

Abstract

The robust detection of small objects in Light Detection and Ranging (LiDAR) point clouds represents a fundamental challenge for autonomous driving systems. Particularly at greater distances, the limited spatial resolution of the sensor often provides only few measurement points per object, which complicates the extraction of meaningful features and thus robust object recognition. In the context of the university project FASTDA, where an autonomous race car must autonomously navigate a track marked by traffic cones, this problem gains particular significance. Precise and real-time perception of track boundaries is therefore a key prerequisite for safe and reliable vehicle operation.

This thesis investigates the suitability of modern three-dimensional deep learning methods for detecting small and point-sparse objects in sparse LiDAR point clouds. To this end, six state-of-the-art 3D object detectors from different architectural classes PointPillars (voxel-based), 3DSSD (point-based), PV-RCNN (hybrid), DeLiVoTr (attention-based), LION (sequence-based Mamba architecture), and VoxelNeXt (fully sparse) are fine-tuned via transfer learning on a custom dataset and systematically evaluated.

The results demonstrate that all investigated methods exhibit a pronounced dependency on available point density. In particular, beyond a critical distance, the small number of LiDAR measurement points per object leads to a significant degradation in detection performance. This motivated the investigation of two distinct approaches for improving recognition performance in the critical far-range region. While the integration of geometric shape priors was discarded due to insufficient sequential data, high architectural complexity, and limited effectiveness under extreme sparsity, data-driven point cloud densification via point cloud super-resolution achieves improved recall rates while maintaining real-time processing capability.

The findings demonstrate that fully sparse 3D detection architectures hold significant potential for deployment in safety-critical and resource-constrained autonomous systems. Simultaneously, low point density of small objects in mid-range and far-range distances is identified as a central challenge. Improving the information density of sparse point clouds thus represents a promising avenue for future research.

Keywords: LiDAR, 3D object detection, deep learning, autonomous vehicles, small objects, sparse point clouds, real-time systems, Formula Student.

Zusammenfassung

Die zuverlässige Detektion kleiner Objekte in LiDAR-Punktwolken stellt eine wesentliche Herausforderung für autonome Fahrsysteme dar. Insbesondere bei größeren Entfernungen stehen aufgrund der begrenzten räumlichen Auflösung des Sensors häufig nur wenige Messpunkte pro Objekt zur Verfügung, was die Extraktion aussagekräftiger Merkmale und damit eine robuste Objekterkennung erschwert. Im Kontext des Hochschulprojekts {FASTDA, in dem ein autonomes Rennfahrzeug eine durch Verkehrshütchen markierte Rennstrecke selbstständig befahren soll, gewinnt diese Problemstellung besondere Bedeutung. Eine präzise und gleichzeitig echtzeitfähige Wahrnehmung der Streckenbegrenzung stellt hierbei eine zentrale Voraussetzung für einen sicheren und zuverlässigen Fahrzeugbetrieb dar.

Die vorliegende Arbeit untersucht die Eignung moderner dreidimensionaler Deep-Learning-Verfahren zur Detektion kleiner und punktarmer Objekte in spärlichen LiDAR-Punktwolken. Hierzu werden sechs repräsentative 3D-Objektdetektoren unterschiedlicher Architekturklassen PointPillars (voxelbasiert), 3DSSD (punktbasiert), PV-RCNN (hybrid), DeLiVoTr (aufmerksamkeitsbasiert), LION (sequenziell/Mamba-basiert) und VoxelNeXt (fully sparse) mittels Transfer Learning auf einem eigens erhobenen Datensatz feinjustiert und systematisch evaluiert.

Die Ergebnisse zeigen, dass alle untersuchten Verfahren eine deutliche Abhängigkeit von der verfügbaren Punktdichte aufweisen. Insbesondere ab einer kritischen Entfernung führt die geringe Anzahl an LiDAR-Messpunkten pro Objekt zu einer signifikanten Abnahme der Detektionsleistung, was zur Untersuchung von zwei verschiedenen Ansätzen zur Verbesserung der Erkennungsleistung im kritischen Fernbereich motiviert. Während die Integration geometrischer Shape Priors aufgrund unzureichender Sequenzdaten, hoher Architekturkomplexität und eingeschränkter Wirksamkeit bei extremer Punktarmut verworfen wird, führt die datengetriebene Punktverdichtung mittels Super Resolution hingegen zu einer verbesserten Erkennungsrate bei gleichzeitig weiterhin echtzeitfähiger Verarbeitung.

Die gewonnenen Erkenntnisse zeigen, dass vollständig spärliche 3D-Detektionsarchitekturen ein hohes Potenzial für den Einsatz in sicherheitskritischen und ressourcenbeschränkten autonomen Systemen besitzen. Gleichzeitig wird die geringe Punktdichte kleiner Objekte im mittleren und größeren Entfernungsbereich als zentrale Herausforderung identifiziert. Die Verbesserung der Informationsdichte spärlicher Punktwolken stellt daher einen vielversprechenden Ansatzpunkt für zukünftige Forschungsarbeiten dar.

Schlüsselwörter: LiDAR, 3D-Objektdetektion, Deep Learning, autonome Fahrzeuge, kleine Objekte, spärliche Punktwolken, Echtzeitsysteme, Formula Student.