

Р. А. Дьяченко^{1,2}, Д. А. Гура^{1,3}, С. А. Ярутин^{2✉}, Т. А. Тихонов²

Подход к формированию синтетических данных лазерного сканирования промышленных объектов

¹Московский физико-технический институт (национальный исследовательский университет),
г. Москва, Российская Федерация

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

³Кубанский государственный аграрный университет, г. Краснодар, Российская Федерация
e-mail: yarutinsa@yandex.ru

Аннотация. Рассматривается метод генерации синтетических LiDAR-облаков точек промышленных объектов для задач машинного обучения. Предложен параметрический подход, основанный на иерархическом представлении сцены, биом-ориентированном моделировании функциональных зон и имитации лазерного сканирования методом трассировки лучей. Реализовано формирование семантически размеченных промышленных сцен и облаков точек с контролируемыми характеристиками плотности, покрытия и окклюзий. Сформирован датасет объемом порядка $1,8 \times 10^8$ точек при 48 позициях сканирования и 12 семантических классах. Оценка качества по метрикам сегментации и геометрической реконструкции показала значения Accurasy до 0,96, IoU до 0,87 и RMSE до 0,056 м. Установлено повышение качества сегментации на 8–15% при использовании синтетических данных. Полученные результаты подтверждают пригодность предложенного подхода для обучения и валидации алгоритмов обработки LiDAR-облаков точек промышленных объектов.

Ключевые слова: LiDAR, облака точек, синтетические данные, машинное обучение, промышленный объект, лазерное сканирование, семантическая разметка, параметрическая генерация, 3D-реконструкция, BIM-моделирование

R. A. Dyachenko^{1,2}, D. A. Gura^{1,3}, S. A. Yarutin^{2✉}, T. A. Tikhonov²

An approach to the formation of synthetic laser scanning data for industrial facilities

¹Moscow Institute of Physics and Technology (National Research University),
Moscow, Russian Federation

²Kuban State Technological University, Krasnodar, Russian Federation

³Kuban State Agrarian University, Krasnodar, Russian Federation
e-mail: yarutinsa@yandex.ru

Abstract. A method for generating synthetic LiDAR clouds of points of industrial facilities for machine learning tasks is considered. A parametric approach based on a hierarchical representation of the scene, biome-oriented modeling of functional zones and simulation of laser scanning by ray tracing is proposed. The formation of semantically marked industrial scenes and clouds of points with controlled characteristics of density, coverage and occlusions is implemented. A dataset has been formed with a volume of about 1.8×10^8 points with 48 scanning positions and 12 semantic classes. The quality assessment based on segmentation and geometric reconstruction metrics showed Accuracy values up to 0.96, IoU up to 0.87, and RMSE up to 0.056 m. An increase in segmentation quality by 8–15% was found when using synthetic data. The results obtained confirm the suitability of the

proposed approach for training and validating algorithms for processing LiDAR clouds of points of industrial facilities.

Keywords: LiDAR, point clouds, synthetic data, machine learning, industrial facility, laser scanning, semantic markup, parametric generation, 3D reconstruction, BIM modeling

Введение

Предлагаемый подход основан на процедурной генерации промышленной сцены с параметрически управляемой пространственной структурой. Формирование сцены выполняется на основе иерархического представления, включающего планировочную структуру, функциональные зоны и внутреннее технологическое наполнение. Параметризация обеспечивает управление плотностью размещения объектов, типами конструкций и пространственной организацией сцены. В состав генерируемых объектов входят промышленное оборудование, трубопроводные системы, инженерные коммуникации и строительные конструкции.

Моделирование лазерного зондирования реализуется посредством имитации работы LiDAR-сканеров с использованием трассировки лучей [1]. Выполняется размещение станций сканирования, моделирование процесса съёмки и формирование облаков точек с учётом физических эффектов, включая шумы измерения, окклюзии и неоднородность распределения плотности. Результирующие данные формируются в формате PLY с автоматической классовой разметкой объектов [2].

Программная реализация включает модуль генерации сцены, подсистему моделирования LiDAR-сканирования и средства экспорта данных. Архитектура обеспечивает возможность пакетной генерации датасетов, масштабирование объёма данных и вариативность параметров сцены и сканирования [3, 4].

В результате работы сформирован набор синтетических облаков точек промышленных объектов с полной семантической разметкой и контролируемыми характеристиками. Обеспечена вариативность геометрии и конфигурации сцен, а также подтверждена пригодность данных для обучения моделей машинного обучения и тестирования алгоритмов обработки облаков точек.

Практическая значимость работы заключается в снижении затрат на получение размеченных LiDAR-данных и возможности моделирования редких, сложных и труднонаблюдаемых сценариев [5]. Предлагаемый подход может применяться в задачах мониторинга промышленных объектов, построения цифровых двойников и анализа данных дистанционного зондирования Земли [6].

Полученные результаты показывают, что предложенная методика позволяет формировать синтетические сцены, адекватно воспроизводящие особенности лазерного сканирования промышленных объектов. Разработанный подход обеспечивает решение проблемы дефицита размеченных данных и может использоваться для разработки, обучения и валидации алгоритмов обработки облаков точек.

Методы

Предлагаемый подход основан на процедурной генерации промышленной сцены, формализуемой как иерархическая параметрическая система

$$S = (V, E, A),$$

где V – множество элементов сцены, E – множество связей между ними, A – множество геометрических и семантических атрибутов [7]. Генерация сцены рассматривается как отображение параметрического пространства в множество допустимых конфигураций:

$$S = G(\Theta),$$

где G – оператор генерации, Θ – вектор параметров сцены [8]. В состав параметров входят характеристики планировочной структуры, распределения функциональных зон, плотности размещения объектов и пространственной организации сцены [9, 10].

Формирование сцены выполняется на основе биом-ориентированного подхода, при котором каждому помещению сопоставляется функциональная зона

$$B_k = \{C_k, D_k, R_k\},$$

где C_k – множество допустимых классов объектов, D_k – параметры плотности и распределения, R_k – ограничения размещения [11]. Для технологических биомов характерны высокая плотность объектов, многоуровневое размещение оборудования и развитая система инженерных коммуникаций [12]. Плотность размещения объектов определяется как

$$\rho_k = \frac{N_k}{V_k},$$

где N_k – число объектов, V_k – объём помещения.

Генерация инженерной инфраструктуры выполняется на основе графового представления технологических связей

$$G_p = (V_p, E_p),$$

где вершины соответствуют единицам оборудования, а рёбра определяют наличие трубопроводных или кабельных соединений. Геометрия коммуникаций формируется посредством трассировки пространственных траекторий между связанными объектами с учётом ограничений сцены и минимальных расстояний.

Моделирование лазерного зондирования реализуется посредством имитации работы LiDAR-сканеров методом трассировки лучей. Пространство сцены предварительно преобразуется в совокупность осесовмещённых ограничивающих объёмов (AABB), используемых при вычислении пересечений лучей с объектами сцены [13]. Для каждой станции сканирования формируется множество точек

$$P_s = \{p_i(x_i, y_i, z_i, c_i)\},$$

где x_i, y_i, z_i — координаты точки, c_i — её семантический класс.

Размещение станций сканирования формализуется как задача покрытия множества целевых областей:

$$S^* \subseteq P,$$

где P — множество кандидатных позиций, S^* — подмножество станций, обеспечивающее максимальное покрытие сцены при минимальной избыточности наблюдений [14]. В процессе моделирования учитываются шумы измерения, окклюзии, ограничения поля зрения и неоднородность распределения плотности точек.

Формирование результирующего датасета включает генерацию per-station облаков точек с последующим объединением в интегральное облако:

$$P = \bigcup_{s \in S} P_s.$$

Экспорт данных реализован в формате PLY с автоматической семантической разметкой. Каждой точке сопоставляется идентификатор класса, формируемый на основе принадлежности соответствующего геометрического примитива [15].

Программная реализация включает модуль генерации сцены, подсистему моделирования LiDAR-сканирования и модуль экспорта данных. Архитектура поддерживает пакетную генерацию датасетов, вариативность параметров сцены и масштабирование объёма данных.

Заключение

В работе предложена методика генерации синтетических LiDAR-облаков точек промышленных объектов для задач машинного обучения, основанная на параметрическом моделировании сцены и имитации процесса лазерного сканирования. Разработанный подход обеспечивает формирование иерархически структурированных промышленных сцен с автоматической семантической разметкой и последующей генерацией облаков точек с контролируемыми характеристиками плотности, покрытия и окклюзий.

В рамках исследования реализована процедурная генерация промышленной сцены, включающая формирование планировочной структуры, распределение функциональных биомов, генерацию инженерной инфраструктуры и моделирование технологических связей между объектами. Выполнена интеграция модели сцены с симуляцией LiDAR-сканирования методом трассировки лучей, учитывающей эффекты окклюзий, неоднородности плотности и ограничений поля зрения.

Сформирован синтетический LiDAR-датасет промышленного объекта, включающий 48 позиций сканирования и порядка $1,8 \times 10^8$ точек при среднем значении $3,75 \times 10^6$ точек на одну станцию. Датасет содержит 12 семантических классов и полностью размечен без использования ручной аннотации.

Проведённый анализ показал, что увеличение числа станций сканирования с 4 до 48 приводит к росту полноты покрытия сцены с 82% до 99% и снижению доли слепых зон с 18% до 1%. Установлено существование области насыщения в диапазоне 24–32 станций, при которой дальнейшее увеличение числа наблюдений приводит к росту избыточности данных без существенного улучшения покрытия.

Оценка качества данных на задачах семантической сегментации и геометрической реконструкции показала значения Ассигасы до 0,96, IoU до 0,87 и RMSE до 0,056 м. Наиболее высокие значения метрик достигаются для конструктивных элементов сцены, тогда как для трубопроводов и кабельных трасс наблюдается снижение Ассигасы до 0,89–0,91 и IoU до 0,72–0,76 вследствие высокой геометрической сложности и влияния окклюзий.

Сравнение с реальными LiDAR-данными промышленного объекта показало преимущества синтетического подхода, включая полную семантическую разметку, наличие эталонной геометрии и контролируемый уровень шумов. Дополнительно установлено, что использование синтетического датасета позволяет повысить качество сегментации на 8–15% по метрикам IoU и Ассигасы.

Полученные результаты подтверждают, что предложенная методика обеспечивает формирование воспроизводимых, структурно согласованных и параметрически управляемых LiDAR-данных, пригодных для обучения и валидации алгоритмов обработки облаков точек. Разработанный подход может применяться в задачах цифрового моделирования промышленных объектов, построения BIM-моделей, мониторинга инфраструктуры и создания цифровых двойников.




Рис. 1. Сравнение реального и синтетического LiDAR-облака промышленного объекта

Благодарности

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

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Optimal Placement of Laser Scanning Stations for Organizing Work on Three-Dimensional Identification of Objects in Space / D. Gura, R. Dyachenko, S. Yarutin, A. Makaryan // Lecture Notes in Networks and Systems : Advances in Interdisciplinary Approaches for Complex Problem Solving,

- Krasnoyarsk, 02–04 декабря 2024 года. – Krasnoyarsk: Springer Nature, 2025. – P. 518-527. – DOI 10.1007/978-3-031-95649-2_45. – EDN ZVWDSX.
2. Ruizhongtai Qi, Charles & Su, Hao & Mo, Kaichun & Guibas, Leonidas. (2016). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. 10.48550/arXiv.1612.00593.
 3. Hackel, T. & Savinov, Nikolay & Ladicky, L. & Wegner, J. & Schindler, Konrad & Pollefeys, Marc. (2017). SEMANTIC3D.NET: A NEW LARGE-SCALE POINT CLOUD CLASSIFICATION BENCHMARK. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. IV-1/W1. 91-98. 10.5194/isprs-annals-IV-1-W1-91-2017.
 4. Гайдамака, К. И. Применение алгоритмов машинного обучения в задачах контроля качества требований / К. И. Гайдамака // Информационные технологии и вычислительные системы. – 2023. – № 1. – С. 87-96. – DOI 10.14357/20718632230109. – EDN OXNYSX.
 5. Димитриенко, Ю. И. Разработка генератора тетраэдральных сеток на основе триангуляции Делоне с ограничениями / Ю. И. Димитриенко, И. О. Богданов // Информационные технологии. – 2023. – Т. 29, № 5. – С. 257-266. – DOI 10.17587/it.29.257-266. – EDN НКYYNP.
 6. Методика построения оптимального маршрута при проведении работ по сканированию территории / Д. А. Гура, Р. А. Дьяченко, С. А. Ярутин, А. С. Макарян // Вестник СГУГиТ (Сибирского государственного университета геосистем и технологий). – 2025. – Т. 30, № 5. – С. 89-100. – DOI 10.33764/2411-1759-2025-30-5-89-100. – EDN IUGKJH.
 7. Armeni, Iro & He, Zhi-Yang & Zamir, Amir & Gwak, Junyoung & Malik, Jitendra & Fischer, Martin & Savarese, Silvio. (2019). 3D Scene Graph: A Structure for Unified Semantics, 3D Space, and Camera. 5663-5672. 10.1109/ICCV.2019.00576.
 8. Ros, German & Sellart, Laura & Materzynska, Joanna & Vázquez, David & López, Antonio. (2016). The SYNTHIA Dataset: A Large Collection of Synthetic Images for Semantic Segmentation of Urban Scenes. 3234-3243. 10.1109/CVPR.2016.352.
 9. Richter, Stephan & Vineet, Vibhav & Roth, Stefan & Koltun, Vladlen. (2016). Playing for Data: Ground Truth from Computer Games. LNCS. 9906. 10.1007/978-3-319-46475-6_7.
 10. Random Number Generation and Monte Carlo Methods Gentle J. E. Random Number Generation and Monte Carlo Methods. 2nd ed. New York: Springer, 2003. 382 p. DOI: <https://doi.org/10.1007/b97336>.
 11. Алтынцев, М. А. Особенности построения трехмерных метрических моделей по данным лазерного сканирования / М. А. Алтынцев, П. А. Карпик // Интерэкспо Гео-Сибирь. – 2020. – Т. 4, № 1. – С. 113-122. – DOI 10.33764/2618-981X-2020-4-1-113-122. – EDN OFYQJV.
 12. Armeni, Iro & Sener, Ozan & Zamir, Amir & Jiang, Helen & Brilakis, Ioannis & Fischer, Martin & Savarese, Silvio. (2016). 3D Semantic Parsing of Large-Scale Indoor Spaces. 1534-1543. 10.1109/CVPR.2016.170.
 13. Wald, Johanna & Dhano, Helisa & Navab, Nassir & Tombari, Federico. (2020). Learning 3D Semantic Scene Graphs From 3D Indoor Reconstructions. 3960-3969. 10.1109/CVPR42600.2020.00402.
 14. Fisher, Matthew & Ritchie, Daniel & Savva, Manolis & Funkhouser, Thomas & Hanrahan, Pat. (2012). Example-based Synthesis of 3D Object Arrangements. ACM Transactions on Graphics (TOG). 31. 10.1145/2366145.2366154.
 15. Мультикритериальный подход к выбору параметров дискретизации для оптимального размещения станций наземного лазерного сканера / Д. А. Гура, Р. А. Дьяченко, С. А. Ярутин, Т. А. Тихонов // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. – 2025. – № 211. – С. 458-474. – DOI 10.21515/1990-4665-211-038. – EDN EXIAKC.

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