

# ПРИМЕНЕНИЕ МЕТОДОВ ИИ В РЕШЕНИИ ЗАДАЧ ФОТОГРАММЕТРИИ

**Тимаков Кирилл Александрович**

МИРЭА — Российский технологический университет

Tim1997.10@yandex.ru

## APPLICATION OF AI METHODS IN SOLVING PHOTOGRAMMETRY PROBLEMS

**K. Timakov**

*Summary.* This article discusses the application of various AI methods to improve the accuracy and automation of the photogrammetry process to create 3D models. The focus is on using advanced deep learning techniques such as image segmentation, depth mapping, and Image Enhancement (Super-Resolution) to improve key steps of photogrammetric processing. This article analyzes the role of neural networks in automating tasks such as identifying key points and creating accurate bit masks, which allows you to speed up the segmentation process and eliminate errors that occur during manual processing.

The article pays special attention to the two most promising possible integrations of neural network models.

The segmentation method helps to accurately highlight targets in images, separating them from the background and unwanted elements. To demonstrate the application of the approach, the CVAT service is used, based on the pre-trained Mask R-CNN model. The result of the service operation is demonstrated in the form of an image with annotated data in automatic mode, as well as high-quality bit masks created.

Finally, the Super-Resolution method is considered, which allows to increase the resolution of the source images, thereby improving the detail and quality of 3D models. The pre-trained neural network VGG19 is used as a possible tool, and its basic principle of operation is considered. As a result, a model created using improved data is demonstrated. According to the results of the Super-Resolution method, it was possible to achieve a 2.5-fold improvement in the quality of the 3D model.

In conclusion, it is emphasized that the integration of neural networks in photogrammetry opens the prospect of significantly accelerating and automating processes when it is necessary to prepare many images necessary to create 3D models. The disadvantages are a large amount of training data, and significant time spent on training, as well as very high requirements for computing resources.

*Keywords:* neural network, Super-Resolution, photogrammetry, image segmentation, bitmask, Depth map.

*Аннотация.* В данной статье рассматривается применение различных методов ИИ для повышения точности и автоматизации процесса фотограмметрии для создания 3D-моделей. Основное внимание уделяется использованию передовых методов глубокого обучения, таких как сегментация изображений, создание карт глубины и улучшение изображений (Super-Resolution), чтобы улучшить ключевые этапы фотограмметрической обработки. В данной статье анализируется роль нейронных сетей в автоматизации таких задач, как выявление ключевых точек и создание точных битовых масок, что позволяет ускорить процесс сегментации и исключить ошибки, возникающие при ручной обработке.

В статье отдельное внимание уделяется двум наиболее перспективным возможным интеграциям моделей нейронных сетей.

Метод сегментации помогает точно выделять целевые объекты на изображениях, отделяя их от фона и нежелательных элементов. Для демонстрации применения подхода используется сервис CVAT, на базе предобученной модели Mask R-CNN. Продемонстрирован результат работы сервиса в виде изображения с аннотированными данными в автоматическом режиме, а также созданные битовые маски высокого качества.

В конце рассматривается метод Super-Resolution, позволяющий повысить разрешение исходных изображений, тем самым улучшая детализацию и качество 3D-моделей. В качестве возможного инструмента используется предобученная нейронная сеть VGG19, рассматривается ее базовый принцип работы. В качестве результатов продемонстрирована модель, созданная при помощи улучшенных данных. По результатам работы метода Super-Resolution получилось достичь улучшения качества 3D модели в 2,5 раза.

В заключении подчеркивается, что интеграция нейронных сетей в фотограмметрию открывает перспективу значительного ускорения и автоматизации процессов, когда необходимо подготовить большое количество изображений, необходимых для создания 3D-моделей. В качестве недостатков выделяется большое количество обучающих данных, и значительные затраты времени на обучение, а также весьма высокие требования к вычислительным ресурсам.

*Ключевые слова:* нейронная сеть, Super-Resolution, фотограмметрия, сегментация изображений, битовая маска, Depth map.

## Введение

Традиционные методы фотограмметрии, основанные на обработке изображений с целью создания 3D-моделей, позволяют достаточно точно воссоздавать объекты и сцены, но нередко сталкиваются с рядом трудностей. Когда речь идет о больших объемах данных, работа с исходными данными требует значительных временных и вычислительных ресурсов, т.к.

возникает необходимость их обрабатывать, сегментировать и объединять в единые модели в ручном режиме. Качество исходных данных также играет важную роль. Периодически необходимые для распознавания объекты на изображениях сложно различимы, или разрешение самих изображений слишком низкое, что отрицательно сказывается на точности конечных результатов фотограмметрической обработки [1,2].

В качестве активно развивающегося примера использования нейронных сетей в фотограмметрии можно выделить целый раздел семантической фотограмметрии. Это подход, который объединяет традиционную фотограмметрию с методами нейронных сетей для добавления семантической информации (например, распознавания типов объектов) в процесс создания 3D-моделей [3]. Основной принцип заключается в сочетании методов 3D-моделирования на основе изображений с алгоритмами глубокого обучения, которые могут распознавать, классифицировать и помечать различные объекты или особенности в сцене. Такой подход позволяет не только реконструировать пространство объектов, но и расширить объем данных о модели дополнительной информацией о содержании каждого объекта в сцене. Например, система с использованием семантической фотограмметрии, автоматически распознает и классифицирует здания, дороги, зеленые насаждения, тротуары, инженерные сети и другие объекты на основе их визуальных и структурных характеристик, и с учетом полученной информации создает соответствующие цифровые двойники.

Анализ текущих исследований в данной вопросе показал, что нейронные сети могут быть использованы как инструмент для улучшения или автоматизации отдельных этапов фотограмметрии, например:

- устранение шума в полигональных сетках. Использование полно связных многослойных нейронных сетей упрощает процесс шумоподавления за счет того, что обученная нейронная сеть самостоятельно отбирает признаки, полученные с помощью билатеральных фильтров с разными параметрами, что позволяет не задавать их вручную. Также такой подход не требует знания характеристик шума, который появился в результате сканирования [4];
- генерация глубинных карт. Возможность нейронной сети восстанавливать глубину объектов на основе одной или нескольких фотографий [5]. Данный подход может дополнять или заменять этапы выравнивания изображений и создания облаков точек в традиционной фотограмметрии;
- сегментация изображений. Автоматизация данного процесса, улучшение идентификации ключевых точек на изображениях, улучшая точность построения 3D-моделей [6];
- улучшение качества изображений. Нейросетевые модели могут улучшить качество исходных изображений, используемых в фотограмметрии, за счет повышения разрешения исходных изображений [7].

Упомянутые выше исследования применяются для решения задач в общем виде. Работ, посвященных применению рассмотренных ИИ решений в фотограмме-

трии весьма мало. Однако использование нейронных сетей в фотограмметрии может позволить автоматизировать ключевые этапы, такие как сегментация изображений, идентификация объектов и реконструкция 3D-моделей, что не только ускорит процесс, но и снизит вероятность ошибок, возникающих при ручной обработке. Далее рассмотрим наиболее перспективные методы ИИ, которые можно применить в фотограмметрии.

## Материалы и методы

### Сегментация изображений:

Сегментация изображений в фотограмметрии необходима для точного выделения границ и классификации различных объектов на изображениях. Этот процесс помогает отделить целевые элементы сцены, т.е. прикладные объекты, от фона и других ненужных объектов, что значительно облегчает дальнейший анализ и обработку данных.

В предметной фотограмметрии, где фокус смещён на реконструкцию 3D-моделей отдельных объектов, сегментация изображений также играет важную роль, но с акцентом на точное выделение контуров и структурных деталей самого объекта. В этой области сегментация помогает отделить объект от фона, что особенно важно, если требуется высокая точность при создании модели, например, технических деталей, объектов интерьера и др. Чёткое разделение объекта и фона позволяет избежать нежелательных «шумов» и артефактов, которые могут появиться при построении 3D-модели, если не выделить объект должным образом. Также благодаря сегментации фотограмметрическое программное обеспечение может более эффективно определять ключевые точки и линии, что повышает точность привязки изображений и создания текстурных карт для модели [8].

Сегментация в ручном режиме может быть достаточно медленным и трудоемким процессом, в особенности при работе с большими объемами данных, так как каждый объект или область должны быть выделены вручную. Ручная сегментация плохо поддается масштабированию: для качественной фотограмметрии для одного объекта используется несколько сотен изображений. Обработка такого объема данных требует значительных ресурсов и времени, что делает ее менее эффективной, также увеличивается шанс ошибки. С целью избежания вышеописанных проблем, можно использовать инструменты автоматизации, основанные на поддержке полуавтоматической сегментации

Одним из ключевых достоинств CVAT является его интеграция с нейронными сетями, которые могут автоматически создавать маски для сегментации [9]. С помощью предобученных моделей, таких как Mask R-CNN или

U-Net, доступных для использования внутри CVAT, можно ускорить процесс аннотирования, так как сеть способна автоматически определять и сегментировать целевые объекты на изображении. Применяя нейронные сети, пользователи могут легко создавать точные маски для объектов, а затем при необходимости корректировать их вручную, что позволяет добиться высокой точности сегментации с минимальными усилиями.

Кроме того, CVAT поддерживает возможность автоматизации с помощью создания скриптов и интеграции с API, что позволяет настраивать процессы аннотации под конкретные задачи. Например, можно автоматизировать процесс загрузки изображений, использования нейронной сети для автоматической сегментации и экспорта готовых аннотаций. Это делает CVAT особенно подходящим для проектов, где требуются регулярные обновления данных или где необходимо быстро масштабировать процесс сегментирования.

В итоге использование CVAT для сегментации изображений не только ускоряет и упрощает создание битовых масок для фотограмметрии, но и обеспечивает гибкость и масштабируемость, которые становятся возможны благодаря интеграции с нейронными сетями и возможностями автоматизации.

В качестве примера рассмотрим фотографию, на которой имеется три объекта для сегментации под задачи фотограмметрии (рис. 1)

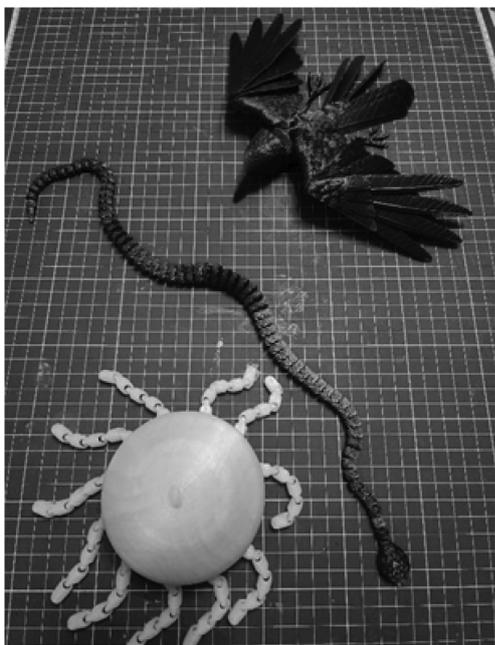


Рис. 1. Фотография, содержащая объекты для сегментации

На рисунке 2 представлен результат сегментации, где каждый из трех объектов имеет уникальный цветовой код: зеленый, желтый и розовый, обозначающие принадлежность к разным классам, атрибуты которых были

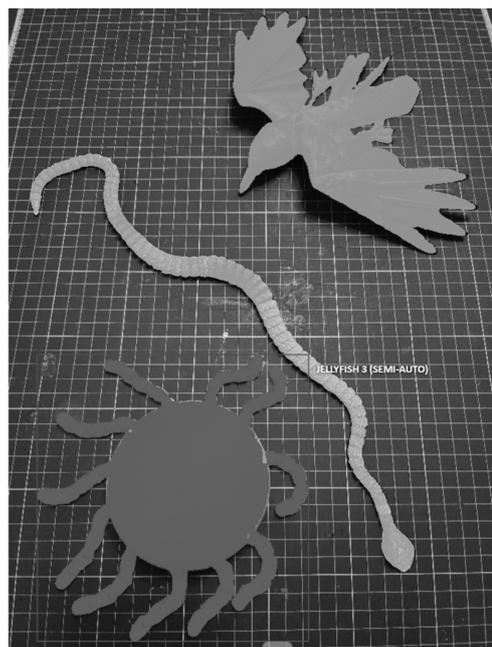


Рис. 2. Отображение аннотированных данных на фотографии

созданы заранее, перед загрузкой изображения. Для сегментации использован метод полуавтоматической аннотации (Semi-Auto). Также система в автоматическом режиме определила класс объектов, к которому он принадлежит. На рисунке видно, что объект розового цвета, принадлежит классу «jellyfish». Сегментация выполнена на высоком уровне, т.к. видно, что контуры объектов четко выделены, с учетом сложной геометрии.

Важно отметить, что CVAT позволяет в автоматическом режиме создавать битовые маски. Битовая маска при сегментации в фотограмметрии используется для точного представления и хранения информации о том, какие пиксели на изображении принадлежат целевым объектам, а какие — фону. Такая маска представляет собой двоичное изображение, где каждый пиксель принимает одно из двух значений, обозначающих, принадлежит ли он целевому объекту («1») или фону («0»). Использование битовых масок упрощает дальнейшую обработку данных, так как они дают четкие границы и минимизируют ошибки при создании облаков точек и реконструкции текстур. Этот подход позволяет эффективно выделить нужные области, игнорируя все ненужные детали и объекты, что особенно важно в задачах 3D-моделирования [10].

CVAT позволяет отобразить полученные битовые маски (рис. 3) полученные данные после процесса сегментации и в дальнейшем экспортировать, с целью загрузки их в ПО фотограмметрии.

ПО для фотограмметрии использует данные сегментации и битовые маски, чтобы выделить целевые объекты на изображениях и улучшить точность их реконструк-

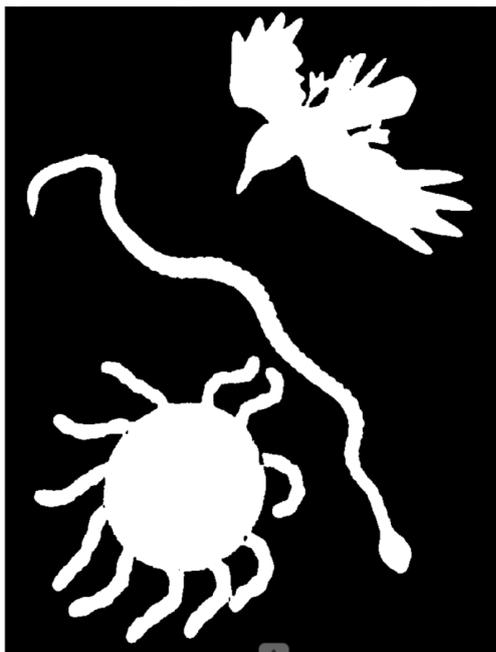


Рис. 3. Отображение битовых масок для задач фотограмметрии

ции. На этапе предварительной обработки программа загружает изображения и битовые маски, которые указывают, какие части изображений относятся к целевому объекту, а какие к фону. Сначала софт применяет маски, чтобы исключить фон и нежелательные объекты из анализа, таким образом ограничивая область работы алгоритмов, строящие плотные облака точек, только на целевой объект. Это позволяет исключить ненужные данные,

ускоряя обработку, и уменьшить «шум» на изображениях, особенно когда объект находится на сложном фоне.

Далее, при выполнении таких задач, как построение облаков точек, привязка ключевых точек и текстурирование, программа опирается на выделенные масками области, чтобы точнее определить характерные точки и линии объекта. Это значительно улучшает точность 3D-реконструкции, так как система работает только с полезной информацией. Кроме того, при создании текстурных карт для 3D-моделей программа использует маски для наложения текстуры исключительно на целевые области, что делает финальные модели фотореалистичными и чистыми от ненужных фрагментов фона.

Некоторые продвинутые фотограмметрические программы также используют маски для автоматического создания моделей в пакетном режиме, минимизируя необходимость ручного вмешательства. В итоге сегментация и битовые маски не только ускоряют процесс обработки данных и улучшают качество финальных моделей, но и делают рабочий процесс более автоматизированным, особенно при массовом создании 3D-моделей.

Стоит отметить, что все выделенные преимущества CVAT, применимы на любую разработку, которая позволяет произвести автоматическую сегментацию изображений.

*Улучшение качества изображений (Super-Resolution)*

Технология улучшения качества изображений (Super-Resolution) направлена на увеличение разрешения изо-

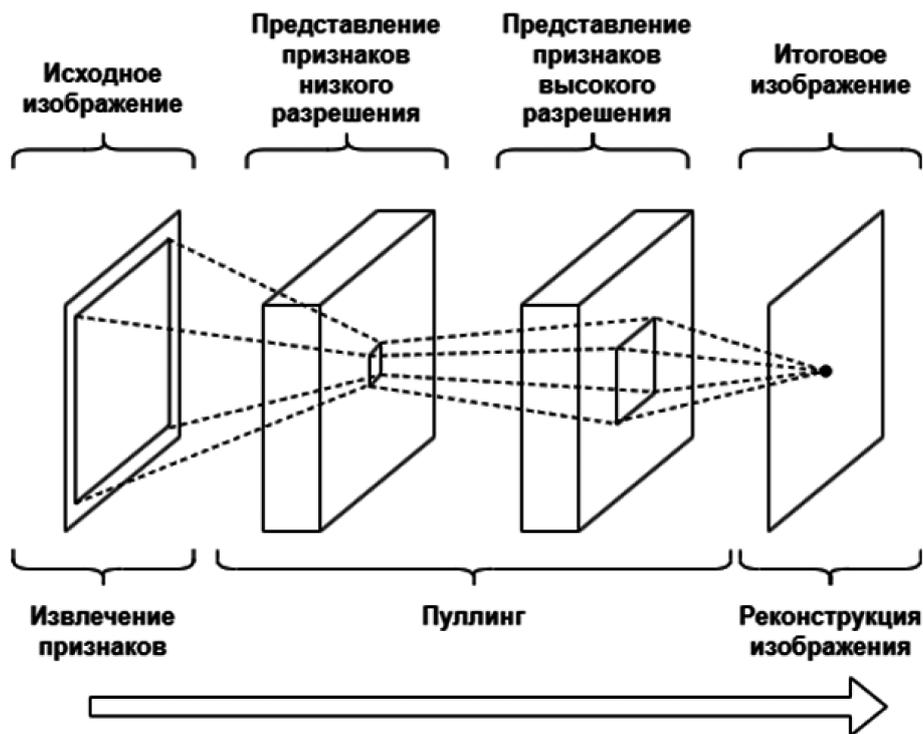


Рис. 4. Принцип работы нейронной модели Super-Resolution

бражений с целью повышения их детализации и четкости. Основной задачей метода является восстановления мелких деталей, проработки границ объектов, потерянных при сжатии или уменьшении разрешения, что достигается за счет алгоритмов машинного обучения и нейронных сетей. Особенность метода заключается в использовании свёрточных нейронных сетей (CNN) и генеративно-сопоставительных сетей (GAN), которые обучаются на парах изображений низкого и высокого разрешения, позволяя алгоритму «восполнять» недостающую информацию и устранять артефакты при увеличении масштаба. Принцип работы такого подхода изображен на рисунке 4, где на вход первого сверточного слоя поступает исходное изображение  $X$  с низким разрешением и далее данный слой извлекает набор признаков присущих данному расположению объектов. Второй слой уменьшает каждый из полученных наборов чтобы искусственно создать низкое разрешение. Третий слой нелинейно преобразует эти признаки объектов в представления высокого разрешения. Последний слой объединяет предсказания в пределах пространственной окрестности для получения реконструированного изображения  $F(X)$  с высоким разрешением. [11,12].

Используя Super-Resolution, появляется возможность работать с изображениями низкого качества, улучшая их для последующего анализа и точного распознавания деталей.

При работе стоит учитывать, что алгоритмы повышения разрешения изображений не способны восстанавливать информацию, которая была потеряна из-за низкого разрешения камеры. Зачастую нейронная сеть

может исказить исходное изображение, особенно при отображении символов, первоначально стараясь сделать изображение приятным человеческому глазу [13]. В качестве примера такого искажения используется изображение 5, [14]. Можно увидеть, что окнам были «дорисованы» дополнительные детали, что может внести дополнительные помехи при фотограмметрической обработке

### Результаты

Для демонстрации применимости Super-Resolution в фотограмметрии, принято решение сделать две 3D модели одного объекта при помощи ПО Agisoft Photoscan. Для контрольной модели без обработки было сделано 102 фотографий объекта, при помощи цифровой фотокамеры, с заниженными настройками разрешения, а именно 640 x 480 пикселей.

В Agisoft Photoscan следует использовать только оригинальные изображения в том виде, в котором они получены на цифровую фотокамеру. Использование фотографий, для которых были произведены геометрические трансформации или кадрирование, скорее всего приведет к отрицательному или крайне неточному результату. Фотометрические модификации не влияют на результаты реконструкции, т.е. обработка с использованием Super-Resolution не мешает созданию облака точек.

В подготовке второго набора фотографий использовался проект с открытым исходным кодом Neural Enhance построенный на основе Python и набора библиотек numpy и scipy, а также предварительно обученная



Рис. 5. Пример искажения изображения при работе метода Super-Resolution

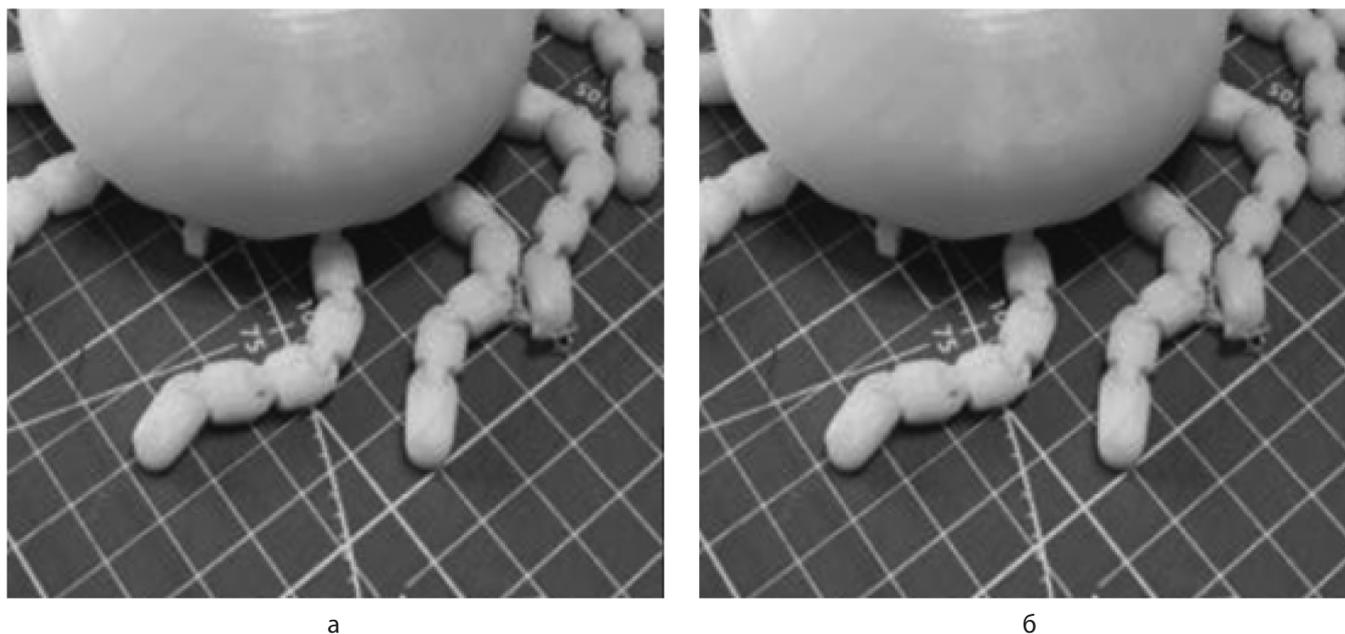


Рис. 6. Сравнение результатов обработки.

а — исходное разрешение фотографий. б — результат улучшения разрешения фотографии

нейронная сеть VGG19. VGG19 — это модель компьютерного зрения, основанная на сверточной нейронной сети (CNN), и обучена на миллионах изображений, способная классифицировать более 1000 объектов. [14,15] В ходе обработки исходного набора фотографий, получилось добиться кратного улучшения разрешения, вплоть до 1920×1080 пикселей. Сравнение результатов обработки представлено на рисунке 6. Так на рисунке 6(б) можно увидеть более резкие контуры объекта, технические сочленения, а также четкую границу между фоном и самим объектом

При создании 3D модели с использованием исходного набора фотографий было определено 2342 точки, за счет чего облако точек получалось разреженным и не плотным. В ходе обработки получена модель, представленная на рисунке 7. Количество полигонов модели 67199.



Рис. 7. Результат построения 3D модели из оригиналов фотографий объекта

Как видно на рисунке 8 при использовании набора фотографий с увеличенным разрешением, програм-

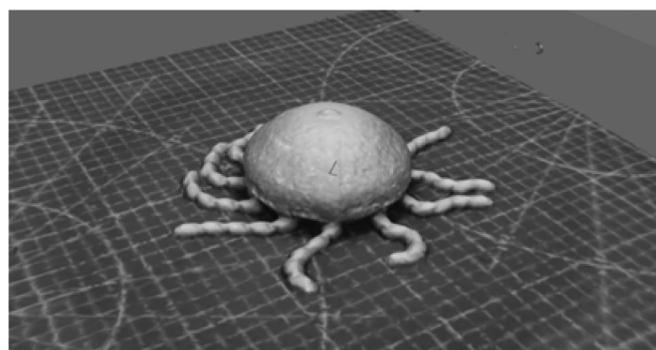


Рис. 8. Результат построения 3D модели из улучшенных фотографий объекта

ма смогла выделить большее количество точек (с 2342 до 38217), за счет чегократно улучшилось качество самой модели. Также увеличено количество полигонов в 2,5 раза до 158923, что позволяет более гибко проводить работы по постобработке модели.

### Обсуждение

Результаты, полученные в ходе данного исследования, о внедрении методов ИИ в фотограмметрию показали способность повысить уровни качества и автоматизации при обработке большого объема данных, особенно на этапах сегментации, а также увеличить разрешение исходных изображений. Анализ полученных результатов позволяет сделать следующие выводы о теоретической и практической значимости примененных технологий в фотограмметрии и их соответствии в современных научных работах, посвященных 3D-реконструкции.

Метод сегментации, рассмотренный в статье, основанный на сверточной нейронной сети Mask R-CNN,

продемонстрировал высокую точность в определении и сегментации объектов на тестовом изображении. Полученный результат может способствовать минимизации ошибок и сокращению времени обработки, что делает возможным автоматизацию процессов в фотограмметрии и уменьшение затрачиваемого времени, за счет сокращения ручной работы. Существенным преимуществом данного подхода является возможность создания битовых масок, обрабатываемых изображений, обеспечивающих создание более точных 3D-моделей и улучшенную привязку ключевых точек. Рассмотренный метод вписывается в современные научные представления об автоматизированной фотограмметрии, расширяя традиционные подходы в интеграции нейронных сетей для идентификации и сегментации объектов на изображениях.

В ходе работы метод Super-Resolution показал значительный прирост в улучшении качества моделей, что подтверждается количественным результатом, таким как: повышение разрешения исходных изображений, приведшее к созданию более детализированной модели с увеличенным количеством полигонов. В контексте современной науки это соответствует применению сверточных нейронных сетей для восстановления недостающих данных в изображениях низкого качества. Использование технологии Super-Resolution в процессе создания 3D-моделей позволяет восполнить отсутствующие детали и повысить детализацию, что особенно важно для объектов со сложной структурой.

Теоретическая значимость полученных результатов заключается в расширении научных исследований в вопросах применения различных нейронных сетей в фотограмметрии, создавая основу для дальнейших работ в области автоматизации и упрощения 3D-реконструкции. Практическая значимость состоит в рассмотрении применимости ИИ алгоритмов обработки изображений для фотограмметрии, что может быть полезно в прикладных сферах, требующих создания точных 3D-моделей.

Исходя из полученных результатов, можно предложить несколько направлений для будущих исследований. Во-первых, более детальное изучение и подбор оптимальных архитектур сверточных нейронных сетей пригодных для сегментации изображений необходимых в создании 3D-реконструкции. Во-вторых, интеграция методов сегментации и Super-Resolution в единый автоматизированный комплекс обработки изображений может существенно упростить подготовку данных для фотограмметрии, а также привнести оптимизацию в эти процессы.

Таким образом, полученные результаты демонстрируют возможные перспективы использования методов ИИ в фотограмметрии, подтверждая их зна-

чимость как с теоретической, так и с практической точек зрения.

### Заключение

Применение решений на основе нейросетей в фотограмметрии могут принести значительные преимущества. Использование подобных систем состоит в их способности автоматизировать сложные процессы анализа изображений и 3D-реконструкции, значительно сокращая время и трудозатраты. К примеру, проект CVAT, основанный на нейронной сети Convolutional Neural Networks (CNNs), отлично справляются с задачами сегментации, детекции объектов и создании битовых масок, позволяя более четко определять объекты, по которым будут создаваться 3D модели, а использование API позволяет кратно ускорить обработку большого набора данных

Также перспективна область улучшения качества исходных данных. Нейронные сети лежащие в основе технологии Super-Resolution, обученные на больших наборах данных, способны воссоздать утерянные детали на фотографиях, реконструировать границы, повысить четкость и разрешение в несколько раз. Это способствует созданию более детализированных и реалистичных 3D-моделей сокращая работы по постобработке.

Однако внедрение нейронных сетей в фотограмметрию связано с некоторыми проблемами. Одна из главных — это необходимость в больших объемах размеченных данных для обучения. Для достижения высокой точности нейронные сети требуют огромного количества изображений с точными аннотациями, что может быть дорого и трудоемко. Кроме того, обучение и настройка нейронных сетей требуют значительных вычислительных ресурсов, включая мощное оборудование и доступ к большим объемам памяти.

Ещё одной потенциальной проблемой является возможность ошибок при переносе модели на новые наборы данных. Нейронные сети могут показывать отличные результаты на обучающих данных, но снижать точность на новых изображениях, если условия съемки, освещение или структура объектов изменяются. Это особенно критично в фотограмметрии, где данные могут сильно различаться по качеству и характеристикам.

Таким образом, нейронные сети значительно повышают эффективность фотограмметрии, предлагая автоматизацию и улучшение качества 3D-реконструкции. Однако для их успешного использования требуется учесть проблемы, связанные с затратами на обучение, потребностью в мощных вычислительных ресурсах.

## ЛИТЕРАТУРА

1. Li Q., Yu W., Jiang S. Optimized Views Photogrammetry: Precision Analysis and A Large-scale Case Study in Qingdao // 2022.
2. Xu N. и др. Multi-tiling Neural Radiance Field (NeRF) — Geometric Assessment on Large-scale Aerial Datasets // 2023.
3. Stathopoulou E.K., Remondino F. Semantic photogrammetry — boosting image-based 3d reconstruction with semantic labeling // Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2019. Т. XLII-2/W9. С. 685–690.
4. Ротова О.М., Пивоварова Н.В. Neural network denoising in polygon meshes // Моделирование, оптимизация и информационные технологии. 2022. Т. 10. № 1(36). С. 13–14.
5. Bittner K., Körner M., Reinartz P. Late or Earlier Information Fusion from Depth and Spectral Data? Large-Scale Digital Surface Model Refinement by Hybrid-cGAN // 2019.
6. Годунов Анатолий Иванович, Баламян Сергей Товмасович, Егоров Павел Сергеевич, Сегментация изображений и распознавание объектов на основе технологии сверточных нейронных сетей // НикСС. 2021. №3 (35). URL: <https://cyberleninka.ru/article/n/segmentatsiya-izobrazheniy-i-raspoznvanie-obektov-na-osnove-tehnologii-svertochnyh-neyronnyh-setey> (дата обращения: 14.11.2024).
7. Сирота А.А., & Бережнов Н.И. (2022). Универсальный алгоритм улучшения изображений с использованием глубоких нейронных сетей. Вестник ВГУ. Серия: Системный анализ и информационные технологии, (2), 81–92. <https://doi.org/10.17308/sait/1995-5499/2022/2/81-92>
8. Erfani S.M.H. и др. ATLANTIS: A Benchmark for Semantic Segmentation of Waterbody Images // Environmental Modelling & Software. 2022. Т. 149. С. 105333.
9. CVAT. ai Corporation. Computer Vision Annotation Tool (CVAT) // 2024.
10. Ledig C. и др. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network // 2016.
11. Dong C. и др. Image Super-Resolution Using Deep Convolutional Networks // IEEE Trans. Pattern Anal. Mach. Intell. 2016. Т. 38. № 2. С. 295–307.
12. Strokova A.V. Experiments with several Convolutional Neural Networks for Evaluating the Super-Resolution Technique // Proceedings of the 33rd International Conference on Computer Graphics and Vision.: Keldysh Institute of Applied Mathematics, 2023. С. 88–96.
13. Ledig C. и др. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network // 2016.
14. Увеличь это! Современное увеличение разрешения в 2023 [Электронный ресурс]. URL: <https://habr.com/ru/articles/716706/> (дата обращения: 14.11.2024).
15. Арзамазов Н. Обзор методов супер-разрешения изображений для начинающих [Электронный ресурс]. URL: <https://neurohive.io/ru/osnovy-data-science/obzor-metodov-super-razresheniya-izobrazhenij-dlya-nachinajushhih/> (дата обращения: 18.10.2024).
16. Punch N. Neural Style Transfer VGG19 [Электронный ресурс]. URL: <https://medium.com/software-dev-explore/neural-style-transfer-vgg19-dab643ec6160> (дата обращения: 23.10.2024).

© Тимаков Кирилл Александрович (Tim1997.10@yandex.ru)  
Журнал «Современная наука: актуальные проблемы теории и практики»