

PROPOSAL DISERTASI S3

PERANCANGAN KOORDINAT GEOGRAFIS MOBIL
OTONOM, MENGGUNAKAN TEKNIK HYBRID
KECERDASAN BUATAN DAN KONVENSIONAL
TERMODIFIKASI

BY HASNAWIYA HASAN
D053201003

PROGRAM S3 TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN

Latar Belakang

definisi

- ❑ *motion control* pada sistem mobil autonomous, terbagi atas dua bagian yaitu gerak lateral dan longitudinal
- ❑ kendali lateral mengatur posisi kendaraan pada tanah serta pengaturan *lane changes* dan *avoid collision*. [1]
- ❑ dan kendali longitudinal yang mengatur kecepatan kendaraan [1]

Latar Belakang


- ❑ Kendaraan otonom terdiri dari beberapa bidang yang saling terkait dan melengkapi, termasuk sistem komunikasi nirkabel, sistem embedded, navigasi, sensor, dan akuisisi data [2]. Pada sistem navigasi, sistem yang robust dan stabil merupakan syarat penting bagi kendaraan otonom untuk bergerak sepanjang jalur. Kontrol longitudinal dirancang untuk mengatur kecepatan kendaraan dan jarak antara kendaraan/objek di jalan untuk mencegah kecelakaan. Sementara itu, kontrol lateral dirancang untuk mengendalikan sistem kemudi kendaraan agar mengikuti/menelusuri jalur yang direncanakan (penelusuran jalur) dan menjaga stabilitas kendaraan selama penelusuran [3]. Oleh karena itu, sistem kontrol kemudi (kontrol lateral) pada kendaraan otonom sangat terkait dengan penentuan koordinat geografis mobil otonom dan perencanaan jalur

Latar Belakang

Algoritma yang umum digunakan dalam sistem kendaraan otonom adalah jaringan saraf konvolusional (convolutional neural network atau CNN), karena kemampuannya dalam memproses klasifikasi gambar dan deteksi objek dari data gambar/video yang diambil oleh kamera. Oleh karena itu, sistem persepsi kendaraan otonom sering menggunakan algoritma jaringan saraf konvolusional. CNN adalah model pembelajaran mesin yang dapat belajar mengekstraksi fitur dari data sensor dan membuat keputusan berdasarkan informasi tersebut. CNN dapat belajar dari kumpulan data contoh yang besar dan beradaptasi dengan situasi baru, sehingga lebih cocok untuk menangani skenario yang kompleks dan beragam.

CNN juga dapat belajar untuk melakukan tugas mengikuti jalur dan jalan tanpa dekomposisi manual menjadi deteksi marka jalan atau jalur, abstraksi semantik, perencanaan jalur, dan kontrol. Motivasi utama dari pekerjaan ini adalah untuk menghindari kebutuhan untuk mengenali fitur yang ditentukan manusia secara spesifik, seperti marka jalan, pembatas jalan, atau mobil lainnya. [4]. Artificial intelligence yang menggunakan CNN ini disebut juga “end to end” yaitu teknik yang menentukan output kendali langsung dari data mentah sensor tanpa membutuhkan desain planning dan kendali secara manual lagi.

LATAR BELAKANG



Driving environment

Gambar 1. Sistem mobil *autonomous* yang menggunakan teknik “end to end”

LATAR BELAKANG

sistem persepsi otonom, seperti yang terlihat pada gambar 1 [5]. Meskipun teknik ini diakui telah berhasil menciptakan kendaraan otonom yang bergerak dengan baik, keselamatan masih menjadi pertanyaan. Karena kendaraan otonom tidak dapat hanya mengandalkan sistem perangkat lunaknya, model dinamik/kinematik kendaraan juga perlu dipertimbangkan sebagai sistem pendukung selain sistem pendukung lainnya. CNN sering dianggap sebagai model kotak hitam, yang berarti sulit untuk memahami bagaimana mereka sampai pada keputusan mereka. Kurangnya transparansi ini dapat membuat sulit untuk mendiagnosis kesalahan atau menyesuaikan perilaku model [6].

Selain itu, kemampuan terbatas mereka untuk menggeneralisasi ke skenario baru dan tak terduga. CNN dilatih pada kumpulan data besar gambar yang diberi label, yang dapat membatasi kemampuan mereka untuk menggeneralisasi situasi yang tidak terwakili dengan baik dalam data pelatihan. Ini dapat menjadi masalah terutama dalam mengemudi otonom, di mana kondisi jalan atau bahaya yang tidak terduga dapat muncul [7]

LATAR BELAKANG

Selain itu, mengumpulkan dan memberi label pada jumlah data besar dari beragam skenario mengemudi dapat memakan waktu dan mahal. CNN dapat menuntut komputasi yang tinggi, yang dapat menjadi tantangan dalam aplikasi real-time seperti mengemudi otonom. Kinerja perangkat keras yang tinggi sering diperlukan untuk menjalankan CNN dengan efisien, yang dapat menambah biaya dan kompleksitas sistem.


Pendekatan berbasis CNN dapat efektif dalam situasi di mana skenario mengemudi terdefinisi dengan baik dan data sensor akurat dan dapat diandalkan. Namun, mungkin sulit dalam situasi di mana lingkungan mengemudi kompleks atau ambigu, atau di mana data sensor berisik atau tidak lengkap.

LATAR BELAKANG

Secara keseluruhan, meskipun CNN telah menunjukkan banyak harapan dalam mengemudi otonom, mereka memiliki beberapa keterbatasan yang harus diperhitungkan saat merancang dan menerapkan sistem ini. Sementara itu, kontrol reaktif adalah pendekatan berbasis aturan yang mengandalkan serangkaian tindakan kontrol yang telah ditentukan berdasarkan data sensor saat ini. Pendekatan ini dapat efektif dalam situasi di mana skenario mengemudi kompleks dan data sensor berisik atau tidak lengkap, karena memungkinkan sistem untuk bereaksi dengan cepat terhadap kondisi yang berubah. Namun, mungkin sulit dalam situasi di mana skenario mengemudi kurang terdefinisi dengan baik atau di mana pengambilan keputusan yang lebih halus diperlukan [8]

LATAR BELAKANG


Pada akhirnya, pilihan pendekatan yang digunakan tergantung pada persyaratan khusus dari sistem mengemudi otonom, dan mungkin perlu menggunakan kombinasi dari pendekatan berbasis CNN dan kontrol reaktif untuk mencapai kinerja yang optimal. Penting untuk mengevaluasi dengan hati-hati kelebihan dan kekurangan dari pendekatan yang berbeda dan memilih pendekatan yang paling sesuai untuk skenario mengemudi tertentu.



BAB 2

METODE PEMECAHAN

Automatic Driving System



Sebuah sistem mobil autonomous yang lengkap, sebaiknya terdiri dari beberapa sistem pendukung, yaitu :

- Sistem autonomous perception (sistem dengan computer vision) yang dikendalikan dengan AI
- Model vehicle kinematic/dinamik
- Trajectory Planning
- Sistem sensor dan aktuasi
- Ego Vehicle States dan Driving Environment


Gambar 2. Blok Diagram mobil autonomous yang lengkap [7]

Metode

SISTEM AUTONOMOUS PERCEPTION

- ❑ Sistem menggunakan tiga kamera yang dipasang pada kaca depan mobil
- ❑ Training data terdiri dari gambar gambar yang diambil dari video kemudian dipasangkan dengan *steering command*

Sistem Autonomous Perception



Pada gambar 3. Gambar dimasukkan ke Convolutional Neural Network (CNN), yang kemudian menghitung *proposed steering command*. Perintah ini dibandingkan dengan *desired command* untuk mendapatkan *weight* dari Convolutional Neural Network yang sesuai, sehingga CNN output hampir mendekati *desired output*.

Gambar 3. Arsitektur Sistem Autonomous Perception

State of The Art


Pada beberapa penelitian sebelumnya, sistem mobil autonomous didesain dengan menggunakan teknik “end to end”. Teknik ini tidak lagi menggunakan sistem deteksi jalur tepi jalan, teknik kendali dan path planning (3). Meskipun beberapa penelitian memperlihatkan hasil yang memuaskan, namun beberapa penelitian lain menganggap bahwa teknik “end to end” ini sebagai sebuah “black box” yang tidak menjamin keamanan penumpang mobil. Olehkarena sebuah mobil autonomous tidak dapat hanya bergantung pada sistem software tanpa memperhatikan sistem pendukung lainnya (2).

STATE OF THE ART

Olehkarena itu penelitin ini bertujuan untuk melengkapi teknik “end to end” dengan menjadikan kecerdasan buatan sebagai pengendali bagi model dinamik/kinematik mobil dan mendesain trajectory planning. Gambar 4 memperlihatkan arsitektur sistem kendali mobil autonomous yang direncanakan.


Algoritma kecerdasan buatan yang dimodifikasi akan diterapkan pada pengendalian gerak lateral mobil, pada bagian sistem autonomous perception seperti gambar 5 . Tujuan dari penggunaan algoritma ini untuk mengelola data images dari kamera untuk menentukan sudut kemudi yang sesuai bagi mobil. Keluaran dari algoritma ini juga akan bertindak sebagai pengendali bagi model mobil

State of The Art



Gambar 4 Arsitektur Sistem Mobil Autonomous yang Direncanakan

State of The Art



Gambar 5. SISTEM AUTONOMOUS PERCEPTION

REFERENSI

- [1] S. Kuutti, R. Bowden, Y. Jin, P. Barber, and S. Fallah, "A Survey of Deep Learning Applications to Autonomous Vehicle Control," *IEEE Trans. Intell. Transp. Syst.*, vol. 22, no. 2, pp. 712–733, 2021, doi: 10.1109/TITS.2019.2962338.
- [2] R. Hussain and S. Zeadally, "Autonomous Cars: Research Results, Issues, and Future Challenges," *IEEE Commun. Surv. Tutorials*, vol. 21, no. 2, pp. 1275–1313, 2019, doi: 10.1109/COMST.2018.2869360.
- [3] C. M. Filho, D. F. Wolf, V. Grassi, and F. S. Osorio, "Longitudinal and lateral control for autonomous ground vehicles," *IEEE Intell. Veh. Symp. Proc.*, no. Iv, pp. 588–593, 2014, doi: 10.1109/IVS.2014.6856431.
- [4] M. Bojarski et al., "End to End Learning for Self-Driving Cars," pp. 1–9, 2016, [Online]. Available: <http://arxiv.org/abs/1604.07316>.
- [5] C. Chan, "Applications of Machine Learning for Autonomous Driving Challenges in Testing & Verifications Taxonomy of A Driving Trip • Driving Experience Taxonomy – Classification by Timeline." 2018.
- [6] G. Devineau, "using Deep Learning * ," no. November, 2018.
- [7] H. Xu, Y. Gao, F. Yu, and T. Darrell, "End-to-end learning of driving models from large-scale video datasets," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 3530–3538, 2017, doi: 10.1109/CVPR.2017.376.
- [8] C. Dai, C. Zong, and G. Chen, "Path tracking control based on model predictive control with adaptive preview characteristics and speed-assisted constraint," *IEEE Access*, vol. 8, pp. 184697–184709, 2020, doi: 10.1109/ACCESS.2020.3029635.

THANK YOU!

Do You Have Any Questions?

*The Power of PowerPoint | thepopp.com
Icons: [Material Design by Google](#) | CC BY 3.0
Fonts: [Ropa Sans](#), [Reenie Beanie](#)
Pencil & Eraser: [Andrew Taylor](#)*

