

Pengembangan Kemampuan Model Autonomous Car Terhadap Aspek Keselamatan Berkendara Saat Kondisi Ekstrem Menggunakan Carla Simulator

Muhammad Fadli Hernanda^{*1}, Muhammad Idham Ananta Timur²

¹Program Studi Elektronika dan Instrumentasi, FMIPA UGM, Yogyakarta, Indonesia

²Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}muhammad.fadli.hernanda@mail.ugm.ac.id, ²idham@ugm.ac.id

Abstrak

Perkembangan teknologi otomatisasi, khususnya dalam kendaraan otonom, mengalami kemajuan pesat dengan penerapan pembelajaran mesin. Namun, sistem ini masih menghadapi tantangan dalam lingkungan dengan lalu lintas padat dan kondisi yang dinamis, sehingga aspek keselamatan menjadi perhatian utama. Data kecelakaan lalu lintas menunjukkan bahwa penerapan kendaraan otonom masih jauh dari optimal, terutama dalam kondisi ekstrem seperti cuaca buruk dan kepadatan lalu lintas yang tidak dapat diprediksi. Penelitian ini bertujuan untuk mengembangkan model sistem kendaraan otonom yang tidak hanya mampu beroperasi dalam kondisi normal tetapi juga dapat beradaptasi dengan kondisi ekstrem. Model ini dikembangkan menggunakan CARLA Simulator, yang memungkinkan pengujian dalam berbagai skenario lingkungan secara realistis. Pengujian dilakukan dengan mensimulasikan faktor cuaca buruk dan kepadatan lalu lintas untuk mengevaluasi ketahanan serta respons model terhadap berbagai skenario. Hasil penelitian menunjukkan bahwa model yang dikembangkan mampu meningkatkan keselamatan berkendara dalam kondisi ekstrem dengan efektivitas tinggi dalam penghindaran rintangan dan pengambilan keputusan dinamis. Dengan demikian, pendekatan ini diharapkan dapat berkontribusi dalam pengembangan kendaraan otonom yang lebih adaptif dan aman untuk diterapkan di lingkungan nyata.

Kata kunci— Kendaraan Otonom, Keselamatan Berkendara, Kondisi Ekstrem, CARLA Simulator

Abstract

The advancement of automation technology, particularly in autonomous vehicles, has rapidly progressed with the integration of machine learning. However, these systems still face challenges in environments with dense traffic and dynamic conditions, making safety a primary concern. Traffic accident data indicate that the implementation of autonomous vehicles remains far from optimal, especially under extreme conditions such as severe weather and unpredictable traffic congestion. This study aims to develop an autonomous vehicle system model that can operate not only under normal conditions but also adapt to extreme situations. The model is developed using the CARLA Simulator, which enables testing in various realistic environmental scenarios. Simulations involving severe weather and high traffic density are conducted to evaluate the model's resilience and responsiveness across different scenarios. The results show that the developed model enhances driving safety under extreme conditions with high effectiveness in obstacle avoidance and dynamic decision-making. Thus, this approach is expected to contribute to the development of more adaptive and safer autonomous vehicles for real-world applications.

Keywords— Autonomous Vehicles, Driving Safety, Severe Weather, CARLA Simulator

1. PENDAHULUAN

Perkembangan teknologi telah menjadi faktor utama dalam berbagai aspek kehidupan, termasuk dalam otomasi kendaraan. Salah satu inovasi yang berkembang pesat adalah mobil otonom, yang telah diteliti sejak pertengahan 1980-an. Perkembangan kecerdasan buatan memungkinkan penerapan algoritma yang lebih canggih untuk meningkatkan kinerja dan keselamatan kendaraan otonom dalam berbagai kondisi. Sistem ini dirancang untuk menghadapi situasi yang dinamis, baik dari faktor internal kendaraan maupun kondisi eksternal seperti lingkungan dan lalu lintas [1]. Namun, tantangan besar dalam pengembangan mobil otonom masih berkisar pada aspek keselamatan, terutama dalam menghadapi kondisi lalu lintas padat dan cuaca ekstrem yang dapat mengganggu kerja sensor dan sistem pengambilan keputusan [2].

Data dari Pusiknas Bareskrim Polri mencatat 134.867 kasus kecelakaan lalu lintas di Indonesia, dengan kerugian mencapai Rp 258,18 miliar, sementara laporan NHTSA menunjukkan 30 kecelakaan yang melibatkan sistem autopilot [3]. Hal ini membuktikan bahwa penerapan teknologi kendaraan otonom yang dapat beroperasi secara aman di jalan raya masih menghadapi berbagai tantangan. Beberapa penelitian telah mengusulkan solusi untuk meningkatkan aspek keselamatan mobil otonom, seperti optimalisasi penggunaan sensor multi-modal dan teknik interpretasi data sensor untuk mendukung pengambilan keputusan yang lebih akurat [4]. Namun, model yang bergantung pada sensor kamera masih mengalami keterbatasan dalam kondisi cuaca buruk dan kepadatan lalu lintas yang tinggi [5]. Oleh karena itu, diperlukan pengembangan model mobil otonom yang lebih adaptif terhadap kondisi lingkungan ekstrem agar dapat meningkatkan aspek keselamatan berkendara.

Salah satu tantangan utama dalam pengembangan mobil otonom adalah bagaimana sistem dapat tetap bekerja secara optimal dalam kondisi cuaca dan lalu lintas yang bervariasi [6]. Model berbasis sensor kamera sering kali mengalami degradasi performa dalam kondisi ekstrem, sehingga diperlukan pendekatan yang lebih fleksibel agar kendaraan dapat tetap beroperasi dengan baik [7]. Untuk itu, penelitian ini berfokus pada pengembangan model sistem autonomous berbasis sistem end-to-end yang dapat menjamin keselamatan berkendara dalam berbagai kondisi, baik normal maupun ekstrem. Model ini akan diuji melalui simulasi menggunakan *Carla Simulator* untuk mengukur efektivitasnya dalam menghadapi berbagai skenario di jalan raya.

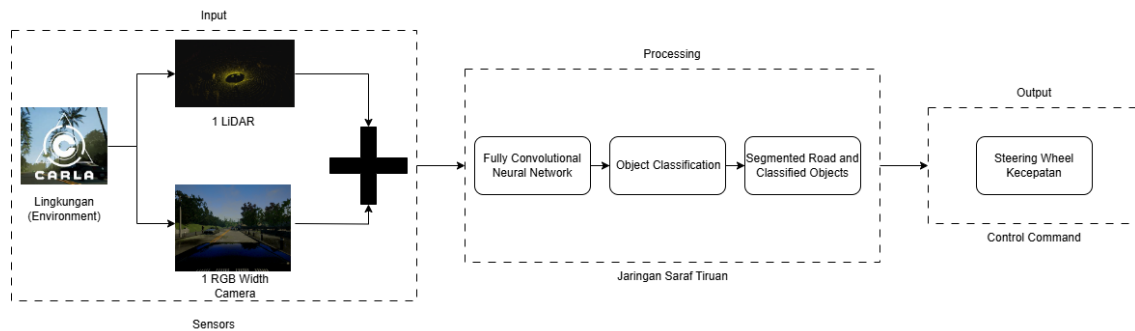
Model sistem mobil *autonomous* yang akan diangkat dalam penelitian ini akan berfokus kepada sebuah pengembangan model yang dapat menjamin aspek keselamatan yaitu untuk menghindari tabrakan. Model ini akan dijalankan dengan beberapa skenario lalu lintas yang mana akan dilihat dari hasil setelah sistem dijalankan, yang dapat dilihat dari sebuah model ini adalah jumlah model ketika mengalami tabrakan ketika berbagai kondisi dan skenario yang diberikan. Model ini akan dikembangkan dari sebuah algoritma pembelajaran machine learning yang akan berbasiskan dengan sebuah pembelajaran *Imitation*. Pemilihan basis model yang ada merupakan upaya untuk mengembangkan sebuah model agar memiliki ego yang sama dengan ego yang ada pada manusia.

2. METODE PENELITIAN

2.1 Analisis Sistem

Penelitian ini berfokus pada pengembangan model sistem mobil autonomous yang menitikberatkan pada aspek keselamatan, khususnya dalam menghindari tabrakan. Model ini akan diuji dalam berbagai skenario lalu lintas untuk menganalisis performanya berdasarkan jumlah tabrakan yang terjadi dalam kondisi berbeda. Sistem ini dikembangkan menggunakan algoritma *machine learning* berbasis *Imitation Learning*, yang dirancang agar memiliki ego

serupa dengan manusia dalam pengambilan keputusan pada kondisi lingkungan yang tidak konsisten, baik dalam lalu lintas maupun cuaca [8].




Gambar 1 Diagram Arsitektur Sistem Model Mobil Autonomous dan Fuse LiDAR serta RGB Camera

Model ini mengintegrasikan data dari sensor kamera dan LiDAR guna meningkatkan keandalan sistem. Untuk menjamin efektivitasnya, pendekatan *end-to-end system* digunakan, memungkinkan model memproses input sensor secara langsung dan menghasilkan keputusan kontrol kendaraan tanpa modul pemrosesan terpisah [9]. Dengan pendekatan ini, respons sistem menjadi lebih cepat dan efisien dalam menghindari tabrakan selama simulasi di jalan raya. Pendekatan ini diharapkan dapat meningkatkan keselamatan mobil autonomous, memastikan keandalannya dalam kondisi lalu lintas yang kompleks dan dinamis. Arsitektur utama yang dirancang untuk penelitian ini ditunjukkan oleh Gambar 1.

2.2 Perancangan Sistem

Rancangan sistem mobil autonomous ini menggabungkan input data dari sensor kamera dan LiDAR yang diproses dalam sistem *end-to-end* untuk menentukan keputusan kendaraan, seperti menambah kecepatan, mengerem, atau mempertahankan kecepatan. Proses ini melibatkan pengolahan data sensor melalui pelatihan berbasis supervisi, di mana model belajar dari data yang telah diajarkan oleh ahli [8,9,10].




Gambar 2 Diagram Model Sistem Mobil *Autonomous*

Setelah data input diproses, dilakukan ekstraksi fitur untuk menganalisis lingkungan sekitar. Informasi ini kemudian dikombinasikan dengan perintah navigasi guna memahami tugas yang diberikan. Model akan merespons berdasarkan hasil observasi dan supervisi, memungkinkan pengambilan keputusan yang lebih akurat [9]. Pelatihan dilakukan menggunakan data demonstrasi yang mencakup observasi, perintah, dan keputusan dari ahli, sehingga model dapat belajar menghadapi berbagai situasi [11].

Setelah tahap pelatihan selesai dan model cukup adaptif, dilakukan serangkaian pengujian untuk mengevaluasi keseluruhan sistem. Evaluasi ini bertujuan untuk memastikan model dapat mengambil keputusan dengan cepat dan akurat, meningkatkan efektivitas mobil autonomous dalam menghadapi kondisi lalu lintas yang kompleks. Untuk lebih lanjut terkait proses perancangan pembuatan model mobil otonom terlihat pada Gambar 2.

2.3 Implementasi Model Sistem

Model sistem yang dibuat ini akan menggunakan implementasi dari rancangan sistem yang terdiri dari fase pengumpulan dataset menggunakan data generation, penambahan augmentasi pada dataset, pelatihan model dan pengujian sistem model. Pada dasarnya model sistem yang dibuat terdiri dari dua model, yaitu model dengan menggunakan dataset reguler dan menggunakan dataset setelah diberikan improvisasi atau pengembangan. Untuk lebih jelasnya dapat dilihat pada gambar 3 berikut.



Gambar 3 Rancangan Penerapan Sistem pada Model Mobil Autonomous

2.3.1 Pembuatan dan Pengumpulan Dataset

Penelitian ini diawali dengan pembuatan dan perolehan dataset yang diperoleh dari *Carla Simulator*, disesuaikan dengan model sistem yang akan dilatih. Dataset dikumpulkan melalui proses data generation, dengan model reguler menggunakan kode bawaan simulator, sementara model lain menggunakan dataset yang telah dikembangkan dari model reguler. Pengumpulan data memanfaatkan model autopilot bawaan *Carla Simulator* dengan penyesuaian rute dan skenario untuk mendapatkan dataset yang sesuai. Data yang dikumpulkan diklasifikasikan berdasarkan output sensor yang akan digunakan dalam pelatihan model. Kode yang digunakan menginisialisasi konfigurasi dataset, pengaturan pengambilan data, serta definisi sensor yang digunakan.

Hasil pengumpulan dataset disimpan dalam format RGB image, yang dapat diakses setelah semua skenario pengambilan data selesai. Dataset ini kemudian digunakan untuk proses training model guna meningkatkan akurasi sistem dalam berbagai kondisi. Contoh hasil dataset yang dikumpulkan terlihat pada Gambar 4.



Gambar 4 Contoh Hasil dari Pengumpulan Dataset Menggunakan Data Generation

2.3.2 Pengembangan Dataset

Pengembangan dataset ini bertujuan untuk meningkatkan performa model dibandingkan dengan model reguler yang menggunakan dataset standar. Hal ini dicapai dengan memperkaya variasi data, termasuk penambahan variasi cuaca dan waktu, sehingga model lebih adaptif terhadap kondisi lingkungan yang dinamis. Dalam dataset improvisasi, jumlah variasi cuaca meningkat dari tujuh menjadi sebelas, sementara variasi waktu bertambah dari enam menjadi delapan kondisi. Kombinasi cuaca dan waktu yang lebih luas memungkinkan model belajar dari skenario yang lebih kompleks dan realistis.



Gambar 5 Hasil Pengumpulan Dataset Setelah Pengembangan dan Modifikasi

Modifikasi ini berdampak pada hasil data generation, menghasilkan dataset yang lebih beragam dan lebih representatif dibandingkan sebelumnya. Dengan dataset yang lebih kaya, model dapat mengoptimalkan pembelajaran Imitation Learning, meningkatkan keandalan dalam pengambilan keputusan, serta menyesuaikan respons dalam kondisi lalu lintas yang lebih variatif. Hasil pengembangan dataset dapat dilihat pada Gambar 5.

2.3.3 Implementasi Pelatihan Model

Dataset yang telah dikumpulkan kemudian digunakan untuk pelatihan guna menghasilkan model sistem yang dapat diterapkan. Pelatihan dilakukan dalam dua tahap: pertama dengan dataset reguler untuk menghasilkan model reguler, dan kedua dengan dataset yang telah dikembangkan untuk menghasilkan model improvisasi. Kedua model ini dilatih dalam environment dan kode program yang sama, sehingga memungkinkan perbandingan performa berdasarkan dataset yang digunakan.

Pelatihan model dijalankan melalui perintah dalam train.py, yang bertanggung jawab memproses dataset yang telah ditentukan. Parameter `--batch_size 10` digunakan untuk menentukan jumlah sampel data yang diproses sebelum pembaruan parameter model, sedangkan `--parallel_training 0` mengontrol mode pelatihan, apakah menggunakan satu atau beberapa GPU. Pendekatan ini memastikan pemanfaatan sumber daya komputasi secara optimal untuk meningkatkan efisiensi pelatihan model [11]. Untuk menjalankan fase training menggunakan kode pada Gambar 6.

```
def train(self):
    self.model.train()
    num_batches = 0
    loss_epoch = 0.0

    for data in tqdm(self.dataloader_train):
        self.optimizer.zero_grad(set_to_none=True)
        losses = self.load_data_compute_loss(data)
        loss = torch.tensor(0.0).to(self.device, dtype=torch.float32)

        for key, value in losses.items():
            loss += self.detailed_weights[key] * value
        loss.backward()
        self.optimizer.step()
        num_batches += 1
        loss_epoch += float(loss.item())

    self.log_losses(loss_epoch, detailed_losses_epoch, num_batches,
    '')
```

Gambar 6 Fungsi utama untuk menjalankan proses pelatihan

2.3.4 Implementasi Evaluasi Model


Model yang telah dilatih dievaluasi menggunakan berbagai town, skenario, dan kondisi cuaca yang tersedia di *Carla Simulator*. Evaluasi dilakukan di Town 5, yang memiliki tata kota berbentuk persegi dengan banyak persimpangan besar, jalur lalu lintas yang kompleks, dan jembatan. Karakteristik ini memungkinkan model diuji dalam berbagai skenario, termasuk pergantian lajur dan navigasi di lingkungan perkotaan [1]. Pengujian dilakukan dengan menjalankan skenario evaluasi menggunakan Python dan Pygame untuk visualisasi. Model reguler dan model improvisasi diuji secara bergantian pada satu perangkat, memungkinkan perbandingan performa berdasarkan dataset yang digunakan. Parameter variasi evaluasi yang diterapkan dapat dilihat dalam tabel berikut.

Tabel 1 Variasi cuaca dan kondisi untuk pengujian evaluasi model

Condition Name	Condition Parameters			
	Rain Precipitation	Sun	Fog Density	Vision Distance
Foggy Noon	0.0	90.0	90.0	5.0
Foggy Night	0.0	-90.0	90.0	5.0
Rain Noon	100.0	90.0	30.0	25.0
Rain Noon	100.0	-90.0	30.0	25.0
Standart Noon	50.0	90.0	50.0	15.0
Standart Night	50.0	-90.0	50.0	15.0

3. HASIL DAN PEMBAHASAN


Pada hasil performa model yang telah didapatkan, khususnya untuk performa model yang telah dilakukan *improve* dari yang reguler memiliki beberapa karakteristik dalam setiap kondisi yang didapatkan selama proses evaluasi performa berlangsung. Pada dasarnya setiap model dilakukan evaluasi performa menggunakan enam variasi kondisi yang sudah disesuaikan dengan kondisi ekstrem. Dari enam kondisi tersebut memiliki karakteristik yang sudah ditentukan untuk setiap variasi yang didapatkannya. Berikut merupakan grafik yang menunjukkan rekap hasil karakteristik performa model reguler pada keseluruhan kondisi evaluasi.



Gambar 7 Grafik Performa Model Reguler Terhadap Berbagai Kondisi Cuaca dan Waktu

Evaluasi performa model reguler menunjukkan bahwa kondisi cuaca dan waktu berpengaruh signifikan terhadap performa serta tingkat keselamatan berkendara model autonomous. Karakteristik setiap kondisi diuji untuk mengidentifikasi sejauh mana model dapat beradaptasi dan menghadapi tantangan tertentu.

Hasil evaluasi menunjukkan bahwa siang hari saat hujan menghasilkan skor mengemudi tertinggi (0.9268), menandakan model dapat berfungsi optimal dalam kondisi tersebut. Sebaliknya, malam hari saat hujan mencatat skor terendah (0.2856), menunjukkan kesulitan model dalam menghadapi kombinasi gelap dan hujan. Secara keseluruhan, performa model lebih baik pada siang hari dibandingkan malam hari, terutama dalam situasi cuaca ekstrem. Hasil ini mengonfirmasi bahwa minimnya pencahayaan dan kondisi hujan menjadi tantangan besar bagi model autonomous, mempengaruhi kemampuan navigasi dan pengambilan keputusan, serta tingkat keselamatan berkendara.



Gambar 8 Grafik Perbandingan Performa Model Reguler dan Augmented Dalam Berbagai Kondisi

Performa dari model yang dikembangkan dalam penelitian ini akan langsung dibandingkan dengan performa dari model reguler yang juga bertindak sebagai variabel kontrol. Perbandingan performa tersebut dapat dilihat pada grafik pada Gambar 8.

Evaluasi performa model menunjukkan bahwa model augmented memiliki peningkatan performa dibandingkan model reguler dalam berbagai kondisi cuaca dan waktu, meskipun tingkat peningkatannya bervariasi. Grafik perbandingan skor mengemudi menunjukkan bahwa kondisi lingkungan sangat mempengaruhi performa model autonomous, dengan tantangan yang berbeda antara siang dan malam hari.

Pada siang hari, model augmented mengalami peningkatan rata-rata 10.44%, dengan performa terbaik pada cuaca standar (+16.67%) dan berkabut (+13.69%). Namun, peningkatan pada kondisi hujan hanya 0.96%, menunjukkan bahwa hujan lebih mempengaruhi performa dibandingkan kabut atau jarak pandang terbatas. Pada malam hari, tantangan lebih besar karena model hanya bergantung pada pencahayaan buatan. Model augmented menunjukkan peningkatan performa 28.02% lebih baik dari model reguler, dengan kenaikan tertinggi pada cuaca standar (+62.63%), diikuti kabut (+21.21%), dan hujan yang hanya meningkat 0.21%.

Secara keseluruhan, model augmented lebih unggul dalam semua kondisi, tetapi masih mengalami kesulitan pada saat kondisi hujan malam hari, dengan skor terendah (0.2862) dibandingkan kondisi lainnya. Ini menunjukkan bahwa kondisi hujan malam hari merupakan tantangan terbesar dan model masih menghadapi kesulitan dalam mengatasi noise yang dihasilkan dari lingkungan tersebut.

4. KESIMPULAN

Penelitian tentang pengembangan kemampuan model autonomous car terhadap aspek keselamatan berkendara dalam kondisi ekstrem menggunakan CARLA Simulator menunjukkan bahwa setiap variasi kondisi cuaca dan waktu memiliki pengaruh yang berbeda terhadap performa model. Karakteristik masing-masing kondisi berkontribusi langsung pada skor mengemudi yang mencerminkan tingkat keselamatan berkendara. Skor ini dihitung berdasarkan nilai kelengkapan rute dan penalti yang diterima oleh model. Semakin rendah skor yang diperoleh, semakin besar tantangan yang dihadapi. Dalam penelitian ini, kondisi hujan pada malam hari menjadi skenario paling sulit, dengan skor mengemudi terendah sebesar 0.2856 pada model reguler dan 0.2862 pada model augmented, dari skala 1.0000.

Pengembangan model augmented menunjukkan peningkatan performa yang lebih baik dibandingkan model reguler, dengan rata-rata peningkatan skor mengemudi sebesar 24.05% dalam berbagai kondisi cuaca dan waktu. Model augmented juga mampu beradaptasi dengan tantangan lingkungan yang diberikan, terbukti dengan rata-rata skor keseluruhan mencapai 0.8454 dari skala 1.0000, menunjukkan peningkatan keandalan dalam menghadapi kondisi ekstrem.

Hasil evaluasi juga mengungkap bahwa parameter cuaca, seperti rain, fog, dan vision distance, memiliki dampak signifikan terhadap performa model. Pada malam hari, tingkat hujan menjadi faktor paling berpengaruh dalam menurunkan performa model dan keselamatan berkendara. Sementara itu, pada siang hari, tidak ada satu parameter yang dominan, tetapi kombinasi beberapa faktor yang memiliki perbedaan besar dapat menyebabkan kesulitan bagi model dalam mempertahankan performa dan keselamatan berkendara. Hal ini membuktikan bahwa kondisi cuaca ekstrem masih menjadi tantangan utama dalam pengembangan sistem autonomous car yang lebih adaptif dan aman.

5. SARAN

Disarankan untuk melakukan pengembangan performa dengan fokus terhadap kondisi hujan dengan tingkat 100% pada malam hari dan melakukan pengujian lebih lanjut pada kondisi

lingkungan simulasi yang berbeda seperti adanya kendaraan lain yang berlalu lintas untuk memastikan performa model dapat meningkat menjadi lebih baik.

Mengeksplorasi integrasi berbagai tambahan sensor untuk dapat meningkatkan performa model yang dikembangkan dan melakukan pengujian dengan berbagai parameter yang lebih bervariasi

DAFTAR PUSTAKA

- [1] Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A., & Koltun, V. (2017). CARLA: An Open Urban Driving Simulator. <http://arxiv.org/abs/1711.03938>
- [2] Dai, L., Lu, S., Xie, W., & Jia, R. (2023). Drift Control of Autonomous Vehicle Under Extreme Condition Based on Neural Network Tire Model. Proceedings of the 2023 7th CAA International Conference on Vehicular Control and Intelligence, CVCI 2023. <https://doi.org/10.1109/CVCI59596.2023.10397310>
- [3] Sinha, A., Vu, V., Chand, S., Wijayaratna, K., & Dixit, V. (2021). A crash injury model involving autonomous vehicle: Investigating of crash and disengagement reports. Sustainability, 13(14), 7938.
- [4] Shao, H., Wang, L., Chen, R., Li, H., & Liu, Y. (2022). Safety-Enhanced Autonomous Driving Using Interpretable Sensor Fusion Transformer. <http://arxiv.org/abs/2207.14024>
- [5] Eraqi, H. M., Moustafa, M. N., & Honer, J. (2022). Dynamic Conditional Imitation Learning for Autonomous Driving. IEEE Transactions on Intelligent Transportation Systems, 23(12), 22988–23001. <https://doi.org/10.1109/TITS.2022.3214079>
- [6] Wang, K. (2020). Safe Reconfiguration of Autonomous Driving Systems. 2020 IEEE MIT Undergraduate Research Technology Conference, URTC 2020. <https://doi.org/10.1109/URTC51696.2020.9668860>
- [7] O. Natan and J. Miura, "End-to-End Autonomous Driving With Semantic Depth Cloud Mapping and Multi-Agent," in IEEE Transactions on Intelligent Vehicles, vol. 8, no. 1, pp. 557-571, Jan. 2023, doi: 10.1109/TIV.2022.3185303.
- [8] Le Mero, L., Yi, D., Dianati, M., & Mouzakitis, A. (2022). A Survey on Imitation Learning Techniques for End-to-End Autonomous Vehicles. IEEE Transactions on Intelligent Transportation Systems. <https://doi.org/10.1109/TITS.2022.3144867>
- [9] Felipe Codevilla, Matthias Muller, Antonio Lopez, Vladlen Koltun, & Alexey Dosovitskiy. (2018). End-to-end Driving via Conditional Imitation Learning.
- [10] Hanselmann, N., Renz, K., Chitta, K., Bhattacharyya, A., & Geiger, A. (n.d.). KING: Generating Safety-Critical Driving Scenarios for Robust Imitation via Kinematics Gradients. <https://lasnik.github.io/king/>.
- [11] Chitta, K., Prakash, A., Jaeger, B., Yu, Z., Renz, K., & Geiger, A. (2022). TransFuser: Imitation with Transformer-Based Sensor Fusion for Autonomous Driving. <http://arxiv.org/abs/2205.15997>