

УДК 004.89

DOI 10.52575/2687-0932-2022-49-1-159-168

## **Технология интеллектуального распознавания сельскохозяйственных культур нейронной сетью по мультиспектральным многовременным данным дистанционного зондирования Земли**

**Асадуллаев Р.Г., Кузьменко Н.И.**

Белгородский государственный национальный исследовательский университет,  
Россия, 308015, г. Белгород, ул. Победы, 85  
E-mail: asadullaev@bsu.edu.ru, 1198645@bsu.edu.ru

**Аннотация.** В данной работе представлена технология распознавания сельскохозяйственных культур по данным дистанционного зондирования Земли. Апробация технологии была проведена на сельскохозяйственных землях Белгородской области Российской Федерации. В соответствии со статистикой севооборота были выбраны следующие сельскохозяйственные культуры: пшеница, ячмень, кукуруза, подсолнечник, соя, сахарная свекла, многолетние травы и пары. В качестве входных данных были использованы мультиспектральные снимки со спутника Sentinel-2 уровня обработки MSI L2A, а именно каналы RGB-спектра, SWIR и NIR. Из полученных данных были составлены временные ряды в вегетационные периоды за 2018–2020 годы. Разработан алгоритм устранения пропусков данных в дни высокой облачности для повышения качества распознавания. В качестве модели классификатора была использована сверточно-рекуррентная нейронная сеть. Разработанная модель на тестовых данных показала общую меру точности  $f$ -мера 88,7%. Предложенная архитектура нейронной сети также применима в других регионах со схожей посевной структурой, фенологическими показателями культур и схожими климатическими условиями.

**Ключевые слова:** нейронная сеть, CNN, LSTM, классификация сельскохозяйственных культур, Sentinel-2

**Для цитирования:** Асадуллаев Р.Г., Кузьменко Н.И. 2022. Технология интеллектуального распознавания сельскохозяйственных культур нейронной сетью по мультиспектральным многовременным данным дистанционного зондирования Земли. Экономика. Информатика, 49(1): 159–168. DOI 10.52575/2687-0932-2022-49-1-159-168

---

## **Technology of intelligent agricultural crops recognition by neural network based on multispectral multitemporal Earth remote sensing data**

**Rustam G. Asadullaev, Nikolay I. Kuzmenko**

Belgorod National Research University,  
85 Pobeda St, Belgorod, 308015, Russia  
E-mail: asadullaev@bsu.edu.ru, 1198645@bsu.edu.ru

**Abstract.** This article presents a technology for recognition of crops based on Earth remote sensing data. Approbation of the technology was carried out on agricultural lands of the Belgorod region, Russian Federation. According to the crop rotation statistics, the following crops were selected: wheat, barley, corn, sunflower, soybean, sugar beet, perennial grasses and fallow lands. As input data, multispectral images from the Sentinel-2 satellite of the MSI L2A processing level were used, namely the channels of the RGB, SWIR and NIR bands. From the data obtained, time series were compiled in the growing seasons for 2018–2020. An algorithm has been developed to eliminate data gaps on days of high cloudiness to improve the quality of recognition. A convolutional-recurrent neural network was used as a classifier model. The developed model



on test data showed an overall measure of accuracy F-score of 88.7%. The proposed architecture of the neural network is also applicable in other regions with a similar sowing structure, phenological phases of crops and similar climatic conditions.

**Keywords:** neural net, CNN, LSTM, agricultural crops classification, Sentinel-2

**For citation:** Asadullaev R.G., Kuzmenko N.I. 2022. Technology of intelligent agricultural crops recognition by neural network based on multispectral multitemporal Earth remote sensing data. Economics. Information technologies, 49(1): 159–168 (in Russian). DOI 10.52575/2687-0932-2022-49-1-159-168

## Введение

Данные дистанционного зондирования Земли в видимом и инфракрасном диапазонах сегодня применяются для широкого спектра задач, таких как классификация земельного и растительного покрова, поиск незаконных построек, мониторинг природных явлений, точное земледелие, контроль лесного хозяйства, создание тематических карт. Одной из таких задач является задача классификации сельскохозяйственных культур.

Актуальность задачи заключается в необходимости получения достоверной информации о посевах сельскохозяйственных культур. Данная информация может быть полезна как контролирующим органам, так и менеджменту крупных аграрных предприятий. Контролирующие органы могут отслеживать используемость полей, соответствие посаженных и заявленных культур на полях, выявлять ненадлежащее использование земель. Эта задача важна для обеспечения продовольственной безопасности регионов. Аграрные предприятия могут осуществлять мониторинг посевных площадей на местах, не выезжая непосредственно на поля.

На сегодняшний день для контроля сельскохозяйственной деятельности используется система отчетной документации, составляемая территориальными надзорными органами. Требуется технология, позволяющая в автоматическом режиме провести сверку всех полей региона на соответствие выращиваемой культуры и заявленной в отчете. Такая технология позволит сократить время обследования, повысить точность и независимость контроля сельскохозяйственных предприятий.

В настоящее время имеется множество исследований на тему распознавания сельскохозяйственных культур. В большинстве работ используется распознавание с помощью алгоритмов машинного обучения [Kamilaris, 2021]. В основном классификация осуществляется с применением методов случайных лесов, нейронных сетей, машин опорных векторов [Liakos, 2018; Neetu and Ray, 2019]. Общим ограничением методов машинного обучения для решения задачи классификации сельскохозяйственных культур является область интереса, для которой производится классификация.

## Объекты и методы исследования

Входными данными для разрабатываемой технологии являются геопривязанные контуры сельскохозяйственных полей. В связи с этим возможно реализовать классификацию по группам пикселей вместо попиксельной классификации. В рамках одного контура поля может выращиваться несколько культур. Необходимо распознать все выращиваемые культуры в рамках одного контура. При подготовке набора обучающих данных для полей с несколькими культурами была произведена ручная переразметка контуров с разделением полей на части. К моменту публикации статьи алгоритм автоматического разделения внутри контура поля на несколько культур находится в стадии разработки и будет опубликован в последующих работах.

Задача осложнена тем фактом, что не все поля имеют актуальную разметку. Из-за этого помимо сельскохозяйственных культур в контурах полей могут располагаться строения, жилые массивы, леса или неиспользуемые земли. В связи с этим, обучающие и тестовые данные были

предварительно очищены от таких полей путем визуальной проверки соответствия поля сельскохозяйственному использованию по спутниковым снимкам.

Каждая сельскохозяйственная культура характеризуется собственным набором параметров: цикл роста, вегетационный период, сорт и условия произрастания (осадки, увлажнение, состояние почвы, количество солнечного света и т. п.). Некоторые исследователи прибегают к анализу вегетационного периода (например, индекса вегетации NDVI) для решения задачи классификации. Данный подход позволяет хорошо отделить озимые культуры от яровых. Однако индекс вегетации у некоторых культур является довольно схожим и не отражает индивидуальных особенностей каждой культуры [Чурсин, 2018]. Поэтому требуется технология, позволяющая делать заключение на основании множества признаков с возможностью формирования оригинальных знаний, не доступных эксперту. В настоящем исследовании в основу такой технологии будет взята нейронная сеть глубокого обучения.

Для решения задачи классификации был составлен план, состоящий из следующих шагов:

- Поиск данных для разметки обучающей и тестовой выборки.
- Выбор источника, скачивание и подготовка спутниковых данных.
- Подбор архитектуры и обучение нейронной сети.
- Тестирование модели и анализ результатов.

## **Материалы**

### **Данные для разметки обучающей и тестовой выборки**

В качестве разметки была использована географическая структура данных в формате GeoJSON. Данная структура полей была получена для Волоконовского и Красногвардейского районов Белгородской области Российской Федерации за 2018–2020 года. Из разметки были убраны необработываемые поля и поля с теми культурами, по которым недостаточно данных для обучения. После данных операций множество полей было разделено на обучающую и тестовую выборки в соотношении 90 % к 10 % соответственно. Всего было представлено 1018 полей с атрибутивной информацией по культурам за три года.

Для классификации было представлено 7 видов культур (многолетние травы, ячмень, кукуруза, сахарная свекла, соя, подсолнечник, пшеница) и пар (поле, на котором в данном году не выращивается культура). В итоге была сформирована обучающая выборка из 2785 примеров (рис. 1). Под обучающим примером мы подразумеваем поле в целом.

### **Выбор источника, скачивание и подготовка спутниковых данных**

Качество методов классификации в задачах дистанционного зондирования Земли зависит от предварительной обработки данных (трансформирование пространственной, спектральной и временной информации в данные для классификационной модели). При выборе источника спутниковых данных необходимо учитывать следующие факторы:

- Пространственное разрешение спутника показывает, насколько детализированное изображение по каждому из пикселей. Например, если пространственное разрешение спутника 10 метров, значит каждый пиксель представляет информацию с области 10x10 метров.
- Спектральное разрешение спутника показывает, насколько большой диапазон спектральных характеристик захватывает сенсор в определенном канале. Как правило, датчики с высоким разрешением имеют более узкие спектральные полосы.
- Частота съемки во времени показывает, с каким временным промежутком спутник проводит съемку поверхности.
- Радиометрическое разрешение показывает, насколько сенсор чувствителен к малому изменению показаний в электромагнитных волнах. Представляет собой количество информации в каждом из пикселей. Выражается в битах [Song, 2021].




Рис. 1. Область интереса с метками классов за 2019 год  
Fig. 1. Area of interest with class labels for 2019 year

В качестве источников спутниковых данных рассматривались такие спутники, как Sentinel-2, Landsat-8 и MODIS. MODIS имеет слишком низкое пространственное разрешение 250x250 метров, поэтому сравнивались два оставшихся спутника.

Sentinel-2 имеет временной интервал в 5 дней для одной точки поверхности, пространственное разрешение в 10 м в каналах RGB и NIR-диапазона, 20 м в каналах вегетации красного края и SWIR-диапазона и 60 м в каналах для прибрежного аэрозоля, водной взвеси и определения перистых облаков [Sentinel-2, 2022].

Landsat-8 имеет меньшее число каналов с меньшим пространственным разрешением (7 каналов в 30 м и 1 канал в 15 м), а также больший временной интервал между съемками одной точки поверхности (15 дней). Данная периодичность достаточна для решения поставленной задачи. Однако вероятность того, что в момент съемки над зоной интереса будет стоять облачность, может сделать сильный временной разрыв между данными. Это сильно искажает динамику вегетации растительности.

По данным сравнения решено было выбрать спутник Sentinel-2. В программе европейского космического агентства Copernicus Sentinel-2 задействовано 2 спутника – Sentinel-2A и Sentinel-2B. Они были запущены в 2015 и 2017 году соответственно. В данной работе использовались данные уровня обработки L2A, включающие атмосферную коррекцию и расчет масок облачности и снежного покрова [Sentinel-2, 2022].

Спутниковые данные были скачаны с сервиса Copernicus Open Access Hub, в котором исходные данные со спутников представлены в виде продуктов – архивированные данные в виде тайлов размером 100 на 100 км [Copernicus OAH, 2022].

Для классификации тайлы были разделены на поля по имеющимся контурам в каждом из каналов и соединены по датам с промежутком в 10 дней. Данные по каждому полю были сохранены как отдельные файлы в виде numpy-массивов.

Для уменьшения влияния облачности на качество предсказаний модели был разработан специальный алгоритм, заполняющий облачные пиксели интерполированными данными. Результат работы алгоритма показан на рис. 2:



Рис. 2. Процесс интерполяции облачных снимков: а) исходные RGB-данные; б) маска заменяемых пикселей; в) интерполированные RGB-данные

Fig. 2. Process of cloud data interpolation: a) original RGB-data; b) pixel replace masks; c) interpolated RGB-data

#### Процедура работы алгоритма

1. Для поля берутся его многоспектральный снимок и маска облачности (скачивается вместе с продуктами Sentinel-2).
2. Алгоритм проходит по каждой из дат и ищет облачные пиксели.
3. При нахождении облачного пикселя алгоритм ищет предыдущую и последующую безоблачные даты для этого пикселя.
4. От крайнего левого до крайнего правого значения каждый канал заполняется методом линейной интерполяции.

Разработанный подход позволил уменьшить влияние облачных снимков на точность классификатора.



Для уменьшения влияния выбросов (дефектные пиксели, пиксели с других полей, постройки, остатки неправильной разметки) перед подачей на нейронную сеть производилось отсеивание 5 % наиболее больших и 5 % наиболее низких по значению вегетационного индекса пикселей. Эти пиксели помечались как незначимые и не подавались на нейронную сеть.

Для обучения модели использовались данные за вегетационный период (с 1 марта по 31 октября с интервалом в 10 дней). Для распознавания были выбраны 8 каналов (B2, B3, B4, B5, B6, B7, B8 и B8A) и добавлен дополнительный канал с рассчитанным индексом вегетации – NDVI.

Операции скачивания и обработки спутниковых данных проводились с помощью библиотек на языке Python: GDAL [GDAL, 2022], Rasterio [Rasterio, 2022], Numpy, Matplotlib.

### **Подбор архитектуры и обучение нейронной сети**

В данной работе было решено использовать собственную архитектуру нейронной сети. Ранее были апробированы другие архитектуры нейронных сетей: с трехмерными сверточными слоями, двухмерными сверточными слоями, LSTM [Brandt, 2019]. Данные архитектуры показали хороший результат, но остался потенциал к улучшению качества предсказаний [Кузьменко, 2020].

Для учета более полного набора признаков (пространственные, временные и межканальные) принято решение о разработке архитектуры нейронной сети с одномерными сверточными слоями и рекуррентным LSTM-слоем.

На вход модели поступает 16 временных примеров с 8 случайными ненулевыми пикселями по 9 каналам с одного поля. Ранее алгоритм предобработки сводил поля к единому размеру и оставлял пространственную геопривязку [Кононов, 2020]. От пространственной привязки решено было отказаться, так как в предыдущих исследованиях модель с пространственной логикой не показала достойного результата [Кузьменко, 2020]. Здесь мы предполагаем, что структура поля однородна и большое число различных сочетаний случайных пикселей должно увеличить вариативность и универсальность модели.

Архитектура модели нейронной сети представлена на рис. 3. Модель нейронной сети состоит из одномерного сверточного слоя и слоя пулинга. Одномерные свертки извлекают признаки, а последующий слой пулинга максимальных значений выбирает наиболее информативные признаки для передачи на следующий слой.

Следующим в модели идет слой исключения (Dropout). Он позволяет уменьшить вероятность переобучения сети за счет исключения из обучения на эпохе заданного процента весовых коэффициентов слоя нейронов.

Затем идет еще один слой одномерных сверток для формирования финальной карты признаков в 64 фильтра.

Все слои, описанные выше, заключены в обертку TimeDistributed для подачи на рекуррентный слой LSTM. Таким образом, сверточные слои нейронной сети формируют карту признаков, которая подается на слои LSTM для поиска временной логики в данных.

После формирования карты признаков данные подаются на рекуррентный слой, состоящий из 64 LSTM ячеек. После этого расположен еще один слой исключения половины обучающих нейронов и полносвязный слой из 128 нейронов с функцией активации ReLU.

Последним стоит слой классификации с числом нейронов, равным числу искомых классов, с функцией активации Softmax.

Разработка и обучение модели производились на фреймворке Keras с TensorFlow v2 API [Tensorflow, 2022], установленных на ОС Ubuntu 20.04. Использовался графический ускоритель Nvidia RTX 2070. Для модели был использован оптимизатор Adam, функция ошибки – categorical cross-entropy, метрики оценки качества – precision и recall. Обучение проводилось несколько раз. Триггером остановки обучения было задано отсутствие уменьшения общей ошибки модели. Обучение с наилучшим результатом продлилось 32 эпохи.




Рис. 3. Архитектура нейронной сети  
Fig. 3. Architecture of the neural network

### Анализ результатов

Для тестирования классификатора использовался следующий алгоритм: тестовая выборка с помощью генератора случайных выборок пикселей с поля подавалась на модель 5 раз, после этого предсказания классов для каждой попытки складывались, а результатом предсказания являлся класс с наибольшей суммой предсказаний.

Модель показала высокую меру точности классификации F-мера 88,7 %, сравнимую, а по нескольким классам превосходящую, точность для схожих моделей других авторов [Viskovic, 2019; Shunping, 2018]. Наибольшая точность была достигнута для наиболее широко представленных классов: пшеницы, сои и подсолнечника. Показатели предыдущих моделей были значительно улучшены.

### Заключение

Новая модель нейронной сети также превзошла точность ранее разработанной модели с трехмерными сверточными слоями. Достигнута высокая точность классификации отдельных культур. Однако достигнутые результаты требуют чистоты данных, которая в настоящем исследовании достигнута в полуручном режиме. Следовательно, требуется разработка новых



подходов предварительной подготовки данных. В рамках данного исследования было проведено пилотное испытание разработанной технологии на примере одного крупного хозяйства с количеством полей в 2000 штук. В частности, было выявлено, что в 2020 году в хозяйстве было заявлено 94 поля под парами, но по факту 13 полей были полностью или частично засеяны сельскохозяйственными культурами.

Таблица 1  
Table 1

Метрики модели по результатам тестирования  
Model quality metrics test results

Класс	Precision	Recall	F-мера
Пшеница	97,4 %	97,4 %	97,4 %
Ячмень	81,3 %	89,7 %	85,2 %
Кукуруза	92,4 %	97,3 %	94,8 %
Подсолнечник	100 %	91,1 %	95,3 %
Соя	95 %	96 %	95,5 %
Сахарная свекла	83,3 %	71,4 %	76,9 %
Многолетние травы	66,7 %	80 %	72,7 %
Пар	90 %	93,8 %	91,8 %
СРЕДНЕЕ	88,3 %	89,6 %	88,7%

### Выводы

Для автоматизации процессов подготовки данных разрабатывается алгоритм разбиения полей на составные части с учетом типа используемости. Специфика формы границ и вариативная смена яркости и цвета пикселей не позволяет применить простые алгоритмы построения границ и требуется проработка подхода для автоматического разбиения. В результате работы с масками облачности было выявлено, что они плохо работают с дымкой, когда явных признаков облачности не видно, однако при визуальном просмотре наблюдается замутнение изображения. В настоящее время разрабатывается алгоритм анализа подобных случаев и корректировки данных. Также прорабатывается алгоритм предварительной оценки используемости полей с целью выявления земель в контурах полей, которые заброшены. Также планируется расширение списка распознаваемых культур по мере доступности новых данных для обучения нейронной сети.

### Список литературы

- Кононов В.М., Асадуллаев Р.Г., Кузьменко Н.И. 2020. Алгоритм подготовки мультиспектральных спутниковых данных для задачи классификации сельскохозяйственных культур. Научный результат. Информационные технологии. URL: [www.rininformation.ru/en/journal/download/2072](http://www.rininformation.ru/en/journal/download/2072) (дата обращения 20 января 2022).
- Кузьменко Н.И., Асадуллаев Р.Г. 2020. Нейронная сеть для классификации сельскохозяйственных культур по многоспектральным данным дистанционного зондирования земли. Сборник материалов VIII международной научно-технической конференции «Информационные технологии в науке, образовании и производстве», (Белгород, 24–25 сентября 2020 г.) Белгород: ИД «БелГУ» НИУ «БелГУ»: 352–357.
- Чурсин И.Н., Филиппов Д.В., Горохова И.Н., 2018. Распознавание сельскохозяйственных культур по мультиспектральным космическим снимкам высокого разрешения. Вестник компьютерных и информационных технологий. №11 (173).

- Brandt J., 2019. Spatio-temporal crop classification of low-resolution satellite imagery with capsule layers and distributed attention. URL: [arxiv.org/pdf/1904.10130v1.pdf](https://arxiv.org/pdf/1904.10130v1.pdf) (дата обращения 21 января 2022). Copernicus Open Access Hub. URL: [www.scihub.copernicus.eu/](http://www.scihub.copernicus.eu/) (дата обращения 20 января 2022). GDAL/OGR Python API. URL: [www.gdal.org/python/index.html](http://www.gdal.org/python/index.html) (дата обращения 1 февраля 2022).
- Kamilaris A., Prenafeta-Boldú F.X., 2018. Deep Learning in Agriculture: A survey. *Computers and Electronics in Agriculture*. URL: [www.arxiv.org/pdf/1807.11809](https://arxiv.org/pdf/1807.11809) (дата обращения 1 февраля 2022).
- Liakos K.G., Busato P., Moshou D., Pearson S., Bochits D., 2018. Machine Learning in Agriculture: A Review. *Sensors* (Special Issue "Sensors in Agriculture 2018"). URL: [www.mdpi.com/1424-8220/18/8/2674/pdf](http://www.mdpi.com/1424-8220/18/8/2674/pdf) (дата обращения 28 января 2022).
- Neetu and Ray S.S., 2019. Exploring machine learning classification algorithms for crop classification using Sentinel 2 data. *ISPRS – International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Vol. XLII-3/W6. URL: [www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-3-W6/573/2019/isprs-archives-XLII-3-W6-573-2019.pdf](http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-3-W6/573/2019/isprs-archives-XLII-3-W6-573-2019.pdf) (дата обращения 27 января 2022).
- Rasterio: access to geospatial raster data. URL: [rasterio.readthedocs.io/en/latest/](https://rasterio.readthedocs.io/en/latest/) (дата обращения 1 февраля 2022).
- Shunping J., Zhang C., Xu A., Shi Y., Duan Y., 2018. 3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images. *Remote Sensing*. URL: [www.mdpi.com/2072-4292/10/1/75/pdf](http://www.mdpi.com/2072-4292/10/1/75/pdf) (дата обращения 1 февраля 2022).
- Song X.-P., Huang W., Hansen M.C., Potapov P., 2021. An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping, *Science of Remote Sensing*, Vol. 3.
- Tensorflow Core API. URL: [www.tensorflow.org/api\\_docs/python/tf/](http://www.tensorflow.org/api_docs/python/tf/) (дата обращения 2 февраля 2022).
- The Copernicus Sentinel-2 mission. URL: [www.sentinel.copernicus.eu/web/sentinel/missions/sentinel-2/](http://www.sentinel.copernicus.eu/web/sentinel/missions/sentinel-2/) (дата обращения 2 февраля 2022).
- Viskovic L., Kosovic I. N., Mastelic T., 2019. Crop Classification using Multi-spectral and Multitemporal Satellite Imagery with Machine Learning. In the Proceedings of the International Conference on Software, Telecommunications and Computer Networks (SoftCOM): 1–5.

## References

- Kononov V.M., Asadullaev R.G., Kuzmenko N.I., 2020. Algorithm of multi-spectral satellite data preparation for agricultural crop classification. *Research Result. Information technologies*. Available at: [www.rrinformation.ru/en/journal/download/2072](http://www.rrinformation.ru/en/journal/download/2072) (accessed 20 January 2022). (in Russian)
- Kuzmenko N.I., Asadullaev R.G., 2020. Neural network for the crop classification on the multispectral Earth remote sensing data. In the Collection of works of the Information Technologies in Science, Education and Production (ITSEP-2020) Conference, pp: 352–357. (in Russian)
- Chursin I.N., Philippov D.V., Gorokhova I.N., 2018. Practice in the recognition of crops on multispectral high-resolution satellite imagery. *Herald of computer and information technologies*. №11 (173). (in Russian)
- Brandt J., 2019. Spatio-temporal crop classification of low-resolution satellite imagery with capsule layers and distributed attention. Available at: [arxiv.org/pdf/1904.10130v1.pdf](https://arxiv.org/pdf/1904.10130v1.pdf) (accessed 21 January 2022). Copernicus Open Access Hub. URL: [www.scihub.copernicus.eu/](http://www.scihub.copernicus.eu/) (accessed 20 January 2022). GDAL/OGR Python API. URL: [www.gdal.org/python/index.html](http://www.gdal.org/python/index.html) (accessed 1 February 2022).
- Kamilaris A., Prenafeta-Boldú F.X., 2018. Deep Learning in Agriculture: A survey. *Computers and Electronics in Agriculture*. Available at: [www.arxiv.org/pdf/1807.11809](https://arxiv.org/pdf/1807.11809) (accessed 1 February 2022).
- Liakos K.G., Busato P., Moshou D., Pearson S., Bochits D., 2018. Machine Learning in Agriculture: A Review. *Sensors* (Special Issue "Sensors in Agriculture 2018"). Available at: [www.mdpi.com/1424-8220/18/8/2674/pdf](http://www.mdpi.com/1424-8220/18/8/2674/pdf) (accessed 28 January 2022).
- Neetu and Ray S.S., 2019. Exploring machine learning classification algorithms for crop classification using Sentinel 2 data. *ISPRS – International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Vol. XLII-3/W6. Available at: [www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-3-W6/573/2019/isprs-archives-XLII-3-W6-573-2019.pdf](http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-3-W6/573/2019/isprs-archives-XLII-3-W6-573-2019.pdf) (accessed 27 January 2022).
- Rasterio: access to geospatial raster data. URL: [rasterio.readthedocs.io/en/latest/](https://rasterio.readthedocs.io/en/latest/) accessed 1 February 2022).
- Shunping J., Zhang C., Xu A., Shi Y., Duan Y., 2018. 3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images. *Remote Sensing*. Available at: [www.mdpi.com/2072-4292/10/1/75/pdf](http://www.mdpi.com/2072-4292/10/1/75/pdf) (accessed 1 February 2022).



- Song X.-P., Huang W., Hansen M.C., Potapov P., 2021. An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping, *Science of Remote Sensing*, Vol. 3.
- Tensorflow Core API. Available at: [www.tensorflow.org/api\\_docs/python/tf/](http://www.tensorflow.org/api_docs/python/tf/) (accessed 2 February 2022).
- The Copernicus Sentinel-2 mission. Available at: [www.sentinel.copernicus.eu/web/sentinel/missions/sentinel-2/](http://www.sentinel.copernicus.eu/web/sentinel/missions/sentinel-2/) (accessed 2 February 2022).
- Viskovic L., Kosovic I.N., Mastelic T., 2019. Crop Classification using Multi-spectral and Multitemporal Satellite Imagery with Machine Learning. In the Proceedings of the International Conference on Software, Telecommunications and Computer Networks (SoftCOM): 1-5.

**Конфликт интересов:** о потенциальном конфликте интересов не сообщалось.

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

## ИНФОРМАЦИЯ ОБ АВТОРАХ

## INFORMATION ABOUT THE AUTHORS

**Асадуллаев Рустам Геннадьевич**, кандидат технических наук, доцент кафедры прикладной информатики и информационных технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

**Rustam R. Asadullaev**, Candidate of Technical Sciences, Associate Professor of the Department of Applied Informatics and Information Technologies, Belgorod National Research University, Belgorod, Russia

**Кузьменко Николай Иванович**, магистрант 2 года обучения кафедры прикладной информатики и информационных технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

**Nikolay I. Kuzmenko**, 2-year undergraduate student of the Department of Applied Informatics and Information Technologies, Belgorod National Research University, Belgorod, Russia