

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ИЗОБРАЖЕНИЯ МЕСТНОСТИ С УЧЕТОМ ГИПЕРСПЕКТРАЛЬНЫХ И СПЕКТРАЛЬНО-ПОЛЯРИЗАЦИОННЫХ ХАРАКТЕРИСТИК

А.В. Сергеенко, А.В. Хижняк, А.Ю. Липлянин

Военная академия Республики Беларусь, Минск

MATHEMATICAL MODEL OF THE TERRAIN IMAGE TAKING INTO ACCOUNT HYPERSPECTRAL AND SPECTRAL-POLARIZATION CHARACTERISTICS

A.V. Siarheyenka, A.V. Khizniak, A.Y. Liplianin

Military Academy of the Republic of Belarus, Minsk

Аннотация. В статье представлена разработанная математическая модель изображения, содержащая гиперспектральные и спектрально-поляризационные характеристики наблюдаемой сцены для оптико-электронных систем. Особенностью предложенной модели являются, во-первых, наличие гиперспектральных и спектрально-поляризационных характеристик; во-вторых, использование авторской математической модели для построения карты областей фоновой составляющей; в-третьих, использование искусственной нейронной сети для формирования гиперспектральных характеристик. В статье приведены количественные оценки адекватности разработанной и существующих математических моделей.

Ключевые слова: математическая модель, гиперспектральная характеристика, спектрально-поляризационная характеристика, искусственная нейронная сеть.

Для цитирования: Сергеенко, А.В. Математическая модель изображения местности с учетом гиперспектральных и спектрально-поляризационных характеристик / А.В. Сергеенко, А.В. Хижняк, А.Ю. Липлянин // Проблемы физики, математики и техники. – 2026. – № 1 (66). – С. 98–105. – DOI: https://doi.org/10.54341/20778708_2026_1_66_98. – EDN: DPTFJF

Abstract. The article presents a developed mathematical image model containing hyperspectral and spectral-polarization characteristics of the observed scene for optoelectronic systems. A special feature of the proposed model is, firstly, the presence of hyperspectral and spectral-polarization characteristics; secondly, the use of the author's mathematical model to build a map of the regions of the background component; thirdly, the use of an artificial neural network to form hyperspectral characteristics. The article provides quantitative estimates of the adequacy of the developed and existing mathematical models.

Keywords: mathematical model, hyperspectral characteristic, spectral and polarization characteristics, artificial neural network.

For citation: Siarheyenka, A.V. Mathematical model of the terrain image taking into account hyperspectral and spectral-polarization characteristics / A.V. Siarheyenka, A.V. Khizniak, A.Y. Liplianin // Problems of Physics, Mathematics and Technics. – 2026. – № 1 (66). – P. 98–105. – DOI: https://doi.org/10.54341/20778708_2026_1_66_98 (in Russian). – EDN: DPTFJF

Введение

Отраженное солнечное излучение от объектов и фонов на входе любой оптико-электронной системы содержит значительно больше характеристик и параметров, чем те, которые она способна зарегистрировать. Это и ультрафиолетовый, видимый, инфракрасный диапазоны, гиперспектральные, поляризационные и другие характеристики. Поэтому на входе каждый элемент наблюдаемой сцены – это вектор. К сожалению, нет таких систем, которые позволяют измерять и обрабатывать все характеристики сразу. Однако, системы, которые позволяют регистрировать отдельные характеристики, существуют и применяются в различных отраслях человеческой деятельности. Основными направлениями, где уже применяются гиперспектральные или спектрально-поляризационные характеристики, являются

оценка состояния сельскохозяйственных культур, лесов, атмосферы, контроль качества некоторых изделий и т. п. Одним из перспективных (неисследованных) направлений, где могут применяться данные характеристики, является обнаружение малоразмерных, малоконтрастных объектов, в том числе замаскированных средствами искусственного происхождения [1]–[3]. Настоящая статья посвящена разработке математической модели изображения местности, учитывающей гиперспектральные и спектрально-поляризационные характеристики. Наличие такой адекватной математической модели позволит вести разработку оптимальных алгоритмов обнаружения за счет: во-первых, формализации фоноцелевой обстановки; во-вторых, обоснования параметров и характеристик результатов работы алгоритмов обработки в заданных условиях применения.

1 Формирования гиперспектрально-поляризационного изображения

Постановка задачи. Для создания адекватной математической модели изображения, содержащего гиперспектральные и спектрально-поляризационные характеристики наблюдаемой сцены требуется:

- формализовать модель изображения местности содержащего гиперспектральные и спектрально-поляризационные характеристики;
- провести сравнение разработанной и существующих моделей с реальными изображениями.

При этом исходными данными являются:

- размер изображения (в пикселях);
- число классов c (объектов и фонов), составляющих фоноцелевую обстановку;
- параметры принадлежности к определенным классам на изображении (объектов и фонов);
- набор гиперспектральных характеристик объектов и фонов;
- математические выражения для расчета степеней поляризации;
- методика расчета параметров адекватности математической модели изображения [4];
- перечень существующих моделей изображений, являющихся объектом сравнения.

Целесообразно разделить процесс формирования изображения на несколько этапов, в статье предложено выполнить разделение на три этапа, подробное описание которых приведено ниже. Общий вид трехэтапного алгоритма формирования гиперспектрально-поляризационного изображения наблюдаемой сцены представлен на рисунке 1.1.

Этап 1. На первом этапе формируется карта расположения областей фона и объектов интереса. Карта представляет собой двумерную матрицу M :

$$M = (m_{ij})_{i=1, j=1}^{row, col},$$

где m_{ij} – значение класса, к которому относится элемент матрицы M ;

row – количество строк матрицы M ;

col – количество колонок матрицы M .

Сначала выполняется формирование только фоновой составляющей. Значение класса, к которому относится каждый отдельный элемент матрицы M , определяется выражением [5]:

$$P_{ij}(c) = \frac{W_c(\Omega_{ij})_{cor} W_c(i, z)_{cor} t m_{cm_{ij-1}}}{\sum_{c=1}^n W_c(\Omega_{ij})_{cor} W_c(i, z)_{cor} t m_{cm_{ij-1}}},$$

где $c \in [1, n]$ – номер класса, к которому относится элемент матрицы;

n – общее число классов;

Ω_{ij} – соседние элементы матрицы;

z – номер итерации;

$W_c(\Omega_{ij})_{cor}$ – скорректированный коэффициент появления класса c от значения соседних элементов матрицы;

$W_c(i, z)_{cor}$ – скорректированный коэффициент появления класса c от значения номера строки матрицы;

$t m_{cm_{ij-1}} \in [0, 1]$ – элемент матрицы, который

определяет, может ли элемент матрицы m_{ij} принять значение класса c при условии, что элемент матрицы с координатами $i, j-1$ относится к классу m_{ij-1} .

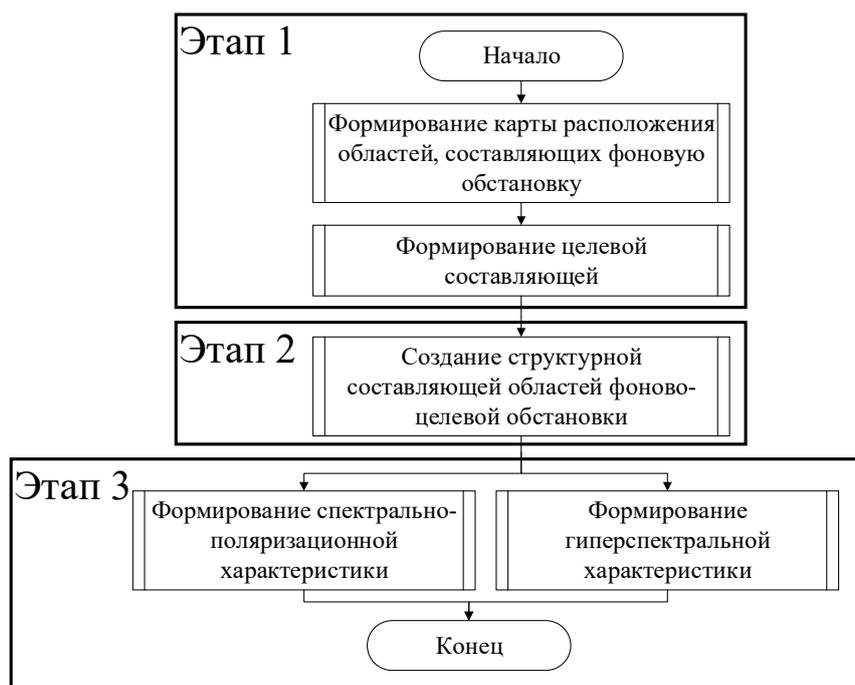


Рисунок 1.1 – Алгоритм формирования гиперспектрально-поляризационного изображения

После формирования карты расположения областей фоновой составляющей выполняется размещение областей целевой составляющей. На данном этапе на матрице M выполняется размещение областей, представляющих собой проекции типовых объектов интереса, примеры их изображений представлены на рисунках 1.2 а), б).

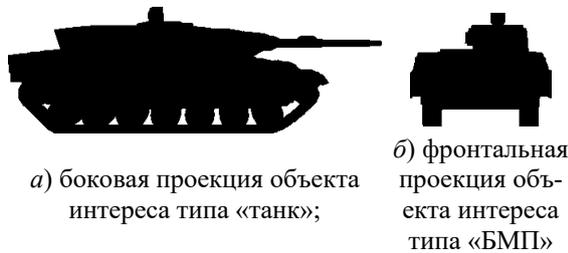


Рисунок 1.2– Примеры изображений проекций типовых объектов интереса

Положение нижнего левого угла области, представляющей объект интереса на матрице M , определяется как совокупность значений дискретных равномерных распределений с функциями вероятности $P(i)$ для колонок и $P(j)$ для рядов:

$$P(i) = \begin{cases} \frac{1}{col - col_{obj} - 1}, & 0 \leq i \leq col - col_{obj}; \\ 0, & \text{иначе;} \end{cases}$$

$$P(j) = \begin{cases} \frac{1}{row - row_{obj} - 1}, & 0 \leq j \leq row - row_{obj}; \\ 0, & \text{иначе;} \end{cases}$$

где col_{obj} – количество колонок, занимаемых областью, представляющей объект интереса;

row_{obj} – количество строк, занимаемых областью, представляющей объект интереса.

Количество строк, занимаемой областью объекта интереса, является входным параметром и задается пользователем, а количество занимаемых колонок определяется выражением:

$$col_{obj} = \frac{col_{obj\ org} row_{obj}}{row_{obj\ org}},$$

где $col_{obj\ org}$ – количество колонок оригинального изображения типового объекта интереса;

$row_{obj\ org}$ – количество строк оригинального изображения типового объекта интереса.

Этап 2. После того, как на матрицу M размещены объекты интереса, выполняется обход каждой области для определения необходимости формирования ее структурной составляющей. Формирование структуры производится только для областей, относящихся к классам, имеющим ярко выраженное разделение на разные подклассы, например хвойный лес – хвоя и кора, поле – сельскохозяйственная культура и пашня, сад – листва деревьев, кора деревьев и подстилающая

растительность и т. п. Если для текущей области требуется формирование текстуры, то определяются параметры (координаты i и j верхнего левого угла, ширина и высота) прямоугольника, ограничивающего область. В соответствии с размерами ограничивающего прямоугольника выполняется формирование изображения-маски текстуры, представляющей собой двумерную матрицу T :

$$T = (t_{kl})_{k=1, l=1}^{row_t, col_t},$$

где row_t – количество строк матрицы T ;

col_t – количество колонок матрицы T .

Авторский метод создания текстур основан на методе А.А. Эфроса и В. Фримана [6] с рядом внесенных изменений и дополнений. Сущность нововведений заключается в следующем: во-первых, размер изображения текстуры задается размерами ограничивающего прямоугольника; во-вторых, одновременно происходит формирование двух новых изображений (первое – это изображение, используемое базовым алгоритмом для подбора лучшего соседнего блока и формирования границы между блоками, второе – это изображение-маска, используемое для определения расположения областей подклассов). При формировании текстуры области используются два изображения: первое – изображение настоящей целевой структуры, второе – изображение-маска, на которой разными цветами выделены интересующие подклассы, примеры пар изображений, используемых для генерации текстур, представлены на рисунке 1.3. На рисунках 1.2 а), б) представлены изображения настоящих целевых структур, а на рисунках 1.3 в), г) соответствующие им изображения-маски.

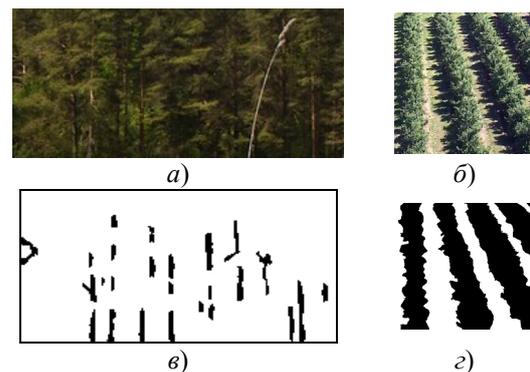


Рисунок 1.3– Изображения целевых структур и их изображения-маски

После того, как формирование изображения-маски завершится, значения элементов матрицы M , относящиеся к оцениваемой области, заменяются значениями матрицы T . После обновления значений элементов матрицы M выполняется переход к следующей области матрицы. Если оцениваемая область не требует формирования текстуры, то осуществляется переход

к следующей области. Данные действия выполняются до тех пор, пока не будут проверены все области матрицы M .

Этап 3. По завершении обхода всех областей матрицы M начинается заключительный этап – формирование гиперспектральной и спектрально-поляризационной составляющих:

$$H = (h_{ijk})_{i=1,j=1,k=1}^{row,col,v}, PL = (pl_{ijk})_{i=1,j=1,k=1}^{row,col,v}$$

где H – тензор гиперспектральной составляющей; h_{ijk} – значение интенсивности излучения; v – число каналов; PL – тензор спектрально-поляризационной составляющей;

pl_{ijk} – значение степени поляризации излучения.

Далее будет представлено описание процедуры формирования тензора H . Для каждого вектора h_{ij} формируется собственная гиперспектральная характеристика, соответствующая классу m_{ij} . Для гиперспектральной характеристики классов с малым числом примеров для обучения (менее 10) применялись реальные гиперспектральные характеристики с наложенной Гауссовой шумовой составляющей. Для остальных классов применялось генеративно-состязательная искусственная нейронная сеть (ИНС), позволяющая добиться уникальности каждого нового спектра с одновременным сохранением формы, идентичной настоящим. Инициализирующим значением для ИНС-генератора является вектор S :

$$S = (s_i)_{i=1}^{rd} \sim \phi,$$

где $rd = 128$ – количество элементов вектора S ; ϕ – нормальное распределение (с нулевым средним и единичной дисперсией).

Путем последовательного прохождения одномерных сверточных слоев происходит преобразование вектора S в выходной вектор. Выходным слоем ИНС-генератора является сигмоидальная функция, гарантирующая, что $h_{ij} \in [0,1]$. Для уменьшения затухания градиента на этапе обучения в структуре ИНС-генератора используется техника «пропуск соединения», при использовании которой часть из последующих слоев ИНС на вход получают данные нескольких предыдущих слоев. Так, в используемой ИНС на вход 3-го блока «Слой увеличения размера» поступают выходные значения 1-го и 2-го блоков «Слой увеличения размера», а на вход 4-го блока «Слой увеличения размера» поступают значения 1-го, 2-го и 3-го блоков «Слой увеличения размера». Структура ИНС-генератора представлена на рисунке 1.4. Подробная структура блоков, составляющих ИНС-генератор, представлена на рисунках 1.6 а), б), в).

Входным значением ИНС-классификатора является вектор TR (реальная или сгенерированная гиперспектральная характеристика):

$$TR = (tr_i)_{i=1}^v,$$

где $tr_i \in [0,1]$ – гиперспектральная характеристика излучения.

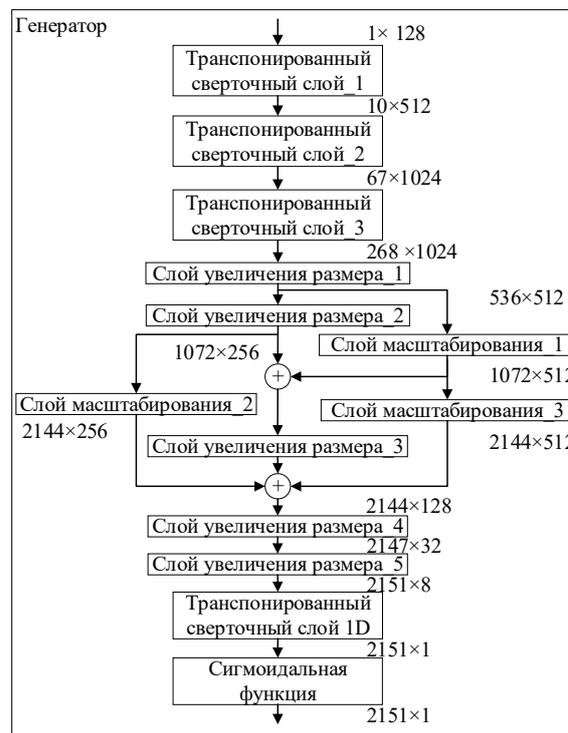


Рисунок 1.4– Структура ИНС-генератора

На первом шаге на входной вектор накладывается шум Гаусса. Необходимость добавления шума обусловлена имитацией реальных условий, когда измеренным оценкам характерно наличие ошибок. Далее путем последовательного прохождения одномерных сверточных слоев происходит извлечение информационных признаков. Аналогично с ИНС-генератором для уменьшения затухания градиента в структуре ИНС-классификатора применяется техника «пропуск соединения». Структура ИНС-классификатора представлена на рисунке 1.4. Подробная структура блоков, составляющих ИНС-классификатор представлены на рисунках 1.5 з), д).

Для формирования тренировочных наборов данных использовались гиперспектральные характеристики объектов, которые размещены в открытом доступе [7], [8], а также каталог спектров объектов и фонов, полученный сотрудниками НИИ ПФП им. А.Н. Севченко БГУ [1], а также данные, полученные авторами. Обучение ИНС выполнялось с использованием следующей методики:

1. Формирование тренировочной выборки в соответствии с целевым классом. Нормализация и аппроксимация данных (при необходимости).
2. Установка параметров обучения ИНС.
3. Инициализация весовых коэффициентов ИНС.
4. Обучение ИНС:

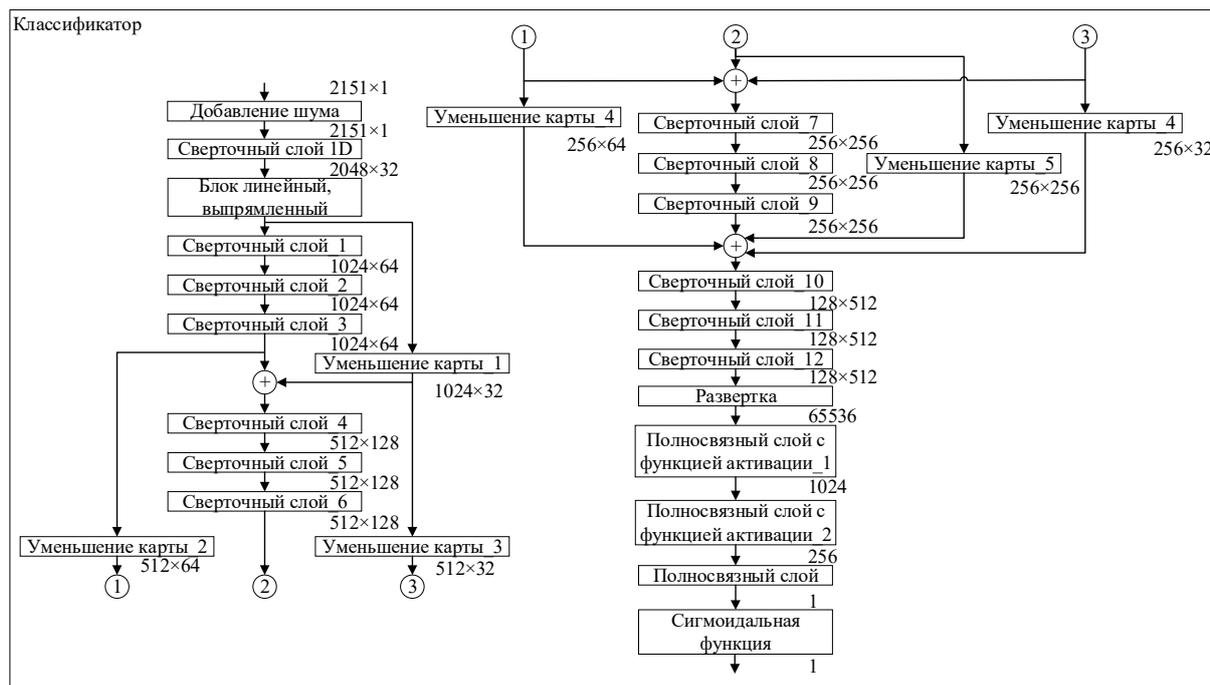


Рисунок 1.5 – Структура ИНС-классификатора

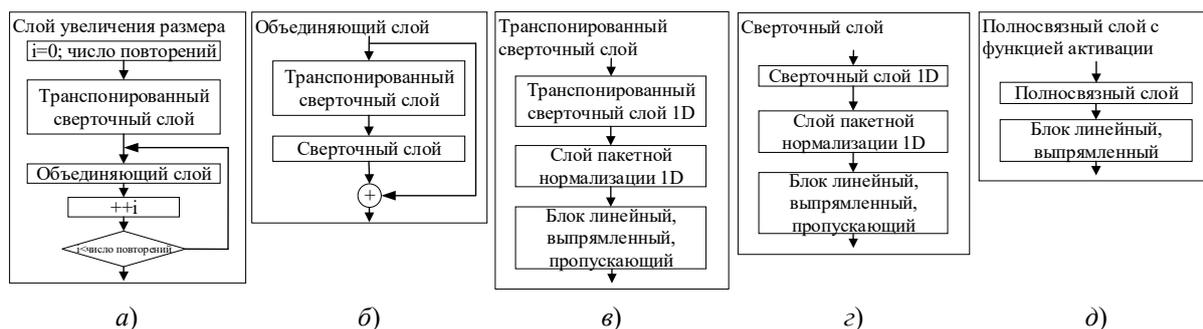


Рисунок 1.6 – Структура блоков, составляющих ИНС-генератор и ИНС-классификатор

- шаг обучения ИНС-классификатора:
- создание тренировочного набора данных, состоящего из реальных и сгенерированных гиперспектральных характеристик в пропорции 1 : 1;
 - предсказание отметок классов;
 - расчет ошибки;
 - корректировка весовых коэффициентов слоев ИНС-классификатора;
- шаг обучения ИНС-генератора:
- генерация гиперспектральных характеристик;
 - присвоение сгенерированным данным отметки «реальная»;
 - предсказание отметок классов с помощью ИНС-классификатора;
 - расчет ошибки;
 - корректировка весовых коэффициентов слоев ИНС-генератора.
5. Сохранение весовых коэффициентов обеих ИНС.

Для расчета ошибки на всех шагах использовалась бинарная кросс-энтропия [9]:

$$BCE(R, PR) = -\frac{1}{o} \sum_{i=1}^o (r_i \log(pr_i) + (1 - r_i) \log(1 - pr_i)),$$

где $R = (r)_{i=1}^o$ – вектор с реальными отметками спектров; $PR = (pr)_{i=1}^o$ – вектор с оценками спектров, полученных от ИНС-классификатора; o – число спектров, используемых на шаге обучения.

Поскольку для каждого класса обучение ИНС выполнялось отдельно, это позволило создать набор весовых коэффициентов ИНС-генератора и ИНС-классификатора. На рисунке 1.6 представлен пример, где красным цветом отображена реальная гиперспектральная характеристика сосновых иголок, а синим цветом отображена их сгенерированная гиперспектральная характеристика, которые практически совпадают.

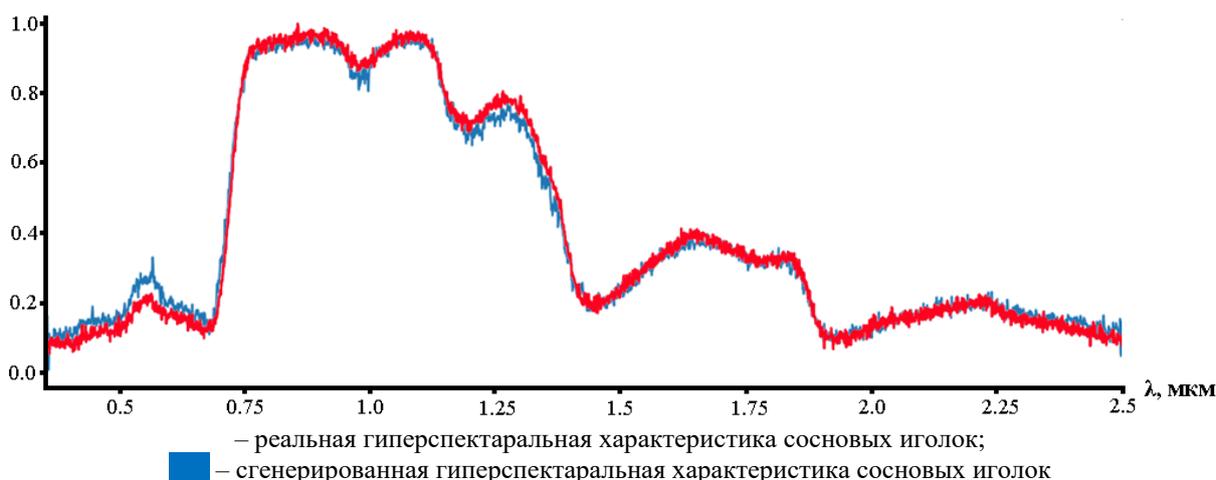


Рисунок 1.7– Пример реальных и сгенерированных гиперспектральных характеристик

Непосредственно при генерации нового спектра сначала выполняется установка весовых коэффициентов ИНС соответствующих классу m_{ij} . После загрузки весовых коэффициентов осуществляется генерация гиперспектральной характеристики, которая далее поступает на вход ИНС-классификатора. Если ИНС-классификатор оценивает сгенерированную характеристику как настоящую, то новая гиперспектральная характеристика присваивается вектору h_{ij} и выполняется переход к следующему элементу тензора H , если же характеристика была оценена как ненастоящая, то выполняется генерация новой. Новая характеристика будет генерироваться до тех пор, пока она не будет классифицирована как настоящая.

Далее выполняется формирование спектрально-поляризационной характеристики. Для этого выполняется расчет степени поляризации заданных длин волн [10]:

$$pl_{ijk} = \frac{K_{pk} - K_{sk}}{K_{pk} + K_{sk}}, \quad (1.1)$$

где K_{pk} – коэффициент отражения компоненты параллельной плоскости падения;

K_{sk} – коэффициент отражения компоненты перпендикулярной плоскости падения.

Коэффициенты отражения для обоих компонент определяются как [10]:

$$K_{sk} = |r_{sk}|^2, \quad K_{pk} = |r_{pk}|^2,$$

где r_{pk} – амплитудный коэффициент отражения компоненты параллельной плоскости падения;

r_{sk} – амплитудный коэффициент отражения компоненты перпендикулярной плоскости падения.

Исходя из закона преломления, амплитудные коэффициенты отражения рассчитываются по выражениям [10]:

$$r_{sk} = \frac{\cos \alpha_0 - r_{ck} \cos \alpha_1}{\cos \alpha_0 + r_{ck} \cos \alpha_1}, \quad (1.2)$$

$$r_{pk} = \frac{r_{ck} \cos \alpha_0 - \cos \alpha_1}{r_{ck} \cos \alpha_0 + \cos \alpha_1}, \quad (1.3)$$

где α_0 – угол падения излучения на объект сцены;

r_{ck} – показатель преломления класса c ;

α_1 – угол преломления излучения.

Для каждого элемента тензора PL , который в соответствии с картой расположения областей M относится к природным объектам, значение угла падения принадлежит диапазону $\alpha_0 \in [0^\circ, 90^\circ]$ и принимает случайное значение.

Для элементов тензора, относящихся к объектам интереса, угол падения принадлежит аналогичному диапазону, но остается постоянным внутри отдельной области класса.

Для определения угла преломления использовался закон Снелиуса [11], таким образом выражения (1.2), (1.3) примут вид:

$$r_{sk} = \frac{\cos \alpha_0 - r_{ck} \cos \left(\arcsin \left(\frac{\sin \alpha_0}{r_{ck}} \right) \right)}{\cos \alpha_0 + r_{ck} \cos \left(\arcsin \left(\frac{\sin \alpha_0}{r_{ck}} \right) \right)},$$

$$r_{pk} = \frac{r_{ck} \cos \alpha_0 - \cos \left(\arcsin \left(\frac{\sin \alpha_0}{r_{ck}} \right) \right)}{r_{ck} \cos \alpha_0 + \cos \left(\arcsin \left(\frac{\sin \alpha_0}{r_{ck}} \right) \right)}.$$

2 Анализ полученных результатов

Сравним предложенную математическую модель изображения, включающую гиперспектральные и спектрально-поляризационные характеристики наблюдаемой сцены с другими математическими моделями. Для этого воспользуемся методикой оценки адекватности математической модели изображения [4]. В ее основе лежит искусственная нейронная сеть, решающая задачу оценки сходства двух изображений по

нормированному показателю сходства и ее k -кратная перекрестная проверка.

На сегодняшний день для моделирования гиперспектральной составляющей распространение получило три способа: представление спектров как набора распределений Гаусса с различными параметрами; Марковские поля; реальные спектры, принадлежащие моделируемым объектам [12]. Спектрально-поляризационную составляющую зачастую рассчитывают также в соответствии с выражением (1.1). Для формирования карты разбиения областей широко применяются: марковская модель изображения, модель изображения Гиббса, блочная модель изображения Гиббса [4].

Для карт расположения областей, полученных с использованием трех моделей, формировались гиперспектральные характеристики с использованием распределений Гаусса с различными параметрами, Марковских полей и реальных спектров. Спектрально-поляризационные характеристики рассчитывались в соответствии с выражением (1.1), всего 9 типов моделей.

Сравнение смоделированных изображений проводилось с реальными изображениями, содержащими гиперспектральные и спектрально-поляризационные характеристики сцен, соответствующих заданным условиям. В таблице 2.1 представлены результаты оценки адекватности существующих и разработанной математических моделей с реальными изображениями.

Таблица 2.1 – Результаты оценки адекватности сравниваемых математических моделей с реальными изображениями

Наименование оцениваемой модели	Нормированная оценка сходства
Марковская модель изображения + распределение Гаусса	0,36
Модель изображения Гиббса + распределение Гаусса	0,43
Блочная модель изображения Гиббса + распределение Гаусса	0,45
Марковская модель изображения + Марковские поля	0,37
Модель изображения Гиббса + Марковские поля	0,42
Блочная модель изображения Гиббса + Марковские поля	0,47
Марковская модель изображения + реальные спектры	0,5
Модель изображения Гиббса + реальные спектры	0,52
Блочная модель изображения Гиббса + реальные спектры	0,6
Модель изображения с учетом гиперспектральных и спектрально-поляризационных характеристик (разработанная)	0,85

Исходя из полученных результатов видно, что существующие в настоящее время математические модели не могут обеспечить адекватное формирование изображения, содержащего гиперспектральные и спектрально-поляризационные характеристики, соответствующие заданным условиям съемки. Предложенная в статье модель напротив обеспечивает адекватное построение такого изображения. Нормированные оценки сходства математических моделей показали, что разработанная модель позволяет повысить адекватность итогового изображения наблюдаемой сцены в диапазоне 1,41–2,36 раза.

Заключение

Разработанная математическая модель изображения местности, отличающаяся во-первых, наличием гиперспектральных и спектрально-поляризационных характеристик; во-вторых, использованием авторской математической модели для построения карты областей фоновой составляющей; в-третьих использованием искусственной-нейронной сети для формирования гиперспектральных характеристик, что в совокупности позволило повысить оценку адекватности, основанную на нормированном показателе сходства до 2,36 раза по сравнению с существующими моделями. Разработанная модель может быть применена при разработке новых методов обработки гиперспектральных и спектрально-поляризационных изображений, а также разработки алгоритмов автоматического обнаружения и сопровождения в перспективных оптико-электронных системах.

ЛИТЕРАТУРА

1. *Беляев, Б.И.* Оптическое дистанционное зондирование / Б.И. Беляев, Л.В. Катковский / БГУ. – Минск, 2006. – 455 с.
2. *Сергеенко, А.В.* Пути повышения эффективности работы оптико-электронных систем обнаружения в условиях применения искусственных средств маскировки / А.В. Сергеенко, А.Ю. Липлянин // Военное образование и наука в условиях цифровой трансформации знаний: междунар. науч. конф. УО «ВА РБ», Минск, 20–21 апр. 2022 г.: тез. докл. / ВА РБ; редкол.: А.Ю. Зализко [и др.] – Минск: ВА РБ, 2022. – С. 105.
3. *Сергеенко, А.В.* Обзор путей повышение эффективности работы оптико-электронных систем обнаружения / А.В. Сергеенко, А.Ю. Липлянин // Технические средства защиты информации: тез. докл. XXI Бел.-Рос. науч. техн. конф., Минск, 6 июня 2023 г. / УО «БГУИР»; редкол.: Т.В. Борбатько [и др.]. – Минск, 2023. – С. 80.
4. *Сергеенко, А.В.* Методика расчета параметров адекватности математической модели изображения / А.В. Сергеенко, А.Ю. Липлянин, А.В. Хижняк // Проблемы физики, математики и техники. – 2023. – № 3 (56) – С. 94–99.

5. *Сергеенко, А.В.* Математическая модель для построения карты расположения областей, составляющих фоновую обстановку для оптико-электронных систем / А.В. Сергеенко, А.Ю. Липлянин, А.В. Хижняк // Доклады БГУИР. – 2024. – № 1. – С. 116–124.
6. *Efros, A.A.* Image quilting for texture synthesis and transfer [Electronic resource] / A.A. Efros, W. Freeman // Seminal Graphics Papers: Pushing the Boundaries. – 2023. – Vol. 2. – Mode of access: https://www.academia.edu/5396588/Image_Quilting_for_Texture_Synthesis_and_Transfer_SIGGRAPH_2001. – Date of access: 31.12.2024.
7. *The ECOSTRESS spectral library version 1.0* [Electronic resource] / S.K. Meerdink, S.J. Hook, D.A. Roberts, E.A. Abbott // Remote Sensing of Environment. – 2019. – № 230. – Mode of access: https://www.researchgate.net/publication/333447307_The_ECOSTRESS_spectral_library_version_10. – Date of access: 31.12.2024.
8. *Spectral Library Version 7* [Electronic resource] // USGS. – Mode of access: <https://pytorch.org/docs/stable/generated/torch.nn.BCELoss.html>. – Date of access: 01.05.2025.
9. *TORCH.NN* [Electronic resource] // PyTorch. – Mode of access: <https://pytorch.org/docs/stable/nn.html>. – Date of access: 23.02.2023.
10. *Путилин, Э.С.* Оптические покрытия / Э.С. Путилин, Л.А. Губанова. – СПб.: Лань, 2015. – 267 с.
11. *Физическая энциклопедия*: в 5 т. / Пойнтинга – Робертсона стримеры; редкол.: А.М. Прохоров (глав. ред.) [и др.]. – Москва: Научное издательство «Большая Российская энциклопедия», 1988–1998. – Т. 4. – 1998. – 704 с.
12. *Имитационное моделирование в задачах оптического дистанционного зондирования* / Г.М. Креков [и др.]. – Новосибирск: Наука, 1988. – 165 с.

Поступила в редакцию 10.11.2025.

Информация об авторах

Сергеенко Андрей Владимирович – мл. науч. сотрудник
Липлянин Антон Юрьевич – к.т.н.
Хижняк Александр Вячеславович – к.т.н., профессор