

УДК 528.8:332.3:004.8

4.1.1. Общее земледелие, растениеводство
(биологические науки, сельскохозяйственные науки)

**АВТОМАТИЗИРОВАННАЯ ОБРАБОТКА
ДАННЫХ ДИСТАНЦИОННОГО
ЗОНДИРОВАНИЯ ЗЕМЛИ НА ОСНОВЕ
ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В
ЗАДАЧАХ МОНИТОРИНГА И
ЗЕМЛЕУСТРОЙСТВА**

Чайковский Михаил Витальевич
e-mail: MishaChi1996@yandex.ru

Коркина Алина Сергеевна
Магистранты
alinka_korkina00@mail.ru

Поддубский Антон Александрович
к.т.н., доцент
*ФГАОУ ВО «Российский университет дружбы
народов имени Патриса Лумумбы»
117198, Москва, ул. Миклухо-Маклая, д. 6, Россия*

В статье рассматривается подход к автоматизированной обработке данных дистанционного зондирования Земли (ДЗЗ) на основе методов искусственного интеллекта. Система обеспечивает полный цикл работы с космическими снимками – от загрузки и предобработки до формирования итогового отчёта. Используются Google Earth Engine, алгоритмы Random Forest и SVM, данные из восьми источников ДЗЗ и языковые модели. Апробация проведена на примерах мониторинга нарушений лесного покрова Иркутской области (2019–2024 гг.) и землеустроительной оценки сельскохозяйственных угодий в двух регионах России (Московская область и Краснодарский край). Точность классификации: 65,6 % для RF и 64,6 % для SVM. Система носит исследовательский характер и требует дальнейшей верификации перед практическим применением

Ключевые слова: ДИСТАНЦИОННОЕ ЗОНДИРОВАНИЕ ЗЕМЛИ, ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ, GOOGLE EARTH ENGINE, SENTINEL-2, МАШИННОЕ ОБУЧЕНИЕ, RANDOM FOREST, SVM, МОНИТОРИНГ ЛЕСНОГО ПОКРОВА, ЗЕМЛЕУСТРОЙСТВО, КАДАСТР

<http://dx.doi.org/10.21515/1990-4665-220-054>

UDC 528.8:332.3:004.8

4.1.1. General agriculture, crop production
(biological sciences, agricultural sciences)

**AUTOMATED PROCESSING OF EARTH
REMOTE SENSING DATA BASED ON
ARTIFICIAL INTELLIGENCE FOR LAND
MONITORING AND LAND MANAGEMENT
TASKS**

Chaikovsky Mikhail Vitalievich
e-mail: MishaChi1996@yandex.ru

Korkina Alina Sergeevna
master's students
alinka_korkina00@mail.ru

Poddubsky Anton Aleksandrovich
Cand.Tech.Sci., associate professor
*Peoples' Friendship University of Russia
named after Patrice Lumumba
117198, Moscow, ul.Miklukho-Maklaya, 6, Russia*

The article discusses an approach to automated processing of Earth remote sensing data (ERS) based on artificial intelligence methods. The system provides a full cycle of working with space images, from loading and preprocessing to generating a final report. Google Earth Engine, Random Forest and SVM algorithms, data from eight ERS sources, and language models are used. The system has been tested on forest cover monitoring in the Irkutsk region (2019-2024) and land management assessment of agricultural lands in two regions of Russia (Moscow Oblast and the Krasnodar region). The classification accuracy was 65.6% for RF and 64.6% for SVM. The system is experimental and requires further verification before practical application

Keywords: REMOTE SENSING, ARTIFICIAL INTELLIGENCE, GOOGLE EARTH ENGINE, SENTINEL-2, MACHINE LEARNING, RANDOM FOREST, SVM, FOREST MONITORING, LAND MANAGEMENT, CADASTRE

Дистанционное зондирование Земли является важным инструментом землеустройства и кадастра. Спутниковые снимки Sentinel-2 и Landsat обеспечивают регулярный охват территорий с разрешением, достаточным для задач мониторинга и оценки угодий.

Практическое применение данных ДЗЗ требует значительных трудозатрат: специалист вынужден последовательно выполнять фильтрацию данных, расчёт индексов, классификацию, интерпретацию и оформление отчётов. В условиях массовых землеустроительных работ это ограничивает оперативность анализа.

Развитие методов машинного обучения и языковых моделей открывает возможности для автоматизации этих операций. Цель настоящей работы – разработать и апробировать экспериментальный прототип системы автоматизированного анализа данных ДЗЗ с формированием итогового отчёта по запросу пользователя.

Обзор литературы

Random Forest остаётся одним из наиболее устойчивых алгоритмов классификации многоспектральных данных [1, 2]. Метод опорных векторов SVM показывает конкурентоспособные результаты при нелинейно разделимых классах [3]. Для мониторинга лесного покрова России применяются методы спутниковой детекции нарушений на основе MODIS и Sentinel-2 [4, 5]. В задачах землеустройства данные SoilGrids v2.0 [6] и платформа Google Earth Engine [8] обеспечивают доступ к глобальным архивам без локальной вычислительной инфраструктуры.

Методология

Разработанный прототип реализует автоматизированный конвейер обработки данных ДЗЗ. Пользователь задаёт территорию, временной период и тип задачи; прототип выполняет загрузку снимков, расчёт индексов, классификацию, анализ динамики и формирование PDF-отчёта.

Рассчитывались спектральные индексы NDVI, EVI, NDWI, NDMI, BSI и NBR. Для классификации использовались алгоритмы Random Forest (150 деревьев) и SVM (ядро RBF). Обучающая выборка формировалась на

основе глобальной карты ESA WorldCover 2021. Все вычисления выполнялись на платформе Google Earth Engine.

В задаче мониторинга лесного покрова использовались десять спектральных каналов Sentinel-2 и шесть индексов, включая NBR для детектирования гарей. В задаче оценки сельхозугодий набор данных расширен: Sentinel-1 SAR, SRTM DEM, ERA5, CHIRPS, SoilGrids, Sentinel-5P, Landsat-8 и OpenStreetMap. Сравнение методологических параметров двух задач приведено в таблице 1.

Таблица 1 – Сравнение методологических параметров двух примеров

Параметр	Пример 1 (леса, Иркутская обл.)	Пример 2 (угодья, 2 региона)
Спутниковые снимки	Sentinel-2 L2A, 10 м	Sentinel-2 + Sentinel-1 + Landsat-8
Индексы	NDVI, EVI, NDWI, NDMI, BSI, NBR	NDVI, EVI, NDWI, NDMI, BSI, LAI
Уникальный индекс	NBR – гарь и вырубки	LAI – плотность биомассы
Топ-3 признака (RF)	BSI → B11 → B12	B5 → B12 → B2
Доп. источники	ESA WorldCover (эталон)	SoilGrids, ERA5, CHIRPS, SRTM, OSM
Тип задачи	Классификация + изменения	Классификация + балльная оценка
Период	2019–2024 (6 срезов)	2019–2025

Пример 1. Мониторинг лесного покрова Иркутской области (2019–2024)

Иркутская область выбрана в качестве объекта исследования из-за высокой интенсивности незаконных рубок (свыше 30 % от общероссийских) и значительной площади лесного покрова (~83 % лесистость). Вся обработка данных выполнялась камерально на основе архивных данных ДЗЗ.

Random Forest достиг общей точности классификации 65,6 % при коэффициенте каппа $\kappa = 0,541$; SVM – 64,6 % и $\kappa = 0,528$ соответственно (таблица 2). Наиболее значимыми признаками оказались BSI, каналы B11, B12 и NBR (рисунок 1).

Таблица 2 – Сравнение точности алгоритмов классификации

Показатель	Random Forest	SVM (RBF)
Общая точность (ОА), %	65,6	64,6
Коэффициент каппа (κ)	0,541	0,528
Важнейший признак	BSI	BSI




Рисунок 1 – Важность признаков алгоритма Random Forest (индекс Gini)

Анализ динамики показал отрицательный тренд площади лесного покрова $-8\,159,2\text{ км}^2/\text{год}$ (рисунок 2). Суммарная площадь нарушений за 2019–2024 гг. составила $30\,156\text{ км}^2$ (по критерию $\text{NDVI} > 0,5$). В 2022 г. зафиксирована аномалия $-14,54\%$ от базового уровня 2019 г., соответствующая аномально интенсивному пожарному сезону в Сибири (рисунок 3). К 2024 г. NBR вышел в положительную зону ($+0,0061$), что указывает на начало лесовозобновительных процессов.

Прототип автоматически локализовал зоны вырубок и горельников по спектральным индексам без ручного вмешательства оператора.




Рисунок 2 – Динамика NDVI и отклонение NBR, Иркутская область 2019–2024




Рисунок 3 – Динамика площади лесного покрова (NDVI > 0,5), Иркутская область 2019-2024

Пример 2. Землеустроительная оценка сельскохозяйственных угодий

Проведена оценка двух сельскохозяйственных участков: в Московской области и Краснодарском крае. Оценка включала агрономические (тип почвы, pH, SOC, NDVI, LAI), климатические (температура, осадки), экологические (NO₂) и логистические критерии.

Использовались данные Sentinel-1, Sentinel-2, Landsat-8, ERA5, CHIRPS, SoilGrids [6] и OpenStreetMap. Языковая модель формировала агрономическое заключение на основе числовых данных GEE. Результаты сравнительной оценки приведены в таблице 3.

Таблица 3 – Результаты сравнительной оценки двух участков

Показатель	Участок №1 (Московская обл.)	Участок №2 (Краснодарский край)
NDVI (среднесезонный)	0,76	0,47
pH почвы (0–5 см)	5,5	6,5 ★
SOC, г/кг	103,3 ★	43,4
Температура, °C/год	6,98	13,98 ★
Осадки, мм/год	137,1	573,4 ★
Уклон рельефа, °	2,35	1,12 ★
Интегральный балл	49	64 ★

★ – лучшее значение по показателю

Наивысший интегральный балл получил участок в Краснодарском крае (64/100) благодаря благоприятному климату (+14°C, 573 мм/год), оптимальному pH 6,5 (без известкования) и ровному рельефу (уклон 1,1°). Участок в Московской области уступил по климатическому блоку, несмотря на более высокий SOC (103,3 г/кг).

Полный отчёт по двум участкам сформирован прототипом за ~4 минуты без полевых обследований.




Рисунок 4 – Спутниковые снимки участка №1 (Московская область): Sentinel-2 RGB, температура поверхности (Landsat-8 B10), рельеф (SRTM DEM), NDVI




Рисунок 5 – Спутниковые снимки участка №2 (Краснодарский край): Sentinel-2 RGB, температура поверхности (Landsat-8 B10), рельеф (SRTM DEM), NDVI

Обсуждение

Результаты показывают применимость предложенного подхода для задач камерального мониторинга земель и первичной землеустроительной оценки. Точность 65,6% удовлетворительна для регионального мониторинга, однако недостаточна для кадастровых и инвентаризационных задач; для их решения потребуется наземная верификация эталонных данных.

Основным ограничением остаётся пространственное разрешение почвенных данных SoilGrids (250 м) и необходимость дополнительной

верификации AI-генерируемых заключений. Прототип применим как инструмент предварительного анализа и требует дальнейшей доработки и интеграции с государственными ГИС кадастрового учёта.

Выводы

1. Разработан экспериментальный прототип системы автоматизированной обработки данных ДЗЗ с использованием методов искусственного интеллекта. Система обеспечивает полный цикл обработки – от загрузки спутниковых данных до формирования аналитического отчёта.

2. При камеральном мониторинге лесного покрова Иркутской области Random Forest показал точность 65,6 % ($\kappa = 0,541$), SVM – 64,6 % ($\kappa = 0,528$). Суммарная площадь нарушений лесного покрова за 2019–2024 гг. составила 30 156 км². Прототип позволяет снизить трудозатраты на камеральную обработку данных.

3. В задаче землеустроительной оценки прототип автоматически сформировал сравнительный отчёт по двум участкам (Московская область и Краснодарский край) за ~4 минуты без полевых обследований. Наиболее перспективным определён участок в Краснодарском крае (64/100).

4. Подход перспективен для первичного обследования территорий и требует дальнейшего совершенствования алгоритмов и интеграции с государственными ГИС.

Список литературы

1. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45(1). P. 5–32. DOI: 10.1023/A:1010933404324
2. Belgiu M., Drăguţ L. Random forest in remote sensing: A review // ISPRS J. Photogramm. Remote Sens. 2016. Vol. 114. P. 24–31. DOI: 10.1016/j.isprsjprs.2016.01.011
3. Mountrakis G., Im J., Ogole C. Support vector machines in remote sensing: A review // ISPRS J. Photogramm. Remote Sens. 2011. Vol. 66(3). P. 247–259. DOI: 10.1016/j.isprsjprs.2010.11.001
4. Барталев С.А., Егоров В.А., Ершов Д.В. и др. Спутниковое картографирование растительного покрова России по данным MODIS // Соврем. пробл. ДЗЗ из космоса. 2011. Т. 8(4). С. 285–302.
5. Котельников Р.В., Лупян Е.А., Барталев С.А., Ершов Д.В. Космический мониторинг лесных пожаров: ИСДМ-Рослесхоз // Лесоведение. 2019. № 5. С. 399–409.
6. Poggio L. et al. SoilGrids 2.0: producing soil information for the globe // SOIL. 2021. Vol. 7. P. 217–240. DOI: 10.5194/soil-7-217-2021

7. Noi P.T., Kappas M. Comparison of RF, kNN and SVM for land cover classification using Sentinel-2 // *Sensors*. 2018. Vol. 18(1). P. 18. DOI: 10.3390/s18010018

8. Gorelick N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone // *Remote Sens. Environ.* 2017. Vol. 202. P. 18–27. DOI: 10.1016/j.rse.2017.06.031

References

1. Breiman L. Random Forests // *Machine Learning*. 2001. Vol. 45(1). P. 5–32. DOI: 10.1023/A:1010933404324

2. Belgiu M., Drăguț L. Random forest in remote sensing: A review // *ISPRS J. Photogramm. Remote Sens.* 2016. Vol. 114. P. 24–31. DOI: 10.1016/j.isprsjprs.2016.01.011

3. Mountrakis G., Im J., Ogole C. Support vector machines in remote sensing: A review // *ISPRS J. Photogramm. Remote Sens.* 2011. Vol. 66(3). P. 247–259. DOI: 10.1016/j.isprsjprs.2010.11.001

4. Bartalev S.A., Egorov V.A., Ershov D.V. i dr. Sputnikovoe kartografirovanie rastitel'nogo pokrova Rossii po dannym MODIS // *Sovrem. probl. DZZ iz kosmosa*. 2011. T. 8(4). S. 285–302.

5. Kotel'nikov R.V., Lupyan E.A., Bartalev S.A., Ershov D.V. Kosmicheskij monitoring lesny'x pozharov: ISDM-Roslesxoz // *Lesovedenie*. 2019. № 5. S. 399–409.

6. Poggio L. et al. SoilGrids 2.0: producing soil information for the globe // *SOIL*. 2021. Vol. 7. P. 217–240. DOI: 10.5194/soil-7-217-2021

7. Noi P.T., Kappas M. Comparison of RF, kNN and SVM for land cover classification using Sentinel-2 // *Sensors*. 2018. Vol. 18(1). P. 18. DOI: 10.3390/s18010018

8. Gorelick N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone // *Remote Sens. Environ.* 2017. Vol. 202. P. 18–27. DOI: 10.1016/j.rse.2017.06.031