

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОПРЕДЕЛЕНИЯ ОПОРНЫХ ОБЪЕКТОВ НА СРЕЗАХ ОБЛАКОВ ТОЧЕК

USING ARTIFICIAL NEURAL NETWORKS TO DETERMINE REFERENCE OBJECTS ON POINT CLOUD SLICES

L. Gagarina
I. Gaiduk

Summary. The article lists the main types of neural network architectures for pattern recognition, analyzes their effectiveness in terms of saving computing resources, and draws conclusions about the appropriateness of their use in various conditions.

Keywords: 3D modeling, 3D scanning, point clouds, neural networks.

Гагарина Лариса Геннадьевна

Д.т.н., профессор, ФГАОУ ВО «Национальный исследовательский университет МИЭТ»
cpintex@yandex.ru

Гайдук Игорь Олегович

Соискатель, ФГАОУ ВО «Национальный исследовательский университет МИЭТ»
igolgai@mail.ru

Аннотация. В статье перечислены основные типы нейросетевых архитектур для распознавания образов, проведен анализ их эффективности с точки зрения экономии вычислительных ресурсов и сделаны выводы о целесообразности их использования в различных условиях.

Ключевые слова: 3D-моделирование, трехмерное сканирование, облака точек, нейронные сети.

Введение

В современном мире интенсивно увеличивается количество предметных областей, в которых получают применение технологии трехмерного моделирования [1]. От самого тривиального применения в индустрии развлечений до использования в медицине [2] для изготовления высокоточных индивидуальных протезов или создания прототипов промышленных изделий. Но разработка трехмерной модели с нуля трудоемкий процесс, требующий больших затрат временных ресурсов со стороны профильных специалистов. Для решения этой проблемы были разработаны комплексы многоракурсного сканирования, позволяющие получить виртуальную копию объекта с минимальным участием человек [3]. К основным недостаткам подобных устройств можно отнести высокие требования к оборудованию для создания модели.

Для уменьшения объема вычислений на создание трехмерной модели было принято решение о разработке модифицированной методики совмещения облаков точек. После проведенного подробного анализа существующих методов генерации единой модели наиболее перспективным с точки зрения возможного улучшения был признан метод совмещения по опорным объектам [4]. В рамках предлагаемой модифицированной методики предполагается предварительная локализация области расположения возможного опорного объекта с последующей триангуляцией данной области вместо триангуляции всего облака и последующего поиска ге-

ометрических примитивов, как в классической методике [5, 6].

Использование модифицированной методики предполагает построение двумерных срезов облака точек и поиск на каждом срезе уникальных контуров опорных объектов с помощью нейросетевого аппарата [7]. Границы данного контура на срезе выступают в качестве горизонтальных пределов области расположения потенциального объекта, а наличие данного контура на соседних срезах дает понимание о вертикальных пределах [8].

Цель работы

Провести сравнительный анализ различных нейросетевых архитектур с точки зрения качества обнаружения уникальных контуров на срезах облаков точек и общего времени работы.

Методы исследования

Для проведения исследований был сформирован датасет из предварительно размеченных облаков точек с указанием областей расположения опорных объектов. Так как разметка набора данных осуществлялась вручную, то в разметку были включены все контуры, вне зависимости от возможности их нахождения классическими или модифицированными методами. Также следует отметить, что данный датасет является гетеро-




Рис. 1. Сравнение точности работы различных нейросетевых архитектур




Рис. 2. Процент детектированных объектов

генным с точки зрения предметной области и за счет этого опорные объекты имеют широкий диапазон возможных форм.

В качестве модулей распознавания использовались пять различных архитектур:

- ◆ классическая, использующая триангуляцию всего облака точек с дальнейшим поиском геометрических примитивов на триангулированной поверхности;
- ◆ VGG-19;
- ◆ ResNet-50;




Рис. 3. Зависимость временных затрат от количества сканирований

- ◆ Inception v.4;
- ◆ GCNN.

Результаты исследований

Первым показателем, по которому проводилось сравнение, выступила точность определения опорных объектов. В качестве параметров для измерения данного показателя использовались стандартные для нейронных сетей метрики: accuracy, precision, recall и f-score. Классическая методика с использованием триангуляции на данном этапе не рассматривалась, так как метрики оценки классификаторов к ней не применимы. Измерения точности различных архитектур проводились после стабилизации кривой обучения нейросетевых алгоритмов во избежание использования недостаточно обученных моделей.

На рисунке 1 представлены показатели точности по четырем основным метрикам. Из приведенных значений видно, что наилучшим образом с задачей обнаружения на срезах контуров потенциальных объектов и их правильной классификацией справляются архитектуры inception и графовые нейронные сети (GCNN).

В качестве второго параметра для сравнения будем использовать вероятность обнаружения опорного объекта сложной формы. Чтобы сопоставить методы по указанной способности были выбраны 50 облаков точек с проведенной предварительной разметкой.

Облака под номерами 8, 28 и 37 содержали преимущественно объекты сложной формы, что хорошо видно на рисунке 2.

Наилучшие показатели с точки зрения процента детектированных объектов принадлежат графовым нейронным сетям [9]. Как можно видеть из графика наличие объектов сложной формы на облаке никоим образом не снижает общий процент найденных объектов.

Второй по проценту детектированных объектов идет архитектура Inception [10]. Из графиков можно видеть, что она наравне с графовой нейронной сетью распознает большую часть объектов, но на двух облаках точек с объектами сложной формы ее результаты значительно скромнее. Связано это с тем, что графовые сети могут распознавать гораздо более сложные зависимости между точками контуров, а вот разнообразия фильтров Inception в этом случае недостаточно для точной идентификации.

Архитектуры ResNet-50 [11] и VGG-19 [12] на графике имеют различия в проценте распознанных объектов между собой и превосходят классический метод с применением триангуляции, но на самом деле данные различия находятся в рамках статистической погрешности и не имеют реального веса.

Наконец, для оценки применимости различных архитектур нейронных сетей следует рассмотреть затра-

ты временных ресурсов на проведение сканирования. Необходимо понимать, что использование нейронных сетей предполагает процесс обучения, следовательно, нужно включать затраты на обучение в продолжительность каждого отдельного сканирования. Графики отражающие временные затраты представлены на рисунке 3.

Так как классический процесс совмещения с использованием триангуляции не предполагает необходимости обучения, то время на проведение каждого отдельного сканирования остается неизменным независимо от номера эксперимента. Для нейронных сетей можно говорить о среднем времени проведения сканирования после выхода графика на плато, а количество экспериментов, проведенных до этого выхода, свидетельствует о сложности обучения того или иного решения.

Наилучшие показатели с точки зрения времени проведения каждого отдельного сканирования показывает архитектура ResNet-50. Происходит это за счет особенностей процесса обучения данной архитектуры, который предполагает исключение излишних блоков свертки из процесса обучения и распознавания, если они не приносят значительного вклада в конечный результат.

Наибольших временных затрат требует архитектура графовых нейронных сетей, так как даже при количестве сканирований, приближающемся к 10000 экспериментов, усредненные временные показатели достигают значений классической методики.

Заключение

Проведенные исследования подтвердили предположение, что использование в процессе совмещения облаков точек аппарата искусственных нейронных сетей для определения опорных объектов позволит повысить эффективность данного процесса. Причем, как с точки зрения времени проведения сканирования для большинства архитектур, так и с точки зрения увеличения числа и сложности обнаруженных объектов (в случае использования графовых нейронных сетей и архитектуры Inception).

Несмотря на перечисленные плюсы, следует отметить серьезный недостаток предлагаемой технологии: модифицированная методика подходит для применения в областях, предполагающих большое количество сканирований и соответственно потоковое использование. В случае разового применения накладные расходы на обучение нейронной сети будут слишком высокими и перекроют возможную выгоду от использования.

ЛИТЕРАТУРА

1. Логинов Г.Н., Дучков А.А., Литвиченко Д.А., Аляшкин С.А. Пример применения сверточных нейронных сетей в обработке реальных данных 3D сейсморазведки // Интерэкспо Гео-Сибирь, 2019. — С. 147–153.
2. Шараев Д.А. Метод определения изогнутой линии черепного шва на основе сверточных нейронных сетей // Инженерный вестник Дона, 2021, № 6.
3. Цапко И.В., Цапко С.Г. Алгоритмы и методы обработки информации в задачах трехмерного сканирования объектов // Известия Томского политехнического университета. 2010. № 5. — С. 134–140.
4. Черников Б.В., Гайдук И.О., Борисова Е.А. Проблема создания единой трехмерной модели объекта по данным многокурсового сканирования // Современные наукоемкие технологии. 2019. № 10–1. — С. 83–91.
5. Тимошев П.В., Тоньшина А.В. Применение технологии 3D сканирования при производстве изделий ракетно-космической техники // Актуальные проблемы авиации и космонавтики, 2019. — С. 283–285.
6. Logah Perumal, New approaches for Delaunay triangulation and optimisation, Heliyon, Volume 5, Issue 8, 2019, e02319, ISSN2405–8440, <https://doi.org/10.1016/j.heliyon.2019.e02319>.
7. Бредихин А.И. Алгоритмы обучения сверточных нейронных сетей // Вестник Югорского государственного университета, 2019, № 1(52).
8. Черников Б.В., Гайдук И.О., Черникова Е.А. Применение аппарата искусственных нейронных сетей в задаче определения опорных объектов для совмещения нескольких облаков точек // Информатизация и связь. 2020. № 6. — С. 7–12.
9. Li Zhichao, Wang Feng, Wang Naiyan LiDAR R-CNN: An Efficient and Universal 3D Object Detector // CVPR, 2021.
10. Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, Alex Alemi. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning // AAAI'17: Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017. — P. 4278–4284.
11. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016. — P. 770–778. doi: 10.1109/CVPR.2016.90.
12. Karen Simonyan, Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition // The 3rd International Conference on Learning Representations (ICLR2015) 2015.