

В. К. Голубцов^{1✉}, М. М. Шляхова¹

Разработка нейросетевой модели для автоматической классификации объектов на основе данных лазерного сканирования

¹Сибирский государственный университет геосистем и технологий,
г. Новосибирск, Российская Федерация
e-mail: vladgolubcov90@gmail.com

Аннотация. В статье описан процесс проектирования и обучения нейросетевой модели для автоматической классификации объектов городской среды на основе данных лазерного сканирования (LiDAR). Основное внимание уделяется этапам подготовки данных, выбора оптимальной архитектуры модели, ее обучения и оценки эффективности. Особое значение придается классификации элементов рельефа и различных урбанистических объектов, включая здания и транспортные средства. Авторы рассматривают методы предварительной обработки данных такие, как фильтрация, нормализация и аугментация, которые способствуют улучшению качества обучения модели и повышению ее устойчивости к вариациям входных данных. Проводится сравнительный анализ различных архитектур нейронных сетей, что позволяет определить наиболее подходящую архитектуру для решения задачи классификации.

Ключевые слова: лазерное сканирование, LiDAR, нейросетевые модели, классификация объектов, городская среда, машинное обучение

V. K. Golubtsov^{1✉}, M. M. Shlyakhova¹

Development of a neural network model for automatic object classification based on LiDAR data

¹Siberian State University of Geosystems and Technologies, Novosibirsk, Russian Federation
e-mail: vladgolubcov90@gmail.com

Abstract. The article provides a detailed description of the process for designing and training a neural network model to automatically classify urban objects based on laser scanning data (LiDAR). The main focus is on the stages of data preparation, selecting the optimal model architecture, training, and evaluating its effectiveness. Particular importance is attached to the classification of terrain elements and various urban objects, including buildings and vehicles. The authors examine methods of preprocessing data, such as filtering, normalization, and augmentation, which help improve the quality of model training and increase its resistance to variations in input data. A comparative analysis of several neural network architectures is presented, enabling the identification of the most suitable approach for solving the classification task.

Keywords: laser scanning, LiDAR, neural network models, object classification, urban environment, machine learning

Введение

Современные города сталкиваются с необходимостью эффективного мониторинга и управления городской инфраструктурой. Технологии лазерного ска-

нирования (LiDAR) предоставляют высокоточные трехмерные данные, позволяющие детально анализировать элементы городской среды. Однако объем и сложность таких данных требуют автоматизированных методов обработки и классификации. Применение нейросетевых моделей в задачах классификации объектов на основе данных LiDAR становится все более актуальным, обеспечивая высокую точность и скорость обработки информации [1].

Целью данного исследования является разработка нейросетевой модели, способной автоматически классифицировать объекты городской среды, включая элементы рельефа, здания и транспортные средства, на основе данных лазерного сканирования. Предполагается, что такая модель будет способствовать улучшению процессов городского планирования, мониторинга и управления инфраструктурой.

Методы и технологии

Для обучения и тестирования нейросетевой модели был сформирован синтетический датасет, смоделированный на основе открытых LiDAR-наборов (в частности, Toronto-3D, Semantic3D, DublinCity), с последующей генерацией псевдослучайных 3D-сцен в городской среде с использованием программного обеспечения Blender + BlenderGIS и библиотек Open3D и PDAL для генерации облаков точек. Для создания виртуальных урбанистических окружений использовался 3D-редактор Blender [2]. С помощью плагина BlenderGIS воссоздавались рельеф и городская инфраструктура по реальным геоданным (например, данным DEM или OpenStreetMap) [3]. Для моделирования работы лидара применялись специализированные аддоны, такие как BlenSor и BLAINDER, которые позволяют эмулировать сканирование сцены лазером и генерировать синтетические облака точек с известной семантикой объектов. Это давало полный контроль над разметкой данных и позволило формировать сбалансированные выборки по классам.

Предварительная обработка LiDAR-облаков выполнялась с помощью PDAL (Point Data Abstraction Library), которая предоставляла средства для фильтрации, трансформации, нормализации координат, удаления шумов и перевода данных в удобные форматы (PCD, PLY). Конвейерная архитектура PDAL обеспечивала автоматизацию этапов препроцессинга и их интеграцию в пайплайн машинного обучения [4]. Работа с облаками точек на этапе обучения производилась на базе библиотеки Open3D, предоставляющей высокоэффективные структуры и GPU-ускоренные алгоритмы, включая визуализацию, сегментацию, кластеризацию и интерфейс для интеграции с PyTorch и TensorFlow. Использовался проект Open3D PointNet++, адаптирующий архитектуру PointNet++ под задачи семантической сегментации LiDAR-облаков [4, 5].

Итоговый датасет содержал 1,2 млн 3D-точек, размеченных по следующим семи классам: здания, дороги, тротуары, транспортные средства, деревья, малая архитектура (лавки, урны и т. п.), рельеф (естественные формы). Каждая точка в облаке представляла собой вектор признаков, включающий пространственные координаты (X , Y , Z), интенсивность отраженного лазерного сигнала, нормали

поверхности (на основе локального соседства из 10 ближайших точек) и относительную высоту над уровнем земли.

Для повышения устойчивости модели к переобучению применялась стратегия аугментации: случайное вращение сцены вокруг оси Z, масштабирование в диапазоне от 0,9 до 1,1, добавление гауссова шума в координаты точек (дисперсия примерно 0,01 м).

Выбранная нейросетевая архитектура PointNet++ представляет собой иерархическую модель, расширяющую оригинальный PointNet за счет извлечения локальных признаков на различных масштабах. Точки группируются в локальные окрестности, для которых обучаются локальные представления, агрегируемые на более высоком уровне. Такая структура позволяет захватывать детальные особенности объектов и сохраняет точность при варьировании плотности облаков. При уменьшении числа точек с 1024 до 256 точность падает менее чем на 1 %. В дополнение к PointNet++ были реализованы и протестированы архитектуры PointCNN и KPConv. Последняя проявила лучшие результаты при детальной сегментации сложных объектов.

Обучение модели проводилось в фреймворке PyTorch на GPU NVIDIA RTX 3060 с 12 Гбайт памяти и CPU Ryzen 7 5800X. Конфигурация включала размер батча 32 200 эпох, начальный learning rate 0,001. Сцены разбивались на патчи 40×40 м, из которых выбирались подвыборки по 4096 точек. Использовался оптимизатор Adam с decay, функция потерь – кросс-энтропия, дополненная фокальным коэффициентом для борьбы с дисбалансом классов.

Для валидации использовалась отложенная часть данных (20 %). Метрики оценки включали Accuracy, Recall, Precision, F1-меру, а также среднее значение метрики IoU по классам. Сохранялась модель с наилучшим значением IoU. В табл. 1 представлены результаты оценки модели.

Таблица 1

Результаты оценки модели

Метрика	Значение
Общие показатели	
Accuracy	92,3 %
Precision	89,8 %
Recall	91,6 %
F1-score	0,90
IoU (среднее по классам)	0,81
IoU по отдельным классам	
Здания	0,94
Дороги	0,89
Машины	0,82
Деревья	0,78
Малая архитектура	0,63

Результаты

Разработанная модель продемонстрировала высокую эффективность в задаче семантической классификации объектов городской среды на основе лазерного сканирования. Средняя точность классификации достигла 92 %, а значение F1-меры составило 0,89, что свидетельствует о сбалансированной производительности модели в терминах как полноты, так и точности. Наиболее хорошие результаты были получены при распознавании крупных и структурно выраженных объектов, таких как здания и дорожное покрытие, где точность сегментации превышала 95 %. Подобная эффективность обусловлена, с одной стороны, высокой плотностью точек в этих зонах, а с другой – ярко выраженными геометрическими характеристиками данных объектов.

При классификации менее выраженных или редких классов таких как дорожные знаки, скамейки и малая архитектура, наблюдалось снижение точности до 80–85 %. Это объясняется как ограниченным представлением этих объектов в обучающем датасете, так и их малой геометрической контрастностью в облаке точек. Несмотря на это, модель демонстрировала уверенное различение классов даже при добавлении шума или уменьшении плотности данных, что подчеркивает ее устойчивость и обобщающую способность.

В рамках сравнительного анализа архитектур PointNet++, KPConv и PointCNN наилучший баланс между точностью и вычислительной эффективностью показала именно PointNet++. Она демонстрировала высокую способность к генерализации и сохраняла стабильность при обработке больших объемов данных. Архитектура KPConv показала более высокую чувствительность к мелким и сложным объектам за счет использования сверточных операций по геометрии, что делает ее перспективной для задач точной локальной сегментации. PointCNN показал умеренные результаты, уступая в производительности и точности двум другим архитектурам.

Таким образом, выбранная в работе архитектура PointNet++ представляет собой рациональный компромисс между сложностью модели, универсальностью и качеством предсказаний. Дальнейшие исследования могут быть направлены на гибридизацию моделей и адаптацию архитектуры под особенности конкретных сцен или задач.

Заключение

В рамках работы была разработана и протестирована нейросетевая модель на архитектуре PointNet++ для автоматической семантической сегментации объектов городской среды на основе LiDAR-облаков. Проведены эксперименты на синтетическом датасете, подтверждена высокая точность классификации и устойчивость к шумам и снижению плотности. Использовались библиотеки Open3D и PDAL, сцены моделировались в Blender с использованием BlenSor и BLAINDER. Модель реализована в PyTorch и обучалась на GPU RTX 3060.

PointNet++ продемонстрировал высокую точность и способность извлекать признаки на разных масштабах. Предложенный подход подтверждает перспек-

тивность глубокого обучения для LiDAR-анализов. Возможные направления дальнейшей работы включают:

- интеграцию модели в ГИС-системы (например, QGIS/ArcGIS) для поддержки мониторинга городской среды и автоматической актуализации карт;
- расширение спектра классов (мебель, транспорт, растительность) и комбинирование с другими источниками данных (оптика, радар);
- масштабирование через облачные платформы (AWS, Azure, GCP) для ускоренной обработки больших объемов данных;
- исследование новых архитектур (PointNeXt, Point Transformer) и оптимизаций (квантование, ускорение инференции).

Таким образом, предложенный подход показал высокую применимость в задачах сегментации и может служить основой для интеллектуальных систем анализа городской среды.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Колесников А. А. Анализ методов и средств искусственного интеллекта для анализа и интерпретации данных активного дистанционного зондирования / А. А. Колесников // Вестник СГУГиТ. – 2022. – Т. 27, № 3. – С. 74-94.
2. Тараховский А. Ю. Трехмерное моделирование объекта на основе данных лазерного 3D сканирования / А. Ю. Тараховский // Автоматизированное проектирование в машиностроении. – 2023. – № 14. – С. 16-19.
3. Шихов, А. Н. Геоинформационные системы: методы пространственного анализа : Учебное пособие / А. Н. Шихов, Е. С. Черепанова, С. В. Пьянков. – Пермь : Издательский центр Пермского государственного национального исследовательского университета, 2017. – 88 с.
4. Алтынцев М. А. , Геращенко Г.Д. Применение современных алгоритмов обработки данных наземного лазерного сканирования для автоматического извлечения контуров / М. А. Алтынцев, Г. Д. Геращенко // Интерэкспо Гео-Сибирь. – 2024. – Т. 1. – С. 22-30.
5. Алтынцева М. А. Автоматизированная сегментация и классификация данных мобильного лазерного сканирования для векторизации контурной части топографического плана городской территории / М. А. Алтынцева, А. В. Комиссаров, М. А. Алтынцев // Вестник СГУГиТ – 2024. – Т. 29, № 6. – С. 32-43.
6. Регистрация облаков точек в трехмерном пространстве с использованием мягкого соответствия / А. Ю. Маковецкий, В. И. Кобер, С. М. Воронин [и др.] // Информационные процессы. – 2024. – Т. 24, № 1. – С. 105-117.

© В. К. Голубцов, М. М. Шляхова, 2025