

УДК 633.1:004.048
DOI 10.52575/2712-7443-2026-50-2-1-0
EDN UDXGXR

Оценка точности классификации многозональных космических снимков при использовании пиксельного и объектно-ориентированного подходов

Гарафутдинова Л.В., Каличкин В.К., Федоров Д.С.

Сибирский федеральный научный центр агробиотехнологий Российской академии наук
Россия, 630501, Новосибирская область, Новосибирский м. р-н,
г.п. рабочий поселок Краснообск, р.п. Краснообск, Центральная ул., зд. 7
lv.garafutdinova@mail.ru

Аннотация. Представлены результаты исследований по оценке точности классификации многозональных космических снимков при использовании пиксельного и объектно-ориентированного подходов. Исследования выполнены на территориях землепользования ОС «Элитная» и ИП ГК(Ф) Х Ковалев С. М. в Новосибирской области. Для реализации различных подходов к классификации типов земной поверхности использовали многозональные космические снимки спутника *Sentinel-2B* с пространственным разрешением 10 м в пикселе. Пиксельный подход реализован на основе контролируемой классификации с использованием методов максимального правдоподобия, параллелепипедов и расстояние Махаланобиса в программном пакете *ERDAS Imagine 2014*. Объектно-ориентированный подход выполняли в два этапа. Вначале проводили сегментацию изображений с использованием алгоритма *OBIS*, а затем классифицировали сегментированные изображения. Сегментация выполнена с использованием *SAGA GIS* версии 8.5.1. Классификация результатов сегментации выполнена с использованием методов машинного обучения: случайный лес (*RF*), метод опорных векторов (*SVM*) и многослойный перцептрон (*MLP*). Исследованиями установлено, что классификаторы при использовании пиксельного подхода показали в целом нестабильные результаты, которые варьировали от удовлетворительной общей точности классификации до низкой и очень низкой, особенно по отдельным классам пространственных объектов. Лучшим оказался метод максимального правдоподобия, который показал удовлетворительную общую точность классификации (82–88 %) и высокие значения коэффициента Каппа Коэна. Непараметрические классификаторы при использовании объектно-ориентированного подхода продемонстрировали более устойчивые результаты для обеих анализируемых территорий землепользования. Лучшей из них была модель *MLP* с общей точностью классификации 96 % для землепользования ОС «Элитная» и 91 % для землепользования ИП ГК(Ф) Х Ковалев С. М., а также с высокими значениями коэффициента Каппа Коэна. Проведённое исследование показывает, что объектно-ориентированный подход с предварительной сегментацией изображения является наиболее эффективной стратегией классификации многозональных космических снимков.

Ключевые слова: дистанционное зондирование, пиксельная классификация, объектно-ориентированная классификация, машинное обучение, картографирование, оценка точности

Для цитирования: Гарафутдинова Л.В., Каличкин В.К., Федоров Д.С. 2026. Оценка точности классификации многозональных космических снимков при использовании пиксельного и объектно-ориентированного подходов. Региональные геосистемы, 50 (2): 352–365. DOI: 10.52575/2712-7443-2026-50-2-1-0 EDN: UDXGXR

Assessing Multispectral Satellite Image Classification Accuracy Using Pixel-Based and Object-Oriented Approaches

Lyudmila V. Garafutdinova, Vladimir K. Kalichkin, Dmitry S. Fedorov

Siberian Federal Scientific Centre of Agro-BioTechnologies of the Russian Academy of Sciences,
7 Tsentralnaya St., 630501, Krasnoobsk urban-type settlement,
Krasnoobsk, Novosibirsky mikrorayon, Novosibirsk region, Russia
lv.garafutdinova@mail.ru

Abstract. The paper presents the results of research focused on assessing the accuracy of multispectral satellite image classification using pixel-based and object-oriented approaches. The studies were conducted on the territories of Elitnaya Experimental Station and Individual Entrepreneur – Head of Peasant (Farm) Enterprise Kovalev S.M. land use areas in Novosibirsk region. Multispectral satellite images from Sentinel-2A with 10 m spatial resolution per pixel were used to implement various approaches for land cover type classification. The pixel-based approach was implemented based on supervised classification using parametric methods of maximum likelihood, parallelepiped, and Mahalanobis distance in ERDAS Imagine 2014 software package. We applied the object-oriented approach in two stages. First, image segmentation was conducted using the OBIS algorithm, and then the segmented images were classified. Segmentation was performed using SAGA GIS version 8.5.1. Machine learning models were used for classification of the obtained segmented image: Random Forest (RF), Support Vector Machine (SVM), and Multi-Layer Perceptron (MLP). In the course of the study, parametric classifiers using the pixel-based approach showed generally unstable results, which varied from satisfactory overall classification accuracy to low and very low, especially for individual classes of spatial objects. The maximum likelihood method proved to be the best, showing satisfactory overall classification accuracy (82.0-88.0%) and high Cohen's Kappa coefficient values. Non-parametric classifiers using the object-oriented approach demonstrated more stable results for both land use territories under analysis. The best among them was the MLP model with overall classification accuracy of 96.0% for Elitnaya Experimental Station land use and 91.0% for Individual Entrepreneur – Head of Peasant (Farm) Enterprise Kovalev S.M. land use, as well as high Cohen's Kappa coefficient values. The research findings show that the object-oriented approach with preliminary image segmentation is the most effective strategy for multispectral satellite image classification.

Keywords: remote sensing, pixel-based classification, object-oriented classification, machine learning, mapping, accuracy assessment

For citation: Garafutdinova L.V., Kalichkin V.K., Fedorov D.S. 2026. Assessing Multispectral Satellite Image Classification Accuracy Using Pixel-Based and Object-Oriented Approaches. *Regional Geosystems*, 50 (2): 352–365 (in Russian). DOI: 10.52575/2712-7443-2026-50-2-1-0 EDN: UDXGXR

Введение

Подходы к классификации снимков дистанционного зондирования можно разделить на две основные категории: классификация на основе пикселей и классификация на основе объектов [Blaschke et al., 2014; Kucharczyk et al., 2020]. Подходы к классификации на основе пикселей используют пиксель в качестве базовой единицы анализа, в то время как подходы к объектной классификации используют объект (т.е. группу смежных пикселей) в качестве базовой единицы анализа. Подход на основе пикселей содержит в свою очередь также два типа: жёсткую и мягкую, последнюю называют спектральным разделением (*spectral unmixing*) [Wang et al., 2021]. При жёсткой классификации на основе пикселей предполагается, что каждый пиксель является чистым, и отдельные пиксели классифицируются по взаимоисключающим классам земной поверхности в зависимости от их спектральных свойств. В отличие от этого, при спектральном разделении определяют вероятность появления различных классов земной поверхности в каждом пикселе, в связи с тем, что на различных снимках дистанционного зондирования часто встречаются смешанные

пиксели, содержащие более одного класса. Результаты спектрального разделения можно преобразовать в результаты жёсткой классификации, присвоив пикселю метку класса с максимальной долей [Manohar Kumar et al., 2022].

Классификация на основе пикселей долгое время была основным методом дешифрирования изображений дистанционного зондирования, особенно с низким и средним пространственным разрешением. В последние годы, с появлением изображений дистанционного зондирования с высоким и очень высоким пространственным разрешением, была разработана усовершенствованная классификация на основе объектов. Объектный подход имеет два отличия от пиксельного. Первое отличие заключается в том, что распознавание классов на основе объектов выполняется для единиц объектов, полученных в результате сегментации изображения [Hossain, Chen, 2022; Ez-zahouani et al., 2023], в то время как процесс классификации на основе пикселей напрямую связан с пикселями изображения и их спектральными свойствами. Второе отличие заключается в том, что при объектном подходе используются не только их спектральные, но и пространственные, текстурные и геометрические свойства [Blaschke et al., 2014; Mehmood et al., 2022; Ozturk, Colkesen, 2024].

Для осуществления сегментации применяется алгоритм объектно-ориентированного анализа изображений (*OBIA-OBIS*), интегрированный с геоинформационными системами (ГИС) – географический объектно-ориентированный анализ изображений (*Geographic object-based image analysis – GEOBIA*). Он генерирует однородные сегменты изображения во вложенной иерархии масштабированных представлений. Спектральная информация агрегируется адаптивным к масштабу образом, при этом потеря детализации сводится к минимуму. Таким образом, создается новая географическая информация в формате, пригодном для использования в ГИС. Последующая классификация типов земной поверхности в парадигме *GEOBIA* осуществляется методами машинного обучения. Преимущества *GEOBIA* заключаются в высокой степени использования информации, надежной защите от помех, высокой степени интеграции данных, высокой точности классификации и меньшем объеме ручного редактирования [Chen et al., 2018; Lang et al., 2019; Liu et al., 2020; Talukdar et al., 2020; Гарафутдинова и др., 2024].

Классификация снимков дистанционного зондирования с использованием машинного обучения в последнее время стала основным направлением в этой предметной области. Алгоритмы машинного обучения, как правило, способны моделировать сигнатуры сложных классов, могут принимать различные входные предикторные данные и не делают предположений о распределении данных (т.е. являются непараметрическими). Исследованиями показано, что эти методы, как правило, обеспечивают более высокую точность по сравнению с традиционными классификаторами, особенно для сложных данных с многомерным пространством признаков, то есть со многими предикторными переменными [Talukdar et al., 2020; Zafar et al., 2024; Behera, 2025; Jancevičius, Kalibatienė, 2025].

Несмотря на растущее признание классификаторов машинного обучения, традиционные методы по-прежнему широко используются в прикладных статьях и остаются одними из основных методов для сравнительных экспериментов по классификации. Например, по данным [Maxwell et al., 2018] при метаанализе более 1600 статей, посвященных проблемам классификации дистанционного зондирования, обнаружено, что наиболее часто применяемым был классификатор максимального правдоподобия (32 % статей), хотя обычно обнаруживалось, что при использовании машинного обучения достигалась значительно более высокая точность. Доминирование этого метода объясняется его широкой доступностью в обычных программных пакетах для обработки изображений дистанционного зондирования, а машинное обучение требует дополнительной разработки программного обеспечения и обучения.

Цель исследования заключалась в сравнительном анализе общей точности классификации многозональных космических снимков при использовании пиксельного и объектно-ориентированного подходов.

Объекты и методы исследования

Исследования выполнены на территориях землепользования ОС «Элитная» Новосибирского района и ИП ГК(Ф) Х Ковалев С. М. Искитимского района Новосибирской области, расположенных в центральной лесостепи (рис. 1). Рельеф ОС «Элитная» представлен слабоволнистой равниной с абсолютными высотами от 103 до 170 м. Почвенный покров территории преимущественно представлен выщелоченными чернозёмами и темно-серыми лесными почвами. Территория ИП ГК(Ф)Х Ковалев С. М. характеризуется значительно расчленённым рельефом, представленным равниной, глубоко изрезанной системой балок и оврагов. Абсолютные отметки высот варьируют от 206 до 278 м. Основными типами почв являются серые лесные, выщелоченные чернозёмы и луговые почвы.




Рис. 1. Пространственное размещение ОС «Элитная» и ИП ГК(Ф) Х Ковалев С. М.

Fig. 1. Spatial distribution of Elitnaya Experimental Station and Individual Entrepreneur – Head of Peasant (Farm) Enterprise Kovalev S.M.

В исследованиях использовали многозональные космические снимки миссии *Sentinel-2B*, полученные через платформу *Sentinel Hub* (<https://www.sentinel-hub.com>). Для анализа были выбраны три канала видимого диапазона — синий (*B02*), зелёный (*B03*), красный (*B04*) — и ближний инфракрасный канал (*B08*) с пространственным разрешением 10 м на пиксель. Все электронные слои приведены к единой системе координат *Pulkovo 1942 / Gauss-Kruger SM 87E (EPSG:2505)* с использованием свободной кроссплатформенной геоинформационной системы *QGIS* (<https://qgis.org/ru/site/>).

В полевых исследованиях осуществляли идентификацию и координатную привязку на местности различных пространственных объектов. Для определения местоположения

пространственных объектов использовали GPS-навигатор (*Garmin 64*) с точностью до 0,5 м. На основе данных полевого обследования каждого землепользования были сформированы обучающие выборки в виде классов пространственных объектов. Для территории землепользования ОС «Элитная» были выделены пять классов: рабочие участки полей, лес и лесополосы, дороги, застройка и водные объекты. Для территории землепользования ИП ГК(Ф) Х Ковалев С. М. – шесть классов: рабочие участки полей, лес и лесополосы, дороги, застройка, растительность (залежь, пастбища и сенокосы) и водные объекты.

Пиксельный подход к классификации основан на анализе спектральных характеристик отдельных пикселей и применении общепринятых статистических методов, предполагающих нормальное распределение данных в каждом классе.

Метод максимального правдоподобия (*Maximum Likelihood*) определяет принадлежность пикселя к классу ω_i на основе вероятности [Richards, 2013]:

$$P(\omega_i|x) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i)\right), \#(1)$$

где: x – вектор спектральных значений пикселя; d – размерность пространства признаков (количество спектральных каналов); μ_i – вектор средних значений для класса ω_i ; Σ_i – ковариационная матрица для класса ω_i ; $|\Sigma_i|$ – определитель ковариационной матрицы; T – операция транспонирования.

Метод параллелепипедов (*Parallelepiped*) относит пиксель к классу ω_i при выполнении условия для всех спектральных каналов $j = 1, 2, \dots, d$ [Richards, 2013]:

$$\mu_{ij} - k_j \sigma_{ij} \leq x_j \leq \mu_{ij} + k_j \sigma_{ij}, \#(2)$$

где: x_j – значение яркости пикселя в j -том канале; μ_{ij} – среднее значение для класса ω_i в j -том канале; σ_{ij} – среднеквадратическое отклонение для класса ω_i в j -том канале; k_j – пороговый коэффициент для j -того канала.

Метод расстояние Махаланобиса (*Mahalanobis Distance*) вычисляет расстояние от пикселя до центра класса ω_i по формуле [Richards, 2013]:

$$D^2(x, \omega_i) = (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i), \#(3)$$

где: x – вектор спектральных значений пикселя; μ_i – вектор средних значений для класса ω_i ; Σ_i – ковариационная матрица для класса ω_i ; T – операция транспонирования.

Пиксель относится к классу с минимальным расстоянием Махаланобиса при условии:

$$D^2(x, \omega_i) \leq T_i, \#(4)$$

где: T_i – пороговое значение для класса ω_i .

Объектно-ориентированный подход использует непараметрические методы машинного обучения, которые не делают предположений о распределении данных и способны моделировать сложные нелинейные зависимости между признаками и классами.

Метод случайный лес (*Random Forest – RF*) формирует окончательное решение путем голосования ансамбля деревьев решений [Breiman, 2001]:

$$\hat{y} = \text{mode}\{h_1(x), h_2(x), \dots, h_B(x)\}, \#(5)$$

где: $\hat{y}$ – предсказание модели; $h_b(x)$ – предсказание b -того дерева решений; B – общее количество деревьев; $\text{mode}\{\}$ – функция, возвращающая наиболее часто встречающееся значение.

Метод опорных векторов (*Support Vector Machine – SVM*) использует решающую функцию вида [Vapnik, 1998]:

$$f(x) = \text{sign}\left(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b\right), \#(6)$$

где: α_i – множители Лагранжа; y_i – метки классов (+1 или -1); $K(x_i, x)$ – функция ядра; b – смещение; n – количество опорных векторов.

Многослойный перцептрон (*Multi-Layer Perceptron – MLP*) вычисляет выходной сигнал нейрона j в слое l по формуле [Haykin, 2009]:

$$a_j^{(l)} = f \left(\sum_i w_{ji}^{(l)} a_i^{(l-1)} + b_j^{(l)} \right), \#(7)$$

где: $a_j^{(l)}$ – активация j -того нейрона в слое l ; $w_{ji}^{(l)}$ – вес связи от нейрона i в слое $(l-1)$ к нейрону j в слое l ; $b_j^{(l)}$ – смещение нейрона j в слое l ; f – функция активации.

Пиксельный подход реализован на основе контролируемой классификации в программном обеспечении *ERDAS Imagine 2014*¹. Синтезированные изображения были созданы с помощью функции *Layer Stack* путем объединения нескольких изображений в разных спектральных зонах. В пиксельном подходе в качестве входных данных использовали значения отражательной способности в приведённых выше спектральных каналах.

Объектно-ориентированный подход выполняли в два этапа. Вначале проводили сегментацию изображений с использованием алгоритма *Object Based Image Segmentation (OBIS)*, а затем классифицировали сегментированные изображения. Сегментация выполнена с использованием программного продукта *SAGA GIS* версии 8.5.1 с открытым исходным кодом (<https://sourceforge.net/projects/saga-gis/files/SAGA%20-%208.5.1/>). Вектор признаков для каждого пикселя формировали на основе данных многозонального космического снимка. В этот вектор входили значения яркости и текстурные характеристики, полученные для каждого спектрального канала. Текстуальные характеристики извлекали из растровых данных с использованием функции *r.texture* в *GRASS GIS*, доступной через интерфейс *QGIS*. Для классификации полученного сегментированного изображения применяли модели машинного обучения с использованием языка программирования *Python* в интерактивном блокноте *Jupyter*. Обучающая и тестовая выборки сформированы в соотношении 80 и 20 % соответственно. Для объектно-ориентированной классификации в качестве входных данных использовали среднее значение спектральной характеристики по сегменту, текстуру, цвет и форму.

Для оценки точности классификации применяли стандартные метрики, основанные на анализе матрицы ошибок (*confusion matrix*).

Общая точность (*Overall Accuracy*) вычисляется как отношение правильно классифицированных пикселей к общему их количеству:

$$OA = \frac{\sum_{i=1}^k x_{ii}}{N} \times 100\%, \#(8)$$

где: x_{ii} – диагональные элементы матрицы ошибок (правильно классифицированные пиксели класса i); N – общее количество пикселей в тестовой выборке; k – количество классов.

Коэффициент Каппа Коэна (*Cohen's Kappa*) учитывает возможность случайного совпадения при классификации [Cohen, 1960]:

$$\kappa = \frac{P_o - P_e}{1 - P_e}, \#(9)$$

где: P_o – наблюдаемая точность (*Overall Accuracy* в долях); P_e – ожидаемая точность при случайном распределении:

$$P_e = \frac{\sum_{i=1}^k (x_{i+} \times x_{+i})}{N^2}, \#(10)$$

где: x_{i+} – сумма элементов i -той строки матрицы ошибок; x_{+i} – сумма элементов i -того столбца матрицы ошибок.

¹ ERDAS IMAGINE TourGuides™. Электронный ресурс. URL: [http://dca.ufcg.edu.br/DCA_download/ISR/UFPE/Tour Guide84-Erdas.pdf](http://dca.ufcg.edu.br/DCA_download/ISR/UFPE/Tour%20Guide84-Erdas.pdf) (Accessed: 10.09.2025)

Результаты и их обсуждение

Для оценки качества выделенных обучающих сигнатур классов был проведён анализ их спектральной различимости, основывающийся на значениях делимости, представленных на рис. 2. Спектральная различимость оценивалась на основе сформированных сигнатур классов. В качестве метрики использовали функциональные характеристики взаимного наложения классов, что позволяет прогнозировать ошибку классификации. Размер ошибки обратно пропорционален критерию разделимости: чем выше значение критерия, тем меньше ожидаемая ошибка при разделении соответствующих классов. Полученные значения критерия разделимости были использованы для оценки качества сформированного набора обучающих выборок.




Рис. 2. Матрица значений для оценки разделимости сигнатур на территориях землепользования ОС «Элитная» (а) и ИП ГК(Ф) Х Ковалев С. М (б)
Fig. 2. Matrix of values for signature separability assessment on the territories of Elitnaya Experimental Station (a) and Individual Entrepreneur – Head of Peasant (Farm) Enterprise Kovalev S.M. (b)

Анализ значений для оценки разделимости сигнатур показал, что все пары классов на территории землепользования ОС «Элитная» имеют значения выше 1320, что соответствует средней и высокой степени спектральной различимости. Минимальное значение разделимости сигнатур наблюдалось между парами классов «рабочие участки полей» и «лес и лесополосы», что требует повышенного контроля при классификации. Максимальные значения разделимости сигнатур характерны для класса «водные объекты», что объясняется их ярко выраженным спектральным контрастом (низкое отражение в ближнем ИК, высокое поглощение). Среднее значение разделимости сигнатур (1403) свидетельствует о высоком качестве обучающих сигнатур и их пригодности для надёжной классификации.

Для землепользования ИП ГК(Ф) Х Ковалев С. М. среднее значение разделимости сигнатур составило 1395, а минимальное 1336 – между классами «рабочие участки полей» и «лес и лесополосы». Наибольшая разделимость также отмечена для пар класса «водные объекты».

Все классы в обоих объектах землепользования показали приемлемый уровень значений разделимости сигнатур, подтверждающий пригодность обучающих выборок для последующей классификации снимков с минимально ожидаемой ошибкой. Однако наибольшие трудности в различении прогнозируются между классами «растительность» и

«дороги»; «рабочие участки полей» и «лес и лесополосы», что требует дополнительной проверки на этапе интерпретации.

Проверка точности классификации типов земной поверхности методом максимального правдоподобия показал удовлетворительные результаты. Общая точность классификации для обоих объектов была выше 80,0 % (табл. 1, 2). Значения коэффициента Каппа Коэна для объекта 1 составила 0,77 и 0,72 – для объекта 2, что указывает на существенную степень согласованности с эталонными классами.

Таблица 1
Table 1

Оценка общей точности классификации многозональных космических снимков
на территории землепользования ОС «Элитная», % (объект 1)
Assessment of overall accuracy of multispectral satellite image classification on the territory
of Elitnaya Experimental Station land use, % (object 1)

Классы	Пиксельный подход			Объектно-ориентированный подход		
	максимального правдоподобия	параллелепипедов	расстояние Махаланобиса	случайный лес (RF)	метод опорных векторов (SVM)	многослойный перцептрон (MLP)
Рабочие участки полей	89,23	82,50	76,92	68,00	92,00	100,00
Лес и лесополосы	81,62	7,32	60,00	89,50	94,70	97,70
Дороги	100,00	23,00	100,00	87,50	87,50	87,50
Застройка	86,36	60,00	20,00	58,80	88,20	100,00
Водные объекты	100,00	100,00	100,00	100,00	100,00	100,00
Общая	88,00	46,00	60,00	81,90	91,70	95,80

Таблица 2
Table 2

Оценка общей точности классификации многозональных космических снимков
на территории землепользования ИП ГК(Ф) Х Ковалев С. М., % (объект 2)
Assessment of overall accuracy of multispectral satellite image classification on the territory of Individual Entrepreneur – Head of Peasant (Farm) Enterprise Kovalev S.M. land use, % (object 2)

Классы	Пиксельный подход			Объектно-ориентированный подход		
	максимального правдоподобия	параллелепипедов	расстояние Махаланобиса	случайный лес (RF)	метод опорных векторов (SVM)	многослойный перцептрон (MLP)
Рабочие участки полей	92,00	89,80	28,85	100,00	88,90	88,90
Лес и лесополосы	96,67	36,36	46,15	81,20	100,00	100,00
Растительность	71,43	68,42	46,15	70,60	88,20	94,10
Дороги	100,00	23,00	100,00	75,00	75,00	75,00
Застройка	15,38	20,00	1,47	50,00	83,30	100,00
Водные объекты	100,00	100,00	100,00	33,30	66,70	66,70
Общая	82,00	68,00	88,10	76,10	88,10	91,00

В то же время для отдельных классов в разрезе объектов землепользования отмечены различия в точности классификации. Так, достаточно высокие показатели общей точности классификации были получены для классов «рабочие участки полей», «лес и лесополосы», «дороги» и «водные объекты» для обоих объектов землепользования. В то же время общая точность класса «застройка» для объекта 1 (см. табл. 1) и объекта 2 (см. табл. 2) различалась в 5,6 раза. Столь низкая общая точность класса «застройка» на объекте 2, по-видимому, обусловлена высокой спектральной изменчивостью этого типа земной поверхности и связана с разнообразием материалов покрытий, тенями от зданий и наличием смешанных пикселей. Поскольку в этом методе предполагается, что значения яркости пикселей в каждом канале имеют нормальные распределения, а в данном случае это правило нарушалось, поэтому получен низкий результат классификации. Класс «растительность», выделенный только для объекта 2, куда отнесены залежные земли, сенокосы и пастбища, был классифицирован с удовлетворительной общей точностью (см. табл. 2).

Метод параллелепипедов продемонстрировал умеренную эффективность. Общая точность классификации типов земной поверхности для объекта 1 составила менее 50 %, а для объекта 2 – менее 70 %. Полученные коэффициенты Каппа Коэна (0,17 и 0,52, соответственно) свидетельствуют об ограниченной согласованности с эталонными классами. Следует отметить, что преимущества этого метода выражены в простоте обучения и использования, по сути, нивелируются его недостатками, а именно, пиксели в областях между параллелепипедами не классифицируются, а в перекрывающихся областях не могут быть классифицированы вообще. Этими особенностями данного метода, вероятно, можно объяснить низкую общую точность классификации классов «лес и лесополосы» и «дороги» как для объекта 1 (см. табл. 1), так и для объекта 2 (см. табл. 2). Вероятно также, что причиной низкой точности классификации явилась спектральная схожесть с другими типами земной поверхностями, такими как «застройка» и «рабочие участки полей», а также влияние состояния дорожного покрытия. Низкая точность классификации класса «застройка» на объекте 2 (см. табл. 2) объясняется теми же причинами, указанными для метода максимального правдоподобия.

Метод классификации на основе расстояния Махаланобиса показал довольно низкую эффективность. Общая точность классификации для объекта 1 составила 60 %, а для объекта 2 – 30 %. Полученные значения коэффициента Каппа Коэна (0,40 и 0,19 соответственно) свидетельствуют о слабой (почти случайной) согласованности между результатами классификации и эталонными классами. Отмечена крайне низкая точность классификации класса «застройка» для объекта 1 (см. табл. 1) и особенно для объекта 2 (см. табл. 2). Полученные результаты свидетельствуют о практически неудовлетворительной способности алгоритма выделять антропогенные объекты, что обусловлено, прежде всего, высокой спектральной изменчивостью данных объектов – различиями в материалах кровель, наличии теней, эффекте смешанных пикселей и фрагментарности застройки. Кроме того, метод расстояния Махаланобиса характеризуется повышенной чувствительностью к выбросам и неоднородностям в обучающих выборках, что дополнительно снижает его устойчивость при работе с неоднородными урбанизированными территориями.

Данные результаты обусловлены фундаментальными ограничениями метода расстояния Махаланобиса, который предполагает нормальное распределение спектральных сигнатур и устойчивость ковариационной структуры обучающих выборок. В реальных условиях классы характеризуются многомодальностью, высокой внутренней изменчивостью (особенно такие как «застройка») и фрагментарностью, что приводит к нестабильности оценок ковариационной матрицы и, как следствие, к искажению расчётных расстояний. В результате алгоритм склонен к массовому отбрасыванию

пикселей, интерпретируя их как «не принадлежащие ни к одному классу». При этом контрастные и однородные классы, такие как «водные объекты», сохраняют высокую точность из-за их выраженной спектральной отделимости, что создаёт ложное впечатление эффективности метода в целом.

Использование объектно-ориентированного подхода показало устойчивые результаты классификации для обоих анализируемых объектов (см. табл. 1, 2). Результаты свидетельствуют о том, что для объекта 1 все модели показали высокий уровень общей точности для большинства классов. Для объекта 2 сохраняется аналогичная тенденция, но с несколько меньшими значениями общей точности.

Анализ общей точности классификации на уровне отдельных классов выявил существенные различия в производительности моделей машинного обучения на обоих исследуемых объектах.

Общая точность классификации моделью *RF* для обоих объектов находилась в пределах 76–82 %. Каппа Коэна для объекта 1 составила 0,75, для объекта 2 – 0,67, что в первом случае соответствует хорошему уровню согласия, а во втором – умеренному. Для объекта 1 модель *RF* (см. табл. 1) показала удовлетворительные результаты, общая точность распознавания классов «рабочие участки полей», «лес и лесополосы» и «дороги» была существенно выше 80 %, что указывает на способность модели корректно выделять земные поверхности с относительно однородными спектральными и текстурными характеристиками. Однако общая точность классификации класса «застройка» существенно снизилась, что может быть обусловлено высокой внутренней гетерогенностью данного класса и значительной спектральной изменчивостью, слабо моделируемой деревьями решений. При этом класс «водные объекты» был распознан с максимально возможной общей точностью, что связано с их чётко выраженным и стабильным спектральным контрастом, позволяющим даже простым пороговым правилам принимать корректные решения. Для объекта 2 (см. табл. 2) наблюдалось значительное падение обобщающей способности модели *RF*. Наиболее критичное снижение точности отмечено для классов «застройка» и «водные объекты». Низкие значения общей точности этих типов земной поверхности, как правило, легко идентифицируемых, свидетельствуют о недостаточной адаптации модели *RF* к изменчивости условий на объекте 2.

Общая точность классификации с использованием модели *SVM* для обоих объектов была высокой и варьировала в пределах 88–92 %. Каппа Коэна для объекта 1 составила 0,88, для объекта 2 – 0,85, что указывает на высокую устойчивость модели к переобучению. Для объекта 1 (см. табл. 1) модель *SVM* показала высокую и сбалансированную производительность по большинству выделенных классов. Общая точность классификации классов «рабочие участки полей», «лес и лесополосы» составила более 90 %. Наиболее низкие, хотя и остающиеся на высоком уровне, значения общей точности отмечены для классов «дороги» и «застройка», что связано, по-видимому, с гетерогенностью их спектральных характеристик, из-за смешанного покрытия, а также с фрагментарностью и небольшими размерами объектов. Для объекта 2 (см. табл. 2) класс «лес и лесополосы» был определён с максимальной точностью. Для классов «рабочие участки полей», «растительность» и «застройка» точность классификации приближалась к 90 %. Класс «дороги» был распознан с меньшей точностью, а наиболее существенное снижение общей точности отмечено для класса «водные объекты».

Общая точность классификации с использованием модели *MLP* составила 96 % для объекта 1 и 91 % – для объекта 2. Значения Каппа Коэна, равные 0,94 и 0,86 соответственно, показывают высокий уровень согласия между результатами классификации и эталонными классами. Такие показатели указывают на высокую достоверность выделения классов и устойчивость модели к внутрисистемным

вариациям спектральных сигнатур. Модель *MLP* для объекта 1 (см. табл. 1) достигла максимальных значений общей точности классификации классов «рабочие участки полей», «водные объекты» и «застройка», что говорит о её способности эффективно разделять объекты с контрастными спектральными значениями. Удовлетворительная точность классификации получена также для классов «дороги» и «лес и лесополосы». Для объекта 2 (см. табл. 2) модель *MLP* сохранила высокую производительность при классификации классов «рабочие участки полей», «лес и лесополосы», «растительность» и «застройка». Однако точность классификации для класса «водные объекты» существенно снизилась.

На основании результатов классификации изображений дистанционного зондирования с помощью модели *MLP* созданы карты-схемы землепользований ОС «Элитная» (рис. 3) и ИП ГК(Ф) Х Ковалев С. М. (рис. 4), содержащие идентифицированные типы земной поверхности в виде классов пространственных объектов.

Картографирование классов пространственных объектов на исследуемых территориях осуществлено с помощью геоинформационных технологий на основе их классификации (идентификации) с помощью анализа данных, полученных из спутниковых изображений. Модели МО позволяют эффективно обрабатывать большие объемы данных векторной информации космических снимков и способствуют повышению точности классификации.




Рис. 3. Карта-схема классификации территории землепользования ОС «Элитная», выполненная с помощью модели *MLP*

Fig. 3. Schematic map showing the classification of the Elitnaya Experimental Station land use territory generated using *MLP* model




Рис. 4. Карта-схема классификации территории землепользования
ИП ГК(Ф) Х Ковалев С. М., выполненная с помощью модели *MLP*

Fig. 4. Schematic map showing the classification of the Individual Entrepreneur – Head of Peasant (Farm) Enterprise Kovalev S.M. land use territory generated using *MLP* model

Заклучение

Традиционные классификаторы при использовании пиксельного подхода показали неоднородные и, в ряде случаев, неудовлетворительные результаты. Метод максимального правдоподобия продемонстрировал удовлетворительную общую точность и высокую точность для таких контрастных классов, как «водные объекты» и «дороги», однако существенно снизил эффективность при распознавании класса «застройки» на территории землепользования ИП ГК(Ф) Х Ковалев С. М., что указывает на его чувствительность к спектральной неоднородности. Метод параллелепипедов оказался недостаточно эффективным, особенно для территории землепользования ОС «Элитная», что обусловлено жёсткими границами в признаковом пространстве и высокой вероятностью ошибок при перекрытии спектральных сигнатур. Метод расстояния Махаланобиса продемонстрировал низкую общую точность для обоих объектов, а также низкие значения Каппа Коэна, что свидетельствует о почти случайной согласованности с эталонными классами. При этом общая точность по отдельным классам, таким как «дороги» и «водные объекты», оставалась высокой, что создаёт ложное впечатление о его эффективности. Для критически важных классов, таких как «застройка» и «рабочие участки полей», общая точность классификации оказалась очень низкой.

Объектно-ориентированный подход, основанный на предварительной сегментации изображения и последующей классификации с использованием моделей машинного обучения, показал значительно более высокую и стабильную производительность. Среди протестированных непараметрических классификаторов наилучшие результаты достигнуты с использованием модели *MLP*, обеспечившей наибольшую общую точность

для обоих объектов, при значениях Каппа Коэна 0,94 и 0,86 соответственно. Модель *SVM* также продемонстрировала высокую устойчивость и общую точность, подтверждая эффективность в условиях многомерных данных. Наименьшую, хотя и приемлемую, точность показала модель *RF*, особенно для территории землепользования ИП ГК(Ф) Х Ковалев С. М.

Проведённое исследование подтверждает, что объектно-ориентированный подход с предварительной сегментацией изображения является наиболее эффективной стратегией классификации многозональных космических снимков.

References

- Garafutdinova L.V., Kalichkin V.K., Fedorov D.S. 2024. Object-Oriented Classification of Remote Sensing Earth Images Using Machine. *Vestnik University of biotechnology*, 2: 37–47 (in Russian). <https://doi.org/10.31677/2072-6724-2024-71-2-37-47>
- Behera D.K., Pujar G.S., Kumar R., Singh S.K. 2025. A Comprehensive Approach Towards Enhancing Land Use Land Cover Classification Through Machine Learning and Object-Based Image Analysis. *Journal of the Indian Society of Remote Sensing*, 53(3): 731–749. <https://doi.org/10.1007/s12524-024-01997-w>.
- Blaschke T., Hay G. J., Kelly M., Lang S., Hofmann P., ... Tiede D. 2014. Geographic Object-Based Image Analysis—Towards a New Paradigm. *ISPRS journal of photogrammetry and remote sensing*, 87: 180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>.
- Breiman L. 2001 Random forests. *Machine learning*, 45(1): 5–32.
- Chen G., Weng Q., Hay G.J., He Y. 2018. Geographic Object-Based Image Analysis (GEOBIA): Emerging Trends and Future Opportunities. *GIScience & Remote Sensing*, 55(2): 159–182. <https://doi.org/10.1080/15481603.2018.1426092>.
- Cohen J. 1960. A Coefficient of Agreement for Nominal Scales. *Educational and psychological measurement*, 20(1): 37–46.
- Ez-zahouani B., Teodoro A., Kharki O.El., Jianhua L., Kotaridis I., ... Ma L. 2023. Remote Sensing Imagery Segmentation in Object-Based Analysis: A Review of Methods, Optimization, and Quality Evaluation over the Past 20 Years. *Remote Sensing Applications: Society and Environment*, 32: 101031. <https://doi.org/10.1016/j.rsase.2023.101031>.
- Haykin S. 2009. *Neural Networks and Learning Machines*. 3rd ed. Pearson Prentice Hall, 906 p.
- Hossain M.D., Chen D. 2022. A Hybrid Image Segmentation Method for Building Extraction from High-Resolution RGB Images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 192, 299–314. <https://doi.org/10.1016/j.isprsjprs.2022.08.024>.
- Jancevičius J., Kalibatiene D. 2025. Application of Image Recognition Methods to Determine Land Use Classes. *Applied Sciences*, 15(9): 4765. <https://doi.org/10.3390/app15094765>
- Kucharczyk M., Hay G.J., Ghaffarian S., Hugenholtz C.H. 2020. Geographic Object-Based Image Analysis: a Primer and Future Directions. *Remote Sensing*, 12(12): 2012. <https://doi.org/10.3390/rs12122012>.
- Lang S., Hay G.J., Baraldi A., Tiede D., Blaschke T. 2019. Geobia Achievements and Spatial Opportunities in the Era of Big Earth Observation Data. *ISPRS International Journal of Geo-Information*, 8(11): 474. <https://doi.org/10.3390/ijgi8110474>.
- Liu B., Du S., Du S., Zhang X. 2020. Incorporating Deep Features into GEOBIA Paradigm for Remote Sensing Imagery Classification: A Patch-Based Approach. *Remote Sensing*, 12(18): 3007. <https://doi.org/10.3390/rs12183007>
- Manohar Kumar C., Jha S.S., Nidamanuri R.R., Dadhwal V.K. 2022. Benchmark Studies on Pixel-Level Spectral Unmixing of Multi-Resolution Hyperspectral Imagery. *International Journal of Remote Sensing*, 43(4): 1451–1484. <https://doi.org/10.1080/01431161.2022.2040755>.
- Maxwell A.E., Warner T.A., Fang F. 2018. Implementation of Machine-Learning Classification in Remote Sensing: An Applied Review. *International journal of remote sensing*, 39(9): 2784–2817. <https://doi.org/10.1080/01431161.2018.1433343>.
- Mehmood M., Shahzad A., Zafar B. Shabbir A., Ali N. 2022. Remote Sensing Image Classification: A Comprehensive Review and Applications. *Mathematical problems in engineering*, 2022(1): 5880959. <https://doi.org/10.1155/2022/5880959>.

- Ozturk M.Y., Colkesen I. 2024. A Novel Hybrid Methodology Integrating Pixel-And Object-Based Techniques for Mapping Land Use and Land Cover from High-Resolution Satellite Data. *International Journal of Remote Sensing*, 45(16): 5640–5678. <https://doi.org/10.1080/01431161.2024.2379515>.
- Richards J.A. 2013. *Remote Sensing Digital Image Analysis: an Introduction*. Berlin, Heidelberg, Springer Berlin Heidelberg, 494 p.
- Talukdar S., Singha P., Mahato S., Pal S., Liou Y.A., Rahman A. 2020. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations – A review. *Remote sensing*, 12(7): 1135. <https://doi.org/10.3390/rs12071135>.
- Vapnik V. 1998. *Statistical Learning Theory*. New York, Wiley, 736 p.
- Wang Q., Ding X., Tong X., Atkinson P. M. 2021. Spatio-Temporal Spectral Unmixing of Time-Series Images. *Remote Sensing of Environment*, 259: 112407. <https://doi.org/10.1016/j.rse.2021.112407>.
- Zafar Z., Zubair M., Zha Y., Fahd S., Nadeem A.A. 2024. Performance Assessment of Machine Learning Algorithms for Mapping of Land Use/Land Cover Using Remote Sensing Data. *The Egyptian Journal of Remote Sensing and Space Sciences*, 27(2): 216–226. <https://doi.org/10.1016/j.ejrs.2024.03.003>.

*Поступила в редакцию 19.09.2025;
поступила после рецензирования 22.10.2025;
принята к публикации 20.11.2025*

*Received September 19, 2025;
Revised October 22, 2025;
Accepted November 20, 2025*

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Гарафутдинова Людмила Вячеславовна, младший научный сотрудник сектора геоинформационных систем, Сибирский федеральный научный центр агробиотехнологий Российской академии наук, Новосибирская область, р.п. Краснообск, Россия

Каличкин Владимир Климентьевич, доктор сельскохозяйственных наук, профессор, главный научный сотрудник лаборатории цифровых технологий в земледелии, Сибирский федеральный научный центр агробиотехнологий Российской академии наук, Новосибирская область, р.п. Краснообск, Россия

Федоров Дмитрий Сергеевич, младший научный сотрудник лаборатории цифровых технологий в земледелии, Сибирский федеральный научный центр агробиотехнологий Российской академии наук, Новосибирская область, р.п. Краснообск, Россия

INFORMATION ABOUT THE AUTHORS

Lyudmila V. Garafutdinova, Junior Researcher of the Geo-Information Systems Sector, Siberian Federal Scientific Centre of Agro-BioTechnologies of the Russian Academy of Sciences, Novosibirsk Region, Krasnoobsk, Russia

Vladimir K. Kalichkin, Doctor of Agricultural Sciences, Professor, Chief Researcher, Laboratory of Digital Technologies in Agriculture, Siberian Federal Scientific Centre of Agro-BioTechnologies of the Russian Academy of Sciences, Novosibirsk Region, Krasnoobsk, Russia

Dmitry S. Fedorov, Junior Researcher, Laboratory of Digital Technologies in Agriculture, Siberian Federal Scientific Centre of Agro-BioTechnologies of the Russian Academy of Sciences, Novosibirsk Region, Krasnoobsk, Russia