

УДК 004.896

DOI 10.35211/1990-5297-2024-4-287-20-26

*Т. Б. Бахов, С. А. Воротников***ИСПОЛЬЗОВАНИЕ СИНТЕТИЧЕСКИХ ДАННЫХ
ДЛЯ ФИЛЬТРАЦИИ ЧАСТИЦ СНЕГА В ЛИДАРНОМ ОБЛАКЕ ТОЧЕК****Московский государственный технический университет им. Н. Э. Баумана**

tamerlan.baxov@mail.ru

В статье рассматривается использование синтетических данных из симулятора CARLA для обучения алгоритма фильтрации снега в облаке точек с лидара, используемого в качестве основного сенсора беспилотного автомобиля или автономного мобильного outdoor-робота.

Ключевые слова: беспилотный автомобиль, автономный мобильный outdoor-робот, компьютерное зрение, фильтрация облака точек, плохие погодные условия, лидар, симулятор.

*T. B. Bahov, S. A. Vorotnikov***UTILIZATION OF SYNTHETIC DATA
FOR SNOW PARTICLES FILTRATION IN A LIDAR POINT CLOUD****Bauman Moscow State Technical University**

The article discusses the use of synthetic data from the CARLA simulator to train an algorithm for snow filtration in a LIDAR point cloud used as the main sensor of a self-driving car or autonomous mobile outdoor robot.

Keywords: self-driving car, autonomous mobile outdoor robot, computer vision, pointcloud denoising, adverse weather conditions, LIDAR, CARLA simulator.

Введение

В настоящее время в мире активно развиваются методы и средства автономного движения автомобилей (*self-driving cars*) и мобильных роботов (*autonomous mobile outdoor robots*). Первые системы появились еще в 80-х годах XX века, но наиболее энергично такие работы стали проводиться с 2004 года, когда департамент американских военных исследований по продвинутым проектам обороны (*DARPA*) организовал первый *DARPA Grand Challenge*, междисциплинарное соревнование самоуправляемых автомобилей. Уже тогда команда из Стэнфордского университета [1], победившая в *DARPA Grand Challenge* 2005 года, использовала в своем решении методы машинного обучения, построения пути и одновременной локализации и построения карты (*SLAM – Simultaneous Localization and Mapping*), подходы, получившие широкое распространение и используемые в наши дни [2]. Конструкции датчиков для беспилотных автомобилей (*autonomous vehicles – AV*) за последние 20 лет претерпели значительные усовершенствования, однако самым лучшим и незаменимым по-прежнему является сканирующий лазерный дальномер – лидар (*lidar*).

Современный лидар – это сложное оптико-механическое устройство, включающее несколько десятков пар лазерных излучателей

и приемников, вращающихся вокруг вертикальной оси, что позволяет сканировать рабочее пространство в широком телесном угле и на большом расстоянии. Опыт эксплуатации лидара продемонстрировал, что наряду с замечательными показателями точности он подвержен влиянию атмосферных осадков, изменяющих оптические свойства среды распространения лазерного луча – дождя, тумана, снега. Помехи, вызванные этими факторами, существенно снижают точность работы лидара и ухудшают надежность AV в целом. Данная проблема особенно актуальна для России, где существует несколько климатических поясов с неустойчивой погодой в каждом из них.

В настоящее время ведутся исследования по повышению точности лидаров, работающих в условиях помех различной природы и повышения надежности построения карты. С этой целью в существующих методах машинного обучения анализируется использование различных алгоритмов фильтрации [3]. Однако ограниченное количество и качество датасетов существенно усложняет эффективность этих исследований. Создание же новых датасетов – трудоемкая задача, требующая подходящей погоды, проведения серии выездов и последующей монотонной разметки данных. Кроме того, лидары, установленные на различных AV, отли-

чаются друг от друга количеством лучей, их распределением, вертикальными углами обзора и паттернами сканирования. Поэтому для каждого из них требуется свой специфичный датасет, и в случае замены лидара в AV на другой, весь процесс нужно проходить с нуля.

Одним из возможных решений данной проблемы является использование симулятора и моделирование атмосферных осадков, например, снега в лидарном облаке точек.

В данной работе проверяется возможность использования искусственного датасета для обучения нейросетевого алгоритма фильтрации снега для его применения в реальных условиях.

Анализ предметной области

Использование синтетических данных для обучения нейронных сетей является широко распространенным методом в компьютерном зрении (*computer vision*) [4–6] и обучении с подкреплением (*reinforcement learning*) [7, 8] в ситуациях отсутствия датасета, трудоемкости его сбора и невозможности или опасности моделирования ряда ситуаций в реальной жизни.

Для создания искусственных датасетов активно применяются игровые движки *Unity* и *Unreal Engine* [9–11], специализированные симуляторы [12–14] и даже игры (как, например, *GTA V*) [15–17]. Однако учет атмосферных осадков, таких как туман, дождь или снег, требует более детального моделирования «физики работы» сенсоров, что обычно не закладывается в симуляторы. В текущей работе круг этих явлений будет сужен до падающего снега. В таком случае используют несколько вариантов решений.

Первый из них – использование открытых датасетов, записанных в снежную погоду [18–23]. Большая часть из них записана в Канаде или Северной части США [18, 20, 23]. В основном использовались 32-лучевые лидары [20–22], но есть и датасеты, содержащие также 64-лучевые [18, 21] и даже 128-лучевой [23] лидары. Однако каждый из них использует определенный тип сенсора, задающий геометрическое расположение лучей и получаемую карту, а сбор датасетов, как в [24] с использованием множества лидаров, будет кратно дороже.

Второй вариант связан с использованием алгоритмов моделирования снега в лидарном облаке точек. Впервые такой подход и его программная реализация для частиц снега были предложены в [34]. Исследователи в [35] дора-

ботали предложенный подход, улучшив моделирование физики процесса посредством более точного вычисления интенсивности и наложения отражений от различных частиц. Данный способ использовался для обучения [25]; в нем с помощью [35] был аугментирован снегом датасет *KITTI* [26] для получения *SnowyKITTI*.

И, наконец, третий вариант заключается в использовании алгоритмов адаптации предметной области (*domain adaptation*) [29, 30, 31]. Основа этих методов заключается в использовании архитектуры GAN [27] и ее вариаций. Авторы [29] были первыми, кто исследовал преобразование из симуляционных данных лидара в *CARLA* к синтетическим облакам точек в формате *KITTI* [26], используя фреймворк *CycleGAN* [28]. Аналогичным образом в работе [30] осуществили преобразование облаков точек между солнечными, дождливыми и туманными погодными условиями. Исследователи в [32] предложили модель, которая не только способна уменьшать снежный шум в облаке точек, но и искусственно синтезировать снежные точки для лидара. К сожалению, описанные подходы с трудом поддаются обобщению, поскольку данные, искаженные погодой, в целом, а не только размеченные данные, недопредставлены.

В данной работе рассматривается синтез алгоритма моделирования снега на основе «физики процесса» и искусственных данных, полученных в симуляторе.

Формирование датасета

Формирование искусственного датасета осуществлялось в два этапа. На первом этапе производилась запись данных в симуляторе, а на втором – их аугментация снегом с использованием алгоритма моделирования снега в облаке точек.

В качестве симулятора для записи датасета был выбран симулятор *CARLA* [14] – широко распространенный для работы с AV. *CARLA* имеет несколько различных сцен города и позволяет моделировать такие сенсоры, как лидар, камера, радар, *IMU*, *GNSS* и другие. В данной работе моделировался 64-лучевой лидар с равномерным распределением лучей в вертикальном диапазоне от -25° до 15° , вращающийся с частотой 20 Гц и установленный на высоте 2,4 м над землей.

Симулятор *CARLA* имеет 12 различных локаций. Часть из них закрыта для использования, а другая часть не подходит для записи датасета.




Рис. 1. Маршруты записи датасета в симуляторе CARLA в локациях 1–7

В данной работе были использованы 7 первых локаций. Автомобиль с установленным на нем лидаром ездил по маршрутам, указанным на рис. 1. Во время езды записывался *bag*-файл. Далее *bag*-файл считывался, и облака точек сохранялись как *numpy*-массив в бинарном файле.

Структура искусственного датасета формировалась по подобию датасета WADS [18]. Из сохраненных облаков было сформировано 20 сцен примерно по 100 облаков в каждой. Особенностью датасета является то, что в нем отсутствуют динамические объекты – другие автомобили и пешеходы.

После записи данных и их сохранения в нужной структуре облака точек аугментировались снегом. Для моделирования снега использовался алгоритм из [35]. Оригинальный алгоритм был рассчитан на лидар *Velodyne HDL-64E* и его поправки. Для использования в искусственном датасете поправки были модифицированы. Также были выбраны параметры снегопада, указанные в табл. 1. В результате был сформирован датасет из 20 сцен по ~100 облаков, запи-

санный в 7 разных локациях и аугментированный снегом.

Таблица 1

Параметры модели для аугментации облака точек частицами снега

Скорость снегопада, мм/ч	0,01
Конечная скорость, м/с	0,2
Плотность снега, г/см ³	0,01
Максимальный диаметр частиц, мм	1
Максимальный радиус видимости снега в лидаре, м	20

Обучение

В качестве нейросетевого алгоритма фильтрации был выбран *LiSnowNet* [33]. *LiSnowNet* отличается высокой скоростью работы (порядка 16 мс) и использованием неразмеченных данных для обучения. В оригинальной статье он обучался на датасетах *CADCD* [20] и *WADS*. В текущей работе искусственный датасет был сформирован по структуре *WADS*. Обучение

производилось в течение 30 эпох. Датасет был разбит на обучающий и тестовый в соотношении (80/20) % соответственно. Размер батча составлял 8, скорость обучения (*learning rate*) – 0,001; затухание скорости (*learning rate decay*) – 0,89. Качество обучения и работы оценивалось на валидационной части датасета WADS.

Используемая в данной работе архитектура отличается от исходной. Облако точек в датасете WADS в формате дальностного изображения имеет размер 64x2048. Здесь размер входного облака составляет 64x900. Ввиду изменения размера входа были удалены четыре глубинных слоя – два для кодирования и два для декодирования, что упростило структуру сети. Также величина ошибки DWT (*Discrete Wavelet Transform* – дискретное вейвлет-преобразование) считается для меньшего количества итераций – поскольку ширина входного изображения нейросети кратна только 2^2 .

Обучение производилось на современном ноутбуке с процессором *Intel Core i7-12700 H* и видеокартой *NVIDIA GeForce RTX 3070 Ti*. Процесс обучения отражен на рис. 2.

Обученная модель также была оценена на датасете WADS. Поскольку размер изображения в WADS составляет 64x2048, а в искусственном датасете он равен 64x900, то были проведены дополнительные операции для их сведения к одному размеру. Все манипуляции производились максимально равномерно, чтобы не вносить существенных искажений в результат. Сперва из исходного изображения облака был взят каждый второй угол по азимуту, что привело к получению размера 64x1024. Далее из него было удален каждый 10-й столбец, что привело к получению размера 64x910. На заключительном этапе был удален каждый 91-й, дав целевой размер 64x900.

Результаты работы сети, в том числе и на преобразованном датасете WADS, показаны в табл. 2.




Рис. 2. Графики изменения ошибки (*loss*) в процессе обучения (сверху) и тестирования (снизу) сети *LiSnowNet*

Таблица 2

Сравнение моделей

Датасет*	Точность (<i>precision</i>)	Полнота (<i>recall</i>)	Время работы, мс
WADS/WADS	0.9249	0.9501	4.1328
CARLA/CARLA	1.0	0.7049	1.6467
CARLA/WADS	0.6265	0.9937	2.0244

* В числителе – датасет, на котором модель обучалась; в знаменателе – на котором тестировалась.

Как следует из табл. 2, сеть, обученная на искусственных данных, работает несколько хуже, чем на реальном датасете. В частности, точность снизилась на 30 %, а полнота стала выше на 5 %. Снижение точности говорит о том, что у сети увеличилось количество ложных срабатываний – она относит к снегу точки, которые им не являются. Повышенная полнота

отражает тот факт, что сеть очень хорошо обнаруживает частицы снега. Время работы сети, обученной на искусственном датасете, меньше, но это объясняется двумя факторами: 1) размер входного изображения меньше; 2) в сети меньше слоев.

Качественный результат работы сети показан на рис. 3 и 4.




Рис. 3. Качественный результат работы сети *LiSnowNet* на облаке из искусственного датасета. Слева – исходное облако (вид сверху); справа – после фильтрации

Рис. 3 отражает работу сети на искусственном датасете, а рис. 4 – на датасете *WADS*.




Рис. 4. Качественный результат работы сети *LiSnowNet*, обученной на искусственном датасете, на облаке из *WADS*. Слева – исходное облако (вид сверху); справа – после фильтрации

По рисункам можно заметить, что распределения лучей у лидаров значительно отличаются. Также стоит обратить внимание, что ин-

тенсивность снега в *WADS* намного выше. Тем не менее визуально сеть отфильтровала все частицы снега несмотря на различия.

Заключение

В данной работе было проведено исследование возможности использования синтетического датасета для обучения модели фильтрации частиц снега в лидарном облаке точек с последующей валидацией результата.

Получившиеся качественные и количественные результаты свидетельствуют о том, что подобный подход позволяет получить модель, выполняющую свои функции. Однако при его использовании наблюдается и некоторое снижение качества.

Отметим также, что было принято несколько допущений, которые могли повлиять на конечный результат. В дальнейшем для уточнения результата планируется использовать датасет с наличием динамических объектов и других участников движения, а также дополнить модель слоями вместо удаленных для более глубокого обучения.

Исследование и использование данного подхода позволит сократить время внедрения фильтров в реальные беспилотные системы при их создании или изменении конфигурации сенсоров.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Thrun, S.* Stanley : The robot that won the DARPA Grand Challenge / S. Thrun et al. // *Journal of field Robotics.* – 2006. – Т. 23. – № 9. – С. 661–692.
2. *Debeunne, C.* A review of visual-LiDAR fusion based simultaneous localization and mapping / C. Debeunne, D. Vivet // *Sensors.* – 2020. – Т. 20. – № 7. – С. 2068.
3. *Cheng, Q.* Robust Lidar SLAM Under Adverse Weather : дис. – 2023.
4. *Nikolenko, S. I.* Synthetic data for deep learning // *arXiv preprint arXiv:1909.11512.* – 2019.
5. *Man, K.* A Review of Synthetic Image Data and Its Use in Computer Vision / K. Man, J. Chahl // *Journal of Imaging.* – 2022. – Т. 8. – № 11. – С. 310.
6. *Manettas, C.* Synthetic datasets for Deep Learning in computer-vision assisted tasks in manufacturing / C. Manettas, N. Nikolakis, K. Alexopoulos // *Procedia CIRP.* – 2021. – Т. 103. – С. 237–242.
7. *Osiński, B.* Simulation-based reinforcement learning for real-world autonomous driving / B. Osiński et al. // 2020 IEEE international conference on robotics and automation (ICRA). – IEEE, 2020. – С. 6411–6418.
8. *Kim, D.* Digital twin for autonomous collaborative robot by using synthetic data and reinforcement learning / D. Kim, M. Choi, J. Um // *Robotics and Computer-Integrated Manufacturing.* – 2024. – Т. 85. – С. 102632.
9. *Gaidon, A.* Virtual worlds as proxy for multi-object tracking analysis / A. Gaidon et al. // *Proceedings of the IEEE conference on computer vision and pattern recognition.* – 2016. – С. 4340–4349.
10. *Ros, G.* The synthia dataset : A large collection of synthetic images for semantic segmentation of urban scenes / G. Ros et al. // *Proceedings of the IEEE conference on computer vision and pattern recognition.* – 2016. – С. 3234–3243.
11. *Saleh, F. S.* Effective use of synthetic data for urban scene semantic segmentation / F. S. Saleh et al. // *Proceedings of the European Conference on Computer Vision (ECCV).* – 2018. – С. 84–100.
12. *Lai, K. T.* Vivid : Virtual environment for visual deep learning / K. T. Lai et al. // *Proceedings of the 26th ACM international conference on Multimedia.* – 2018. – С. 1356–1359.
13. *Shah, S.* Airsim : High-fidelity visual and physical simulation for autonomous vehicles / Shah S. et al. // *Field and Service Robotics: Results of the 11th International Conference.* – Springer International Publishing, 2018. – С. 621–635.
14. *Dosovitskiy, A.* CARLA : An open urban driving simulator / A. Dosovitskiy et al. // *Conference on robot learning.* – PMLR, 2017. – С. 1–16.
15. *Richter, S. R.* Playing for benchmarks / S. R. Richter, Z. Hayder, V. Koltun // *Proceedings of the IEEE International Conference on Computer Vision.* – 2017. – С. 2213–2222.
16. *Richter, S. R.* Playing for data : Ground truth from computer games / S. R. Richter et al. // *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part II 14.* – Springer International Publishing, 2016. – С. 102–118.
17. *Hurl, B.* Precise synthetic image and lidar (presil) dataset for autonomous vehicle perception / B. Hurl, K. Czarnecki, S. Waslander // 2019 IEEE Intelligent Vehicles Symposium (IV). – IEEE, 2019. – С. 2522–2529.
18. *Kurup, A. & Bos, J.* (2021). The Winter Adverse Driving dataSet (WADS). Retrieved from: <https://digitalcommons.mtu.edu/wads/>
19. *Kurup, A.* Dsor : A scalable statistical filter for removing falling snow from lidar point clouds in severe winter weather / A. Kurup, J. Bos // *arXiv preprint arXiv:2109.07078.* – 2021.
20. *Pitropov, M.* Canadian adverse driving conditions dataset / M. Pitropov et al. // *The International Journal of Robotics Research.* – 2021. – Т. 40. – № 4–5. – С. 681–690.
21. *Bijelic, M.* Seeing through fog without seeing fog : Deep multimodal sensor fusion in unseen adverse weather / M. Bijelic et al. // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.* – 2020. – С. 11682–11692.
22. *Sheeny, M.* RADIATE: A Radar Dataset for Automotive Perception / M. Sheeny et al. // *arXiv preprint arXiv:2010.09076.* – 2020.
23. *Burnett K. et al.* Boreas: A Multi-Season Autonomous Driving Dataset.
24. *Carballo, A.* LIBRE : The multiple 3D LiDAR dataset / A. Carballo et al. // 2020 IEEE Intelligent Vehicles Symposium (IV). – IEEE, 2020. – С. 1094–1101.
25. *Seppänen, A.* 4denoisenet : Adverse weather denoising from adjacent point clouds / A. Seppänen, R. Ojala, K. Tammi // *IEEE Robotics and Automation Letters.* – 2022. – Т. 8. – № 1. – С. 456–463.
26. *Geiger, A.* Vision meets robotics : The kitti dataset / A. Geiger et al. // *The International Journal of Robotics Research.* – 2013. – Т. 32. – № 11. – С. 1231–1237.
27. *Goodfellow, I.* Generative adversarial nets / I. Goodfellow et al. // *Advances in neural information processing systems.* – 2014. – Т. 27.
28. *Zhu, J. Y.* Unpaired image-to-image translation using cycle-consistent adversarial networks / J. Y. Zhu et al. // *Proceedings of the IEEE international conference on computer vision.* – 2017. – С. 2223–2232.

29. *Sallab, A. E.* LiDAR Sensor modeling and Data augmentation with GANs for Autonomous driving / A. E. Sallab et al. // arXiv preprint arXiv:1905.07290. – 2019.

30. *Lee, J.* Gan-based lidar translation between sunny and adverse weather for autonomous driving and driving simulation / J. Lee et al. // *Sensors*. – 2022. – Т. 22. – № 14. – С. 5287.

31. *Chen, Z.* Revisiting Domain-Adaptive 3D Object Detection by Reliable, Diverse and Class-balanced Pseudo-Labeling / Z. Chen et al. // *Proceedings of the IEEE/CVF International Conference on Computer Vision*. – 2023. – С. 3714–3726.

32. *Zhang, Y.* L-DIG : A GAN-Based Method for LiDAR Point Cloud Processing under Snow Driving Conditions /

Y. Zhang et al. // *Sensors*. – 2023. – Т. 23. – № 21. – С. 8660.

33. *Yu, M. Y.* LiSnowNet : Real-time Snow Removal for LiDAR Point Clouds / M. Y. Yu, R. Vasudevan, M. Johnson-Roberson // 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). – IEEE, 2022. – С. 6820–6826.

34. *Kilic, V.* Lidar light scattering augmentation (lisa): Physics-based simulation of adverse weather conditions for 3d object detection / V. Kilic et al. // arXiv preprint arXiv:2107.07004. – 2021.

35. *Hahner, M.* Lidar snowfall simulation for robust 3d object detection / M. Hahner et al. // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. – 2022. – С. 16364–16374.