

Мониторинг состояния растительного покрова в районе разработки Кедровского угольного разреза на основе спутниковых данных

А.А. Камаев, П.П. Маневич✉, М.С. Сатубалова

Национальный исследовательский технологический университет «МИСиС», г. Москва, Российская Федерация
✉manevich.polina@gmail.com

Резюме: Рассмотрен подход к мониторингу растительного покрова в районах угольных карьеров на примере Кедровского угольного месторождения на основе данных дистанционного зондирования Земли из космоса – снимках Landsat-8, визуализация и обработка которых происходила в программном обеспечении QGIS и Google Earth Engine. На основе отличительных дешифровочных признаков были выделены основные классы землепользования исследуемого района, включающие в себя 11 микроклассов объектов земного покрова. Произведена оценка эффективности различных алгоритмов классификации методами машинного обучения с определением качества и точности распознавания ими набора выделенных макроклассов.

На основе выбранного алгоритма классификации представлен анализ временной динамики объектов землепользования, динамики деградации и восстановления земель в районе Кедровского угольного разреза. Рассмотрены основные тенденции изменения площадей макроклассов в региональном масштабе. Определение функциональной взаимосвязи динамики площадей объектов землепользования осуществлялось линейными уравнениями регрессии, составленными для каждого класса. Дана оценка состояния земель рассматриваемого региона, с учетом факторов, влияющих на деградацию вегетации площадей, основу которых составляет антропогенная деятельность: ведение добычи полезных ископаемых, расширение городской инфраструктуры, пахотных угодий.

Ключевые слова: дистанционное зондирование Земли, землепользование, угольный разрез, мониторинг растительности, машинное обучение, нарушенные земли, классификация с обучением

Для цитирования: Камаев А.А., Маневич П.П., Сатубалова М.С. Мониторинг состояния растительного покрова в районе разработки Кедровского угольного разреза на основе спутниковых данных. *Горная промышленность*. 2023;(2):70–74. <https://doi.org/10.30686/1609-9192-2023-2-70-74>

Monitoring of vegetation conditions in the Kedrovsky coal mine area based on satellite data

A.A. Kamaev, P.P. Manevich✉, M.S. Satubalova

National University of Science and Technology "MISIS", Moscow, Russian Federation
✉manevich.polina@gmail.com

Abstract: This paper demonstrates an approach to monitoring vegetation in areas of coal mines using space-derived data from remote sensing of the Earth for the Kedrovsky coal deposit. Space-derived data consists of Landsat-8 snapshots. Visualization and processing of the data was implemented in geospatial data analysis systems such as QGIS and Google Earth Engine. The main classes of land use are identified, based on their distinctive deciphering features that include 11 microclasses of land cover objects. Several machine learning methods were applied to assess the performance of various classification algorithms for their potential for quality and accurate recognition of the highlighted set of macroclasses.

The proposed analysis for the temporal dynamics of land use objects, land degradation and restoration dynamics in the area of the Kedrovsky coal mine is based on the chosen classification algorithm. The determination of functional correlation of dynamics for land use object areas was carried out by linear regression equation compiled for each class. Condition of lands of the region at issue was assessed considering the factors influencing degradation of vegetation areas which are developed on anthropogenic activities such as mining, expansion of urban infrastructures and croplands.

Keywords: remote sensing of the Earth, land use, coal mine, vegetation monitoring, machine learning, disturbed lands, supervised classification

For citation: Kamaev A.A., Manevich P.P., Satubalova M.S. Monitoring of vegetation conditions in the Kedrovsky coal mine area based on satellite data. *Russian Mining Industry*. 2023;(2):70–74. <https://doi.org/10.30686/1609-9192-2023-2-70-74>

Введение

В настоящее время наблюдаются тенденции к увеличению объемов угля, добываемых открытым способом, что приводит к увеличению площади нарушенных земель [1]. Данная проблема на протяжении долгого времени неизменно присутствует и будет присутствовать в Кузбассе – одном из наиболее развитых регионов России в сфере промышленности и крупнейшем регионе России по добыче угля. В распределении земельного фонда региона по угольям за 2021 год нарушенные земли составляют 98 тыс. га, что значительно превышает среднероссийские показатели. В связи с этим необходимы оперативный и качественный способ систематического слежения за состоянием и использованием земель, а также выявление нарушений земельного законодательства. Перспективными для решения данной задачи являются методы дистанционного зондирования Земли из космоса [2]. Этому способствуют интенсивное развитие спутниковых и ГИС-технологий, высокий временной и пространственный охват спутниковой съемки и свободный доступ к данным спутниковых миссий.

Нарушенные земли – это земли, потерявшие изначальную хозяйственную ценность в результате нарушения и вызывающие негативное воздействие на окружающую среду. По государственному стандарту ГОСТ Р 59070–2020¹ под нарушением земель понимается процесс, происходящий при добыче полезных ископаемых, выполнении геологоразведочных, изыскательных, строительных и других работ и приводящий к нарушению почвенного покрова, гидрологического режима местности, образованию техногенного рельефа и другим качественным изменениям земель [3].

Для выявления площадей нарушенных земель используется так называемая технология «Land Use / Land Cover» (LULC), которая подразумевает проведение категоризации земного покрова в интересующем районе за определенный промежуток времени [4]. LULC-карты играют важную роль в планировании, управлении и мониторинге на местном, региональном и национальном уровнях [5–8]. Информация, извлекаемая из таких карт, обеспечивает лучшее понимание в использовании земельных ресурсов и помогает в исследовании изменений, происходящих в экосистеме и окружающей среде [9].

LULC-классификация широко применяется в таких сферах, как: управление природными ресурсами; защита среды обитания диких животных; выделение зон поражений природными стихиями (торнадо, наводнения, извержения вулканов, землетрясения); построение маршрутов сейсморазведки / геологоразведки / походов; объектное определение: выделение дорог, полей, взлетно-посадочных полос, мостов, границ земли и воды; учет нарушенных земель [10].

Методы и данные

Принцип классификации земного покрова основан на том, что все объекты на земной поверхности обладают уникальными спектральными характеристиками. Цель классификации – заменить визуальный анализ снимка автоматизированной процедурой идентификации объектов, в ходе которой каждый пиксел цифрового снимка относят на основании некоторых статистических критериев к одному из классов пространственных объектов. Выделяют информационные и спектральные классы. Информационные классы – это объекты земной поверхности, которые

нужно распознать на снимке (элементы растительного покрова и рельефа, типы горных пород, геологические структуры). Спектральные классы – это группы пикселов, характеризующихся одинаковой яркостью в определенном спектральном диапазоне. Основная цель классификации – совмещение спектральных и информационных классов.

Классификация при создании карт распределения земельного покрова в наибольшей степени связана с применением методов машинного обучения, способных обработать большие объемы данных [11]. Цель алгоритмов машинного обучения – обучить программу решать задачу на основе входных данных, от разнообразия которых зависит конечный результат [12]. Входные данные могут быть числовые, текстовые, визуальные и т. д. Результатом работы программы может быть любое рациональное число (в таком случае говорят о регрессионных моделях) или целое число из ограниченного диапазона, представляющее категорию (класс) – для моделей классификации.

В данной работе при проведении классификации использовались данные спутниковой миссии Landsat-8, на основе которых проводилась автоматизированная классификация при помощи средств машинного обучения. Для скачивания снимков Landsat-8 использована облачная платформа Google Earth Engine [13]. Отображение, обработка и интерпретация спутниковых снимков Landsat-8 осуществлялись в ПО QGIS версии 3.26.

Для выбора метода классификации и оценки эффективности работы различных алгоритмов было проведено несколько классификаций на основе обучающей выборки [14; 15] разными способами: CART, Naive Bayes, Random Forest, SVM, Minimal Distance и K-Nearest Neighbor [16]. Чтобы увеличить точность распознавания и исключить мелкие ошибки классификации, было принято объединить исходные микроклассы в макроклассы. Таким образом, макрокласс «Промышленные зоны» состоит из полигонов микроклассов «Угольные отвалы», «Горные выработки», «Нерекультивированные отвалы», «Городская инфраструктура». Макрокласс «Низкорослая растительность» образован путем слияния полигонов «Редкая низкорослая растительность», «Густая низкорослая растительность», «Рекультивированные отвалы». Макрокласс «Водные объекты» состоит из подклассов «Техногенные воды» и «Природные воды». Микроклассам «Почвы» и «Густая высококорослая растительность» были присвоены соответствующие макроклассы. В результате получено 5 макроклассов.

Для реализации методов Random Forest и K-Nearest Neighbor использован модуль для QGIS «dzetsaka», а для остальных – платформа Google Earth Engine, для которой был написан необходимый скрипт и импортированы обучающие выборки. Получившиеся в GEE изображения были загружены в QGIS для дальнейшего анализа.

Результаты

Для сравнительного анализа спектральных характеристик каждого класса были выявлены и оконтурены инструментами QGIS выборки для каждого класса (рис. 1). В них был однозначно определен класс землепользования методом визуального дешифрирования на основе анализа аномалий спектральных параметров классов, приведенных выше. Оконтуренные выборки представляют собой векторные данные – полигоны, которые впоследствии, для удобства оперирования ими, были объединены в один векторный слой, а для удобства в их различии им были присвоены разные цвета.

¹ ГОСТ Р 59070–2020 Охрана окружающей среды. Рекультивация нарушенных и нефтезагрязненных земель.

Для определения количественных показателей спектральных характеристик классов землепользования были вычислены описательные статистики «среднее», «минимум» и «максимум» для каналов GREEN, RED и NIR. Для этого была использована функция «Зональная статистика». Входными данными являются растровый и векторный слои, а также спектральный канал, по которому будет производиться расчет. Функция вычисляет статистические данные раstra в пределах контура полигона и создает новый слой с атрибутами описательной статистики. В результате объединения полигонов в один векторный слой результирующий файл содержит статистику для всех классов землепользования. Для расчета зональной статистики был использован космический снимок 2021 г. с пространственным разрешением 30 м. Результаты вычислений приведены в табл. 1.




Рис. 1
Обучающие полигоны классов и их цветовые обозначения

Fig. 1
Training class polygons and their colour coding

Таблица 1
Зональная статистика для канала NIR

Класс	Коэффициент спектральной яркости, Вт/(м²×ст×нм)		
	Среднее значение	Минимальное значение	Максимальное значение
Горные породы, выработки	1366,82	858,50	2091,00
Городская инфраструктура	1817,75	1133,00	3102,00
Густая высокорослая зелень	2911,71	2448,00	3551,00
Густая низкорослая зелень	3076,42	2571,00	3753,50
Отвалы вскрыши, не-рекультивированные	1296,04	892,50	1792,00
Почвы	1851,09	1616,00	3633,00
Природные воды	454,69	148,00	3403,00
Редкая низкорослая зелень	2519,47	1847,00	3404,50
Рекультивированные отвалы	1916,65	1107,00	2909,00
Техногенные воды	237,88	114,00	1662,00
Угольные, золошлаковые отвалы	595,20	357,00	1193,50

В результате анализа наиболее эффективными алгоритмами являются Random Forest (2-е место) и Naive Bayes (1-е место). Алгоритм Naive Bayes является наиболее точным на целевых классах низкорослой зеленой растительности, площадей отвалов и земель с отсутствием растительного покрова, а алгоритм Random Forest на целевом классе площадей земель, нарушенных ведением горными работами и в среднем по всем классам сразу. При этом точность распознавания класса «горные выработки» у Naive Bayes достаточно низкая (4–5-е место в рейтинге). Поэтому, несмотря на незначительное техническое превосходство по метрикам качества алгоритма Naive Bayes, для дальнейшей работы более целесообразно применить алгоритм классификации Random Forest.

Обсуждение результатов

На основе выбранного метода Random Forest были классифицированы спутниковые снимки за временной интервал 2013–2022 гг. в летние периоды. Были рассчитаны площади классов землепользования по каждому году (табл. 2). Представленные результаты получены в региональном масштабе и отражают динамику макрокласов землепользования района исследований. Анализируя полученные результаты, можно с уверенностью сказать, что в данной области исследования наибольшей деградации подвержена низкорослая растительность, площадь которой непрерывно сокращалась начиная с 2018 г. При этом скорость убывания площади низкорослой растительности составляет около 27 км² в год. Убывание низкорослой растительности компенсируется увеличением площадей, подверженных влиянию промышленной деятельности, и почвенного покрова, что можно связать с антропогенными факторами в виде обработки месторождений открытым способом, эксплуатацией сельскохозяйственных полей и урбанизацией. Изменение площадей водных объектов незначительно на всем исследуемом промежутке времени.

Table 1
Zonal statistics for the NIR channel

Таблица 2
Площади классов землепользования района Кедровского угольного разреза

Table 2
Land use class areas of the Kedrovsky coal strip mine region

Класс	Год съемки области спутником									
	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
Промышленные зоны, км²	159	112	131	119	150	135	164	123	160	231
Густая зелень, км²	1717	1655	1597	1700	1693	1642	1626	1700	1817	1699
Низкорослая зелень, км²	577	642	721	613	626	707	640	562	399	330
Почвенный покров, км²	80	123	83	99	64	49	103	146	153	276
Водные объекты, км²	27	27	26	28	26	26	26	29	30	24



Рис. 2
Динамика площади класса
«Промышленные зоны»
в районе Кедровского разреза

Fig. 2
Dynamics of the 'Industrial
Zone' class area in the
Kedrovsky coal strip mine
region



Рис. 3
Динамика площади класса
«Низкорослая растительность»
в районе Кедровского разреза

Fig. 3
Dynamics of the 'Darf
Vgetation' class area in the
Kedrovsky coal strip mine
region

Наблюдается рост площади высокорослой растительности вплоть до 2021 г., на момент 2022 г. наблюдается ее резкий спад на 120 км², что свидетельствует о вырубках лесов.

Выводы

Была проведена классификация спутниковых снимков алгоритмом Random Forest в летние периоды за 2013–2022 гг. Произведен расчет площадей классов землепользования по каждому году, по которому были составлены графики динамики.

Региональный анализ динамики нарушенных земель показал высокую степень деградации низкорослой растительности начиная с 2018 г., параллельно с этим увеличивались площади почвенного покрова и районов ведения промышленной деятельности, что связано с антропогенными факторами: разработкой и эксплуатацией открытых месторождений, сельскохозяйственной деятельностью и урбанизацией.

Список литературы

- Петренко И.Е., Шинкин В.К. Итоги работы угольной промышленности России за январь – март 2022 года. *Уголь*. 2022;(6):6–16. <https://doi.org/10.18796/0041-5790-2022-6-6-16>
- Naghibi S.A., Pourghasemi H.R., Dixon B. GIS-based groundwater potential mapping using boosted regression tree, classification and regression tree, and random forest machine learning models in Iran. *Environment Monitoring Assessment*. 2016;188(1):44. <https://doi.org/10.1007/s10661-015-5049-6>
- Xie H., Zhang Ya., Wu Z., Lv T. A bibliometric analysis on land degradation: Current status, development, and future directions. *Land*. 2020;9(1):28. <https://doi.org/10.3390/land9010028>
- Talukdar S., Singha P., Mahato S., Shahfahad V., Pal S. Liou Y.-A., Rahman A. Land-use land-cover classification by machine learning classifiers for satellite observations – A review. *Remote Sensing*. 2020;12(7):1135. <https://doi.org/10.3390/rs12071135>
- Mansour S., Al-Belushi M., Al-Awadhi T. Monitoring land use and land cover changes in the mountainous cities of Oman using GIS and CA-Markov modelling techniques. *Land Use Policy*. 2020;91:104414. <https://doi.org/10.1016/j.landusepol.2019.104414>
- Abdullah A.Y., Marur A., Adnan M.S., Bake A.A., Hassan Q.K., Dewan A. Spatio-temporal patterns of land use/land cover change in the heterogeneous coastal region of Bangladesh between 1990 and 2017. *Remote Sensing*. 2019;11(7):790. <https://doi.org/10.3390/rs11070790>
- Маневич П.П., Коликов К.С. Обоснование метода оценки негативного воздействия угольного разреза на вегетационную активность растительного покрова по данным дистанционного зондирования Земли из космоса. *Горный информационно-аналитический бюллетень*. 2022;(11):109–120. https://doi.org/10.25018/0236_1493_2022_11_0_109
- Филиппов Д.В., Чурсин И.Н., Бояренкова А.Д., Рулёв Д.Д. Результаты исследований окарбоначивания почв орошаемых участков по материалам дистанционного зондирования Земли. *Геодезия и картография*. 2022;(8):39–44. <https://doi.org/10.22389/0016-7126-2022-986-8-39-44>
- Черепанов А.С. Вегетационные индексы. *Геоматика*. 2011;(2):98–102.
- Thessen A.E. Adoption of machine learning techniques in ecology and earth science. *One Ecosystem*. 2016;(1): e8621. <https://doi.org/10.3897/oneeco.1e8621>
- Shahabi M., Jafarzadeh A.A., Neyshabouri M.R., Ghorbani M.A., Kamran K.V. Spatial modeling of soil salinity using multiple linear regression, ordinary kriging and artificial neural network methods. *Archives of Agronomy and Soil Science*. 2017;63(2):151–160. <https://doi.org/10.1080/03650340.2016.1193162>
- Janiesch C., Zschech P., Heinrich K. Machine learning and deep learning. *Electron Markets*. 2021;31(3):685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Mutanga O., Kumar L. Google earth engine applications. *Remote Sensing*. 2019;11(5):591. <https://doi.org/10.3390/rs11050591>
- Ramezan C.A., Warner T.A., Maxwell A.E., Price B.E. Effects of training set size on supervised machine-learning land-cover classification of large-area high-resolution remotely sensed data. *Remote Sensing*. 2021;13(3):368. <https://doi.org/10.3390/rs13030368>
- Брагина Е.В. Методологический подход к формированию каталога тестовых объектов для оценки качества материалов космической съемки. *Геодезия и картография*. 2021;(10):33–41. <https://doi.org/10.22389/0016-7126-2021-976-10-33-41>
- Sarker I.H. Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*. 2021;2(3):160. <https://doi.org/10.1007/s42979-021-00592-x>

References

- Petrenko I.E., Shinkin V.K. Russia's coal industry performance for January – March, 2022. *Ugol'*. 2022;(6):6–16. (In Russ.) <https://doi.org/10.18796/0041-5790-2022-6-6-16>
- Naghibi S.A., Pourghasemi H.R., Dixon B. GIS-based groundwater potential mapping using boosted regression tree, classification and regression tree, and random forest machine learning models in Iran. *Environment Monitoring Assessment*. 2016;188(1):44. <https://doi.org/10.1007/s10661-015-5049-6>
- Xie H., Zhang Ya., Wu Z., Lv T. A bibliometric analysis on land degradation: Current status, development, and future directions. *Land*. 2020;9(1):28. <https://doi.org/10.3390/land9010028>
- Talukdar S., Singha P., Mahato S., Shahfahad V., Pal S. Liou Y.-A., Rahman A. Land-use land-cover classification by machine learning classifiers for satellite observations – A review. *Remote Sensing*. 2020;12(7):1135. <https://doi.org/10.3390/rs12071135>
- Mansour S., Al-Belushi M., Al-Awadhi T. Monitoring land use and land cover changes in the mountainous cities of Oman using GIS and CA-Markov modelling techniques. *Land Use Policy*. 2020;91:104414. <https://doi.org/10.1016/j.landusepol.2019.104414>
- Abdullah A.Y., Marur A., Adnan M.S., Bake A.A., Hassan Q.K., Dewan A. Spatio-temporal patterns of land use/land cover change in the heterogeneous coastal region of Bangladesh between 1990 and 2017. *Remote Sensing*. 2019;11(7):790. <https://doi.org/10.3390/rs11070790>
- Manevich P.P., Kolikov K.S. Justification of assessment method of adverse impact exerted by open pit coal mine on green cover vegetation activity using earth remote sensing data. *Mining Informational and Analytical Bulletin*. 2022;(11):109–120. (In Russ.) https://doi.org/10.25018/0236_1493_2022_11_0_109
- Filippov D.V., Chursin I.N., Boyarenkova A.D., Rulev D.D. Results of soil carbonate enrichment research in irrigated areas using remote sensing data. *Geodesy and Cartography*. 2022;(8):39–44. (In Russ.) <https://doi.org/10.22389/0016-7126-2022-986-8-39-44>
- Cherepanov A.S. Vegetation indices. *Geomatics*. 2011;(2):98–102. (In Russ.)
- Thessen A.E. Adoption of machine learning techniques in ecology and earth science. *One Ecosystem*. 2016;(1): e8621. <https://doi.org/10.3897/oneeco.1.e8621>
- Shahabi M., Jafarzadeh A.A., Neyshabouri M.R., Ghorbani M.A., Kamran K.V. Spatial modeling of soil salinity using multiple linear regression, ordinary kriging and artificial neural network methods. *Archives of Agronomy and Soil Science*. 2017;63(2):151–160. <https://doi.org/10.1080/03650340.2016.1193162>
- Janiesch C., Zschech P., Heinrich K. Machine learning and deep learning. *Electron Markets*. 2021;31(3):685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Mutanga O., Kumar L. Google earth engine applications. *Remote Sensing*. 2019;11(5):591. <https://doi.org/10.3390/rs11050591>
- Ramezan C.A., Warner T.A., Maxwell A.E., Price B.E. Effects of training set size on supervised machine-learning land-cover classification of large-area high-resolution remotely sensed data. *Remote Sensing*. 2021;13(3):368. <https://doi.org/10.3390/rs13030368>
- Bragina E.V. Methodological approach to creating a catalog of test objects for evaluating the space survey materials quality. *Geodesy and Cartography*. 2021;(10):33–41. (In Russ.) <https://doi.org/10.22389/0016-7126-2021-976-10-33-41>
- Sarker I.H. Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*. 2021;2(3):160. <https://doi.org/10.1007/s42979-021-00592-x>

Информация об авторах

Камаев Артем Анатольевич – студент кафедры геологии и маркшейдерского дела Горного института, Национальный исследовательский технологический университет «МИСиС», г. Москва, Российская Федерация; e-mail: artemkakamaev@gmail.com

Маневич Полина Павловна – аспирант кафедры безопасности и экологии горного производства Горного института, Национальный исследовательский технологический университет «МИСиС», г. Москва, Российская Федерация; e-mail: manevich.polina@gmail.com

Сатубалова Мадина Сраждиновна – студент кафедры геологии и маркшейдерского дела Горного института, Национальный исследовательский технологический университет «МИСиС», г. Москва, Российская Федерация; e-mail: madina.sat04@gmail.com

Информация о статье

Поступила в редакцию: 24.02.2023

Поступила после рецензирования: 27.03.2023

Принята к публикации: 03.04.2023

Information about the authors

Artem A. Kamaev – Student, Department of Geology and Surveying, Mining Institute, National University of Science and Technology “MISIS”, Moscow, Russian Federation; e-mail: artemkakamaev@gmail.com

Polina P. Manevich – Postgraduate Student, Department of Safety and Ecology of Mining Production, Mining Institute, National University of Science and Technology “MISIS”, Moscow, Russian Federation; e-mail: manevich.polina@gmail.com

Madina S. Satubalova – Student, Department of Geology and Surveying, Mining Institute, National University of Science and Technology “MISIS”, Moscow, Russian Federation; e-mail: madina.sat04@gmail.com

Article info

Received: 24.02.2023

Revised: 27.03.2023

Accepted: 03.04.2023