

Методика типизации земельных угодий алгоритмами контролируемой классификации (на примере промышленно развитых районов Белгородской области)

О. И. Григорьева, Л. Хуан

*Белгородский государственный национальный исследовательский университет
Белгород, 308015, Россия
E-mails: grigoreva_o@bsuedu.ru, lhuang0@163.com*

Создана модель типизации земельных угодий на основе классификации спутниковых данных Sentinel-2. В ходе работ проведена оценка сопряженности обучающих данных и фактического состояния типов земельных угодий. Выполнена классификация типов земельных угодий по трём основным методам контролируемой классификации. Наилучший результат показала классификация, осуществлённая по методу максимального правдоподобия. Проведена оценка точности на основе коэффициента Каппа, значение которого составило 0,9. При сравнении с визуально-интерпретационными данными по космическим снимкам типов земельных угодий выявились отклонения в таких типах земель, как пашня с посевами и сенокосы и пастбища, земли под застройкой, промышленно-разработанные земли и дороги, нарушенные земли. Модель адаптирована для локальных условий региона исследования. Она способна оперативно обрабатывать большие объёмы данных, создавать продукты регионального масштаба с высоким пространственным разрешением и итеративно улучшаться для возможности принятия оперативных решений в области управления земельными ресурсами. Полученные результаты подтверждают эффективность созданной модели, метода максимального правдоподобия для решения задач картографирования земельных угодий с высоким уровнем точности. Разработанная модель может быть использована для мониторинга землепользования, инвентаризации сельскохозяйственных земель и решения других прикладных задач в сфере управления земельными ресурсами.

Ключевые слова: дистанционное зондирование Земли, контролируемая классификация, метод максимального правдоподобия, типизация земельных угодий

Одобрена к печати: 30.11.2025
DOI: 10.21046/2070-7401-2026-23-2-204-215

Введение

Обеспечение органов государственной власти объективной информацией о количественном и качественном состоянии земель — одно из основных условий эффективной реализации земельной политики. Текущее состояние средств мониторинга динамики изменения земельных угодий диктует необходимость применения данных дистанционного зондирования Земли (ДЗЗ), инструментов машинного обучения и геопространственного анализа в качестве средств управления. При этом одним из условий создания эффективной системы оперативного спутникового мониторинга следует считать наличие алгоритмов и технологий обработки спутниковых данных, не предполагающих участия экспертов или минимизирующих необходимость в их участии (Барталев и др., 2006).

К настоящему времени накоплен значительный массив исследовательских работ, направленных на создание методов обработки спутниковых данных для получения информации о состоянии земель. Разработаны алгоритмы и программные комплексы распознавания типов земельных угодий (Уваров, Барталев, 2007, 2010). Применение спутниковых данных подтвердило высокую эффективность при решении задач мониторинга растительного покрова (Лупян и др., 2020; Плотников и др., 2020; Шабанов и др., 2018).

Многие исследователи вышли на новый информационный уровень идентификации изменений в землепользовании и земном покрове. В современной научной литературе предлагается множество методов моделирования по их использованию и покрытию поверхности

LULC (*англ.* Land Use and Land Cover) по массивам данных ДЗЗ, имеющих различные методологические подходы, а также свои преимущества и недостатки.

Учёными Института космических исследований РАН разработан программный комплекс, позволяющий выполнять вычислительные процедуры по распознаванию типов земельных угодий на основе локально-адаптивной классификации спутниковых изображений с помощью алгоритма обучаемой классификации LAGMA (*англ.* Locally-Adaptive Global Mapping Algorithm), а также отслеживать участки пашни как введённой в сельскохозяйственный оборот, так и заброшенной (Барталев и др., 2011). Используемые композитные изображения формировались по данным наблюдений и содержат значения коэффициента спектральной яркости в каналах с пространственным разрешением 250 м. Применение спутниковых данных относительно невысокого пространственного разрешения приводит к достаточно большим погрешностям в оценке площадей (Барталев и др., 2006). Нивелирование такой погрешности возможно с помощью дополнительных процедур по введению данных о границах и площадях территорий, участвующих в выборке или исключаящих её. Но, как правило, в свободном доступе подобные сведения отсутствуют, что усложняет процесс классификации земель предложенным способом.

В современной классификации земель по данным дистанционного зондирования машинное обучение развивается от традиционных алгоритмов к сложным глубоким нейросетям. Среди традиционных методов случайный лес RF (*англ.* Random Forest) показывает лучшие результаты: так, в задачах агроэкологической классификации его точность достигала 97,9 % (Павлова, 2023). Градиентный бустинг XGBoost (*англ.* EXtreme Gradient Boosting) и анализы временных рядов в классификации сельскохозяйственных культур с использованием сезонных профилей NDVI (*англ.* Normalized Difference Vegetation Index) от Sentinel-2 показали точность выше 94 % (Дубровин и др., 2023). Минусы этих методов заключаются в том, что они требуют ручной инженерии признаков и могут уступать в точности на сложных гетерогенных масштабах, например, в городской застройке (Алпысбай и др., 2025; Wang et al., 2025). Традиционные методы классификации ограничены тем, что они основаны на низкочастотном анализе признаков, что не позволяет им извлекать высокоуровневую семантическую информацию и часто не соответствует требованиям к точности, предъявляемым к классификации объектов дистанционного зондирования (Wang et al., 2025). В настоящее время распространение глубокого обучения привело к появлению множества методов классификации изображений, полученных с помощью ДЗЗ. Их можно условно разделить на три типа: на основе автокодировщиков, свёрточных нейронных сетей и генеративно-состязательных сетей (Cheng et al., 2022). Используются свёрточные нейронные сети и архитектуры глубокого обучения для автоматического обучения пространственным и контекстным признакам высокого уровня из изображений (Wang et al., 2025). Комбинации глубокого обучения с активным обучением для эффективной работы с временными рядами изображений (Хуснутдинов и др., 2025), а также методы, которые объединяют свёрточные нейронные сети и архитектуры глубокого обучения без изменений архитектуры, обеспечивают высокую точность при малом размере модели (Song et al., 2025). Положительные стороны глубокого обучения — это максимальная точность и автоматическое извлечение признаков. Из минусов отметим: необходимость большого массива размеченных данных, высокие вычислительные затраты, риск переобучения модели и сложная интерпретируемость результатов.

Количество новых методов обработки изображений, реализованных в профессиональных программных комплексах, очень незначительно. Также наблюдается схожесть между профессиональными программными комплексами как по реализованным в них этапам обработки, так и непосредственно по методам обработки изображений ДЗЗ. Несмотря на то, что изображения дистанционного зондирования с высоким разрешением содержат обширную семантическую информацию, типизация классов земель сталкивается со значительными трудностями из-за ограниченного количества размеченных образцов и дисбаланса классов. Хотя в некоторых исследованиях изучался дисбаланс классов в контексте дистанционного зондирования (Guan et al., 2020), комплексные исследования в этой области по-прежнему ограничены. В этой связи возникает необходимость анализа состояния и основных тенденций

в области методов обработки изображений ДЗЗ. Отсутствие работ по комплексной классификации типов земельных угодий на территории Белгородской области, учитывающей специфику экосистем Белгородчины, порождает необходимость создания методики, предусматривающей построение локализованных сигнатур различных типов земельных угодий по признакам, характерным для исследуемого региона.

В качестве алгоритма обработки данных дистанционного зондирования нами выбран метод контролируемой классификации, так как данный тип классификации используют в случаях, когда необходимо идентифицировать объекты с более высокой точностью, чем позволяет классификация без обучения (Bakkestuen et al., 2023; Hamzah, Abdul-Rhaim, 2022).

Объект исследования

В качестве объекта исследования выбраны два экономически и демографически перспективных района Белгородской области, входящие в состав Старооскольско-Губкинской агломерации, которая консолидирует активно развивающиеся кластеры промышленного производства и сельскохозяйственной деятельности.

За последнее 50 лет здесь отмечен высокий темп изменения земельного фонда, коснувшийся всех категорий земель Губкинского и Старооскольского районов по сравнению с другими административными районами Белгородской области, что послужило решающим фактором в выборе данной территории в качестве исследуемой.

Из исследования исключена территория административных центров — городов Губкин и Старый Оскол.

Материалы и методы

В настоящее время разработаны многочисленные LULC-продукты, на основе которых проводятся различные исследования, в том числе отслеживается динамика изменения земельных угодий. Свободно доступные данные LULC, которые можно сразу использовать, основаны на спутниковых снимках с пространственным разрешением более 30 м. Однако разрешение в 30 м не позволяет точно распознать объекты меньшего размера. Более того, во многих анализируемых нами LULC-продуктах дороги вообще не выделяются как отдельная категория. В международной классификации земельных угодий отсутствуют такие типы угодий, установленные в России, как нарушенные земли, сенокосы, пастбища, многолетние насаждения (фруктовые сады), пашня без посевов. Нарушенные земли в существующих LULC-продуктах по системе классификации земли, разработанной Организацией продовольствия и сельского хозяйства, относятся к классу оголённые земли, но, как правило, в этом же классе также отображены улицы, дороги, открытые, не занятые растительностью угодья. Пашня без посевов также идентифицируется как оголённые земли. Земли, занятые под садами, не имеют отдельного класса, так как идентифицируются как земли, занятые растительностью, и могут попадать в класс леса. Таким образом, для осуществления мониторинга земель в разрезе категорий и угодий, принятых в России, применение существующих LULC-продуктов нецелесообразно. Необходимо создать адаптированную LULC-платформу, содержащую информацию о земельных угодьях, классифицированных по типам, применяемым органами власти.

Первоначально был осуществлён выбор спектральных каналов и проведена предварительная обработка космических снимков. В работе использованы изображения Sentinel-2 уровня обработки MSIL2A (*англ.* Multispectral Instrument Level-2A), охватывающие территорию исследования в период вегетационного сезона 2020 г. (июнь — август). Изображения уровня L2A уже прошли атмосферную коррекцию и радиометрическую калибровку, что делает их пригодными для дальнейшего анализа. Изображения этого уровня обработки включают значения отражательной способности земной поверхности на нижней границе атмосферы (*англ.* bottom of atmosphere) (Терехин, 2023, 2024). Хотя пространственное разрешение сним-

ков Sentinel-2, используемое в нашей работе, накладывает некоторые ограничения на проведение очень детального анализа (например, идентификацию объектов шириной менее 10 м), потенциал данных с таким уровнем пространственной детализации, хорошо подобранными спектральными диапазонами и региональным охватом можно считать привлекательным с точки зрения их применения в дальнейших исследованиях.

В настоящей работе была выбрана мозаика, сшитая из растров, датированных 24 и 31 августа 2020 г., с минимальным пространственным разрешением 10 м (длина сторон пикселя) и с минимальной облачностью (<1 %).

С помощью программного обеспечения SNAP были извлечены спектральные каналы для дальнейшего анализа: B4 (красный), B3 (зелёный), B2 (синий). Для создания RGB-изображений и визуальной интерпретации использовались следующие каналы: B4, B3, B2, B8 (ближний инфракрасный), а каналы B11, B12 (коротковолновый инфракрасный) — для проведения классификации. Далее изображения были объединены в единый слой, обрезаны по границам исследуемой территории и экспортированы в формате ENVI (*англ.* Environment for Visualizing Images) (.dat). Дополнительно авторами использованы переменные, которые были включены в классификацию: нормализованный индекс растительности NDVI, нормализованный индекс различий застройки NDBI (*англ.* Normalized Difference Building Index), а также нормализованный разностный водный индекс RNDWI (*англ.* Relative Normalized Difference Water Index).

Оценка классификации водных объектов, выполненная на основе RNDWI, по мнению авторов работы (Nimbalkar et al., 2025), превышает 90 %. Индекс RNDWI вычислен по формуле:

$$\text{RNDWI} = \frac{\text{B3} - \text{B11}}{\text{B3} + \text{B11}}.$$

В качестве индекса растительности в нашем исследовании был выбран NDVI, поскольку он продолжает доминировать в области применения индексов растительности, полученных на основе существующих и новых источников данных дистанционного зондирования (Huang et al., 2020), а его последовательное использование различными датчиками и платформами повышает эффективность NDVI при оценке растительности в пространстве и во времени (Grant, 2017).

Математически индекс NDVI рассчитан по формуле:

$$\text{NDVI} = \frac{\text{B8} - \text{B4}}{\text{B8} + \text{B4}}.$$

На сегодняшний день существует несколько простых способов автоматического картографирования застроенных территорий, таких как использование индексов. Нормализованный индекс различий застройки NDBI, предложенный в работе (Zha et al., 2003), пока выбран как единственный предлагаемый для реализации нашей цели. Математическое выражение индекса NDBI имеет следующий вид:

$$\text{NDBI} = \frac{\text{B11} - \text{B8}}{\text{B11} + \text{B8}}.$$

Интерпретация значений индексов осуществлялась на основе диапазонов (*табл. 1*), применяемых в работах (Jones, Vaughan, 2010; Zha et al., 2003).

Поскольку алгоритмы контролируемой классификации систематизируют спутниковые снимки на основе спектральных значений на уровне пикселей, содержащих отражательные свойства природных и антропогенных объектов, в программном продукте ENVI была выполнена визуальная интерпретация изображений и построены полигоны в формате ROI (*англ.* Region Of Interest) (область интересов, соответствующих необходимым типам земельных угодий) на основе рассчитанных индексов NDVI, RNDWI, NDBI и RGB-композиций, поддерживаемых для различных классов землепользования (*рис. 1*, см. с. 208).

Таблица 1. Диапазоны классификаций изображений по спектральным характеристикам

Индекс	Диапазоны по классификации	Интерпретация
NDVI	$-1 < 0$	Водные объекты (реки, водоёмы)
	$0-0,2$	Отсутствие растительности
	$0,2-0,5$	Для пастбища и пашни с растительностью
	$0,5-1,0$	Для лесных земель и участков под садами
RNDWI	>0	Водные объекты (реки, водоёмы)
	<0	Растительность, почвы, застройка
NDBI	>0	Урбанизированные территории
	<0	Неурбанизированные объекты

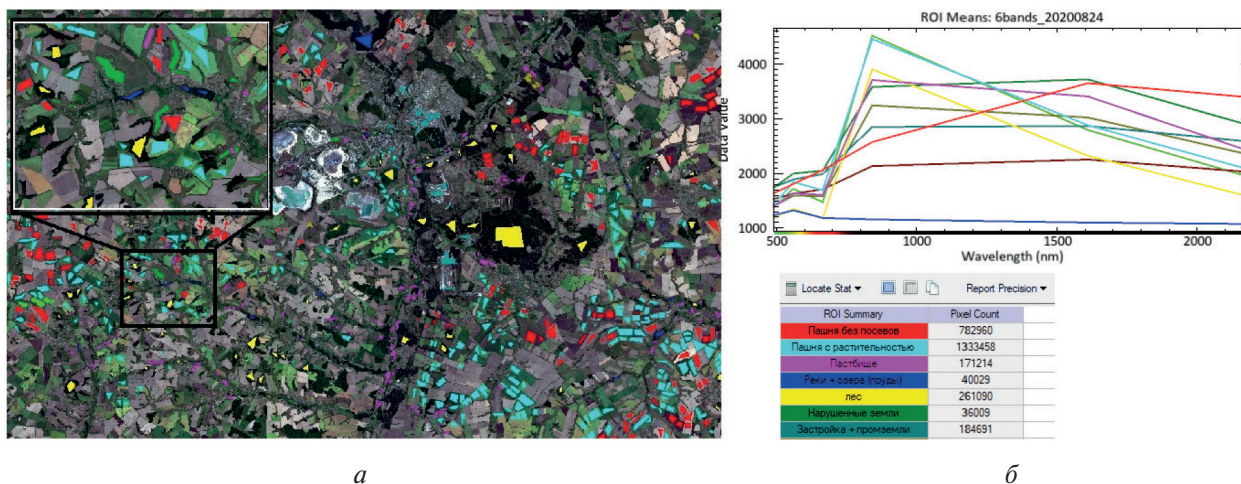


Рис. 1. Формирование обучающих выборок ROI: а — полигоны обучения; б — кривые спектральной яркости для эталонов обучающей выборки

Следует отметить, что пахотные земли в периоды, свободные от посевов, визуально легко распознаются по спутниковым изображениям, однако построение эффективного автоматического алгоритма их картографирования на больших территориях сопряжено с необходимостью учёта множества факторов (Барталев и др., 2006). В данной работе в качестве такого фактора было применено обстоятельство регионального различия в динамике развития сельскохозяйственных культур и яркости почв.

Выявление по данным спутниковых наблюдений используемых пахотных земель и их отделение от естественной растительности осуществляли по признакам, удовлетворяющим ряду условий, приведённых в публикации (Плотников и др., 2010). Данные признаки, построенные на основе многолетних рядов перпендикулярного индекса растительности PVI (англ. Perpendicular Vegetation Index), учитывают характерные отличия между естественной и сельскохозяйственной растительностью.

В общей сложности отобрано 700 географических объектов, которые были разделены на 7 различных классов по 100 полигонов для каждого класса. Так как в структуре земельного фонда исследуемой территории пашня занимает преобладающее большинство, то, соответственно, для повышения точности при идентификации пашни было обучено наибольшее количество пикселей — около 1 млн, для лесных массивов — 261 тыс. пикселей, для сенокосов и пастбищ — 171 тыс. пикселей, для земель, занятых застройкой — 184 тыс. пикселей, для водных объектов — 40 тыс. пикселей. Каждому создаваемому классу объекта присваивался соответствующий код, а типы угодий идентифицировались по визуально-интерпретационным характеристикам. Выделено семь типов угодий: пашня; сенокосы и пастбища; лес

и древесно-кустарниковая растительность (ДКР); земли, занятые застройкой и дорогами; промышленно-разработанные земли; нарушенные земли; земли, занятые водными объектами (далее — водные объекты). Пашня классифицировалась по двум параметрам: с наличием посевов сельскохозяйственных культур и без посевов.

Затем был осуществлён анализ разделимости типов земель, основанный на классификации индексов трансформированной дивергенции (*англ.* Transformed Divergence) в ENVI. Наивысшие результаты (1,9–2,0) отмечены практически для всех типов земель. Переобучению подверглись только земли, занятые под застройкой и дорогами, а также нарушенные земли, поскольку они имели самый низкий коэффициент разделимости (1,4).

На следующем этапе с помощью инструмента контролируемой классификации (*англ.* Supervised Classification) в ENVI проведена классификация изображений по всей территории исследования. Были использованы три алгоритма контролируемой классификации изображений: метод максимального правдоподобия MLC (*англ.* Maximum Likelihood Classification), метод минимального расстояния MD (*англ.* Minimum Distance), метод спектрального угла SAM (*англ.* Spectral Angle Mapper).

Для проверки точности выполненной классификации изображений построена матрица несоответствий (ошибок). Опорные данные матрицы включали результаты визуальной интерпретации NDVI/NDWI/NDBI, RGB-синтез из каналов B4, B3, B2 и официальную статистику землепользований.

Чтобы оценить эффективность созданной модели типизации земельных угодий, использованы несколько общепринятых ключевых статистических показателей, включая общую точность, коэффициент согласия Каппа, точность пользователя и точность производителя. Каждая из этих метрик даёт уникальную информацию о различных аспектах работы модели, позволяя всесторонне оценить результаты классификации (Cerulli, 2023).

Результаты

В результате разработана методика типизации земельных угодий на основе данных космических снимков, конечным шагом которой выступает создание картосхемы типов земельных угодий в виде LULC-продукта. Процесс создания LULC-продукта по данной методике представлен в виде блок-схемы (*рис. 2*, см. с. 210).

Для оценки точности контролируемой классификации в границах исследуемой территории использовались тестовые зоны, сопоставимые по размеру с тренировочными зонами. При этом количество тестовых зон было ограничено до 10 для каждого класса с целью обеспечения сопоставимости и корректности оценки. Результаты проверки классификации представлены в *табл. 2*.

Таблица 2. Точность алгоритмов контролируемой классификации изображений

Вид угодий	Точность пользователя			Точность производителя			Коэффициент Каппа		
	SAM	MD	MLC	SAM	MD	MLC	SAM	MD	MLC
Пашня с посевами	95,3	97,7	96,3	99,6	99,3	100,0	0,8	0,8	0,9
Пашня без посевов	71,7	89,4	95,1	95,9	87,1	99,9			
Сенокосы и пастбища	69,9	97,6	94,6	97,7	99,6	99,9			
Водные объекты	96,9	98,8	100,0	99,3	99,8	99,4			
Лес и ДКР	99,8	97,0	99,8	99,9	99,9	99,9			
Застройка, промышленно-разработанные земли и дороги	90,2	98,7	95,9	92,1	58,6	88,2			
Нарушенные земли	42,6	44,9	41,8	44,7	87,2	59,8			

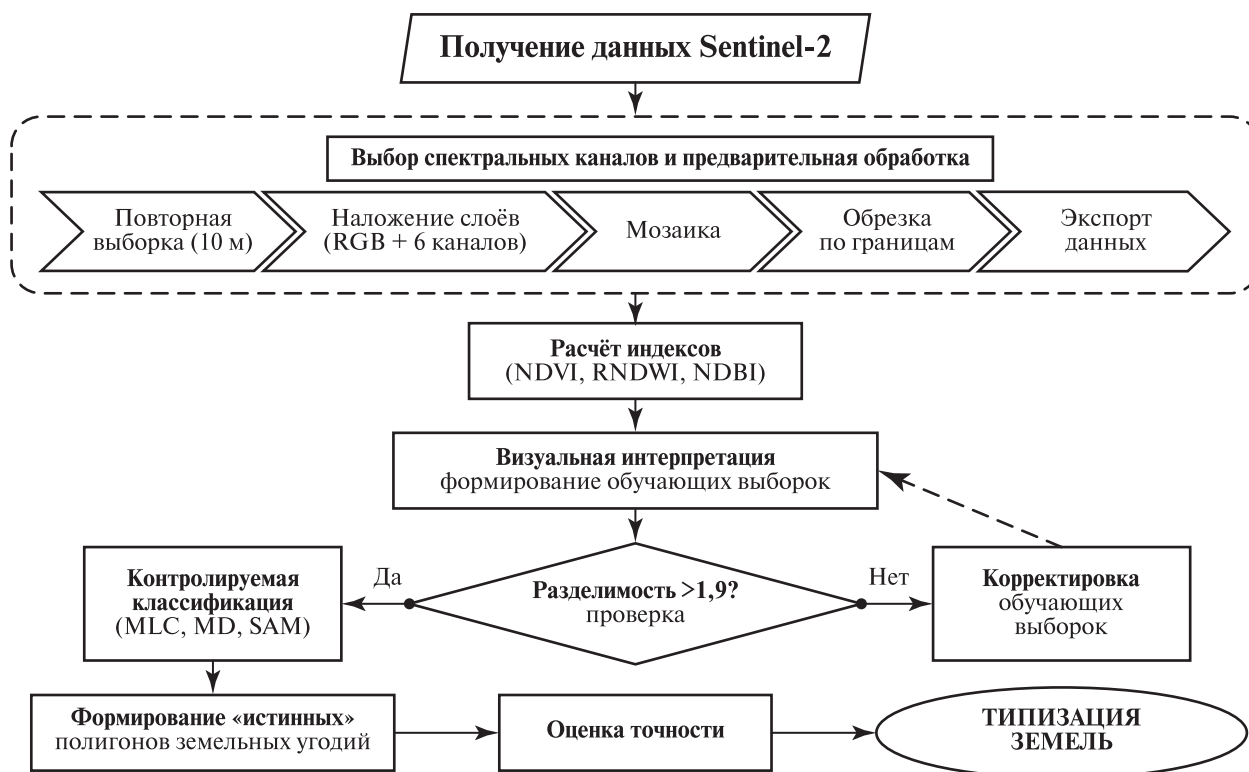


Рис. 2. Блох-схема модели типизации земельного покрова (составлена авторами)

В качестве входных признаков для классификатора использован многоканальный растр, объединяющий шесть спектральных каналов (B2, B3, B4, B8, B11, B12) и три рассчитанных индекса (NDVI, RNDWI, NDBI). Выполнена классификация широко известными алгоритмами.

Сравнительный анализ точности классификации показал, что применённые алгоритмы существенно различаются по своим интегральным и классовым показателям. Алгоритм SAM характеризуется наименьшими значениями общей точности (83,0 %) (коэффициент Каппа 0,8), что указывает на его ограниченные возможности при разделении спектрально неоднородных классов. Наиболее низкие значения пользовательской и производственной точности для данного алгоритма отмечены для класса нарушенные земли, а также для классов сенокосы и пастбища и пашня без посевов, что может быть связано с высокой внутриклассовой вариабельностью отражательных характеристик, идентификацией мелкоконтурных участков шириной менее 10 м как соседних, более выраженных типов земельных угодий. Наибольшая точность совпадения отмечена для класса водные объекты.

Алгоритм MD продемонстрировал улучшение общей точности (86,8 %) (коэффициент Каппа 0,8) по сравнению с SAM, обеспечив более устойчивую классификацию большинства природных классов, включая водные объекты, леса и ДКР. Вместе с тем для антропогенно трансформированных территорий, в частности класса застройка, промышленно-разработанные земли и дороги, сохраняется снижение производственной точности, что свидетельствует о сложности их однозначного распознавания.

Наиболее высокие показатели точности получены при использовании алгоритма максимального правдоподобия (MLC), для которого зафиксированы максимальные значения общей точности (95,3 %) и коэффициента Каппа (0,9). Данный алгоритм обеспечил высокую и относительно равномерную пользовательскую и производственную точность по большинству классов землепользования и земельного покрова, включая пашню, лес и ДКР, а также водные объекты. Вместе с тем класс нарушенные земли во всех алгоритмах характеризуется пониженной точностью, что подчёркивает сложность его корректной классификации и необ-

ходимость дальнейшего уточнения методики. Классификация изображений методом максимального правдоподобия показывает более точные результаты, несмотря на то, что требует больших вычислительных затрат и времени.

Наиболее частые ошибки классификации отмечены между такими угодьями как пашня с посевами и сенокосы и пастбища. Границы между крупными однородными участками (лес, водные объекты) выявлены отчётливо.

Таким образом, для окончательного построения модели авторами был выбран алгоритм максимального правдоподобия, значения которого достигли наивысшей общей производительности (коэффициент Каппа равен 0,9). Этот алгоритм не только обладал высочайшей общей точностью, но и поддерживал сбалансированную точность в отдельных классах.

На основе разработанной методики авторами осуществлена типизация земельных угодий (рис. 3).

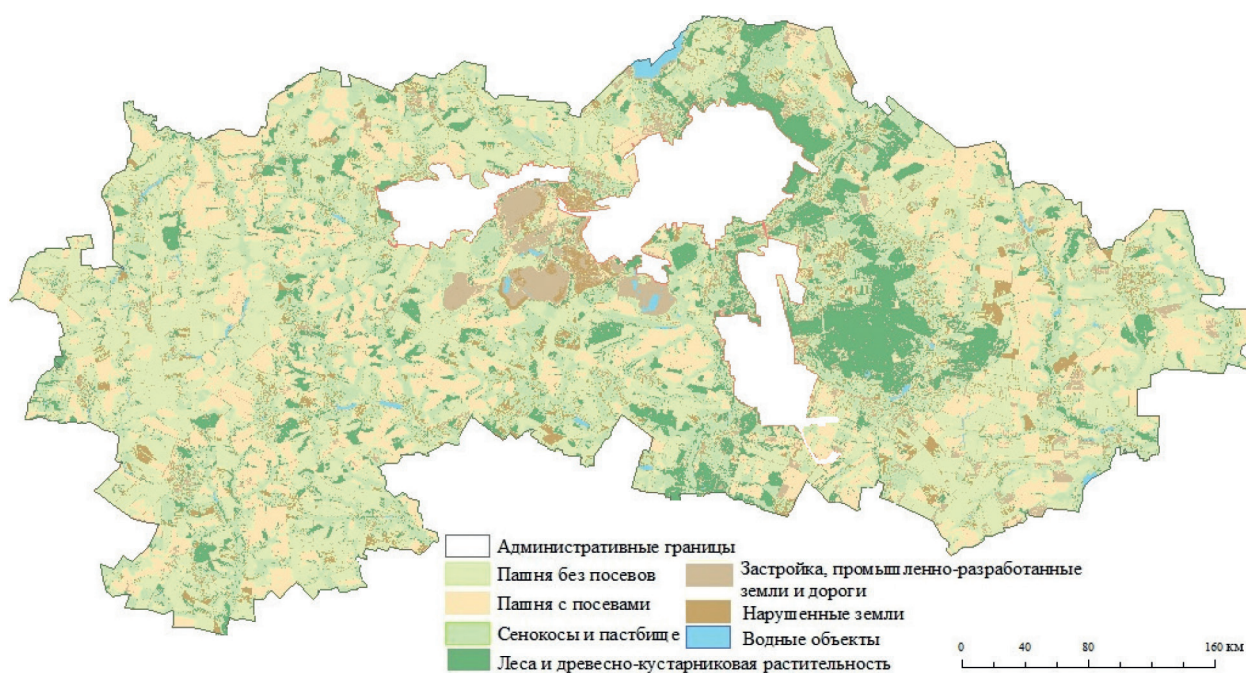


Рис. 3. Типизация земельных угодий, выполненная по разработанной методике

Далее выполнена апробация результатов типизации земель, реализованной по предлагаемой методике. Учитывая высокую точность исходных снимков, верификация построенных классов проведена визуально по RGB-синтезу из каналов B4, B3, B2. Результат модели наложен на RGB-композит тестовых полигонов, охватывающих разные типы местности. Выборочно было обследовано по 3–5 угодий каждого типа земель. Результаты показали точное совпадение классификации земель с визуальной интерпретацией космических снимков.

Заключение

Созданная модель типизации земельных угодий на основе выбранных спектральных каналов Sentinel-2 и комбинации рассчитанных индексов с использованием контролируемой классификации MLC продемонстрировала высокую точность классификации по всем трём оценкам (за исключением нарушенных земель). Полученное значение коэффициента Каппа, равное 0,9, указывает на высокое соответствие между классификацией и контрольными данными, на надёжность модели, что делает её самой точной в этом сравнении, а также на более сбалансированную классификацию по отдельным классам. Разработанный рабочий процесс,

представленный в исследовании в виде блок-схемы, адаптирован на локальном уровне для региона исследования и позволяет эффективно создавать карты LULC, пригодные для использования в задачах мониторинга земельных ресурсов, экологического планирования и управления территориями на региональном уровне.

Исследование выполнено при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках государственного задания № FZWG-2025-0006.

Литература

1. *Алысбай М. А., Серикбаева Э. Б., Талгарбаева Д. Н., Ниязбеков Б. Л.* Сравнительный анализ методов машинного обучения для обработки данных дистанционного зондирования // Вестн. КазНУ. Сер. геогр. 2025. Т. 78(3). С. 142–152. <https://doi.org/10.26577/JGEM202578310>.
2. *Барталев С. А., Лулян Е. А., Нейштадт И. А.* Метод выявления используемых пахотных земель по данным дистанционного зондирования со спутников // Современные проблемы дистанционного зондирования Земли из космоса. 2006. Вып. 3. Т. 2. С. 271–280.
3. *Барталёв С. А., Егоров В. А., Лулян Е. А., Плотников Д. Е., Уваров И. А.* Распознавание пахотных земель на основе многолетних спутниковых данных спектрорадиометра MODIS и локально-адаптивной классификации // Компьютер. оптика. 2011. Т. 35. № 1. С. 103–116.
4. *Дубровин К. Н., Верхотуров А. Л., Степанов А. С.* Использование временных рядов NDVI и методов машинного обучения для классификации пахотных земель Хабаровского края // Материалы 21-й Международной конференции «Современные проблемы дистанционного зондирования Земли из космоса». М.: ИКИ РАН, 2023. С. 361. DOI 10.21046/21DZZconf-2023a.
5. *Лулян Е. А., Денисов П. В., Середа И. И. и др.* Наблюдение развития озимых культур в южных регионах России весной 2020 г. на основе данных дистанционного мониторинга // Современные проблемы дистанционного зондирования Земли из космоса. 2020. Т. 17. № 2. С. 285–291. DOI: 10.21046/2070-7401-2020-17-2-285-291.
6. *Павлова А. И.* Агроэкологическая классификация сельскохозяйственных земель с использованием машинного обучения, ГИС и ДДЗЗ // Siberian J. Life Sciences and Agriculture. 2023. Т. 15. № 6. С. 72–88. DOI: 10.12731/2658-6649-2023-15-6-960.
7. *Плотников Д. Е., Барталев С. А., Лулян Е. А.* Признаки распознавания пахотных земель на основе многолетних рядов данных спутникового спектрорадиометра MODIS // Современные проблемы дистанционного зондирования Земли из космоса. 2010. Т. 7. № 1. С. 330–341.
8. *Плотников Д. Е., Ёлкина Е. С., Дунаева Е. А. и др.* Развитие метода автоматического распознавания озимых культур на основе спутниковых данных для оценки их состояния на территории Республики Крым // Таврический вестн. аграрной науки. 2020. № 1(21). С. 64–83. DOI: 10.33952/2542-0720-2020-1-21-64-83.
9. *Терехин Э. А.* Анализ спектрально-отражательных свойств залежных земель Среднерусской лесостепи по данным Sentinel-2 // Компьютер. оптика. 2023. Т. 47. № 2. С. 306–313. DOI: 10.18287/2412-6179-СО-1160.
10. *Терехин Э. А.* Особенности восстановления древесной растительности на постагrogenных землях юга Среднерусской возвышенности // Региональные геосистемы. 2024. Т. 48. № 3. С. 405–415. DOI: 10.52575/2712-7443-2024-48-3-405-415.
11. *Уваров И. А., Барталев С. А.* Разработка автоматического регионально-адаптивного алгоритма обучаемой классификации лесов по спутниковым данным MODIS // Аэрокосм. методы и ГИС-технологии в лесоведении и лесном хоз-ве: докл. 4-й Международ. конф. М.: ГОУ ВПО МГУЛ, 2007. С. 145–146.
12. *Уваров И. А., Барталев С. А.* Алгоритм и программный комплекс распознавания типов земного покрова на основе локально-адаптивной обучаемой классификации спутниковых изображений // Современные проблемы дистанционного зондирования Земли из космоса. 2010. Т. 7. № 1. С. 353–365.
13. *Хуснутдинов А. О., Хабаров В. И., Карманов В. С.* Глубокое обучение для анализа многомерных временных рядов: систематизация типов данных, задач, архитектур и подходов // Системы анализа и обработки данных. 2025. Т. 99. № 3. С. 113–136. DOI: 10.17212/2782-2001-2025-3-113-136.
14. *Шабанов Н. В., Барталев С. А., Ерошенко Ф. В., Плотников Д. Е.* Развитие возможностей дистанционной оценки индекса листовой поверхности по данным MODIS // Современные проблемы дистанционного зондирования Земли из космоса. 2018. Т. 15. № 4. С. 166–178. DOI: 10.21046/2070-7401-2018-15-4-166-178.

15. Bakkestuen V., Venter Z., Ganerød A. J., Framstad E. Delineation of wetland areas in South Norway from Sentinel-2 imagery and LiDAR using TensorFlow, U-Net, and Google Earth Engine // *Remote Sensing*. 2023. V. 15. No. 5. Article 1203. DOI: 10.3390/rs15051203.
16. Cerulli G. *Fundamentals of supervised machine learning: With applications in Python, R, and Stata*. Springer, 2023. 420 p. DOI: 10.1007/978-3-031-41337-7.
17. Cheng G., Sun X., Li K. et al. Perturbation-seeking generative adversarial networks: A defense framework for remote sensing image scene classification // *IEEE Trans. Geoscience and Remote Sensing*. 2022. V. 60. Article 5605111. DOI: 10.1109/TGRS.2021.3081421.
18. Grant B. G. UAV imagery analysis: challenges and opportunities // *Proc. SPIE. Long-Range Imaging II*. 2017. V. 10204. Article 1020406. DOI: 10.1117/12.2264138.
19. Guan J., Liu J., Sun J. et al. Meta metric learning for highly imbalanced aerial scene classification // 45th Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP 2020). IEEE, 2020. P. 4047–4051. DOI: 10.1109/ICASSP40776.2020.9052900.
20. Hamzah A. S., Abdul-Rhaim L. A. Smart home automation system using cloud computing based enhancement security and environment // 2nd Intern. Conf. on Advances in Engineering Science and Technology (AEST 2022). 2022. P. 334–339. DOI: 10.1109/AEST55805.2022.10412921.
21. Huang S., Tang L., Hupy J. P. et al. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing // *J. Forestry Research*. 2020. V. 32. No. 5. P. 1–6. DOI: 10.1007/s11676-020-01155-1.
22. Jones H. G., Vaughan R. A. *Remote sensing of vegetation: Principles, techniques, and applications*. N.Y.: Oxford University Press, 2010. 384 p.
23. Nimbalkar M. S., Shinde P. S., Chaure R. S. Remote sensing-based assessment of surface water bodies in Sahara District, Maharashtra // *InSight Bull.: A Multidisciplinary Interlink Intern. Research J*. 2025. V. 2. No. 6. P. 79–85.
24. Song H., Xie H., Duan Y. et al. Pure data correction enhancing remote sensing image classification with a lightweight ensemble model // *Scientific Reports*. 2025. V. 15. No. 1. Article 5507. DOI: 10.1038/s41598-025-89735-1.
25. Wang P., Zhao X., Chen Y., Zhan L. Improving remote sensing scene classification with data augmentation techniques to mitigate class imbalance // *Frontiers in Computer Science*. 2025. V. 7. Article 1613648. DOI: 10.3389/fcomp.2025.1613648.
26. Zha Y., Gao J., Ni S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery // *Intern. J. Remote Sensing*. 2003. V. 24. No. 3. P. 583–594. DOI: 10.1080/01431160304987.

Methods of land cover typification using controlled classification algorithms (illustrated by industrially developed areas of Belgorod Region)

O. I. Grigoreva, L. Huang

Belgorod State National Research University, Belgorod 308015, Russia
E-mails: grigoreva_o@bsuedu.ru, lhuang0@163.com

A model for creating maps of land use types based on classification of Sentinel-2 satellite data has been created. During the work, the correlation between the training data and the actual state of land use types was assessed. The classification of land use types was performed using three methods, of which classification using the maximum likelihood method showed the best results. The accuracy was assessed using the Kappa coefficient, which was 0.9. When compared with visual interpretation data based on space images of land use types, deviations were found in such land types as arable land with crops, hayfields and pastures, land under construction, industrial land and roads, and disturbed land. The model was adapted to local conditions of the study region. The model is capable of processing large amounts of data in real time, creating regional-scale products with high spatial resolution, and iteratively improving to enable timely land management decisions. The results obtained confirm the effectiveness of the created model, the maximum likelihood method for solving the tasks of mapping land areas with a high level of accuracy. The developed model can be used for monitoring land use, inventory of agricultural land and solving other applied tasks in the field of land resources management.

Keywords: remote sensing of the Earth, controlled classification, maximum likelihood method, land use typification

Accepted: 30.11.2025

DOI: 10.21046/2070-7401-2026-23-2-204-215

References

1. Alpysbay M. A., Serikbayeva E. B., Talgarbaeva D. N., Niyazbekov B. L., Comparative analysis of machine learning methods for remote sensing data processing, *J. Geography and Environmental Management*, 2025, V. 78(3), pp. 142–152, <https://doi.org/10.26577/JGEM202578310>.
2. Bartalev S. A., Loupian E. A., Neishtadt I. A., Method for identifying used arable lands based on satellite remote sensing data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2006, Iss. 3, V. 2, pp. 271–280 (in Russian).
3. Bartalev S. A., Egorov V. A., Loupian E. A., Plotnikov D. E., Uvarov I. A., Recognition of arable lands based on long-term satellite data from the MODIS spectroradiometer and locally adaptive classification, *Computer Optics*, 2011, V. 35, No. 1, pp. 103–116 (in Russian).
4. Dubrovin K. N., Verhoturov A. L., Stepanov A. S., Using NDVI time series and machine learning methods to classify arable land in the Khabarovsk Territory, *Materialy 21-i Mezhdunarodnoi konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa"* (Proc. 21th Intern. Conf. "Current Problems in Remote Sensing of the Earth from Space"), Moscow: IKI RAS, 2023, p. 361 (in Russian), DOI: 10.21046/21DZZconf-2023a.
5. Loupian E. A., Denisov P. V., Sereda I. I. et al., Analysis of winter crops development in the southern regions of Russia in spring 2020 based on remote monitoring, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2020, V. 17, No. 2, pp. 285–291 (in Russian), DOI: 10.21046/2070-7401-2020-17-2-285-291.
6. Pavlova A. I., Agro-ecological classification of agricultural land using machine learning, GIS, and remote sensing data, *Siberian J. Life Sciences and Agriculture*, 2023, V. 15, No. 6, pp. 72–88 (in Russian), DOI: 10.12731/2658-6649-2023-15-6-960.
7. Plotnikov E. D., Bartalev S. A., Loupian E. A., The recognition features to map arable lands based on multiannual MODIS Earth observation data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2010, V. 7, No. 1, pp. 330–341 (in Russian).
8. Plotnikov D. E., Elkina E. S., Dunaeva E. A. et al., Development of an automatic recognition method for winter crops based on satellite data for assessing their condition in the Republic of Crimea, *Tavrisheskii vestnik agrarnoi nauki*, 2020, No. 1(21), pp. 64–83 (in Russian), DOI: 10.33952/2542-0720-2020-1-21-64-83.
9. Terekhin E. A., Spectral reflectance analysis of abandoned agricultural lands in the Central Russian forest-steppe using Sentinel-2 satellite data, *Computer Optics*, 2023, V. 47, No. 2, pp. 306–313 (in Russian), DOI: 10.18287/2412-6179-CO-1160.
10. Terekhin E. A., Natural afforestation of postagrogenic lands in the south of the Central Russian Upland, *Regional Geosystems*, 2024, V. 48, No. 3, pp. 405–415 (in Russian), DOI: 10.52575/2712-7443-2024-48-3-405-415.
11. Uvarov I. A., Bartalev S. A., Development of an automatic regionally adaptive algorithm for training forest classification based on MODIS satellite data, *Aehrokosmicheskie metody i GIS-tehnologii v lesovedenii i lesnom khozyaistve: doklady 4-i Mezhdunarodnoi konferentsii* (Aerospace Methods and GIS Technologies in Forestry and Agriculture: Reports of the 4th Intern. Conf.), Moscow: GOU VPO MGUL, 2007, pp. 145–146 (in Russian).
12. Uvarov I. A., Bartalev S. A., The algorithm and software suite for land cover types recognition based on locally-adaptive supervised classification of satellite imagery, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2010, V. 7, No. 1, pp. 353–365 (in Russian).
13. Khusnutdinov A. O., Khabarov V. I., Karmanov V. S., Deep learning for multivariate time series analysis: systematization of data types, tasks, architectures and approaches, *Analysis and data processing systems*, 2025, V. 99, No. 3, pp. 113–136 (in Russian), DOI: 10.17212/2782-2001-2025-3-113-136.
14. Shabanov N. V., Bartalev S. A., Eroshenko F. V., Plotnikov D. E., Development of capabilities remote sensing estimate of Leaf Area Index from MODIS data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2018, V. 15, No. 4, pp. 166–178 (in Russian), DOI: 10.21046/2070-7401-2018-15-4-166-178.
15. Bakkestuen V., Venter Z., Ganerød A. J., Framstad E., Delineation of wetland areas in South Norway from Sentinel-2 imagery and LiDAR using TensorFlow, U-Net, and Google Earth Engine, *Remote Sensing*, 2023, V. 15, No. 5, Article 1203, DOI: 10.3390/rs15051203.

16. Cerulli G., *Fundamentals of supervised machine learning: With applications in Python, R, and Stata*, Springer, 2023, 420 p., DOI: 10.1007/978-3-031-41337-7.
17. Cheng G., Sun X., Li K. et al., Perturbation-seeking generative adversarial networks: A defense framework for remote sensing image scene classification, *IEEE Trans. Geoscience and Remote Sensing*, 2022, V. 60, Article 5605111, DOI: 10.1109/TGRS.2021.3081421.
18. Grant B. G., UAV imagery analysis: challenges and opportunities, *Proc. SPIE. Long-Range Imaging II*, 2017, V. 10204, Article 1020406, DOI: 10.1117/12.2264138.
19. Guan J., Liu J., Sun J. et al., Meta metric learning for highly imbalanced aerial scene classification, *45th Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP 2020)*, IEEE, 2020, pp. 4047–4051, DOI: 10.1109/ICASSP40776.2020.9052900.
20. Hamzah A. S., Abdul-Rhaim L. A., Smart home automation system using cloud computing based enhancement security and environment, *2nd Intern. Conf. on Advances in Engineering Science and Technology (AEST 2022)*, 2022, pp. 334–339, DOI: 10/1109/AEST55805.2022.10412921.
21. Huang S., Tang L., Hupy J. P. et al., A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing, *J. Forestry Research*, 2020, V. 32, No. 5, pp. 1–6, DOI: 10.1007/s11676-020-01155-1.
22. Jones H. G., Vaughan R. A., *Remote sensing of vegetation: Principles, techniques, and applications*, New York: Oxford University Press, 2010, 384 p.
23. Nimbalkar M. S., Shinde P. S., Chaure R. S., Remote sensing-based assessment of surface water bodies in Sahara District, Maharashtra, *InSight Bull.: A Multidisciplinary Interlink Intern. Research J.*, 2025, V. 2, No. 6, pp. 79–85.
24. Song H., Xie H., Duan Y. et al., Pure data correction enhancing remote sensing image classification with a lightweight ensemble model, *Scientific Reports*, 2025, V. 15, No. 1, Article 5507, DOI: 10.1038/s41598-025-89735-1.
25. Wang P., Zhao X., Chen Y., Zhan L., Improving remote sensing scene classification with data augmentation techniques to mitigate class imbalance, *Frontiers in Computer Science*, 2025, V. 7, Article 1613648, DOI: 10.3389/fcomp.2025.1613648.
26. Zha Y., Gao J., Ni S., Use of normalized difference built-up index in automatically mapping urban areas from TM imagery, *Intern. J. Remote Sensing*, 2003, V. 24, No. 3, pp. 583–594, DOI: 10.1080/01431160304987.