



<http://dx.doi.org/10.35596/1729-7648-2024-30-1-63-70>

*Оригинальная статья*  
*Original paper*

УДК 004.89

## МОДЕЛЬ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОБРАБОТКИ АЭРОКОСМИЧЕСКИХ ИЗОБРАЖЕНИЙ ЗЕМНОЙ ПОВЕРХНОСТИ

Т. Ф. СТАРОВОЙТОВА<sup>1</sup>, И. А. СТАРОВОЙТОВ<sup>2</sup>

<sup>1</sup>Академия управления при Президенте Республики Беларусь (г. Минск, Республика Беларусь)

<sup>2</sup>РУП «Проектный институт Белгипрозем» (г. Минск, Республика Беларусь)

Поступила в редакцию 14.11.2023

© Белорусский государственный университет информатики и радиоэлектроники, 2024  
Belarusian State University of Informatics and Radioelectronics, 2024

**Аннотация.** Представлены особенности получения и обработки аэрокосмических изображений земной поверхности в контексте цифровизации для создания точных топографических карт и планов в цифровом и графическом форматах. Создана модель обработки данных на основе языка программирования Python и нейронных сетей, целью которой является улучшение распознавания объектов на аэрокосмических снимках. Методология разработки модели машинного обучения включает в себя определение целей и задач модели, выбор подходящего алгоритма обучения (в данном случае – нейронных сетей), сбор и подготовку набора данных, настройку модели и тестирование на тестовом наборе данных. Рассмотрены недостатки существующих алгоритмов обработки данных, представлен подход, позволяющий повысить эффективность распознавания и анализа данных.

**Ключевые слова:** аэрокосмические изображения, машинное обучение, нейронные сети, обработка данных, распознавание объектов, Python, Tensorflow.

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

**Для цитирования.** Старовойтова, Т. Ф. Модель машинного обучения для обработки аэрокосмических изображений земной поверхности / Т. Ф. Старовойтова, И. А. Старовойтов // Цифровая трансформация. 2024. Т. 30, № 1. С. 63–70. <http://dx.doi.org/10.35596/1729-7648-2024-30-1-63-70>.

## MACHINE LEARNING MODEL FOR PROCESSING AEROSPACE IMAGES OF THE EARTH'S SURFACE

TATIANA F. STAROVOITOVA<sup>1</sup>, ILIA A. STAROVOITOV<sup>2</sup>

<sup>1</sup>Academy of Public Administration under the President of the Republic of Belarus (Minsk, Republic of Belarus)

<sup>2</sup>Republican Design Institute for Land Management "Belgiprozem" (Minsk, Republic of Belarus)

Submitted 14.11.2023

**Abstract.** The article presents the specifics of acquisition and processing aerospace images of the earth's surface in the context of their digitalization for creating accurate topographic maps and plans in digital and graphic formats. A data processing model has been developed based on the Python programming language and neural networks, the purpose of which is to improve the recognition of objects in aerospace images. The methodology for creating a machine learning model includes defining the goals and objectives of the model, selecting an appropriate learning algorithm (in this case, neural networks), collecting and preparing a data set, tuning the model, and testing on a test data set. The shortcomings of existing data processing algorithms are also discussed and an approach is presented to improve the efficiency of data processing and analysis.

**Keywords:** aerospace images, machine learning, neural networks, data processing, object recognition, Python, Tensorflow.

**Conflict of interests.** The authors declare no conflict of interests.

**For citation.** Starovoitova T. F., Starovoitov I. A. (2024) Machine Learning Model for Processing Aerospace Images of the Earth's Surface. *Digital Transformation*. 30 (1), 63–70. <http://dx.doi.org/10.35596/1729-7648-2024-30-1-63-70> (in Russian).

## Введение

Важность применения методов машинного обучения обусловлена не только огромным объемом собираемых, обрабатываемых и хранимых данных, но и тем, что технологии искусственного интеллекта являются одним из основных современных инструментов цифровой трансформации. Компании и государственные организации активно собирают и аккумулируют обширные массивы информации о своих продуктах, услугах, клиентах, сотрудниках и других аспектах деятельности. Одной из ключевых особенностей Machine Learning является способность этих систем обучения анализировать собранные данные и извлекать ценную информацию, что позволяет не только прогнозировать тенденции, оптимизировать инвестиции и улучшать стратегическое планирование, но и вносить принципиальные изменения в общую структуру экономической системы как компании, так и национальной экономики в целом.

В современном мире аэрокосмические изображения земной поверхности стали неотъемлемой частью множества сфер деятельности, начиная от картографии и заканчивая экологическим мониторингом и гражданским инжинирингом. Эволюция информационных технологий привела к взрывному росту объемов данных, получаемых с использованием аэрокосмических изображений земной поверхности. Эти изображения не только стали неотъемлемой частью многих отраслей, но и являются источником ценных информационных ресурсов для научных исследований и коммерческих проектов.

Начиная от мониторинга климата и окружающей среды, заканчивая планированием городской инфраструктуры и агрокультур, аэрокосмические изображения дают уникальную возможность получить обширное представление о нашей планете. Однако объем данных, получаемых с использованием таких изображений, стал столь огромным, что обработка и анализ этой информации оказались сложной задачей для человека. В связи с этим применение моделей машинного обучения для обработки земной поверхности имеет большое значение.

Модели машинного обучения позволяют автоматизировать процесс обработки изображений, увеличивая скорость анализа, повышая точность распознавания объектов и снижая трудозатраты. Использование их при обработке аэрокосмических изображений земной поверхности открывает новые перспективы для автоматизации этого процесса [1].

## Методика проведения эксперимента

Цифровая трансформация как проявление качественных революционных изменений, заключающихся не только в отдельных цифровых преобразованиях, но и в принципиальном изменении структуры экономики, предполагает использование новых методов и технологий во всех сферах жизнедеятельности. Сегодня в мире применяются различные способы для получения топографических карт. Основным является фотограмметрический метод. Он основан на использовании фотограмметрических приборов для получения изображения местности. Полученные изображения обрабатываются с помощью фотограмметрических программ, в результате чего формируется цифровая модель местности (ЦММ). ЦММ может быть использована для создания топографических карт и планов.

Другим широко известным методом получения топографических карт является аэрофото съемка. В последнее время все большее распространение получают космические методы создания топографических карт. Космические снимки местности могут быть получены с помощью спутников дистанционного зондирования Земли. Обрабатываются они посредством специальных программ, в результате чего формируется ЦММ. ЦММ – трехмерное цифровое представление поверхности земли, которое включает в себя высотные данные. Она отличается от топографических карт и планов тем, что более детально описывает рельеф, включая высотные характеристики, что позволяет точнее моделировать местность [2].

Каждый из перечисленных методов имеет свои преимущества и недостатки. Фотограмметрический позволяет получать карты с высокой детализацией, но требует использования дорогостоящего оборудования. С помощью аэрофотосъемки можно получать карты с высокой скоростью, но она ограничена погодными условиями. Космические методы позволяют получать карты с большой площадью охвата, но имеют низкую детализацию.

В настоящее время активно развиваются новые методы получения топографических карт, основанные на использовании лазерных сканеров и других технологий. Эти методы позволяют создавать карты с высокой детализацией и точностью. Одной из таких технологий является применение моделей машинного обучения с целью улучшения процесса распознавания объектов на снимках, получаемых из различных источников.

Важный тренд – использование дистанционного зондирования с применением лазерных сканеров LiDAR (Light Detection and Ranging). LiDAR позволяет создавать высоко детализированные трехмерные модели местности, измеряя расстояния до объектов на земной поверхности с помощью лазерных импульсов. Это идеальный инструмент для создания точных цифровых моделей рельефа, что особенно полезно для инженерных и геологических приложений. Еще одной инновацией является использование методов машинного обучения и искусственного интеллекта в обработке и анализе данных. Эти методы позволяют автоматизировать процессы классификации и распознавания объектов на аэроснимках и космических изображениях, увеличивая скорость и точность картографических работ. Также технологии дронов становятся популярными в создании топографических карт. Беспилотные летательные аппараты могут выполнять аэрофотосъемку и LiDAR-сканирование с низкой стоимостью и возможностью летать в различных условиях. Выбор метода зависит от конкретных задач, доступных ресурсов и требований к точности и детализации данных. В некоторых случаях комбинированный подход, включая использование нескольких методов, может быть наиболее эффективным способом получения полной и точной топографической информации [3].

Сегодня одним из самых перспективных языков программирования для написания высокоуровневого кода моделей машинного обучения для фрагментации и дешифровки аэрокосмических изображений земной поверхности является Python. Наиболее популярная библиотека машинного обучения для Python – Tensorflow, которая предоставляет удобные инструменты для реализации алгоритмов машинного обучения, включая как обучение на учителе, так и обучение без учителя. Данная библиотека поддерживает глубокое обучение и является одним из самых популярных решений для реализации нейронных сетей.

Под моделью машинного обучения будем понимать программный алгоритм, который «обучен» распознаванию определенных типов закономерностей. Предполагается обучение модели на основе набора данных, предоставляя ей возможность найти закономерности, которые она сможет использовать для анализа, обучения и прогнозирования. Завершив обучение модели, можно будет применить ее для принятия решений и выполнения прогнозов по данным, ранее не встречавшимся.

Разработка модели машинного обучения с использованием языка программирования Python версии 3.10 проводилась на базе РУП «Проектный институт Белгипрозем». Версия 3.10 использовалась с целью улучшения процесса распознавания объектов на изображениях. Входящими данными являлись снимки, получаемые с источников космических систем дистанционного зондирования Земли. При разработке модели для улучшения процесса распознавания объектов на изображениях выполнялись следующие этапы.

1. Определялось, для каких целей будет использоваться модель и какие задачи она должна решать. В данном случае цель – улучшение точности распознавания объектов на изображениях, для расчета которой применяется итеративный подход проверки работы модели. Для решения этой задачи модель должна научиться различать разные объекты, представленные на изображениях.

2. Выбирался алгоритм обучения, который будет применяться для обучения модели. В данном случае можно использовать различные типы моделей машинного обучения, включая:

- линейную регрессию;
- классификаторы на основе деревьев принятия решений;
- метод опорных векторов;
- нейронные сети.

3. Выбирался алгоритм обучения, зависящий от конкретных задач, которые должна решать модель. В данном случае для повышения точности распознавания объектов на изображениях можно использовать нейронную сеть.

4. Осуществлялись сбор и подготовка набора данных, на котором будет обучаться модель. Набор данных должен содержать изображения распознаваемых объектов. Изображения должны быть представлены в формате, который может быть обработан выбранным алгоритмом обучения. В данном случае набор данных может быть собран из различных источников, включая:

- сайты, посвященные распознаванию объектов;
- общедоступные наборы данных;
- собственные изображения.

Перед обучением модели набор данных необходимо подготовить, чтобы он соответствовал требованиям выбранного алгоритма обучения. Рекомендуется выполнить следующие действия:

- нормализацию данных;
- удаление шумов;
- добавление изображений, отсутствующих в наборе данных.

Необходимость этих действий не диктуется алгоритмом обучения, однако их выполнение позволит улучшить итоговый результат, который будет выдавать модель машинного обучения.

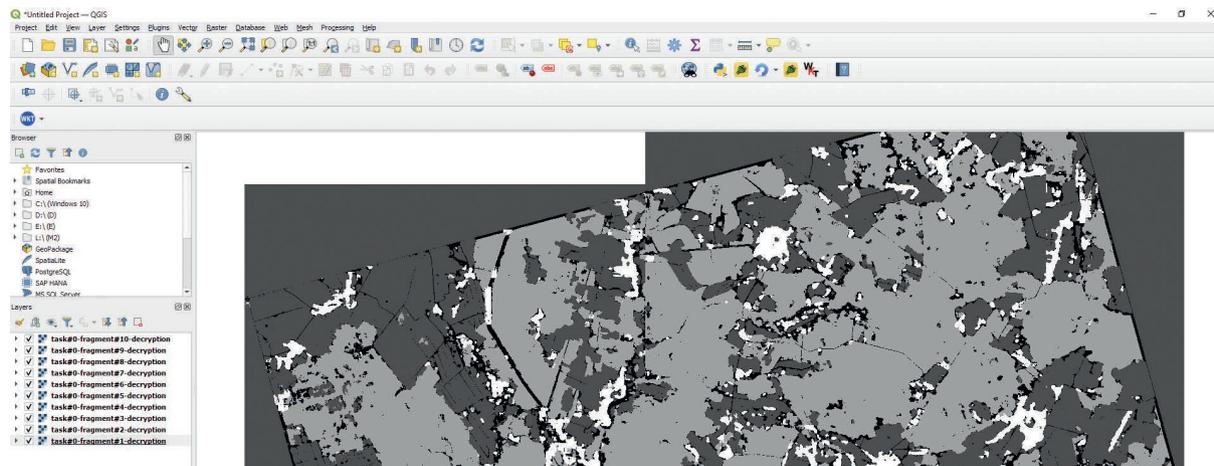
5. Проводилась настройка модели для достижения наилучших результатов. Настройка модели может включать в себя следующие действия:

- выбор параметров алгоритма обучения;
- подбор архитектуры нейронной сети;
- настройка гиперпараметров.

Настройка модели может выполняться вручную или с помощью автоматической оптимизации.

6. Тестировалась модель на тестовом наборе данных, чтобы оценить ее точность. Тестовый набор данных должен содержать изображения, которые не использовались для обучения модели.

Просмотр результатов работы модели проводился в среде геоинформационной системы QGIS, пример использования которой представлен на рис. 1.

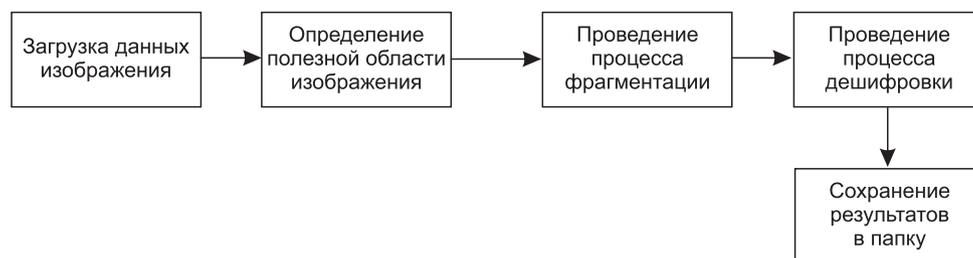


**Рис. 1.** Интерфейс приложения QGIS для просмотра результатов, полученных в результате работы модели машинного обучения (*собственная разработка авторов*)

**Fig. 1.** QGIS application interface for viewing results obtained from a machine learning model (*authors' own development*)

Если точность модели на тестовом наборе данных не удовлетворяет требованиям, необходимо повторить этапы проектирования модели или изменить набор данных. Процесс работы алгоритма представлен на рис. 2.

Существующие алгоритмы обработки данных содержат такие недостатки, как отсутствие гарантий надежности выполнения, низкая скорость обработки, отсутствие асинхронного метода дешифрирования. Эти недостатки были учтены в процессе разработки, что позволило увеличить эффективность обработки и анализа данных.



**Рис. 2.** Процесс обработки изображений, загружаемых в модель машинного обучения (*собственная разработка авторов*)  
**Fig. 2.** The process of processing images fed into a machine learning model (*authors' own development*)

Для запуска работы модели машинного обучения необходимо открыть консольное окно операционной системы Windows, указав входные параметры, такие как:

- путь к файлу в файловой системе Windows в формате TXT, содержащий в себе набор путей к исходным файлам, используемым для проведения процесса дешифровки;
- путь к выходной папке в файловой системе Windows для сохранения результатов процесса дешифрования;
- тип файлов, сохраняемых в выходной папке.

Процесс дешифрования представляет собой последовательную обработку элементов набора данных, цель которого – выявление целевых объектов на загружаемых изображениях. В первую очередь необходимо создать функцию, ставящую задачу на выполнение, содержащую набор файлов для обработки и возвращающую ее контур, список геометрий и информацию о файлах. Далее следует разработать функцию фрагментации задания на уменьшенные элементы, что позволит оптимизировать процесс обработки и уменьшить итоговую сложность и загруженность модели машинного обучения. Результатом работы данной функции будет являться список, содержащий информацию о каждом фрагменте, включая границы полезного фрагмента, границы выходного фрагмента и исходные файлы. После получения списка необходимо провести итерацию по каждому элементу для загрузки его в функцию получения результатов дешифрования. В дальнейшем все полученные результаты перестраиваются в соответствии с параметрами задачи и сохраняются в указанную пользователем директорию в операционной системе.

Перед запуском процесса дешифрования следует указать параметры, необходимые для корректной работы обработчика изображений. После указания нужных параметров и запуска процесса открывается консольное окно с отображением полосы прогресса выполнения процедуры. При завершении задачи дешифрования в выходной папке появляются файлы, являющиеся результатом работы кода по фрагментации и дешифрованию файлов, указанных в исходном наборе. Использование консольного окна для запуска работы модели машинного обучения на операционной системе Windows является удобным и эффективным способом управления процессом дешифровки, предоставляя возможность ручного управления задаваемыми параметрами.

Отсутствие интерфейса повышает необходимый порог знаний, предъявляемый инженеру для работы с моделью машинного обучения, однако позволяет упростить процесс написания исходного кода решения, избегая накладных расходов при проектировании и конструировании проекта. Процесс дешифрования, представляемый в виде совокупности методов фрагментации и обработки данных моделью машинного обучения, может выдавать некорректный результат, связанный с неверным распознаванием входящих изображений. Это может быть вызвано различными причинами, включая:

- некачественные изображения, которые могут содержать шумы, искажения или другие дефекты, затрудняющие их распознавание моделью машинного обучения;
- недостаточный набор данных. Модель машинного обучения обучается на наборе данных изображений, содержащих примеры различных объектов, которые она должна распознавать. Если набор данных недостаточно большой или не отражает разнообразие объектов, которые могут быть представлены на изображениях, модель может давать некорректные результаты;
- некорректно подобранная модель машинного обучения. Для дешифрования изображений могут использоваться различные модели машинного обучения, каждая из которых имеет свои преимущества и недостатки. Если модель машинного обучения некорректно подобрана для конкретных задач, она может давать некорректные результаты;

– некорректные параметры модели машинного обучения. Параметры модели машинного обучения могут быть отрегулированы для повышения ее точности. Однако, если параметры некорректны, это может привести к некорректным результатам.

Чтобы уменьшить вероятность получения некорректного результата дешифрирования, необходимо учитывать следующие факторы:

- использовать качественные изображения, которые должны быть четкими, хорошо освещенными и не содержать шумов или других дефектов;
- собрать достаточно большой и разнообразный набор данных, содержащий примеры различных объектов, которые могут быть представлены на изображениях;
- правильно подобрать модель машинного обучения, которая должна быть подходящей для конкретных задач;
- тщательно настроить параметры модели машинного обучения, отрегулированные для повышения ее точности.

При соблюдении этих факторов можно снизить вероятность получения некорректного результата дешифрирования.

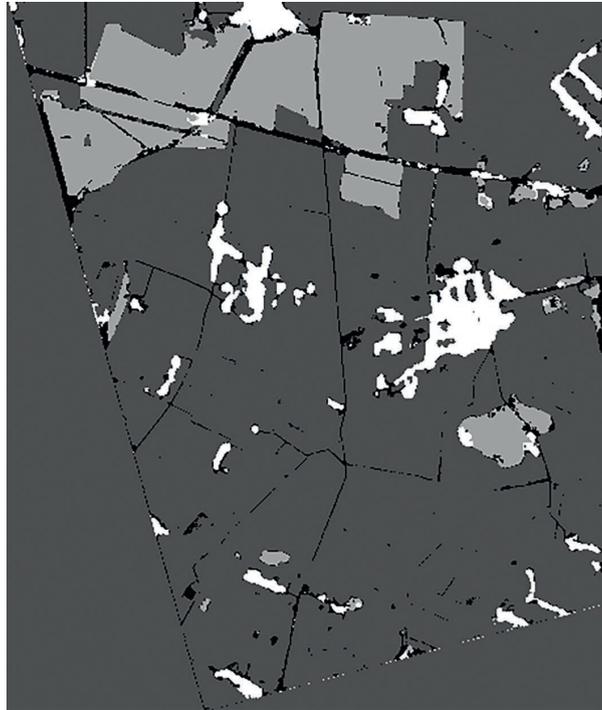
Для выполнения процесса фрагментации необходимо инициализировать набор параметров, используемый в дальнейшем для определения границ изображения, формата наложения создаваемых фрагментов, количества и расположения приоритетных областей и т. д. После задания всех необходимых параметров нужно получить информацию о расположении основного файла изображения в формате tif для дальнейшего извлечения информации о преобразовании снимка, а также параметров разрешения изображения и его положения в пространстве. Далее следует провести итеративный переход по каждому изображению с целью расчета границ и площади создаваемого фрагмента, после чего провести внутреннюю итерацию по рядам, начиная с верхней границы изображения с шагом, установленным ранее. В результате проведенной итерации на текущем шаге формируется четырехугольник, который в дальнейшем необходимо разделить на некоторое количество фрагментов. Для этого на основе данной фигуры создается полигон с проверкой на наличие ошибок, после чего происходит процесс итерации по оси абсцисс для получения итоговых фрагментов. При этом к фрагменту осуществляется добавление области перекрытия, существующей для обеспечения полноценного захвата частей изображения несколькими фрагментами, что обеспечивает лучший результат при обучении модели. Далее происходит формирование полигона на основе полученных координат объекта сетки, который сохраняется в указанное место на машине пользователя. Сам полигон дополнительно проходит проверку на наличие пересечения с приоритетной областью, и, в случае нахождения указанного совпадения, добавляется в список координат первым. Функция после выполнения возвращает список координат сохраненных объектов для их дальнейшего использования в процессе формирования набора данных.

В результате обработки и проведения процесса дешифрирования с применением моделей машинного обучения был получен набор файлов, представляющий собой совокупность слоев на изображении. Вид обработанного космического изображения и изображения аэрофотосъемки, открытых в приложении QGIS, показан на рис. 3 и 4 соответственно.

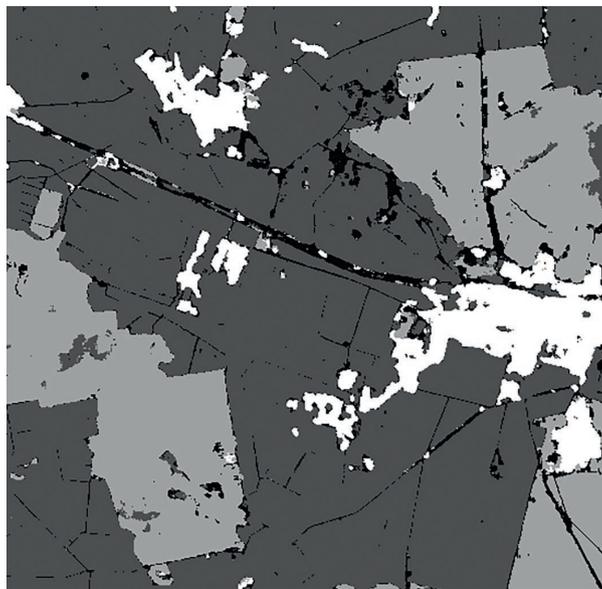
Результатом работы предлагаемой модели машинного обучения является изображение, представляющее собой обработанный снимок соответствующего типа съемки с выделенными на нем серыми секторами. Это позволяет в дальнейшем корректно идентифицировать соответствующие зоны на снимке и использовать данную информацию как для улучшения отклика рассматриваемых моделей, так и для автоматизации процесса разделения карты на необходимые участки. Полученные результаты находят применение в практической деятельности предприятий Республики Беларусь в области землеустройства.

## Заключение

1. Машинное обучение может использоваться для выявления потребностей клиентов и разработки новых продуктов и услуг, которые удовлетворяют эти потребности; для персонализации обслуживания и предоставления более качественного обслуживания; для автоматизации задач, оптимизации процессов и выявления возможностей для сокращения затрат. Разработка проектов, основанных на моделях машинного обучения, позволит создавать более точные карты, эффективно контролировать состояние окружающей среды, прогнозировать природные изменения, обеспечивать безопасность общества и проч.



**Рис. 3.** Обработанное космическое изображение  
**Fig. 3.** Processed space image



**Рис. 4.** Обработанное изображение аэрофотосъемки  
**Fig. 4.** Processed aerial image

2. Разработанная модель машинного обучения для обработки аэрокосмических изображений земной поверхности отличается наличием инструментов создания задач и их асинхронного выполнения, позволяет задавать параметры для проведения процесса дешифровки как с начального элемента загружаемого датасета, так и с установленной контрольной точки, задаваемой разработчиком при запуске процесса. Модель имеет усовершенствованный алгоритм фрагментации загружаемых изображений для улучшения скорости и точности процесса обучения, использует в реализации алгоритмов обучения современные инструменты библиотеки Tensorflow языка Python, имеет усовершенствованную архитектуру файлов, позволяющую интегрировать основной фрагмент кода модели машинного обучения в различные геоинформационные системы для визуализации получаемых результатов.

3. Использование модели машинного обучения при обработке результатов кадастровых работ посредством нейронных сетей распознавания объектов на местности позволит, по сравнению с аналогами, основанными на иных методах обучения, повысить точность и скорость автоматизации процессов определения и классификации зданий, сооружений и иных элементов, расположенных на картах. Модель обладает возможностью последовательной фрагментации, дешифрирования аэрокосмических изображений и распознавания на них объектов определенных классов. Нейронные сети, используемые в модели, обеспечивают повышенную производительность в распознавании паттернов и обработке сложных данных, в том числе в классификации изображений.

### Список литературы

1. Коэльо, Л. П. Построение систем машинного обучения на языке Python / Л. П. Коэльо, В. Ричарт, пер. с англ. М.: ДМК Пресс, 2016.
2. How Does Lidar Work? [Электронный ресурс]. Режим доступа: [velodynelidar.com/what-is-lidar/](http://velodynelidar.com/what-is-lidar/). Дата доступа: 20.09.2023.
3. Обзор самых популярных алгоритмов машинного обучения [Электронный ресурс]. Режим доступа: <https://tproger.ru/translations/top-machine-learning-algorithms>. Дата доступа: 20.09.2023.

### References

1. Coelho L. P., Richart V. (2016) *Building Machine Learning Systems in Python*. Moscow, DMK Press Publ.
2. *How Does Lidar Work?* Available: [velodynelidar.com/what-is-lidar/](http://velodynelidar.com/what-is-lidar/) (Accessed 20 September 2023).
3. *Review of the Most Popular Machine Learning Algorithms*. Available: <https://tproger.ru/translations/top-machine-learning-algorithms> (Accessed 20 September 2023).

### Вклад авторов / Authors' contribution

Авторы внесли равный вклад в написание статьи / The authors contributed equally to the writing of the article.

#### Сведения об авторах

**Старовойтова Т. Ф.**, канд. экон. наук, доц., доц. Академии управления при Президенте Республики Беларусь

**Старовойтов И. А.**, техник отдела геоинформационных систем, РУП «Проектный институт Белгипрозем»

#### Адрес для корреспонденции

220019, Республика Беларусь,  
г. Минск, ул. Скрипникова, 35–92  
Тел.: +375 29 757-59-11  
E-mail: [tan.star00@gmail.com](mailto:tan.star00@gmail.com)  
Старовойтова Татьяна Феликсовна

#### Information about the authors

**Starovoitova T. F.**, Cand. of Sci., Associate Professor, Associate Professor at the Academy of Public Administration under the President of the Republic of Belarus

**Starovoitov I. A.**, Technician at the Geographic Information Systems Department, Republican Design Institute for Land Management “Belgiprozem”

#### Address for correspondence

220019, Republic of Belarus,  
Minsk, Skripnikova St., 35–92  
Tel.: +375 29 757-59-11  
E-mail: [tan.star00@gmail.com](mailto:tan.star00@gmail.com)  
Starovoitova Tatiana Feliksovna