_k(j_{pos}). \quad (21)$$

Параметры полинома  $a_k, b_k, c_k \in R$ , подбираются в процессе обучения модели, что повышает обобщающую способность нейросетевой архитектуры.

#### 4.3. Векторная факторизация калибровочной матрицы

Для уменьшения числа параметров калибровочной матрицы предлагается использовать векторную факторизацию, где комбинированный коэффициент коррекции для каждой пары  $(j, k)$  определяется как:

$$M(j, k) = v(j) \cdot u(k), \quad (22)$$

где:

- $v(j) \in R^J$  – обучаемый вектор параметров по измерению столбца  $j$ ;
- $u(k) \in R^K$  – обучаемый вектор параметров по измерению каналов  $k$ .

Такое представление слоя позволяет существенно сократить число обучаемых параметров по сравнению калибровочной матрицей, сохраняя при этом возможность компенсировать пространственно-спектральные искажения. Коррекция спектрального значения осуществляется по формуле:

$$\hat{S}_v(i', j', k) = S_p(i', j', k) \cdot v(j_{pos}) \cdot u(k), \quad (23)$$

Аналогично слою с матрицей калибровки, после применения коррекции осуществляется RMS-нормализация значений спектрального подтензора  $\hat{S}_v(i', j', k)$  (23). Таким образом мы получаем  $\hat{S}_{rms}(i', j', k)$ , корректное значение, соответствующее  $\hat{S}$  из (8).

#### 4.4. Интеграция калибровочных слоев в нейросетевые модели

Предложенные обучаемые калибровочных слоев были интегрированы в две различных нейросетевых архитектуры классификации ГСИ, сверточная NM3DCNN [56] и трансформерная SSFTT (Spatial-Spectral Feature Token Transformer) [35] (см. рис. 10). Выбор архитектур обусловлен необходимостью оценки работы предлагаемых калибровочных слоев как в рамках классического свёрточного подхода, так и в современных трансформерных моделях.

В ходе работы протестированы несколько вариантов включения предложенных обучаемых калибровочных слоев в архитектуры NM3DCNN и SSFTT. Схема интеграции калибровочных слоев в архитектуры указанных моделей приведены на рис. 11. Наиболее эффективными оказались следующие конфигурации:

1. Полиномиальный слой и матрица параметров;
2. Полиномиальный слой и два вектора параметров;
3. Матрица параметров  $(j, k)$ ;
4. Два вектора параметров  $j$  и  $k$ .

Изначально NM3DCNN и SSFTT имеют 95316 и 1166132 обучаемых параметров соответственно. Количество обучаемых параметров нейросетевых моделей при модификации различными комбинациями калибровочных слоев изменилось следующим образом (см. Таб. 1).

Для оценки возможности использования предобученных калибровочных слоёв вне обученной нейронной сети для предобработки данных, был проведён отдельный эксперимент. Модель с калибровочным слоем обучалась, после чего параметры калибровочного слоя использовались для предварительной обработки данных. Далее, обучение выполнялось на базовой модели без дополнительных калибровочных слоёв. Результат классификации показал, что исходная модель на предобработанных данных демонстрирует производительность, сопоставимую с результатами моделей, включающих калибровочные слои.

Модель без калибровочных слоёв показала метрики acc и f1-score 76,51 % 75,27 % соответственно, на одном из двадцати «фолдов» обучающей выборки. С калибровочным слоем, представленным в виде калибровочной матрицы, метрики классификации составили 81,42% 80,96% (acc и f1-score) для архитектуры NM3DCNN, что обеспечило значительный прирост качества классификации. Это подтверждает возможность использования предобученных калибровочных слоёв для предварительной коррекции данных и подтверждает свойство переносимости предобученных весов.

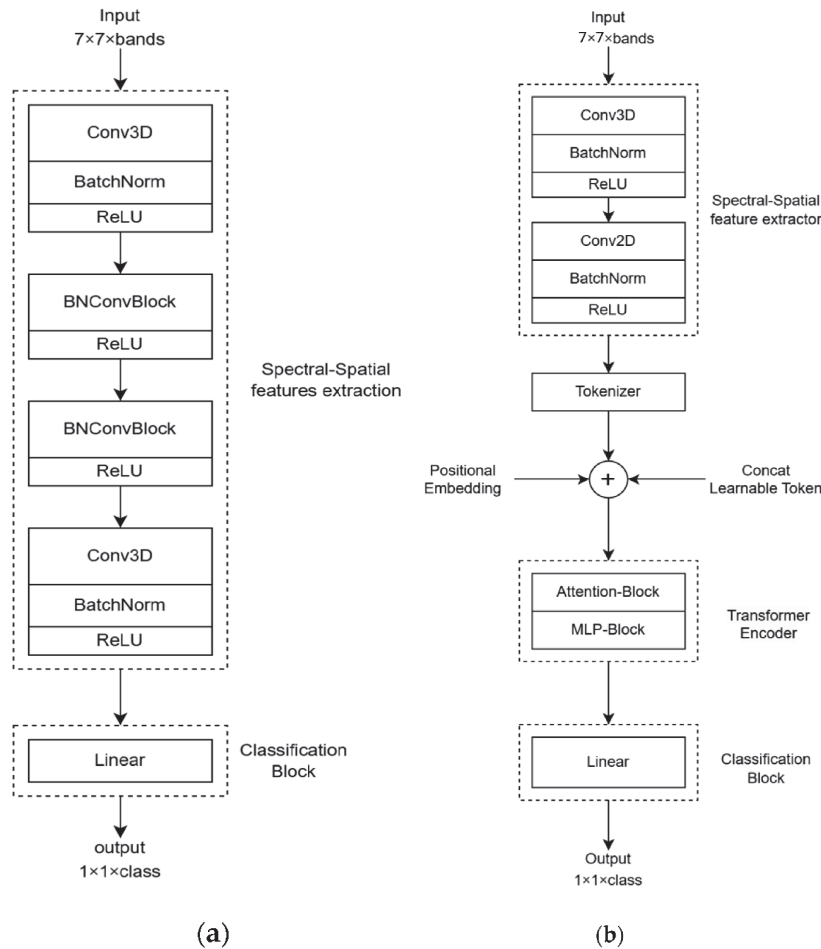


Рис. 10. Архитектуры нейросетей. (а) NM3DCNN, (б) SSFTT

Таб. 1. Оценка количества обучаемых параметров при добавлении калибровочных слоёв в нейросетевую модель

Архитектуры	Базовая архитектура без калибровки	Базовая архитектура + матрица калибровки	Базовая архитектура + векторная факторизация матрицы калибровки	Базовая архитектура + полиномиальная аппроксимация и векторная факторизация	Полиномиальная аппроксимация и матрица калибровки
NM3DCNN	95316	335316	96526	97276	336066
SSFTT	1166132	1406132	1167342	1168092	1406882

### 5. Экспериментальное исследование

#### 5.1. Наборы данных

В экспериментах использовались два гиперспектральных изображения [36] – ГСИ №1 и ГСИ №2 (см.

рис. 12 и 13), полученные одним и тем же сканирующим гиперспектрометром [50] при близких, но отличающихся условиях съёмки. В обеих сценах представлен один и тот же набор объектов, с различной освещённостью сцены, вследствие чего полученные ГСИ

далее рассматриваются как принадлежащие различным доменам. Размер каждого гиперспектрального куба составляет  $3000 \times 960 \times 250$ , где измерения куба соответствуют отчетам  $i, j, k$  соответственно. В экспериментальном наборе данных для каждого ГСИ также существует разметка, где каждому гиперпикселу соотносится значение от 0 до 3, четыре класса: кукуруза, овёс, сорняк и области, которые не используются в эксперименте (см. рис. 14) [36]. Пиксели, не относящиеся к целевым классам, объединены в класс 0 и исключены из анализа.

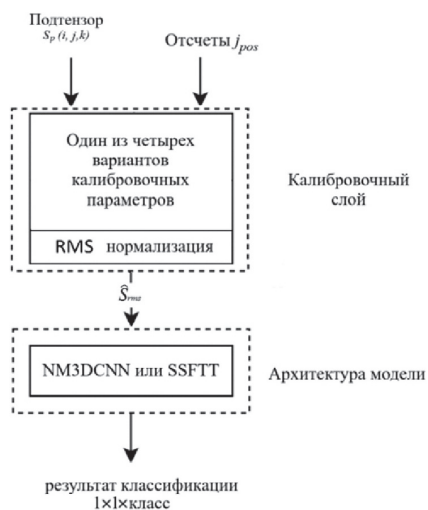


Рис. 11. Схема интеграции калибровочных слоев в архитектуру моделей классификации ГСИ

### 5.2. Методика экспериментального исследования

Для оценки эффективности предложенных обучаемых калибровочных слоев были проведены эксперименты с двумя гиперспектральными изображениями, полученными в разных условиях съёмки. Обучение выполнялось на одном изображении, тестирование – на втором. Затем ГСИ менялись местами, и эксперименты повторялись. Разметка обучающего изображения разбивалась на 20 непересекающихся подмножеств, содержащих по 5% пикселей каждого целевого класса. На каждом запуске использовалось одно из подмножеств, тестирование проводилось на

полном втором изображении. Таким образом, для каждой конфигурации выполнялось 20 независимых запусков. Обучение проводилось в течение 30 эпох. Пример графиков обучения нейросетевых моделей представлен на рис. 15. Параметры обучения приведены в Таб. 2.




Рис. 12. Цветосинтез гиперспектрального изображения №1 [36]




Рис. 13. Цветосинтез гиперспектрального изображения №2 [36]

Производилось сравнение следующих конфигураций моделей NM3DCNN и SSFTT:

1. Без калибровочного слоя (базовая модель);
2. Матрица параметров;
3. Слой векторной факторизации матрицы параметров;
4. Полиномиальный слой и слой векторной факторизации;
5. Полиномиальный слой и калибровочная матрица параметров;

#### 5.2.2. Анализ результатов эксперимента

Качество классификации представлено в таб. 3 и 4. В большинстве сценариев добавление обучаемых калибровочных слоев приводит к повышению качества классификации по сравнению с исходными версиями моделей без калибровки.




Рис. 14. Визуализация разметки данных. (а) Разметка ГСИ №1, (б) Разметка ГСИ №2 [36]




Рис. 15. Пример графиков обучения нейросетевых моделей, accuracy и loss (CrossEntropyLoss) (NM3DCNN + полиномиальная аппроксимация + векторная факторизация калибровочной матрицы)

Таб. 2. Параметры обучения нейросетевых архитектур

Архитектура	SSFTT	NM3DCNN
Оптимизатор	SGD	SGD
Начальная скорость обучения (lr)	0.0005	0.01
Планировщик (scheduler)	StepLR	StepLR
Параметры планировщика	step_size = 10, gamma = 0.5	step_size = 5, gamma = 0.5
Функция потерь	CrossEntropyLoss	CrossEntropyLoss
Кол-во эпох	20	20
Размер батча	256	256
Размер патча	1 × 250 × 7 × 7	1 × 250 × 7 × 7

Таб. 3. Качество классификации (accuracy) для базовых моделей и моделей с различными типами обучаемых калибровочных слоев

Архитектуры	Сценарий эксперимента: (обучение → тест)	Базовая архитектура без калибровки	Базовая архитектура ++ матрица калибровки	Базовая архитектура + + векторная факторизация матрицы калибровки	Базовая архитектура + + полиномиальная аппроксимация и векторная факторизация	Базовая архитектура + + полиномиальная аппроксимация и матрица калибровки
NM3DCNN	№2 → №1	0,7839	0,9269	0,9204	0,9243	<b>0,9349</b>
	№1 → №2	0,7982	0,7902	0,7922	0,7996	<b>0,8041</b>
SSFTT	№2 → №1	0,7880	0,8930	0,8929	0,8987	<b>0,9066</b>
	№1 → №2	0,7698	0,7547	0,7576	<b>0,7760</b>	0,7662

Для NM3DCNN наибольший прирост наблюдается в сценарии ГСИ №2 → ГСИ №1 при использовании полиномиальной аппроксимации и матрицы калибровки, где точность (асс) достигла 0,9349 при 0,7839 в базовой модели, а F1-score вырос с 0,8150 до 0,9377. Средний прирост при использовании калибровочных слоев составил 14,27% для ассурасу и 11,46% для F1-score. В сценарии ГСИ №1 → ГСИ №2 прирост модели при использовании полиномиальной аппроксимации и матрицы калибровки составил 0,59% и 1,97% соответственно. В некоторых конфигурациях калибровочные слои снижали качество классификации.

Для SSFTT наибольший эффект также наблюдается в сценарии ГСИ №2 → ГСИ №1, где калибровочный слой в виде полиномиальной аппроксимации и матрицы калибровки повысил ассурасу с 0,7880 до 0,9066, а F1-score – с 0,8144 до 0,9090. Средний прирост составил 10,98% и 8,67% соответственно. В

обратном сценарии ГСИ №1 → ГСИ №2 прирост составил 0,62% ассурасу и 0,17% F1-score у комбинации слоев полиномиальной аппроксимации и векторной факторизации матрицы калибровки. В остальных конфигурациях калибровочные слои снижали качество классификации.

Из полученных значений метрик ассурасу и F1-score видно, что для трансформерной архитектуры SSFTT наиболее стабильный прирост достигается при использовании комбинаций слоев с полиномиальной аппроксимацией и векторной факторизацией матрицы калибровки, поскольку в обоих сценариях данная конфигурация обеспечила повышение значений метрик.

Устойчивый положительный эффект для архитектуры NM3DCNN наблюдается при использовании слоев с полиномиальной аппроксимацией в сочетании с векторной факторизацией или с матрицей калибровки.

Таб. 4. Качество классификации (*f1-score*) для базовых моделей и моделей с различными типами обучаемых калибровочных слоев

Архитектуры	Сценарий эксперимента: (обучение→тест)	Базовая архитектура без калибровки	Базовая архитектура + матрица калибровки	Базовая архитектура + векторная факторизация матрицы калибровки	Базовая архитектура + полиномиальная аппроксимация и векторная факторизация	Полиномиальная аппроксимация и матрица калибровки
NM3DCNN	№2 → №1	0,8150	0,9300	0,9235	0,9273	<b>0,9377</b>
	№1 → №2	0,7808	0,7862	0,7889	0,7958	<b>0,8005</b>
SSFTT	№2 → №1	0,8144	0,8974	0,8971	0,9010	<b>0,9090</b>
	№1 → №2	0,7652	0,7437	0,7472	<b>0,7669</b>	0,7565




Рис. 16. Строчный срез гиперспектрального изображения, однородного белого объекта, освещенного солнечным светом до/после нейросетевой калибровки (полиномиальная аппроксимация и векторная факторизация калибровочной матрицы)

Визуально также можно оценить преобразование гиперспектральных данных калибровочным слоем после обучения на рисунках 16 – 18.

На рис. 16 приведен пример нейросетевой калибровки пространственной спектрограммы белого тест объекта, демонстрируется что метрика RMSE [57] уменьшается после калибровки, что подтверждает «успешность» процедуры калибровки. На рис. 17 представлено сравнение прямых, аппроксимирующих методом наименьших квадратов распределение интенсивности сигнала вдоль координаты *j* в области ГСИ №2 (*i*=700), содержащей однородные объекты (растение «овес»). На а рис. 18 демонстрируются «калибровочные» полиномы.

### Заключение

В работе разработан метод использования обучаемых калибровочных слоев для компенсации позиционно–зависимой чувствительности сканирующего гиперспектрометра. Представленные калибровочные слои не компенсируют пространственные искажения, но частично компенсируют неравномерную пространственно–

спектральную чувствительность гиперспектрометра. Рассмотрены три типа слоев – матричный, полиномиальный и векторно факторизованный, а также их комбинации, интегрированные как входные слои свёрточных и трансформерных архитектур. Сравнение эффективности проведено на задаче поэлементной классификации объектов на гиперспектральных данных, полученных при различных условиях съёмки.

Результаты экспериментов показали, что включение обучаемых слоев в свёрточные и трансформерные модели позволяет повысить качество поэлементной классификации по сравнению с теми же моделями без калибровочных слоев в прикладной задаче сельского хозяйства: распознавания культурных и сорных растений. Предложенный подход не требует проведения отдельного этапа калибровки и способна адаптироваться к особенностям условий в процессе обучения. Экспериментально подтверждена переносимость разработанных калибровочных слоев на нейросетевые модели без калибровочных слоев, в виде предварительной калибровки данных, используемых в эксперименте. В дальнейшем планируется: расширить сравнительный анализ нейросетевых моделей поэлементной классификации, использовать более разнообразные наборы данных, а также исследовать возможность развития предложенных калибровочных модулей.

### Благодарности

Статья подготовлена при финансовой поддержке Министерства науки и высшего образования Российской Федерации, грант № 075–15–2025–610.

### References

- [1] Lu B, Dao PD, Liu J, He Y, Shang J. Recent advances of hyperspectral imaging technology and applications in agriculture. *Remote Sens* 2020; 12(16): 2659. DOI: 10.3390/rs12162659.
- [2] Bhargava A, Ijaz MF, Do DT. Hyperspectral imaging and its applications: A review. *Heliyon* 2024; 10(11): e33208. DOI: 10.1016/j.heliyon.2024.e33208.
- [3] Yu K. A critical review on applications of hyperspectral remote sensing in crop monitoring. *Exp Agric* 2022; 58(5): 607–628. DOI: 10.1017/S0014479722000278.
- [4] Stuart MB, McGonigle AJS, Willmott JR. Hyperspectral imaging in environmental monitoring: A review of recent developments and technological advances in compact field deployable systems. *Sensors* 2019; 19(14): 3071. DOI: 10.3390/s19143071.

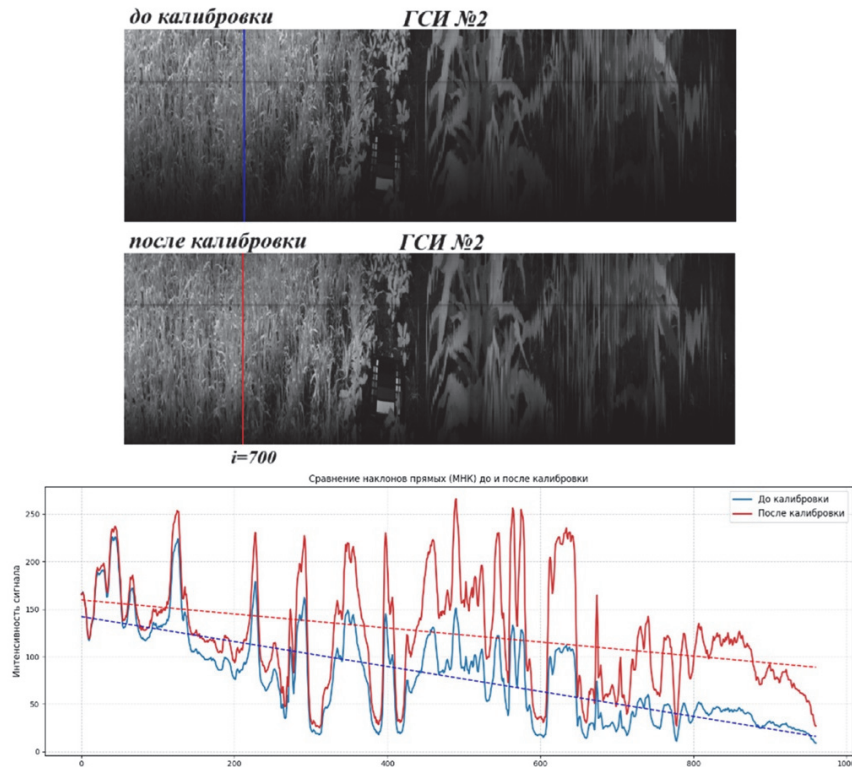


Рис. 17. Слой ГСИ до после калибровки ГСИ №1 и ГСИ №2 (полиномиальная аппроксимация и векторная факторизация калибровочной матрицы)




Рис. 18. Визуализация калибровочных полиномов вместе с векторной факторизацией матрицы параметров (NM3DCNN)

[5] Alanazi H, Almotiri S, Alqahtani H, Alharthi A, Alsubaie N. A hybrid graph–spatial spectral transformer framework for hyperspectral image analysis. *J Phys Conf Ser* 2024; 2906(1): 012025. DOI: 10.1088/1742–6596/2906/1/012025.

[6] Gewali UB, Monteiro ST, Saber E. Machine learning based hyperspectral image analysis: A survey. *arXiv:1802.08701 [cs.CV]*; 2018. Available from: <https://arxiv.org/abs/1802.08701>.

[7] Jia B, Wang W, Ni X, Lawrence KC, Zhuang H, Yoon S–C, Gao Z. Essential processing methods of hyperspectral images of agricultural and food products. *Chemometrics and Intelligent Laboratory Systems* 2020; 198: 103936. DOI: 10.1016/j.chemolab.2020.103936

[8] Al–Hourani A, Balendhran S, Walia S, Hourani T. Line Scan Hyperspectral Imaging Framework for Open Source Low–Cost Platforms. *Remote Sensing* 2023; 15(11): 2787. DOI: 10.3390/rs15112787.

[9] Liu X, Jiang Z, Wang T, Cai F, Wang D. Fast hyperspectral imager driven by a low–cost and compact galvo–mirror. *Optics & Laser Technology* 2021; 140: 106987. DOI: 10.1016/j.ijleo.2020.165716.

[10] Gao L, Smith R T. Optical hyperspectral imaging in microscopy and spectroscopy – a review of data acquisition. *J Biophotonics* 2015; 8(6): 441–456. DOI: 10.1002/jbio.201400051.

[11] Høyе G, Løke T, Fridman A. Method for quantifying image quality in push–broom hyperspectral cameras. *Opt Eng* 2015; 54(5): 053102. DOI: 10.1117/1.OE.54.5.053102.

[12] Jablonski J, Durell C, Slonecker ET, Wong KKA, Simon B, Eichelberger A, Osterberg J. Best practices in passive remote sensing VNIR hyperspectral system hardware calibrations. *Proc SPIE* 2016; 9860: 98600D. DOI: 10.1117/12.2223012.

[13] Leung MCH, Chen S, Jurgenson C. Accurately measuring hyperspectral imaging distortion in grating spectrographs using a clustering algorithm. *Proc SPIE* 2022; 12188: 121883W. DOI: 10.1117/12.2630442.

[14] Yokoya N, Miyamura N, Iwasaki A. Preprocessing of hyperspectral imagery with consideration of smile and keystone properties. In: Larar AM, Chung H–S, Suzuki M, eds. *Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques, and Applications III*. *Proc SPIE* 2010; 7857: 73–81. DOI: 10.1117/12.870437.

- [15] Bakker W, van der Werff HMA, van der Meer FD. Determining smile and keystone of hyperspectral lab cameras. In: Proc. of the 10th Workshop on Hyperspectral Imaging and Signal Processing (WHISPERS) 2019; 1–5. DOI: 10.1109/WHISPERS.2019.8921045
- [16] Riihihio K.A., Eskelinen M.A., Pölonen I. A do-it-yourself hyperspectral imager brought to practice with open-source Python. *Sensors* 2021; 21(4): 1072. DOI: 10.3390/s21041072.
- [17] Morales A, Horstrand P, Guerra R, Leon R, Ortega S, Díaz M, Melián JM, López S, López JF, Callico GM, Martel E, Sarmiento R. Laboratory hyperspectral image acquisition system setup and validation. *Sensors* 2022; 22(6): 2159. DOI: 10.3390/s22062159.
- [18] Specim, Spectral Imaging Ltd. FX17 Reference Manual. 2016. Source: <https://ftp.stemmer-imaging.com/webdav/docmanager/152613-Specim-FX17-Reference-Manual.pdf>.
- [19] Aasen H, Kirchgessner N, Walter A, et al. Specim IQ: Evaluation of a new, miniaturized handheld hyperspectral camera and its application for plant phenotyping and disease detection. *Sensors* 2018; 18(2): 441. DOI: 10.3390/s18020441.
- [20] Zhang X, Liu F, He Y, Li X. Application of hyperspectral imaging and chemometric calibrations for variety discrimination of maize seeds. *Sensors* 2012; 12(12): 17234–17246. DOI: 10.3390/s121217234.
- [21] Hu X, Ma Y, Zhao J, Li W, Sun L, Zhang Y. A novel scene-based non-uniformity correction method for short-wavelength infrared push-broom hyperspectral sensors. *ISPRS J Photogram Remote Sens* 2017; 131: 160–169. DOI: 10.1016/j.isprs.2017.08.006.
- [22] Shaikh MS, Jaferzadeh K, Thörnberg B, Casselgren J. Calibration of a hyper-spectral imaging system using a low-cost reference. *Sensors* 2021; 21(11): 3738. <https://doi.org/10.3390/s21113738>.
- [23] Kosce M, Bürmen M, Tomažević D, Pernuš F, Likar B. Characterization of a spectrograph-based hyperspectral imaging system. *Optics Express* 2013; 21(10): 12085–12099. DOI: 10.1364/OE.21.012085.
- [24] Høye G, Fridman A. Spatial misregistration in hyperspectral cameras: lab characterization and impact on data quality in real-world images. *Opt Eng* 2020; 59(8): 084103. DOI: 10.1117/1.OE.59.8.084103.
- [25] Wang A, Wang Y, Chen Y. Hyperspectral image classification based on convolutional neural network and random forest. *Remote Sens Lett* 2019; 10(11): 1086–1094. DOI: 10.1080/2150704X.2019.1649736.
- [26] Jablonski J, Durell C, Slonecker ET, Wong KKA, Simon B, Eichelberger A, Osterberg J. Best practices in passive remote sensing VNIR hyperspectral system hardware calibrations. *Proc SPIE* 2016; 9860: 9860 04. DOI: 10.1117/12.2224022.
- [27] Aasen H, Honkavaara E, Lucieer A, Zarco-Tejada PJ. Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: A review of sensor technology, measurement procedures, and data correction workflows. *Remote Sens* 2018; 10(7): 1091. DOI: 10.3390/rs10071091.
- [28] Gómez-Chova L, Alonso L, Guanter L, Camps-Valls G, Calpe J, Moreno J. Correction of systematic spatial noise in push-broom hyperspectral sensors: Application to CHRIS/PROBA images. *Appl Opt* 2008; 47(28): F46–F60. DOI: 10.1364/AO.47.000F46.
- [29] Markelin L, Honkavaara E, Takala T, Pellikka P. Calibration and validation of hyperspectral imagery using a permanent test field. In: Proc 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS); 2013. p. 1–4. DOI: 10.1109/WHISPERS.2013.8080708.
- [30] Noël S, Bramstedt K, Bovensmann H, Gerilowski K, Burrows J P, Standfuss C, Dufour E, Veihelmann B. Quantification and mitigation of the impact of scene inhomogeneity on Sentinel-4 UVN UV-VIS retrievals. *Atmospheric Measurement Techniques*. 2012;5(6):1319–1331. DOI: 10.5194/amt-5-1319-2012.
- [31] Firsov N, Podlipnov V, Ivliev N, Nikolaev P, Mashkov S, Ishkin P, Skidanov R, Nikonorov A. Neural network-aided classification of hyperspectral vegetation images with a training sample generated using an adaptive vegetation index. *Comput Opt* 2021; 45(6): 887–896. DOI: 10.18287/2412-6179-CO-890.
- [32] Firat H, Asker ME, Hanbay D. Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN. *Remote Sens Appl Soc Environ* 2022; 25: 100694. DOI: 10.1016/j.rsase.2022.100694.
- [33] Zhao J, Hu L, Huang L, Wang C, Liang D. MSRA-G: Combination of multi-scale residual attention network and generative adversarial networks for hyperspectral image classification. *Eng Appl Artif Intell* 2023; 121: 106017. DOI: 10.1016/j.engappai.2023.106017.
- [34] Hong D, Han Z, Yao J, Gao L, Zhang B, Plaza A, Chanussot J. SpectralFormer: Rethinking hyperspectral image classification with transformers. *IEEE Trans Geosci Remote Sens* 2022; 60: 5518615. DOI: 10.1109/TGRS.2021.3130716.
- [35] Sun L, Zhao G, Zheng Y, Wu Z. Spectral-spatial feature tokenization transformer for hyperspectral image classification. *IEEE Trans Geosci Remote Sens* 2022; 60: 5522214. DOI: 10.1109/TGRS.2022.3144158
- [36] Makarov A, Mirpulatov I, Firsov N, Lobanov V, Illarionova S, Podlipnov V, Vybornova Y, Shadrin D, Rastorguev A, Skidanov R, Burnaev E, Nikonorov A. Deep spectral-spatial transformer for robust hyperspectral image segmentation in varying field conditions. *IEEE Access* 2025; 13: 97453–97467. DOI: 10.1109/ACCESS.2025.3575699.
- [37] Shajkofci A, Liebling M. Spatially-variant CNN-based point spread function estimation for blind deconvolution and depth estimation in optical microscopy. *IEEE Trans Image Process* 2020; 29: 5848 – 5861. DOI: 10.1109/TIP.2020.2986880
- [38] Xu J, Yin Q, Guo P, Zheng X. Two-dimensional multi-fiber spectrum image correction based on machine learning techniques. *arXiv preprint arXiv:2002.06600 [astro-ph.IM]*; 2020. Available from: <https://doi.org/10.48550/arXiv.2002.06600>.
- [39] Gashnikov MV, Soifer VA, eds. Promising information technologies for Earth remote sensing [In Russian]. Samara: Samara State Aerospace University named after acad. S.P. Korolev (National Research University); 2015. 255 p. ISBN 978-5-88940-138-4.
- [40] Ligan B, Jbilou K, Kalloubi F, Ratnani A. Parameter-efficient fine-tuning of multispectral foundation models for hyperspectral image classification. *arXiv preprint arXiv:2505.15334 [cs.CV]*; 2025. Available from: <https://arxiv.org/abs/2505.15334>. DOI: 10.48550/arXiv.2505.15334.
- [41] Zidi FAA, Bouchari JE, Sellam AZ, Wafi A, Distant C, Bekhouche SE, Taleb-Ahmed A. LoLA-SpecViT: Local attention SwiGLU Vision Transformer with LoRA for hyperspectral visualization. *arXiv preprint arXiv:2506.17759 [cs.CV]*; 2025. Available from: <https://arxiv.org/abs/2506.17759>. DOI: 10.48550/arXiv.2506.17759.

- [42] Duan Y, Wang N, Zhang Y, Song C. Tensor-based sparse representation for hyperspectral image reconstruction using RGB inputs. *Mathematics* 2024; 12(5): 708. DOI: 10.3390/math12050708.
- [43] Ren Y, Liu L, Yang H, Zhang J, Yang X. Hyperspectral image spectral-spatial feature extraction via tensor principal component analysis. arXiv preprint arXiv:2412.06075 [cs.CV]; 2024. Available at: <https://arxiv.org/abs/2412.06075>.
- [44] Ozdemir A, Iwen MA, Aviyente S. A multiscale approach for tensor denoising. In book: Proc. IEEE Statistical Signal Processing Workshop (SSP). 2016: 1–5. Source: [https://users.math.msu.edu/users/iwenmark/Papers/SSP16\\_alp.pdf](https://users.math.msu.edu/users/iwenmark/Papers/SSP16_alp.pdf).
- [45] Rastorguev AA, Kharitonov SI, Kazanskiy NL. Modeling of image formation with a space-borne Offner hyperspectrometer. *Comput Opt* 2020; 44(1): 12–21. DOI: 10.18287/2412-6179-CO-644.
- [46] Wanajaroen W, Lepine T, Chartsiriwattana P, Wannawichian S, Rujopakarn W, Poshyachinda S, Soonthornthum B. TSC-1 Offner spectrometer prototype characterization. *Photonics* 2024; 11(7): 644. DOI: 10.3390/photonics11070644.
- [47] Mouroulis P, Green RO, Chrien TG. Design of pushbroom imaging spectrometers for optimum recovery of spectroscopic and spatial information. *Appl Opt* 2000; 39(13): 2210–2220. DOI: 10.1364/AO.39.002210.
- [48] Stergar J, Ravbar M, Pernuš F, Likar B, Majaron H. Design of a laboratory setup for the calibration of hyperspectral imaging systems. *Sensors* 2022; 22(18): 6811. DOI: 10.3390/s22186811.
- [49] Shaikh S, Lohumi S, Lee H, Mo C, Cho B–K. Performance evaluation of a low-cost diffuse reflectance standard for hyperspectral imaging system calibration. *Sensors* 2021; 21(2): 697.
- [50] Gaidel AV, Podlipnov VV, Ivliev NA, Paringer RA, Ishkin PA, Mashkov SV, Skidanov RV. Agricultural plant hyperspectral imaging dataset. *Computer Optics* 2023; 47(3): 442–450. DOI: 10.18287/2412-6179-CO-1226.
- [51] Benelli A, Cevoli C, Fabbri A. In-field hyperspectral imaging: An overview on the ground-based applications in agriculture. *J Agric Eng* 2020; 51(3): 129–139. DOI: 10.4081/jae.2020.1030.
- [52] Galeazzi C, Carpentiero R, De Cosmo V, Garramone L, Longo F, Lopinto E, Varacalli G. The PRISMA system and PAN/HYP instrument. In: Proc 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS) 2009: 10. Available from: [https://old.earsel.org/workshops/IS\\_Tel-Aviv\\_2009/PDF/earsel-PROCEEDINGS/3020%20Galeazzi.pdf](https://old.earsel.org/workshops/IS_Tel-Aviv_2009/PDF/earsel-PROCEEDINGS/3020%20Galeazzi.pdf)
- [53] Nansen C, Mishra S, Prabhakar M, Roberts S, Andow D, Paris J. Radiometric calibration and repeatability assessment of hyperspectral imaging from UAV platforms. *Front Plant Sci* 2023; 14: 1051410. DOI: 10.3389/fpls.2023.1051410.
- [54] Suomalainen J, Näsi R, Hakala T, Viljanen N, Peltoniemi JI, Kaasalainen S. Direct reflectance transformation methodology for drone-based hyperspectral imaging. *Remote Sens Environ* 2021; 266: 112691. DOI: 10.1016/j.rse.2021.112691.
- [55] Shen S, Yao Z, Gholami A, Mahoney MW, Keutzer K. PowerNorm: Rethinking batch normalization in transformers. In: Proc Int Conf on Machine Learning (ICML); 2020. PMLR. arXiv preprint arXiv:2003.07845. Available from: <https://arxiv.org/abs/2003.07845>. DOI: 10.48550/arXiv.2003.07845
- [56] Firsov N A, Podlipnov V V, Ivliev N A, Ryskova D D, Pirogov A V, Muzyka A A, Makarov A R, Lobanov V E, Platonov V I, Babichev A N, Monastyrskiy V A, Olgarenko V I, Nikolaev D P, Skidanov R V, Nikonorov A V, Kazanskiy N L, Soyfer V A. Ensembles of spectral-spatial convolutional neural network models for classifying soil types in hyperspectral images. *Computer Optics* 2023; 47(5): 795–805. DOI: 10.18287/2412-6179-CO-1260.
- [57] Chai T, Draxler RR. Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. *Geosci Model Dev* 2014; 7(3): 1247–1250. DOI: 10.5194/gmd-7-1247-2014.

#### Сведения об авторах

**Макаров Андрей Романович**, 1999 года рождения, аспирант кафедры суперкомпьютеров и общей информатики Самарского университета, работает инженером в лаборатории интеллектуального анализа видеоданных Института систем обработки изображений, НИЦ «Курчатовский институт». E-mail: [andre.makar1999@gmail.com](mailto:andre.makar1999@gmail.com)

**Никоноров Артём Владимирович**, 1979 года рождения, в 2005 году окончил Самарский национальный исследовательский университет им. академика С.П. Королева. Доктор технических наук (2016). В настоящее время работает профессором кафедры суперкомпьютеров и общей информатики Самарского национального исследовательского университета им. академика С.П. Королева, ведущим научным сотрудником в лаборатории интеллектуального анализа видеоданных Института систем обработки изображений, НИЦ «Курчатовский институт». Опубликовал более 90 работ, две монографии. E-mail: [artniko@gmail.com](mailto:artniko@gmail.com)

Поступила в редакцию 15 февраля 2025 г. Окончательный вариант – 29 октября 2025 г.

---

# Neural-based spatial-spectral sensitivity correction for push-brum hyperspectral cameras

A.R. Makarov<sup>1</sup>, A.V. Nikonorov<sup>1</sup>

<sup>1</sup> Samara National Research University, Moskovskoye Shosse 34, Samara, 443086, Russia;

## Abstract

A neural network-based method for trainable spatial-spectral sensitivity correction of a push-broom hyperspectral sensor is proposed. Unlike traditional calibration approaches that equalize the recorded signal from a uniformly illuminated Lambertian reference target along the slit using pre-computed correction coefficients, the proposed calibration is implemented as neural network layers whose parameters are jointly optimized with the classification model during training. Three types of trainable calibration layers have been developed, based on a learnable matrix of correction coefficients, its partial polynomial approximation, and vector factorization. Experimental evaluation was conducted on hyperspectral images acquired under similar but not identical capture conditions. The calibration layers were integrated into a 3D convolutional neural network and a spatial-spectral transformer. The results demonstrate a consistent improvement in classification quality compared to baseline models without calibration: the accuracy increased by 0.59% to 14.27%, and the F1-score increased by 0.17% to 10.98%, which confirms the effectiveness of the proposed layers.

**Keywords:** hyperspectrometer, parametric correction layers, deep learning, classification, position-dependent hyperspectrometer sensitivity correction.

**Citation:** Makarov AR, Nikonorov AV. Neural-based spatial-spectral sensitivity correction for pushbrum hyperspectral cameras. *Computer Optics* 2025; 49(6): 947–960. DOI: 10.18287/COJ1812.

**Acknowledgements:** This work was supported by the Ministry of science and higher education of the Russian Federation, grant No 075–15–2025–610.

---

## About authors

**Andrey Romanovich Makarov** (b. 1999), a Ph.D. student at the Department of Supercomputing and General Informatics of Samara University. He works as an engineer in the Laboratory of Intelligent Video Data Analysis at the Institute of Image Processing Systems, NRC "Kurchatov Institute". E-mail: [andre.makar1999@gmail.com](mailto:andre.makar1999@gmail.com)

**Artem Vladimirovich Nikonorov** (b. 1979), graduated from Samara National Research University in 2002. He received his PhD degree in 2005 and DrSc in 2016. Now he works as a Director of Mobility AI Center in Samara National Research University. He has more than 90 publications, two monographs. Field of scientific interest: pattern recognition and image analysis, system identification, parallel and distributed programming, GPGPU programming. E-mail: [artniko@gmail.com](mailto:artniko@gmail.com)

---

Received February 15, 2025. The final version – October 29, 2025.

---