

Геоинформатика. 2024. № 2. С. 25–35.
Geoinformatika. 2024;(2):25–35.

Применение ГИС-технологий

Научная статья
 УДК 528.8-004.855.5
<https://doi.org/10.47148/1609-364X-2024-2-25-35>

Картографирование пахотных земель на основе данных ДЗЗ (на примере Еврейской автономной области)

© 2024 г. — Артем Николаевич Поляков^{1, а)}, Алексей Сергеевич Степанов^{2, б)}

¹Вычислительный центр Дальневосточного отделения Российской академии наук; Россия, Хабаровск

²Дальневосточный научно-исследовательский институт сельского хозяйства; Россия, Хабаровск

^{а)}artem_polyakov@inbox.ru, ^{б)}stepanfx@mail.ru

Аннотация: Методы классификации и картографирования подстилающей поверхности с использованием данных спутникового мониторинга в последнее время часто применяются для решения практических задач цифрового земледелия, в том числе уточнения контуров полей и выявления неиспользуемых земель. В статье рассмотрены вопросы распознавания пахотных земель по спутниковым изображениям Sentinel-2. Для классификации пяти типов подстилающей поверхности Октябрьского и Ленинского районов Еврейской автономной области были использованы снимки с проведенной атмосферной коррекцией, а также без коррекции. Для классификации изображений применялись разные методы машинного обучения и программные инструменты. Установлено, что общая точность классификации для изображений с выполненной атмосферной коррекцией составила более 80 %, что достоверно выше соответствующего показателя для неоткорректированных снимков. Полученные результаты были использованы для подготовки shp-файлов с контурами сельскохозяйственных полей Еврейской автономной области в 2022 г. Предложенный подход может быть применен для уточнения границ полей на региональном уровне без подготовки и обработки временных рядов спутниковых изображений, требующих значительных временных и вычислительных ресурсов.

Ключевые слова: *картографирование; классификация; пахотные земли; подстилающая поверхность; спутниковый мониторинг.*

Для цитирования: Поляков А.Н., Степанов А.С. Картографирование пахотных земель на основе данных ДЗЗ (на примере Еврейской автономной области) // Геоинформатика. — 2024. — № 2. — С. 25–35. <https://doi.org/10.47148/1609-364X-2024-2-25-35>.

Application of GIS-technologies

Original article

Recognition of Arable Lands Based on Remote Sensing Data (on the Example of the Jewish Autonomous Oblast)

© 2024 — Artem N. Polyakov^{1, а)}, Alexey S. Stepanov^{2, б)}

¹Computer Center of the Far Eastern Branch of the Russian Academy of Sciences; Khabarovsk, Russia

²Far Eastern Agricultural Research Institute; Khabarovsk, Russia

^{а)}artem_polyakov@inbox.ru, ^{б)}stepanfx@mail.ru

Abstract: Methods of classification and mapping of the land cover using satellite monitoring data have recently been frequently applied to solve practical tasks in digital agriculture, including refining field boundaries and identifying unused lands. This paper discusses the recognition of arable lands using Sentinel-2 satellite images. Images with and without atmospheric correction were utilized for classifying five types of underlying surfaces in the Oktyabrsky and Leninsky districts of the Jewish Autonomous Region. Various machine learning methods and software tools were applied for image classification. It was determined that the overall classification accuracy for images with atmospheric correction exceeded 80%, which is significantly higher than the corresponding rate for uncorrected images. The obtained results were used to prepare shapefiles outlining agricultural fields in the Jewish Autonomous Region in 2022. The proposed approach can be applied to refine field boundaries at the regional level without the preparation and processing of time series of satellite images, which require substantial time and computational resources.

Keywords: *mapping; classification; arable lands; land cover; satellite monitoring.*

For citation: Polyakov A.N., Stepanov A.S. Recognition of Arable Lands Based on Remote Sensing Data (on the Example of the Jewish Autonomous Oblast). *Geoinformatika*. 2024;(2):25–35. <https://doi.org/10.47148/1609-364X-2024-2-25-35>. In Russ.

Введение

В последние годы достаточно активно развиваются методы картографирования растительного покрова, основанные на использовании данных дистанционного зондирования Земли из космоса. В частности, наиболее широкое применение в проектах, связанных с автоматизированной классификацией и картографированием растительности, получили данные спутниковых систем Terra/Aqua-MODIS, Landsat-TM/ETM/OLI, Sentinel-2 [1]. С использованием разработанного локально-адаптивного алгоритма (LaGMA) были созданы и пополняются вплоть до настоящего времени карты растительного покрова России [2]. Было выделено 22 тематических класса, характеризующих различные типы растительности. В зарубежной науке также были реализованы масштабные проекты по составлению карт растительного покрова. В частности, в Китае на основе комбинации данных Sentinel-1 и Sentinel-2, а также Modis построена карта растительного покрова с общей точностью 94 % [3]. Разработанная и протестированная методика для Германии (выделено 24 класса растительных покровов) базировалась на сочетании использования данных Sentinel-2 и Landsat-8 и ежемесячных сводных материалов Sentinel-1. Точность метода для разных регионов составила около 80 % [4].

Для распознавания сельскохозяйственных угодий в ИКИ РАН был разработан метод, учитывающий особенности сезонной и межгодовой динамики отражательных характеристик, отличающих пашню от естественной растительности [5]. При этом точность методики снижалась для регионов Дальнего Востока, что связано со спецификой фенологических циклов, особенностями растительности и т. д. [6].

Вместе с тем, в ряде исследований, посвященных отдельным регионам, показаны возможности использования спутниковых данных Landsat и Sentinel для решения локальных задач мониторинга и оценки земель сельскохозяйственного назначения [7–10]. При этом, хотя подходы, приведенные выше, позволяют решать задачи как картографирования растительных покровов, так и выделения контуров сельскохозяйственных угодий с достаточной точностью, они являются вычислительно затратными, требующими обработки разновременных снимков, полученных в течение вегетационного сезона. Вместе с тем, одними из актуальных задач мониторинга сельскохозяйственных угодий являются предварительное уточнение контуров полей и подготовка shp-файлов для дальнейшей оценки степени зарастания полей, контролирования севооборота и т. д. Эти задачи являются важными для большинства сельскохозяйственных регионов российского Дальнего Востока, в том числе для Еврейской автономной области (ЕАО). На текущий момент в ЕФИС ЗСН не пред-

ставлены достоверные сведения об используемых сельскохозяйственных землях, хотя для региона характерно зарастание и заболачивание земель, а также периодическое подтопление Амуром и его притоками. В таком случае альтернативой ручному оконтуриванию полей может стать полуавтоматическое выделение пахотных земель и некоторых классов растительности [11]. Для минимизации затрат на подготовку и обработку космических снимков предложено выбрать спутниковые изображения Sentinel-2 для основных сельскохозяйственных районов ЕАО в августе 2022 г. — месяце, для которого характерен максимум вегетации растительности, и при достаточно больших подтоплениях поймы Амура. При этом важной задачей является оценка необходимости предобработки данных, в первую очередь, атмосферной коррекции снимков, что снижает влияние атмосферных взаимодействий и атмосферного рассеивания на цифровые значения коэффициентов спектральной яркости [12].

Цель настоящего исследования — распознавание пахотных земель ЕАО с использованием методов машинного обучения. Для достижения цели были поставлены следующие задачи:

1. Подготовка изображений Sentinel-2 для выбранных районов ЕАО с проведением атмосферной коррекции.
2. Оценка степени влияния выбранных методов машинного обучения и проведенной атмосферной коррекции снимков на точность классификации растительных покровов ЕАО.


Область исследования

В качестве области исследования были выбраны Ленинский и Октябрьский районы Еврейской автономной области, являющейся одним из регионов южной части российского Дальнего Востока, ориентированных в основном на сельскохозяйственное производство (рис. 1). Площадь сельскохозяйственных угодий ЕАО в 2021 г. составляла 14,8 % общего земельного фонда области [13]. При этом для ЕАО характерна достаточно высокая доля залежных земель и низкая доля пашни. Так, доля пахотных земель в регионе составила 32,1 %, сенокосов — 20,1 %, пастбищ — 22,8 %, а залежей — 23,7 % [14]. По данным Росстата (<https://rosstat.gov.ru>), площадь пахотных земель в Ленинском районе в 2022 г. составляла 53,6 тыс. га, в Октябрьском районе — 46,4 тыс. га, преобладающая культура, занимавшая более 90 % посевной площади — соя.

Ленинский и Октябрьский районы расположены между 48°40' с. ш., 130°40' в. д. и 47°40' с. ш., 133°40' в. д. на Среднеамурской низменности. Для северной части области исследования характерна гористо-лесистая местность, в южной части, в том числе пойме р. Амур, — луговая. Высота равнины постепенно понижается от 100–150 м у подножия

Рис. 1. Область исследования

Fig. 1. Semantic segmentation



предгорий Малого Хингана до 50–40 м в пойме Амура. В целом пашни, сенокосы и пастбища составляют около 6 % площади Среднеамурской низменности, а культурные и техногенные ландшафты — 2 % [15]. Среднеамурская низменность является избыточно увлажненной, но вместе с тем обладает благоприятными почвенно-климатическими условиями для сельского хозяйства и характеризуется умеренным континентальным климатом с выраженными сезонами. Лето в этих районах теплое и влажное, при этом начало лета обычно засушливое, средние температуры июля составляют около +20 °С. Вегетационный период, продолжающийся с апреля по сентябрь (145 дней на севере Ленинского и Октябрьского районов, в предгорьях; 165 — на равнинной части), обеспечивает благоприятные условия для роста и развития сельскохозяйственных культур. Для конца лета характерны обильные дожди, которые часто способствуют наводнениям с подтоплением сельскохозяйственных угодий.

Получение и обработка спутниковых изображений

Для исследуемой области в августе 2022 г. было получено 5 снимков со спутника Sentinel-2 (2 снимка уровня L1C и 3 снимка уровня L2A) с раз-

решением 10 м. Предварительная обработка спутниковых снимков относится к важному этапу получения достоверной информации. Основной целью предобработки данных является устранение артефактов и искажений, а также подготовка снимков для дальнейшей классификации. Уровень обработки L1C (Level-1C) представляет собой необработанные данные, полученные после процедур калибровки и геометрической коррекции. Эти снимки содержат информацию об отражательной способности поверхности земли в различных каналах спектра, но не подвергаются атмосферной коррекции. Снимки L1C позволяют исследователям выполнять более гибкую обработку данных с последующим анализом, но могут содержать атмосферные артефакты, что, во-первых, затрудняет точную классификацию, и во-вторых, требует больших временных затрат. Для предобработки изображений уровня L1C авторы использовали программное обеспечение SNAP (Sentinel Application Platform), разработанное Европейским космическим агентством (ESA) для обработки спутниковых снимков Sentinel. SNAP позволяет выполнять различные операции предобработки, включая атмосферную и геометрическую коррекцию, в том числе точное привязывание снимков к местности.

Уровню обработки L2C (Level-2C), напротив, соответствуют снимки после атмосферной коррекции, что позволяет получить информацию, свободную от атмосферных искажений. Наличие готового продукта, разработанного ESA для определения коэффициента отражения поверхности уровня 2A, очень важно для минимизации усилий пользователей при обработке [16]. Для атмосферной коррекции при переходе к уровню 2A используется программное обеспечение Sen2Cor [17].

Методы машинного обучения и программные продукты для классификации изображений

Для классификации сельскохозяйственных угодий на спутниковых снимках Sentinel-2 использовались следующие методы машинного обучения:

1) метод k -ближайших соседей (k -Nearest Neighbors, KNN): метод машинного обучения, который позволяет классифицировать объекты на основе ближайших соседей с известным классом в многомерном пространстве;

2) классификатор на основе случайного леса (Random Forest Classifier, RF): метод ансамблевого машинного обучения, который использует несколько деревьев решений для улучшения точности классификации;

3) метод максимального правдоподобия (Maximum Likelihood, ML): статистический метод, который позволяет оценить параметры вероятностной модели и определить наиболее вероятный класс объектов;

4) метод минимальных дистанций (Minimum Distance, MD): метод классификации, который определяет класс объекта на основе минимального расстояния до центров классов.

Данные методы частично реализованы в следующих программных модулях: 1) SNAP, 2) Semi-Automatic Classification Plugin (SCP), являющийся

плагином для программы QGIS, 3) DZETSAKA — инструмент классификации, который может использоваться для обработки спутниковых данных.

Основное различие между этими инструментами заключается в подходе к обработке данных, наборе функций и поддерживаемых типах данных. SCP ориентирован на использование в среде QGIS, SNAP специализируется на обработке данных Sentinel, а DZETSAKA предлагает ограниченный набор методов классификации и предполагает обработку данных разного вида.

Основной алгоритм выполнения исследований

Рассмотрено 5 классов подстилающей поверхности земли: пахотные земли 1-го типа — с открытой (вспаханной) почвой, характеризующиеся относительно низкими значениями NDVI (обозначено далее как поле 1), пахотные земли 2-го типа — в состоянии активной вегетации растительного покрова (поле 2), луговая растительность, естественные пастбища и сенокосы (трава), лесостарничковая растительность (лес) и водные объекты (вода). В работе были использованы подготовленные и отредактированные shp-файлы сельскохозяйственных полей ЕАО, а также экспертно выявленные полигоны классов «Трава», «Лес», «Вода». Общая площадь сформированной выборки для каждого класса представлена в табл. 1. В обучающую выборку были включены полигоны суммарной площадью от 684 до 906 га каждого класса, что составляло от 35 до 47 % общей площади выбранных участков поверхности в классах.

Общий ход проведения исследования представлен на рис. 2. На начальном этапе в программном обеспечении QGIS осуществлялся выбор соответствующего уровня обработки — L1C или L2A. Для снимков уровня L1C проводилась атмосферная коррекция изображения. На следующем этапе формировался векторный файл формата SHP


Табл. 1. Площадь сформированной выборки по разным классам поверхностей Ленинского и Октябрьского районов ЕАО

Tab. 1. Area of the generated sample for different classes of surfaces of the Leninsky and Oktyabrsky districts of the Jewish Autonomous Oblast

Класс	Общая выборка, га	Обучающая выборка, га	Тестовая выборка, га
Поле1	1921,4	684,3	1237,1
Поле2	1999,4	883,8	1115,6
Трава	1920,3	906,6	1013,7
Лес	2041,9	854,6	1187,3
Вода	1890,3	769,5	1120,8

Рис. 2. Алгоритм проведения исследований

Fig. 2. Research algorithm



с геометрическим типом «полигон». Полигоны всех классов в дальнейшем делились на обучающую и тестовую выборки (см. табл. 1). В дальнейшем в зависимости от заданного уровня обработки проводилась классификация изображения с использованием разных методов машинного обучения и программного обеспечения.

После проведения классификации осуществлялась оценка точности на тестовом множестве.

Общая точность (ОА, %) для каждого метода определялась по формуле

$$OA = \frac{TP}{TP + FP} 100, \quad (1)$$

где TP — число верно идентифицированных пикселей в каждом классе; FP — число неверно идентифицированных пикселей в классе.

Для сравнительной оценки точности классификации с применением разных программных комплексов, методов машинного обучения и уровней обработки снимков применялся дисперсионный анализ с последующим апостериорным сравнением с использованием LSD-теста.

Результаты исследований

В табл. 2 представлены средние значения ОА при использовании разных методов машинного обучения для классификации пахотных земель ЕАО по изображениям уровней L1C и L2A.

В среднем точность классификации при использовании изображений уровня L1C находилась в диапазоне 53–80 %, изображений L2A — 79–83 %. Как видно из диаграммы размаха (рис. 3), средние значения ОА для L2A достоверно выше соответствующих показателей L1C на уровне значимости 0,1 ($p = 0,081$).

Как видно из рис. 4, ОА при применении разных методов машинного обучения значимо не различалась ($p = 0,865$) — средние значения показателя составили от 71,1 % для MD до 79,7 % для KNN.

Для уровня L1C средние значения общей точности варьируют от 53,5 % для ML до 79,7 % для KNN, при этом значимых различий в точности методов не было выявлено (рис. 5). Вместе с тем, ОА при использовании Dzetsaka (78,4 %) достоверно выше, чем при применении Snap (56,5 %) и SCP (60,8 %).

Как видно из рис. 6, для уровня L2A значимых различий в средних значениях ОА при применении

разных методов машинного обучения и программных продуктов Snap и SCP выявлено не было — межквартильный размах находился в пределах 3–5 %, средние значения ОА для методов MD, RF, ML были равны соответственно 79,0, 80,1 и 83,1 %, для программных продуктов Snap и SCP — 81,9 и 79,3 %.

На рис. 7, 8 представлены результаты распознавания подстилающей поверхности для части Ленинского и Октябрьского районов по изображению уровня L2A. В качестве метода машинного обучения использовался ML программного комплекса — SNAP. Общая точность метода составила 83,1 %. Как видно из рис. 7, для августа характерно подтопление поймы Амура, в том числе выход реки на пахотные земли Ленинского района. Наибольшее число возделываемых полей сосредоточено в юго-восточной части района, а гористая местность к северу от реки покрыта лесами. На рис. 8 отображена южная часть Октябрьского района. Сельскохозяйственные угодия также были идентифицированы на юге района, вблизи российско-китайской границы, в пойме р. Амур. Для северной части Октябрьского района лес также являлся преобладающим типом растительности.

Табл. 2. Средние значения ОА для изображений разного уровня обработки, % (ЕАО, август 2022 г.)

Tab. 2. Average OA values for images at different levels of processing, % (Jewish Autonomous Oblast, August 2022)

Уровень обработки снимка	Метод машинного обучения				Среднее значение
	MD	ML	RF	KNN	
L1C	59,1	53,4	66,4	79,7	65,2
L2A	79,0	83,1	80,1	—	80,6
Среднее значение	71,1	71,3	73,3	79,7	72,9

Рис. 3. Диаграмма размаха (изображения L1C и L2A)

Fig. 3. Box plot (Images L1C and L2A)




Рис. 4. Диаграмма размаха (методы машинного обучения): все уровни обработки изображений

Fig. 4. Box plot (machine learning methods): all levels of image processing





Рис. 5. Диаграмма размаха для уровня L1C


Fig. 5. Box plot for L1C level





A — методы машинного обучения, B — программные продукты
A — machine learning methods, B — software products

Рис. 6. Диаграмма размаха для уровня L2A

Fig. 6. Box plot for L2A level



A — методы машинного обучения, B — программные продукты
A — machine learning methods, B — software products

Рис. 7. Результаты распознавания подстилающей поверхности Ленинского района ЕАО (L2A, Snap, ML)*Fig. 7. Results of recognition of the underlying surface of the Leninsky district of the Jewish Autonomous Oblast (L2A, Snap, ML)***Рис. 8.** Результаты распознавания подстилающей поверхности Октябрьского района ЕАО (L2A, Snap, ML)*Fig. 8. Results of recognition of the underlying surface of the Oktyabrsky district of the Jewish Autonomous Oblast (L2A, Snap, ML)*

В целом достигнутая точность распознавания пахотных земель двух классов (поле 1 и поле 2) позволила осуществлять дальнейшую корректировку границ сельскохозяйственных земель в ручном режиме.

Заключение

В статье показана возможность использования методов машинного обучения на основе изображений спутника Sentinel-2 для распознавания пахотных земель муниципальных районов ЕАО. В августе 2022 г. подготовлены снимки уровней L2A и L1C, для снимков L1C проведена атмосферная коррекция. С использованием программного обеспечения SNAP, SCP, Dzetsaka и разных методов машинного обучения проведена классификация подстилающей поверхности Ленинского и Октябрьского районов ЕАО. По результатам статистической обработки установлено, что оптималь-

ным явилось использование изображений уровня L2A — с предварительно проведенной атмосферной коррекцией. При этом выбранный метод машинного обучения и применяемые программные инструменты не оказывали значимого влияния на точность классификации. Средняя точность классификации составила 80,6 %. Разработанный подход, базирующийся на оценке одного спутникового снимка, может быть использован для предварительной подготовки размеченных контуров сельскохозяйственных полей и последующей ручной корректировки границ, что позволяет, с одной стороны, снизить трудозатраты, возникающие при полноценной разметке полей экспертом; с другой стороны, не требует применения трудоемких методов подготовки серии временных изображений за один вегетационный период.

Список источников

1. Барталев С.А., Лупян Е.А. Основные направления и результаты развития методологии спутникового картографирования растительного покрова России // 7-я международная научно-техническая конференция «К.Э.Циолковский – 160 лет со дня рождения. Космонавтика. Радиоэлектроника. Геоинформатика»: тезисы докладов (Рязань, 4–6 октября 2017 г.). – Рязань: РГРТУ, 2017. – С. 74–79.
2. Барталев С.А., Егоров В.А., Ершов Д.В., Исаев А.С., Лупян Е.А., Плотников Д.Е., Уваров И.А. Спутниковое картографирование растительного покрова России по данным спектрорадиометра MODIS // Современные проблемы дистанционного зондирования Земли из космоса. – 2011. – Т. 8. – № 4. – С. 285–302.
3. Qiu B., Lin D., Chen C., Yang P., Tang Z., Jin Z., Ye Z., Zhu X., Duan M., Huang H., Zhao Z., Xu W., Chen Z. From cropland to cropped field: A robust algorithm for national-scale mapping by fusing time series of Sentinel-1 and Sentinel-2 // International Journal of Applied Earth Observation and Geoinformation. – 2022. – Vol. 113. – 103006. DOI: 10.1016/j.jag.2022.103006.
4. Blickensdörfer L., Schwieder M., Pflugmacher D., Nendel C., Erasmí S., Hostert P. Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany // Remote sensing of environment. – 2022. – Vol. 269. – 112831. DOI: 10.1016/j.rse.2021.112831.
5. Барталев С.А., Егоров В.А., Жарко В.О., Лупян Е.А., Плотников Д.Е., Хвостиков С.А., Шабанов Н.В. Спутниковое картографирование растительного покрова России. – М.: ИКИ РАН, 2016. – 208 с.
6. Миклашевич Т.С., Барталев С.А., Плотников Д.Е. Интерполяционный алгоритм восстановления длинных временных рядов данных спутниковых наблюдений растительного покрова // Современные проблемы дистанционного зондирования Земли из космоса. – 2019. – Т. 16. – № 6. – С. 143–154. DOI: 10.21046/2070-7401-2019-16-6-143-154.
7. Hua L., Zhang X., Chen X., Yin K., Tang L. A Feature-Based Approach of Decision Tree Classification to Map Time Series Urban Land Use and Land Cover with Landsat 5 TM and Landsat 8 OLI in a Coastal City, China // ISPRS International Journal of Geo-Information. – 2017. – Vol. 6. – No. 11. – 331. DOI: 10.3390/ijgi6110331.
8. Иванов М.А., Прищепов А.В., Голосов В.Н., Залыалиев Р.Р., Ефимов К.В., Кондратьева А.А., Киняшова А.Д., Ионова Ю.К. Методика картографирования динамики пахотных угодий в бассейнах рек Европейской территории России за период 1985–2015 гг. // Современные проблемы дистанционного зондирования Земли из космоса. – 2017. – Т. 14. – № 5. – С. 161–171. DOI: 10.21046/2070-7401-2017-14-5-161-171.
9. Singh G., Singh S., Sethi G., Sood V. Deep Learning in the Mapping of Agricultural Land Use Using Sentinel-2 Satellite Data // Geographies – 2022. – Vol. 2. – № 4. – pp. 691–700. DOI: 10.3390/geographies2040042.
10. Pan L., Xia H., Yang J., Niu W., Wang R., Song H., Guo Y., Qin Y. Mapping cropping intensity in Huaihe basin using phenology algorithm, all Sentinel-2 and Landsat images in Google Earth Engine // International Journal of Applied Earth Observation and Geoinformation. – 2021. – Vol. 102. – 102376. DOI: 10.1016/j.jag.2021.102376.
11. Ковалев В.А., Калиновский А.А., Дмитрук А.А., Левчук В.А. Алгоритмы автоматизации выделения контуров полей на цифровых аэрокосмических снимках для решения задач мониторинга сельскохозяйственных земель // Доклады Белорусского государственного университета информатики и радиоэлектроники. – 2015. – № 7 (93). – С. 71–76.
12. Тарасов А.В. Современные технологии автоматического картографирования облачности // Интерэкспо Гео-Сибирь. – 2020. – Т. 1. – № 2. – С. 55–61. DOI: 10.33764/2618-981X-2020-1-2-55-61.

13. Горбушина О.И., Крохалева С.И. Аналитический анализ состояния земельного фонда на территории Еврейской автономной области // Мировые научные исследования современности: возможности и перспективы развития : материалы XVI международной научно-практической конференции (Ростов-на-Дону, 31 марта 2022 г.). – Ч. 1. – Ставрополь: Параграф, 2022. – С. 575–579.
14. Хашиев А.Б., Бабаков В.П. Мелиорация сельскохозяйственных земель в Еврейской автономной области // Аграрная наука. – 2020. – № 10. – С. 95–98. DOI: 10.32634/0869-8155-2020-342-10-95-98.
15. Климина Е.М. Ландшафтно-экологическое зонирование для реализации задач ландшафтного планирования (на примере Среднеамурской низменности) // Вестник ДВО РАН. – 2018. – № 4 (200). – С. 65–72.
16. Dwyer J.L., Roy D.P., Sauer B., Jenkerson C.B., Zhang H.K., Lyburner L. Analysis Ready Data: Enabling Analysis of the Landsat Archive // Remote Sensing. – 2018. – Vol. 10. – No 9. – 1363. DOI:10.3390/rs10091363.
17. Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for sentinel-2 // Proceedings SPIE 10427, Image and signal processing for remote sensing XXIII, 1042701 (4 October 2017). – 2017. – pp. 37–48. DOI: 10.1117/12.2278218.

References

1. Bartalev S.A., Lupyan E.A. Osnovnye napravleniya i rezul'taty razvitiya metodologii sputnikovogo kartografirovaniya rastitel'nogo pokrova Rossii [Main directions and results of development of methodology for satellite mapping of vegetation cover in Russia]. In: 7-ya mezhdunarodnaya nauchno-tehnicheskaya konferentsiya «K.E.Tsiolkovskii – 160 let so dnya rozhdeniya. Kosmonavtika. Radioelektronika. Geoinformatika»: tezisy dokladov (Ryazan', 4–6 October 2017). Ryazan': RGRTU; 2017. pp. 74–79.
2. Bartalev S.A., Egorov V.A., Ershov D.V., Isaev A.S., Loupian E.A., Plotnikov D.E., Uvarov I.A. Mapping of Russia's vegetation cover using MODIS satellite spectroradiometer data. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 2011;8(4):285–302.
3. Qiu B., Lin D., Chen C., Yang P., Tang Z., Jin Z., Ye Z., Zhu X., Duan M., Huang H., Zhao Z., Xu W., Chen Z. From cropland to cropped field: A robust algorithm for national-scale mapping by fusing time series of Sentinel-1 and Sentinel-2. *International Journal of Applied Earth Observation and Geoinformation*. 2022;113:103006. DOI: 10.1016/j.jag.2022.103006.
4. Blickensdörfer L., Schwieder M., Pflugmacher D., Nendel C., Erasmí S., Hostert P. Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany. *Remote sensing of environment*. 2022;269:112831. DOI: 10.1016/j.rse.2021.112831.
5. Bartalev S.A., Egorov V.A., Zharko V.O., Loupian E.A., Plotnikov D.E., Khvostikov S.A., Shabanov N.V. Land cover mapping over Russia using Earth observation data. Moscow: Russian Academy of Sciences' Space Research Institute; 2016. 208 p.
6. Miklashevich T.S., Bartalev S.A., Plotnikov D.E. Interpolation algorithm for the recovery of long satellite data time series of vegetation cover observation. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 2019;16(6):143–154. DOI: 10.21046/2070-7401-2019-16-6-143-154.
7. Hua L., Zhang X., Chen X., Yin K., Tang L. A Feature-Based Approach of Decision Tree Classification to Map Time Series Urban Land Use and Land Cover with Landsat 5 TM and Landsat 8 OLI in a Coastal City, China. *ISPRS International Journal of Geo-Information*. 2017;6(11):331. DOI: 10.3390/ijgi6110331.
8. Ivanov M.A., Prishchepov A.V., Golosov V.N., Zalyaev R.R., Efimov K.V., Kondrat'eva A.A., Kinyashova A.D., Ionova Yu.K. Method of croplands dynamics mapping in river basins of the European part of Russia for the period of 1985–2015. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*. 2017;14(5):161–171. DOI: 10.21046/2070-7401-2017-14-5-161-171.
9. Singh G., Singh S., Sethi G., Sood V. Deep Learning in the Mapping of Agricultural Land Use Using Sentinel-2 Satellite Data. *Geographies*. 2022;2(4):691–700. DOI: 10.3390/geographies2040042.
10. Li P., Xia H., Yang J., Niu W., Wang R., Song H., Guo Y., Qin Y. Mapping cropping intensity in Huaihe basin using phenology algorithm, all Sentinel-2 and Landsat images in Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*. 2021;102:102376. DOI: 10.1016/j.jag.2021.102376.
11. Kovalev V.A., Kalinovsky A.A., Dmitruk A.A., Liauchuk V.A. Automatic algorithms of agricultural fields segmentation on aerial images for remote sensing and environmental monitoring. *Doklady BGUIR*. 2015;(7):71–76.
12. Tarasov A.V. Current technologies of automatic cloud mapping. *Interexpo GEO-Siberia*. 2020;1(2): 55–61. DOI: 10.33764/2618-981X-2020-1-2-55-61.
13. Gorbushina O.I., Krokhaleva S.I. Analytical analysis of the state of the land fund in the territory of the Jewish Autonomous region. In: World Scientific Research of Our Time: Opportunities and Prospects of Development: Materials of the XVI International Scientific and Practical Conference (Rostov-on-Don, 31 March 2022). Stavropol: Paragraph; 2022. pp. 575–579.
14. Hashiev A.B., Babakov V.P. Land reclamation in the Jewish Autonomous region. *Agrarian science*. 2020;(10):95–98. DOI: 10.32634/0869-8155-2020-342-10-95-98.
15. Klimina E.M. Landscape and ecological zoning for realization of landscape planning (on the example of the Middle Amur Lowland). *Vestnik of the Far East Branch of the Russian Academy of Sciences*. 2018;(4):65–72.
16. Dwyer J.L., Roy D.P., Sauer B., Jenkerson C.B., Zhang H.K., Lyburner L. Analysis Ready Data: Enabling Analysis of the Landsat Archive. *Remote Sensing*. 2018;10(9):1363. DOI:10.3390/rs10091363.
17. Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for sentinel-2. In: Proceedings SPIE 10427, Image and signal processing for remote sensing XXIII, 1042701 (4 October 2017). 2017. pp. 37–48. DOI: 10.1117/12.2278218.

Статья поступила в редакцию 27.04.2023 г., одобрена после рецензирования 15.05.2024 г., принята к публикации 07.06.2024 г.
The article was submitted 27.04.2023; approved after reviewing 15.05.2024; accepted for publication 07.06.2024.

Информация об авторах

Поляков Артем Николаевич

Аспирант

Хабаровский Федеральный исследовательский центр
Дальневосточного отделения Российской Академии наук
680000 Хабаровск, ул. Дзержинского, д. 54

Инженер

Вычислительный центр Дальневосточного отделения
Российской академии наук

680063 Хабаровск, ул. Ким Ю Чена, д. 65

e-mail: artem_polyakov@inbox.ru

ORCID: 0009-0007-9526-5114

Information about authors

Artem N. Polyakov

Postgraduate Student

Khabarovsk Federal Research Center of the Far Eastern Branch
of the Russian Academy of Sciences

54, Dzerzhinsky Str., Khabarovsk, 680000, Russia

Engineer

Computing Center of the Far Eastern Branch
of the Russian Academy of Sciences

65, Kim Yu Chen Str., Khabarovsk, 680063, Russia

e-mail: artem_polyakov@inbox.ru

ORCID: 0009-0007-9526-5114

Степанов Алексей Сергеевич

Доктор фармацевтических наук

Ведущий научный сотрудник

Дальневосточный научно-исследовательский институт
сельского хозяйства

680521 Хабаровский край, Восточное, ул. Клубная, д. 13

e-mail: stepanfx@mail.ru

ORCID: 0000-0001-8395-8350

Web of Science ResearcherID: AAY-7208-2020

Scopus AuthorID: 7402419500

AuthorID: 247904

Alexey S. Stepanov

Doctor of Pharmaceutical Sciences

Leading Researcher

Far Eastern Agricultural Research Institute

13, Klubnaya Str., Vostochnoe, kr. Khabarovskiy, 680521, Russia

e-mail: stepanfx@mail.ru

ORCID: 0000-0001-8395-8350

Web of Science ResearcherID: AAY-7208-2020

Scopus AuthorID: 7402419500

AuthorID: 247904