

НЕЙРОСЕТЕВАЯ МОДЕЛЬ КЛАССИФИКАЦИИ ЛЕСНОГО МАССИВА ПО ДАННЫМ СПУТНИКОВЫХ СНИМКОВ

NEURAL NETWORK MODEL OF FOREST CLASSIFICATION BASED ON SATELLITE IMAGERY DATA

*I. Evdokimova
I. Tulokhonova
G. Galdanov*

Summary. The article examines neural network models for classifying forests based on satellite images. Various neural network architectures, including convolutional, segmenting and residual networks, are considered, and the most appropriate ResNet-34 architecture is selected. Algorithms for cutting and assembling satellite images have been developed. The neural network model of forest classification was developed using the TensorFlow framework and the error back propagation method. The model was trained on a training sample using NVIDIA RTX 2060 Super GPUs.

Keywords: classification, forest, satellite images, loss function, neural network, model, Jacquard coefficient, markup, image slicing algorithm, result evaluation.

Евдокимова Инга Сергеевна

Доцент, к.т.н., ФГБОУ ВО «Восточно-Сибирский государственный университет технологий и управления»
evdinga@gmail.com

Тулохонова Инна Степановна

Доцент, к.п.н., ФГБОУ ВО «Восточно-Сибирский государственный университет технологий и управления»
istulokhonova@mail.ru

Галданов Гэсэр Жамбалович

ФГБОУ ВО «Восточно-Сибирский государственный университет технологий и управления»
geser.galdanov@mail.ru

Аннотация. В статье исследованы нейросетевые модели для классификации лесных массивов на основе спутниковых снимков. Рассмотрены различные архитектуры нейросетей, включая, сверточные, сегментирующие и остаточные сети, и выбрана наиболее подходящая архитектура ResNet-34. Разработаны алгоритмы нарезки и сборки спутниковых снимков. Нейросетевая модель классификации лесных массивов разработана с использованием фреймворка TensorFlow и метода обратного распространения ошибки. Обучение модели проводилось на обучающей выборке с использованием графических процессоров NVIDIA RTX 2060 Super.

Ключевые слова: классификация, лесной массив, спутниковые снимки, функция потерь, нейронная сеть, модель, коэффициент Жаккара, разметка, алгоритм нарезки изображения, оценка результата.

Введение

Лесные массивы играют важную роль в экосистеме планеты, предоставляя не только природные ресурсы, но и выполняя ключевые функции, такие как удержание углерода, поддержание биоразнообразия и защита почвы от эрозии. Поэтому разработка автоматизированных инструментов для классификации и мониторинга лесных участков на основе спутниковых снимков становится все более актуальной.

С появлением современных методов машинного обучения и глубокого обучения, нейросетевые модели стали мощным инструментом для решения сложных задач классификации и сегментации изображений. Нейросетевые модели обладают способностью автоматически извлекать сложные закономерности из спутниковых снимков и выявлять характеристики, связанные с классами лесного покрова. Сверточные нейронные сети (CNN) широко применяются в области компьютерного зрения и обработки изображений, и они демонстрируют высокую эффективность при классификации лесного массива на основе спутниковых снимков [1].

В свою очередь, точная классификация лесного массива на основе спутниковых снимков позволяет оценить динамику изменений лесного покрова, выявить проблемы в экосистеме, например, связанные с вырубкой леса или лесными пожарами, а также способствует разработке более эффективных мер по сохранению и управлению лесными ресурсами.

Таким образом, разработка нейросетевых моделей для классификации лесного массива на основе спутниковых снимков является актуальной и важной задачей, предоставляющей новые возможности для анализа лесного покрова и принятия обоснованных решений в области лесного хозяйства, экологии и других смежных областей.

Проблема распознавания лесного массива

Распознавание лесного массива может включать в себя несколько сложностей, связанных с обработкой изображений, анализом данных и особенностями окружающей среды. Приведем несколько потенциальных аспектов, которые могут представлять сложности:

- плотность и разнообразие растительности могут усложнить процесс распознавания, особенно если объекты перекрывают друг друга на изображении [4];
- зависимость от времени суток, погодных условий и сезонов может привести к изменениям в освещении и созданию теней, что затрудняет анализ изображений и выделение лесных областей;
- географические и климатические особенности приводят к тому, что алгоритмы распознавания могут потребовать адаптации к различным условиям;
- сезонные изменения: лес изменяет внешний вид в зависимости от времени года.

Предлагаемое решение — инновационная модель нейронной сети, разработанная для выполнения анализа изображений в ускоренном режиме.

Распознавание лесного массива с использованием нейросетевых моделей является сложным и многокомпонентным процессом, который включает в себя получение и обработку спутниковых изображений, создание и обучение нейросетевой модели, а также классификацию новых изображений. Этот подход позволяет достичь точности и эффективности в классификации лесных участков и имеет большой потенциал для применения в области геоинформатики, экологии и лесопользования.

Процесс работы модели основывается на глубоком обучении и высокоскоростных вычислениях, позволяющих модели быстро и точно анализировать сложные изображения и автоматически извлекать ключевые признаки из входного изображения, применять обученные алгоритмы классификации и распознавания для вывода подробных результатов анализа.

Описание модели нейронной сети и набора данных

В качестве действующей модели нейронной сети была выбрана остаточная нейронная сеть ResNet-34, которая представляет собой глубокую нейронную сеть, состоящую из общего числа 34 слоев, основной целью которой является повышение точности классификации изображений [1].

Основная структура ResNet-34 включает в себя следующие элементы:

Входной слой принимает входное изображение размером, соответствующим требованиям задачи. Обычно это RGB-изображение размером 224x224 пикселей.

Сверточные слои ResNet-34 выполняют операции свертки и пулинга для извлечения признаков из вход-

ного изображения, позволяя обнаруживать пространственные шаблоны, такие как границы, углы и текстуры.

Остаточные блоки нейросети состоят из нескольких сверточных слоев, где каждый блок имеет два ветвления: прямое соединение и сверточное соединение. Прямое соединение передает непосредственно выход предыдущего слоя в следующий блок, обеспечивая обмен информацией и устранение проблемы затухания градиентов. Сверточное соединение выполняет операции свертки для обработки признаков внутри блока [5].

После нескольких остаточных блоков следуют слои с понижением размерности, такие как, среднее пулинг или слой субдискретизации, которые уменьшают размерность карт признаков и сжимают информацию.

Полносвязные слои ResNet-34 принимают признаки после понижения размерности и выполняют классификацию на основе задачи, при этом последний полносвязный слой имеет количество выходных нейронов, соответствующее количеству классов для классификации.

Структура ResNet-34 является глубокой и сложной, позволяет извлекать и учиться представлять более абстрактные признаки изображений, что, несомненно, связано с достижением высокой точности классификации и хорошей обобщающей способности модели при анализе лесных массивов на основе спутниковых снимков (рис. 1).

Для подготовки наборов данных был проведен обзор источников спутниковых данных: Google Earth Engine, USGS Earth Explorer, Sentinel.

Google Earth Engine предлагает широкий спектр спутниковых данных, включая снимки различных спутников, таких как Landsat, Sentinel и MODIS. Эти данные охватывают большие территории и имеют различные временные разрешения, что позволяет анализировать изменения в лесном покрове на разных пространственных и временных масштабах.

USGS Earth Explorer является одним из ключевых источников геопространственных данных для исследования и анализа земной поверхности. Эти снимки могут быть использованы для анализа изменений в лесном покрове, оценки биологического разнообразия, мониторинга климатических изменений и других геоинформационных задач [2].

Использование USGS Earth Explorer в разработке нейросетевых моделей классификации лесного массива позволяет получить высококачественные спутниковые данные и интегрировать их в процесс обучения модели. Это способствует более точной классификации лесных

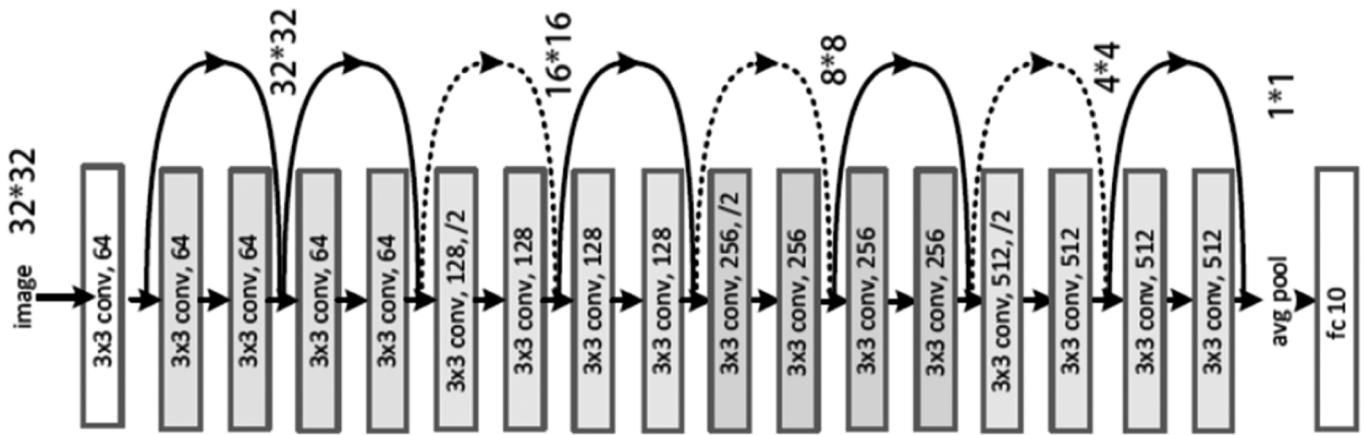


Рис. 1. Структура Resnet-34

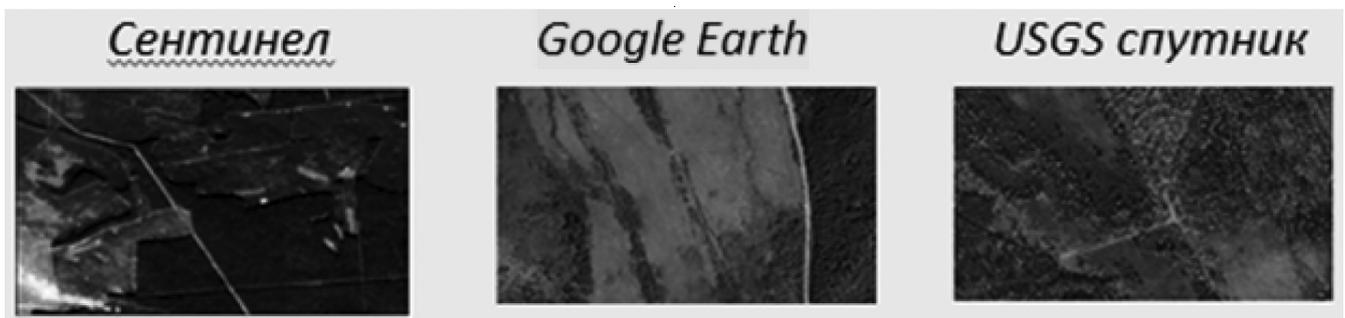


Рис. 2. Примеры спутниковых снимков

участков, а также обеспечивает актуальность и достоверность информации для мониторинга и управления лесными ресурсами.

Sentinel-2 является важным источником спутниковых данных для многих геопространственных приложений, включая анализ лесного покрова. Эта миссия спутниковой системы Copernicus предоставляет бесплатный доступ к высококачественным мультиспектральным изображениям, которые могут быть использованы для различных целей, включая классификацию лесного массива [2]. Данные от Sentinel-2 доступны через открытую платформу Copernicus Open Access Hub, что облегчает доступ и использование этих данных исследователями и специалистами в области геоинформатики (рис. 2) [3].

Модель и алгоритмы классификации лесного массива

Модель классификации лесного массива по спутниковым снимкам можно описать следующим образом:

$$KlassFor = \{NR, KIRez, Input, Activ, Output, CutImg, AssImg\}, \quad (1)$$

где *KlassFor* — множество данных и функций, применяемых для решения задачи классификации лесного массива.

NR — обученная нейронная сеть, способная распознавать на изображении классы из массива *KIRez*.

KIRez является результатом нейронной сети и показывает к какому классу относится локализованный на изображении фрагмент (2):

$$KIRez = [1: Береза, 2: Ель, 3: Лес, 4: не классифицированно] \quad (2)$$

В процессе распознавания и классификации каждому классу будет соответствовать своя цветовая разметка:

- Класс 1: Береза, цвет — зеленый;
- Класс 2: Ель, цвет — оранжевый;
- Класс 3: Лес, цвет — светло-синий;
- Класс 4: Нет классификации, цвет — белый.

Параметр *Input* включает входной снимок *X* и множество фрагментов исходного снимка *X*:

$$Input = \langle X, \{x_i, k_i\}; i = 1, n \rangle, \quad (3)$$

где *x_i* — фрагмент входного изображения размером 128x128 пикселей, полученный путем нарезки входного снимка на фрагменты; *k_i* — фрагмент маски изображения размером 128x128 пикселей; *n* — количество нарезанных фрагментов.

Функция *Activ* представляет собой алгоритм оптимизации ReLU (Rectified Linear Unit), который применяется для обучения моделей классификации, регрессии и других задач машинного обучения.

Алгоритм оптимизации ReLU использует функцию активации с нелинейным поведением, которая основана на принципе положительного значения. При этом все отрицательные значения заменяются на ноль, а положительные значения остаются без изменений. Формально, функция активации ReLU выражается следующим образом (4):

$$f(x) = \max(0, z), \quad (4)$$

где z — входной сигнал или взвешенная сумма входов модели перед применением функции активации.

Алгоритм классификации лесного массива по спутниковым снимкам включает следующие этапы (рис. 3):

- подготовка спутниковых снимков для анализа;
- обучение нейронной сети;
- применение нейронной сети для распознавания лесного массива на спутниковых снимках.

На первом этапе проводится разметка изображений, нарезка исходных изображений и нарезка полученных масок.

На втором этапе в нейронную сеть подаются нарезанные исходные изображения в паре с соответствующими масками. Далее обозначаются классы (1, 2, 3, 4) и параметры (весы, тренировочная и тестовая выборки) нейронной сети, происходит обучение сети, ее тестирование путем выбора случайного изображения из всего массива изображений и её маски.

На третьем этапе:

- анализируемое изображения фрагментируется на небольшие части;
- полученные части передаются нейронной сети;
- полученный результат сохраняется в виде небольших фрагментов (фрагменты сохраняются в изображение без цветов, например, лес синий, но по классу он 3, поэтому цвет у него 3, 3, 3 — это оттенок серого);
- собирается целое изображение, а распознанные изображения переводятся в необходимые цвета (если изображение было просто несколькими оттенками серого, то на этом шаге они превращаются в цвета);
- отображается итоговый результат классификации.



Рис. 3. Алгоритм модели классификации лесного массива по спутниковым снимкам

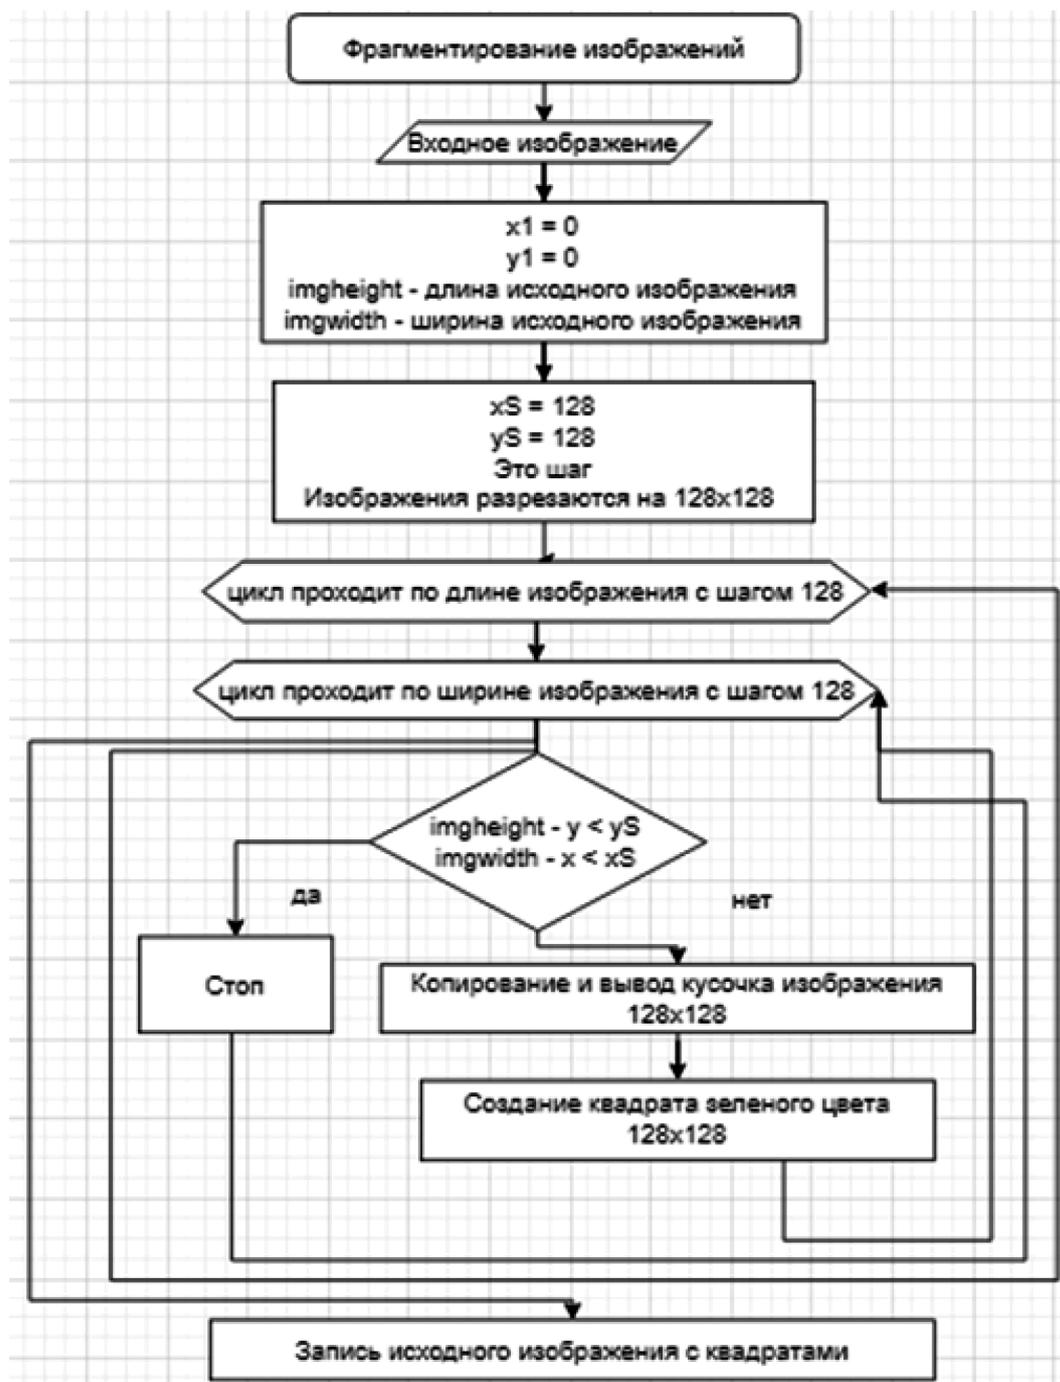


Рис. 4. Алгоритм нарезки изображения

Для повышения скорости и точности работы нейронной сети было принято решение нарезать изображения на более мелкие, размером 128x128 пикселей. Такой подход позволяет снизить сложность задачи классификации, улучшить распознавание мелких деталей и ускорить обработку изображений нейронной сетью. Также это позволяет справиться с ограничениями вычислительных ресурсов и позволяет обрабатывать большие объемы данных. Разработанный алгоритм нарезки изображений приведен на рисунке 4.

Сборка фрагментов локализованных масок и алгоритм компиляции в одно изображение представлены на рисунке 5.

Вычислительный эксперимент

В работе принято решение использовать кастомную функцию потерь, а именно комбинацию функций потерь Dice и Focal Loss.

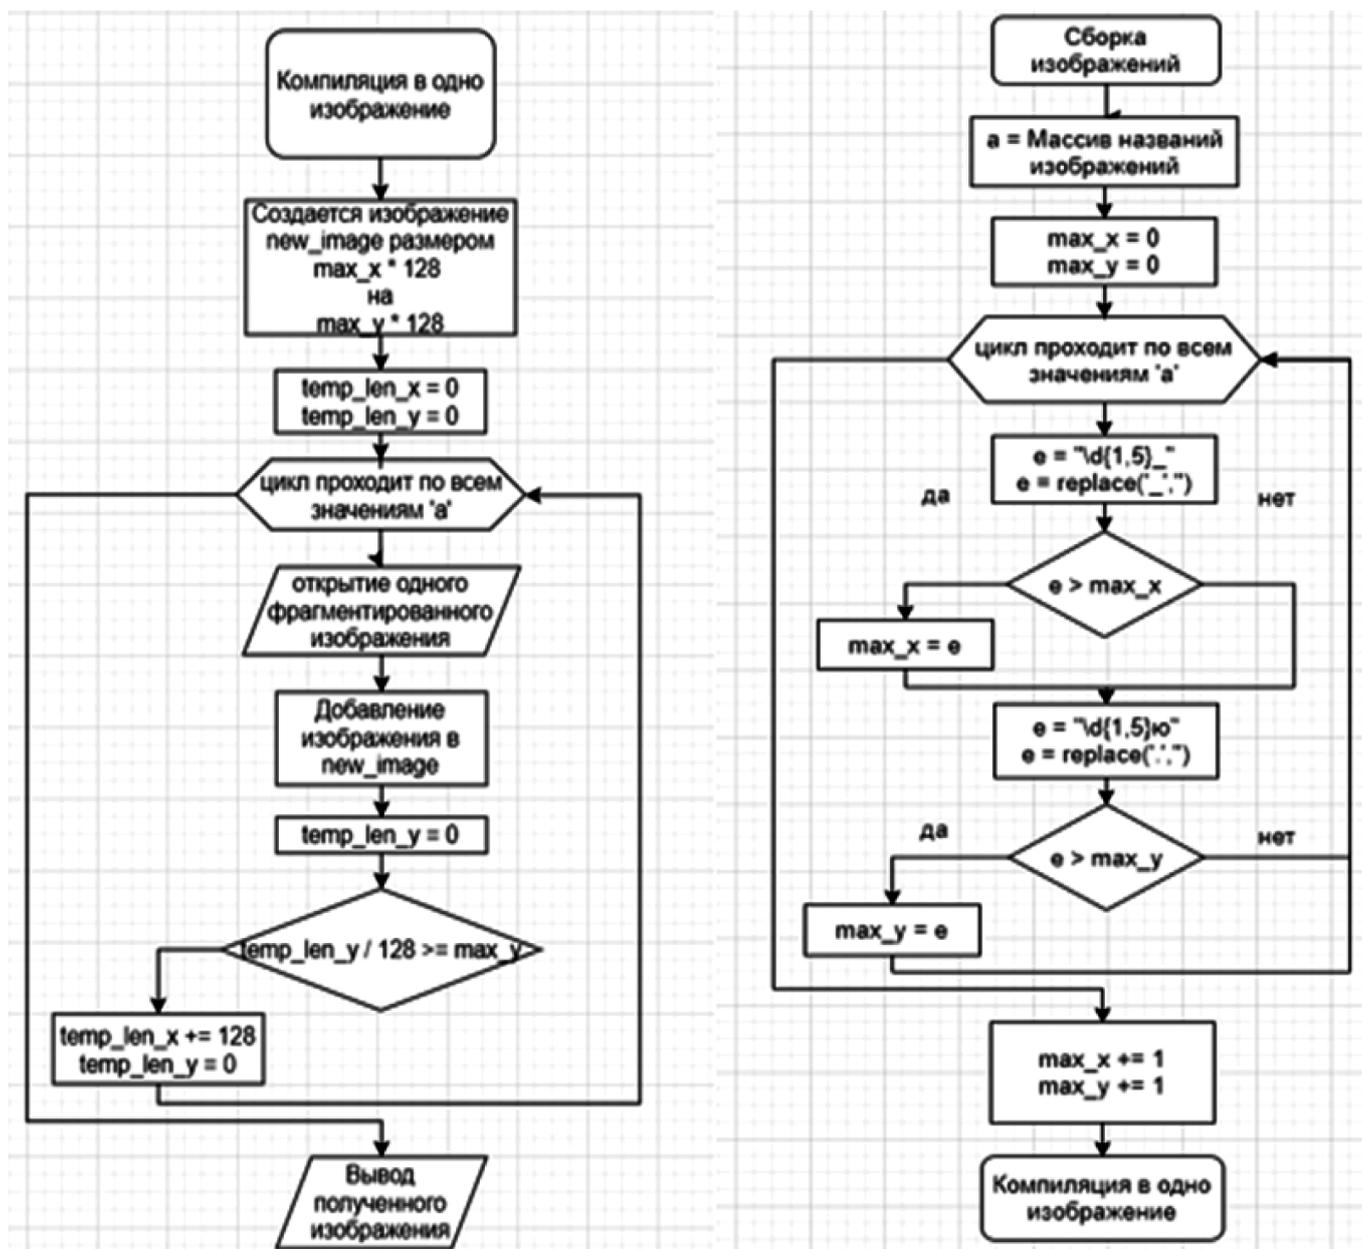


Рис. 5. Алгоритм сборки масок и компиляции изображения

В качестве основного механизма оценки эффективности выбранных параметров модели, функция потери является надежным индикатором производительности, что позволяет определить, насколько хорошо модель обучается и какие изменения вносятся с каждой эпохой обучения.

Таблица 1.

Влияние количества эпох на значение Total Loss

Тип эксперимента	50 эпох	70 эпох	100 эпох	120 эпох	150 эпох	180 эпох	200 эпох
Изменение параметров нейронной сети, количество эпох	0.267	0.183	0.151	0.162	0.202	0.212	0.219

Очевидно, изменения эпох являются важным аспектом обучения нейросетевой модели классификации лесного массива. Анализ этих изменений помогает определить оптимальные значения параметров модели и обеспечивает надежную оценку ее эффективности. Влияние количества эпох на значение Total Loss представлено таблицей 1.

Коэффициент Жаккара играет важную роль в оценке и оптимизации точности сегментации [6]. Улучшение этой метрики приводит к более точным и надежным результатам модели (табл. 2).

Вычислительный эксперимент представлен таблицей 3.

Таблица 2.

Параметры коэффektivности Жаккара

Название измененных значений	Значение коэффициента Жаккара
Loss комбинированная, нет категорической кроссэнтропии	0,75
Loss комбинированная с кроссэнтропией	0,755
Только focal loss	0,54
Dice loss + 5 focal loss	0,73
Dice loss + 1 focal loss	0,67
Dice loss + 5 focal loss + 40 эпох	0,71

В результате анализа полученных классов на изображениях можно сделать следующие выводы:

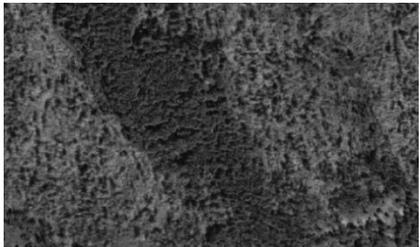
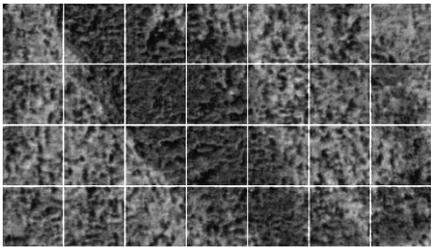
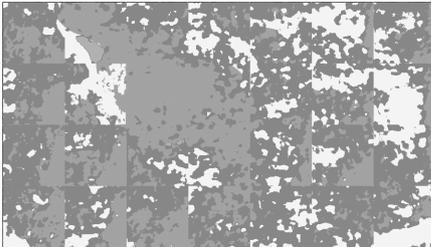
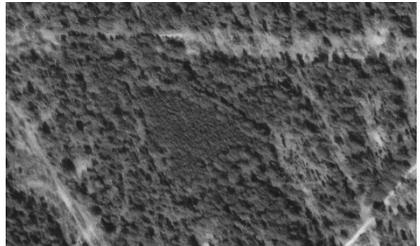
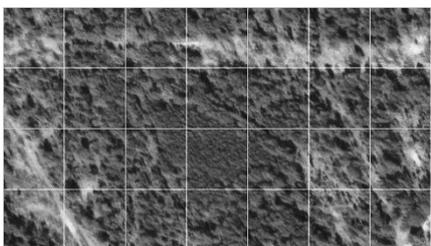
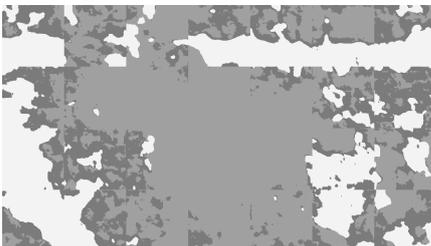
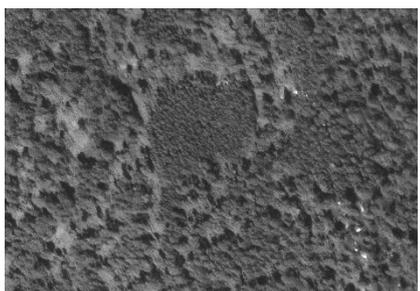
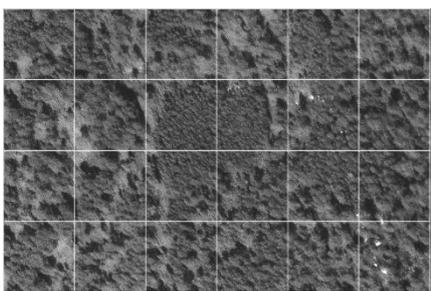
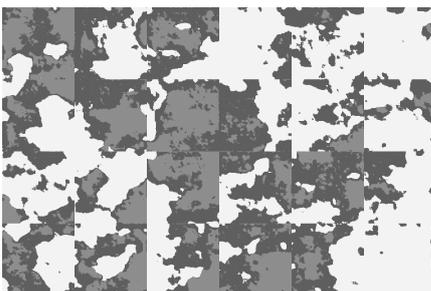
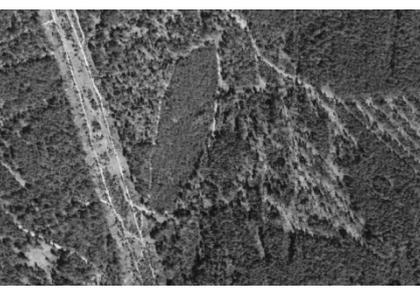
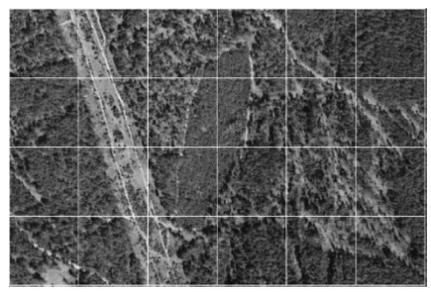
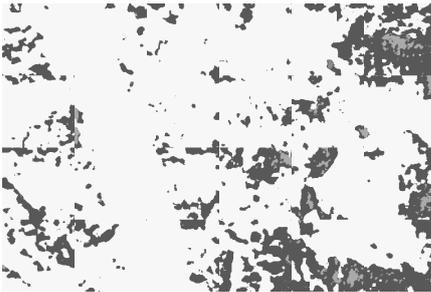
- нейронная сеть хорошо определяет изображения, когда лесной массив находится в ярком оттенке зеленого, при блеклом изображении считает, что это ель или не определяет ничего;
- нейронная сеть требует большей тренировки для определения березы;
- нейронная сеть очень хорошо определяет, есть ли растительность или она отсутствует на космоснимке.

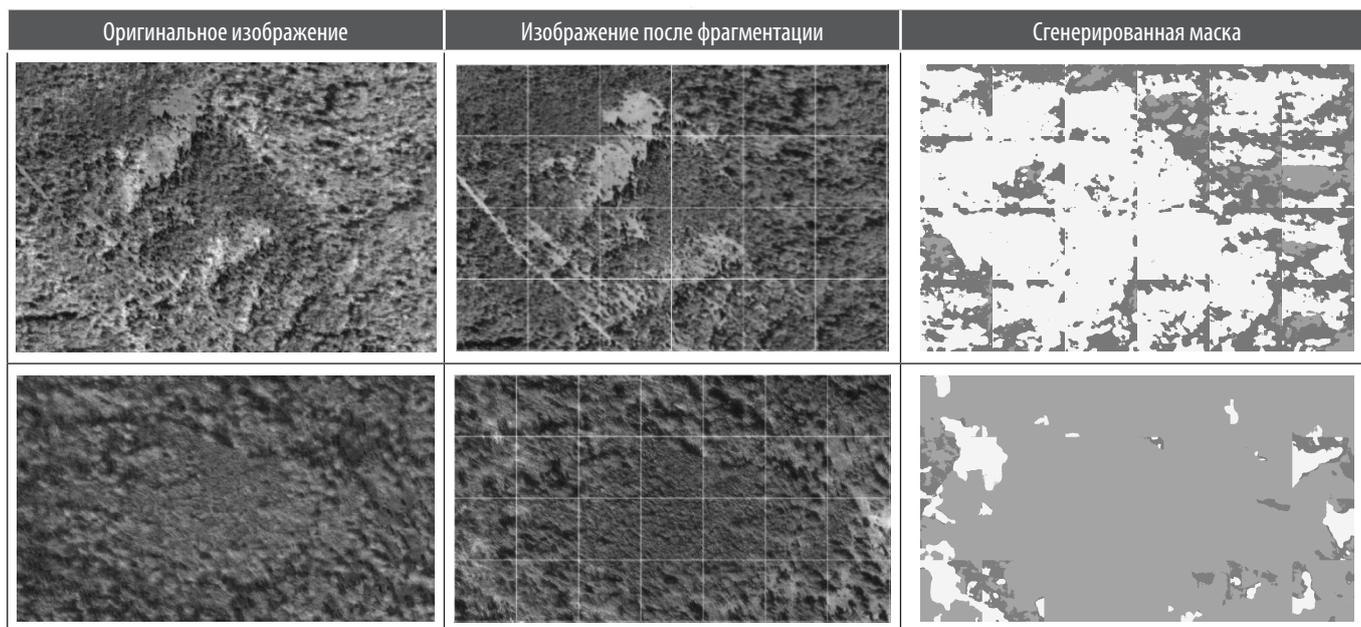
Заключение

В результате проведенных вычислительных экспериментов получена оценка эффективности и точности

Таблица 3.

Результат экспериментальных данных

Оригинальное изображение	Изображение после фрагментации	Сгенерированная маска
		
		
		
		



разработанной нейросетевой модели классификации лесного массива на основе спутниковых снимков. Результаты классификации сравнены с другими методами и алгоритмами, что подтвердило конкурентоспособность разработанной модели.

Анализ результатов позволяет сделать выводы о достижении точности модели и ее способности классифицировать лесные участки. Разработанная нейросетевая модель классификации лесного массива является работоспособной и имеет место развития в дальнейшем.

ЛИТЕРАТУРА

1. Inna Tulokhonova, Inga Evdokimova and Alexander Grigorenko. Neural network model for detection of changes in forest environment using multispectral images E3S Web of Conferences XI International Scientific and Practical Conference Innovative Technologies in Environmental Science and Education (ITSE-2023 Volume 431(2023).
2. USGS Earth Explorer: База данных высококачественных спутниковых данных. — URL: <https://earthexplorer.usgs.gov/?>. (дата обращения 24.05.2023)
3. Copernicus: База данных изображений спутников Sentinel. — URL: <https://dataspace.copernicus.eu> (дата обращения 24.09.2023)/
4. Погonyшев В.А., Погonyшева Д.А., Торииков В.Е. Нейронные сети в цифровом сельском хозяйстве // Вестник ФГОУ ВПО Брянская ГСХА. 2021. №5 (87). URL: <https://cyberleninka.ru/article/n/neyronnye-seti-v-tsifrovom-selskom-hozyaystve> (дата обращения: 01.12.2023).
5. Бычков И.В., Ружников Г.М., Федоров Р.К., Попова А.К., Авраменко Ю.В. О классификации космических снимков Sentinel-2 нейронной сетью ResNet-50 // КО. 2023. №3. URL: <https://cyberleninka.ru/article/n/o-klassifikatsii-kosmicheskikh-snimkov-sentinel-2-neyronnoy-setyu-resnet-50> (дата обращения: 01.10.2023).
6. Соловьев Р.А., Тельпухов Д.В., Кустов А.Г. Автоматическая сегментация спутниковых снимков на базе модифицированной сверточной нейронной сети UNET // ИВД. 2017. №4 (47). URL: <https://cyberleninka.ru/article/n/avtomaticheskaya-segmentatsiya-sputnikovyh-snimkov-na-baze-modifitsirovannoy-svyortchnoy-neyronnoy-seti-unet> (дата обращения: 05.11.2023).

© Евдокимова Инга Сергеевна (evdinga@gmail.com); Тулохонова Инна Степановна (istulokhonova@mail.ru);

Галданов Гэсэр Жамбалович (geser.galdanov@mail.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»