

Д. А. Гура¹, Р. А. Дьяченко^{1,3}, Т. А. Тихонов¹✉

Подход к решению проблемы дисбаланса классов облаков точек на основе генерации синтетических данных

¹Кубанский государственный технологический университет, г. Краснодар,
Российская Федерация

²Кубанский государственный аграрный университет, г. Краснодар,
Российская Федерация

³Московский физико-технический институт (национальный исследовательский университет)
Москва, Российская Федерация
e-mail: timka2015@yandex.ru

Аннотация. Рассматривается подход к повышению качества семантической сегментации облаков точек городской территории в условиях выраженного дисбаланса классов. Актуальность исследования обусловлена тем, что реальные облака точек характеризуются неравномерным распределением объектов по семантическим классам: массовые классы представлены большим числом точек, тогда как отдельные классы встречаются существенно реже. В результате модель машинного обучения демонстрирует более устойчивое распознавание доминирующих классов и недостаточную чувствительность к малопредставленным классам. В качестве исходных данных использовано размеченное облако точек территории г. Краснодара, включающее более 2 миллионов точек, размеченное на восемь классов объектов городской среды. В работе выполнено базовое обучение архитектуры PointNext, затем применены методы компенсации дисбаланса классов на уровне процесса обучения. Дополнительно предложен подход к генерации синтетических облаков точек, позволяющий управляемо изменять распределение обучающей выборки и пополнять недостаточно представленные классы.

Ключевые слова: семантическая сегментация, облака точек, городская территория, дисбаланс классов, синтетические данные, генерация облаков точек, PointNext, машинное обучение, 3D-данные, городская застройка

D. A. Gura^{1,2}, R. A. Dyachenko^{1,3}, T. A. Tikhonov¹✉

An approach to solving the problem of point cloud class imbalance based on synthetic data generation

¹Kuban State Technological University, Krasnodar, Russian Federation

²Kuban State Agrarian University, Krasnodar, Russian Federation

³Moscow Institute of Physics and Technology (National Research University) Moscow, Russia
e-mail: timka2015@yandex.ru

Abstract. This paper examines an approach to improving the quality of semantic segmentation of urban point clouds under conditions of pronounced class imbalance. The relevance of the study lies in the fact that real-world point clouds are characterized by an uneven distribution of objects across semantic classes: common classes are represented by a large number of points, while individual classes are significantly less common. As a result, the machine learning model demonstrates more robust recognition of dominant classes and insufficient sensitivity to underrepresented classes. The initial data used was a labeled point cloud of Krasnodar, comprising over 2 million points, labeled into eight urban object classes. The study performed basic training of the PointNext architecture, followed by the application of class imbalance compensation methods at the training level. Additionally, an

approach to generating synthetic point clouds is proposed, allowing for controlled changes in the distribution of the training sample and the addition of underrepresented classes.

Keywords: semantic segmentation; point clouds; urban area; class imbalance; synthetic data; point cloud generation; PointNext; machine learning; 3D data; urban development

Введение

Методы искусственного интеллекта позволяют автоматизировать обработку облаков точек и извлекать из них сведения о земной поверхности, зданиях, сооружениях, растительности и других объектах городской среды [1]. Особое значение в этом процессе имеет семантическая сегментация, обеспечивающая переход от неструктурированного массива точек к классифицированному представлению пространственной сцены. Развитие таких методов может способствовать повышению качества геопространственного анализа, совершенствованию государственного кадастрового учета и формированию предпосылок для перехода к трехмерному кадастру недвижимости [2,3].

Развитие методов семантической сегментации во многом связано с появлением крупных открытых наборов данных, задавших стандарты экспериментальной проверки алгоритмов. К их числу относятся Stanford Large-Scale 3D Indoor Spaces (S3DIS), Semantic3D, SemanticKITTI, Toronto-3D и другие бенчмарки, содержащие размеченные облака точек различного масштаба и назначения [4-7].

Одновременно с ростом объема данных особенно заметной стала проблема дисбаланса классов. В облаках точек городской территории обычно доминируют поверхности земли, покрытия, здания и растительность, тогда как небольшие объекты, инженерные элементы, автомобили, артефакты и отдельные сооружения представлены существенно меньшим числом примеров. В результате модель при обучении получает значительно больше данных для одних классов и меньше данных для формирования устойчивых признаков других классов.

Проблема дисбаланса классов имеет принципиальное значение для задач семантической сегментации. Даже при приемлемых значениях общей точности модель может демонстрировать низкое качество распознавания мало представленных классов. Поэтому оценка качества сегментации должна учитывать не только общую точность, но и средние межклассовые метрики, прежде всего IoU, F1 и mIoU.

В существующих исследованиях для компенсации дисбаланса классов в облаках точек применяются различные подходы, направленные как на изменение структуры обучающей выборки, так и на модификацию процедуры обучения модели. В частности, используются методы гибридной выборки, сочетающие увеличение числа примеров редких классов и уменьшение числа примеров доминирующих категорий, а также специальные функции потерь, усиливающие вклад низко представленных классов в процессе обучения [9]. Применяются подходы, основанные на раздельной настройке этапов выделения признаков и классификации объектов, что позволяет уменьшить смещение модели в сторону доминирующих классов. Для дополнительной компенсации дисбаланса также используются модифицированные

функции потерь, повышающие влияние редких классов на процесс оптимизации модели [9]. Проанализированные методы позволяют снизить влияние дисбаланса на этапе обучения и перераспределить внимание модели к редким классам объектов, однако они преимущественно компенсируют последствия дисбаланса, а не устраняют его первопричину, связанную с недостатком репрезентативных примеров редких классов.

Одним из перспективных направлений является дополнение обучающей выборки синтетическими данными. В отличие от классической аугментации, сгенерированные данные можно использовать не только для случайного расширения набора данных, но и для управляемого изменения его структуры. Это позволяет целенаправленно пополнять те классы, которые недостаточно представлены в реальных облаках точек, сохраняя при этом пространственную логику городской сцены.

Цель настоящего исследования заключается в повышении качества семантической сегментации объектов городской территории в облаке точек за счет настройки параметров влияющих на дисбаланс классов при обучении модели и дополнения обучающей выборки синтетическими данными. Для достижения цели решались следующие задачи: формирование и подготовка набора данных облаков точек г. Краснодара, исследование влияния параметров обучения и методов компенсации дисбаланса классов, генерация синтетических данных и оценка влияния синтетических данных на качество сегментации по основным метрикам.

Методы и материалы

В качестве исходных данных использовалось размеченное облако точек территории г. Краснодара. Система семантических классов была сформирована по аналогии с бенчмарком Semantic3D [5]. В исследовании использовались восемь классов: класс 1 - искусственные поверхности, класс 2 - естественные поверхности, класс 3 - высокая растительность, класс 4 - низкая растительность, класс 5 - здания, класс 6 - сооружения, класс 7 - артефакты, класс 8 - автомобили. Выбранная классификация позволяет описывать основные компоненты городской сцены и сопоставлять результаты с общепринятыми подходами к классификации крупномасштабных облаков точек. Набор данных включал 25 участков с общим количеством точек более 2 миллионов. Использование данных реальной городской территории позволило оценить работу модели в условиях неоднородной пространственной структуры и выраженного дисбаланса классов (рис. 1).

В качестве базовой нейросетевой архитектуры использовалась PointNext. Качество обучения оценивалось по основным метрикам: IoU, F1, Acc и mIoU. Метрика IoU характеризует степень пересечения предсказанной и истинной области класса, F1 отражает баланс полноты и точности, Acc показывает точность распознавания класса, а mIoU использовалась как основная интегральная метрика качества сегментации по всем восьми классам.




Рис. 1. Гистограмма распределения точек по классам в наборе данных

Вычислительный эксперимент включал три последовательных этапа. На первом этапе проводилось базовое обучение модели без специальных средств компенсации дисбаланса классов. На втором этапе изменялся процесс обучения: применялись стабилизация весовых коэффициентов редких классов, балансировка пространственных выборок, приоритетное обучение на фрагментах сцены с низко представленными классами и взвешивание функции потерь. На третьем этапе обучающая выборка дополнялась синтетически сгенерированными облаками точек.

Для компенсации дисбаланса на уровне обучения использовались параметры, представленные в табл. 1.

Таблица 1. Наилучшие параметры обучения для компенсации дисбаланса классов

Параметр	Значение	Назначение
class weight epsilon	0,010	Стабилизация весовых коэффициентов редких классов при вычислении функции потерь
class balanced crop	True	Балансировка пространственных фрагментов обучающих сцен
class balanced focus prob	0,7	Повышение вероятности выбора участков сцены с низко представленными классами
cls weighed loss	True	Взвешивание функции потерь для увеличения вклада редких классов

Синтетическая генерация рассматривалась как способ управляемого пополнения обучающей выборки редкими классами. Для этого на уровне генерации задавалось требуемое распределение точек по классам. Доля точек, приходящаяся на i -й класс, определялась по формуле:

$$p_i = \frac{w_i}{\sum_{j=1}^C w_j}, \quad (1)$$

где p_i - доля точек i -го класса; w_i - вес i -го класса; w_j - вес j -го класса, используемый при суммировании; C - общее число классов.

Количество точек, генерируемых для i -го класса, вычислялось как:

$$n_i = \text{round}(p_i N) + \delta_i, \quad (2)$$

где n_i - число точек i -го класса; N - заданное общее число точек синтетической сцены; δ_i - корректирующая добавка, компенсирующая ошибку округления.

Корректирующая добавка вводилась для выполнения условия:

$$\sum_{i=1}^C n_i = N, \quad (3)$$

Для учета масштаба моделируемой территории площадь сцены в гектарах определялась выражением:

$$A_{ca} = \frac{WL}{10^4}, \quad (4)$$

где A_{ca} - площадь синтетической сцены в гектарах; W - ширина моделируемой области, м; L - длина моделируемой области, м.

Ожидаемое количество объектов i -го класса задавалось формулой:

$$E_i = \max(m_i, \rho_i A_{ca}), \quad (5)$$

где E_i - ожидаемое количество объектов i -го класса; m_i - минимально допустимое число объектов i -го класса; ρ_i - плотность объектов i -го класса на один гектар.

Результаты

В результате последовательного применения базового обучения, обучения с учетом дисбаланса классов и дополнения обучающей выборки синтетическими данными были получены следующие значения IoU по классам и среднего mIoU (табл. 2).

Таблица 2

Результаты сегментации при различных подходах к компенсации дисбаланса классов

Класс	Базовое обучение, IoU, %	Обучение с учетом дисбаланса, IoU, %	Прирост после учета дисбаланса, п.п.	Обучение с синтетическими данными, IoU, %	Прирост после добавления синтетических данных, п.п.	Общий прирост, п.п.
1	65,49	70,77	+5,28	70,41	-0,36	+4,92
2	45,45	69,33	+23,88	78,31	+8,98	+32,86
3	41,77	46,61	+4,84	56,66	+10,05	+14,89
4	29,47	44,28	+14,81	63,40	+19,12	+33,93
5	47,81	72,64	+24,83	88,79	+16,15	+40,98
6	13,21	17,07	+3,86	26,12	+9,05	+12,91
7	2,51	3,60	+1,09	3,20	-0,40	+0,69
8	7,10	37,56	+30,46	52,11	+14,55	+45,01
mIoU	31.60	45.23	+13,63	54,88	+9,65	+23,28

Обсуждение

Анализ результатов показал, что учет дисбаланса классов на этапе обучения заметно улучшает качество сегментации по сравнению с базовым вариантом. Среднее значение mIoU увеличилось с 31,60 % до 45,23 %, что соответствует приросту на 13,63 п.п. Наиболее выраженное улучшение наблюдалось для классов 2, 5 и 8, что указывает на положительное влияние балансировки обучающих выборок и взвешивания функции потерь на распознавание менее устойчивых классов. Добавление искусственно сегментированных обучающих данных также улучшило показатели среднего значения mIoU до 54,88.

Заключение

Таким образом, результаты исследования показывают, что настройка параметров обучения и синтетическое пополнение обучающей выборки обладают взаимодополняющим эффектом. При этом сохранение низких значений качества по метрикам для отдельных классов указывает на необходимость дальнейшего совершенствования процедуры генерации синтетических данных и более точной настройки их распределения по классам.

Благодарности

Исследование выполнено при финансовой поддержке Кубанского научного фонда в рамках проекта № ЛАБ-24.1/2.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Гура Д. А. Возможности использования технологий 3D-идентификации объектов недвижимости в автоматизированных системах для обнаружения самовольного строительства / Д. А. Гура, Т. А. Тихонов, К. В. Зеленская, К.О. Степаненко, Е.А. Шаркова // Московский экономический журнал. 2026. Т. 11, № 1. С. 116-139. DOI: 10.55186/2413-046X-2026-116-139.
2. Гура Д. А. Возможность внедрения модуля трехмерной идентификации объектов недвижимости в сервисы национальной системы пространственных данных / Д. А. Гура, М. М. Велибекова, Т. А. Тихонов // Региональные геосистемы. 2025. Т. 49, № 2. С. 282-293. DOI: 10.52575/2712-7443-2025-49-2-282-293.
3. Гура Д.А. Методика использования воздушного лазерного сканирования и нейросетевых технологий для обеспечения достоверными пространственными данными кадастра недвижимости / Д. А. Гура, Р. А. Дьяченко, С. В. Самарин, Д. А. Беспятчук // Геодезия и картография. 2025. Т. 86, № 6. С. 54-63. DOI: 10.22389/0016-7126-2025-1020-6-54-63.
4. Armeni I., Sener O., Zamir A. R., Jiang H., Brilakis I. K., Fischer M., Savarese S. 3D Semantic Parsing of Large-Scale Indoor Spaces // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 1534-1543. DOI: 10.1109/CVPR.2016.170.
5. Hackel T., Savinov N., Ladicky L., Wegner J. D., Schindler K., Pollefeys M. Semantic3D.net: A New Large-Scale Point Cloud Classification Benchmark // ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2017. Vol. IV-1/W1. P. 91-98. DOI: 10.5194/isprs-annals-IV-1-W1-91-2017.
6. Behley J., Garbade M., Milioto A., Quenzel J., Behnke S., Stachniss C., Gall J. SemanticKITTI: A Dataset for Semantic Scene Understanding of LiDAR Sequences // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). 2019. P. 9296-9306. DOI: 10.1109/ICCV.2019.00939.
7. Tan W., Qin N., Ma L., Li Y., Du J., Cai G., Yang K., Li J. Toronto-3D: A Large-Scale Mobile LiDAR Dataset for Semantic Segmentation of Urban Roadways // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). 2020. DOI: 10.1109/CVPRW50498.2020.00109.
8. Lin H.-I., Nguyen M. C. Boosting Minority Class Prediction on Imbalanced Point Cloud Data // Applied Sciences. 2020. Vol. 10, No. 3. Art. 973. DOI: 10.3390/app10030973.
9. Li M., Lin S., Wang Z., Shen Y., Zhang B., Ma L. Class-Imbalanced Semi-Supervised Learning for Large-Scale Point Cloud Semantic Segmentation via Decoupling Optimization // Pattern Recognition. 2024. Vol. 156. Art. 110701. DOI: 10.1016/j.patcog.2024.110701.

© Д. А. Гура, Р. А. Дьяченко, Т. А. Тихонов, 2026