

USULAN PENELITIAN DISERTASI

**PENINGKATAN KINERJA MOBIL OTONOM MELALUI
PENGATURAN SUDUT KEMUDI BERBASIS KENDALI HIBRID
LEARNING DAN REAKTIF**

**IMPROVEMENT PERFORMANCE OF AUTONOMOUS VEHICLE WITH
STEERING ANGLE CONTROL BASED ON HYBRID CONTROL LEARNING
AND REACTIVE**

disusun dan diajukan oleh

**HASNAWIYA HASAN
D053201003**



**PROGRAM STUDI DOKTOR ILMU TEKNIK ELEKTRO
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2023**

HALAMAN PENGESAHAN

PENGESAHAN PROPOSAL SEMINAR USULAN PENELITIAN

**PENINGKATAN KINERJA MOBIL OTONOM MELALUI
PENGATURAN SUDUT KEMUDI BERBASIS KENDALI HYBRID
LEARNING DAN REAKTIF**


Diajukan Oleh :

HASNAWIYA HASAN
NIM : D053201003

**Telah Diperiksa dan Dinyatakan Memenuhi Syarat Untuk
Melaksanakan Seminar Usulan Penelitian**


Menyetujui

Tim Promotor




Prof. Dr. Ing. Faizal Arya Samman, ST, MT,
Promotor

Tanggal :



Ir. RHIZA, S.SADJAD, MSEE, PhD
Co-Promotor



MUH. ANSHAR, ST, M.Sc (RESEARCH), Ph.D
Co-Promotor

DAFTAR ISI

Halaman Sampul Depan	i
Halaman Sampul Dalam	ii
Halaman Pengesahan	iii
Daftar Isi	iv
Daftar Tabel	v
BAB 1.PENDAHULUAN	
1.1. Latar Belakang	1
1.2. Rumusan Permasalahan	2
1.3. Tujuan Penelitian	2
1.4. Batasan Masalah	3
1.5. Manfaat Penelitian	3
BAB II.TINJAUAN PUSTAKA	
2.1. Landasan Teori	4
2.2. Penelitian Terkait	15
2.3. State of The Art	18
2.4. Kerangka Pikir Penelitian	21
BAB III. METODE PENELITIAN	22
3.1. Tahapan Penelitian	22
3.2. Waktu dan Lokasi Penelitian	23
3.3. Jenis Penelitian	23
3.4. Perancangan Sistem	23
3.5. Sumber Data	25
3.6. Instrumentasi Penelitian	25
3.7. Jadwal Penelitian	25
DAFTAR PUSTAKA	

DAFTAR TABEL

Tabel 1. Klasifikasi Tracking Control	18
Mobil Otonom	
Tabel 2. Tahapan Penelitian	22

DAFTAR GAMBAR

Gambar 1. Level autonomous driving menurut SAE	4
Gambar 2. Sensor sensor pada mobil otonom	5
Gambar 3. Sistem mobil otonom yang umum dan bidang bidang kompetensi nya	6
Gambar 4 Problem pada mobil otonom saat ini dan yang akan datang	6
Gambar 5. Sistem mobil <i>autonomous</i> yang menggunakan “end to end”	9
Gambar 6. Blok Kendali Mobil Otonom	9
Gambar 7. Data Collection System	10
Gambar 8. Arsitektur Sistem Autonomous Perception	10
Gambar.9. Model 3 DoF dari mobil	11
Gambar 10. Arsitektur State Feedback Linearization	12
Gambar 11. Arsitektur State Feedback Linearization dengan PD Observer	14
Gambar 12. Aplikasi deep learning pada mobil otonom	17
Gambar 13. Arsitektur Kendali Mobil Otonom yang Diusulkan	20
Gambar 14. Kerangka Pikir Penelitian	21
Gambar 15. Blok Rancangan Sistem	24

BAB I

PENDAHULUAN

1.1. LATAR BELAKANG

Pada beberapa dekade terakhir ini, industri automobile berkembang dengan pesat dan membuat mobil gerak mandiri menjadi produk yang dipasarkan diseluruh dunia. Hal ini disebabkan oleh perkembangan yang mengejutkan pada teknologi komputasi, komunikasi, sistem embedded, navigasi, sensor, data akusisi dll. Mobil gerak mandiri mentransformasikan mobil konvensional ke dalam bentuk mobil cerdas dan kaya informasi dan hiburan yang bergerak tanpa sopir. [1]

Pengembangan teknologi mobil gerak mandiri membutuhkan sebuah sistem yang terdiri dari berbagai macam teknologi seperti deteksi obyek, sensor, pemetaan, perencanaan jalur berkendara, pemodelan, dan kendali lateral dan longitudinal. Diantara teknologi tersebut, kendali gerak atau *motion control* adalah bagian yang terpenting, olehkarena mampu menentukan kinerja dan stabilitas dari kendaraan dalam kondisi jalan yang normal dan tidak ideal. [2]

Gerak lateral dari mobil dikendalikan oleh unit kemudi pada mobil, sementara gerak longitudinal dikendalikan oleh gas dan rem pada kendaraan. Lateral lebih berhubungan dengan kendali posisi pada jalur agar mobil mampu berjalan sesuai dengan jalur yang telah direncanakan dan berpindah jalur (*lane change*). Sedangkan kendali longitudinal lebih berkaitan dengan pengaturan kecepatan pada kendaraan untuk menghindari kecelakaan antar mobil. [2]

Gerak lateral terjadi menggunakan masukan (input) dari lingkungan menggunakan sensor sensor, masukan (input) tersebut diproses dengan menggunakan *algorithm control based learning* maupun *reactive control based model*. Sementara kendali longitudinal mengatur kecepatan dan akselerasi mobil untuk mempertahankan kecepatan yang sesuai di jalan raya dan menjaga jarak yang aman antar kendaraan di jalan raya serta tepi jalan. [2].

Olehkarena, model dinamik dari mobil umumnya adalah model nonlinear tinggi sehingga jika menggunakan metode kendali konvensional akan menjadi tidak fleksibel disebabkan oleh *uncertainties*. Sementara, metode kecerdasan buatan seringkali digunakan pada sistem mobil otonom, dan yang paling terkenal adalah deep learning dan machine learning.

Mereka mampu melakukan banyak aksi seperti metode kendali konvensional seperti estimasi ruang keadaan, pengenalan obyek, dan bahkan *tracking*.. Mobil otonom saat ini menggunakan sistem kecerdasan buatan (AI) sebagai algoritma kendali pada bagian persepsi,

planning dan kendali. Dalam penggunaannya control based learning (AI) membutuhkan data training yang besar untuk dapat memberikan prediksi yang tepat. Kelebihan daripada algoritma ini adalah kemampuannya bekerja dalam jumlah data yang besar, yang dibutuhkan oleh mobil gerak mandiri.[3]. Namun, mobil otonom, beroperasi dalam sebuah dynamic environment yang kompleks dan bervariasi. Olehkarena itu, keadaan dilapangan bisa saja ada yang belum diantisipasi didalam data training, sehingga control based learning (AI) memberi prediksi yang tidak sesuai dengan kondisi saat itu yang membutuhkan pengambilan keputusan yang cepat dan tepat. Olehkarena itu dibutuhkan suatu sistem tambahan yang mampu mengambil keputusan dengan cepat dan mengoreksi kesalahan prediksi yang diberikan model based learning tersebut.

Sistem tambahan merupakan sistem reactive control based model menggunakan state feedback linearization control dan PD observer yang cukup bagus dalam merespon sistem dengan model nonlinear.

Berdasarkan beberapa penelitian, masih banyak *scenario* jalan yang belum didesain untuk mobil *autonomous*, sehingga penelitian dibidang ini masih terbuka lebar [1].

1.2.RUMUSAN MASALAH

Dalam rangka membuat mobil *autonomous* dapat berjalan di jalan raya dibutuhkan jumlah data dari lingkungan yang cukup besar. Sementara kendali berbasis learning belum cukup mampu memproses data yang besar, olehkarena seringkali memakan waktu yang lama [2]. Keterlambatan dalam memproses data cukup berpengaruh pada kinerja mobil otonom khususnya pada saat mobil membutuhkan keputusan yang cepat dan tepat sesuai dengan kondisi berkendara. Olehkarena mobil otonom diharapkan mampu berjalan di lingkungan yang bersifat dinamik.

Sementara algoritma kendali konvensional meski tidak perlu belajar dari data yang besar dan cukup cepat dalam memberi respon, namun masih kurang *robust* dan kurang fleksibel bila dibandingkan dengan control based learning (AI).

1.3.TUJUAN PENELITIAN

Tujuan yang ingin dicapai adalah meningkatkan performa mobil otonom dalam berinteraksi dengan lingkungan yang dinamis, sehingga mobil otonom dapat diandalkan dan dipercaya. Sementara, sasaran yang ingin dicapai dalam penelitian ini antara lain adalah :

1. Mobil otonom mampu beroperasi dalam lingkungan yang dinamis dengan menggunakan CNN (Convolutional Neural Network)
2. Mobil otonom mampu mengambil keputusan dengan cepat namun tepat dengan cara mengoptimasi/koreksi sudut kemudi dan kecepatan dari CNN menggunakan reactive control based model

1.4. MANFAAT PENELITIAN

Manfaat dari penelitian ini adalah meningkatkan kinerja mobil otonom di jalan raya melalui optimasi/koreksi kendali sudut kemudi mobil sehingga diperoleh sebuah sistem yang memberikan prediksi yang tepat dan cepat dan dapat bekerja di lingkungan yang bersifat dinamis.

1.5. BATASAN MASALAH

Penelitian ini terbatas pada pengujian dua algoritma kendali yaitu CNN dan state feedback linearization terhadap peningkatan performa mobil otonom di jalan raya. Penelitian ini tidak terkait dengan kehandalan sensor dan instrument yang digunakan, Sehingga dalam penelitian ini, semua sensor yang digunakan diasumsikan dalam kondisi baik.


BAB II.

TINJAUAN PUSTAKA

2.1.LANDASAN TEORI

2.1.1. PENGENALAN


Autonomous atau otonom adalah mesin atau komputer yang bekerja tanpa campur tangan manusia. Sehingga mobil otonom adalah mobil yang mampu bergerak sendiri tanpa bantuan atau intervensi dari sopir manusia. Saat ini dikenal ada 6 level otomatisasi dalam mengemudi menurut SAE (Standard Automation Engineer). Pada level 0 hingga 4, masih dilengkapi dengan sopir manusia sebagai pengendali yang dikurangi fungsinya seiring peningkatan level. Level 0 adalah mobil yang hanya menggunakan sopir manusia sebagai pengendali, level 1 dan level 2 adalah mobil yang telah dilengkapi dengan driving assistant seperti automatic cruise control, lane assistant, dan highway assistant. Level 1 memiliki minimum satu fungsi otomatis, dan level dua memiliki minimal dua fungsi otomatis. Pada level ini, sopir masih harus terus mengawasi dan mengendalikan mobil secara terus menerus selama perjalanan. Pada level 3, mobil otonom telah dilengkapi dengan traffic assistant, sehingga sopir sudah bisa mengemudi dengan santai atau bahkan bisa sambil membaca dll. Di level ini, mobil otonom membantu sopir untuk mengemudi, namun apabila dalam kondisi macet yang berat, sopir harus mengambil alih kemudi.



Gambar 1. Level autonomous driving menurut SAE [4]

Level 4 dikenal dengan nama fully automatic, dimana semua fungsi vehicle control telah disediakan oleh sistem tanpa harus ada intervensi dari manusia lagi. Namun di level 4, sopir masih bisa mengambil alih kemudi jika fungsi otomatis tersebut gagal beroperasi. Di level 5, mobil otonom sudah berfungsi sebagai robot berbentuk mobil, dimana manusia tidak dapat lagi melakukan intervensi terhadap kemudi, semua nya telah berjalan otomatis. Saat ini mobil otonom yang telah dipasarkan masih di level 3, sementara level 4 masih dalam pengujian dan validasi di lapangan. Sedangkan level 5 masih dilakukan riset. [4].


Mobil gerak mandiri terdiri atas beberapa bidang yang saling terkait dan melengkapi, diantaranya; sistem komunikasi wireless, embedded systems, navigasi, sensor, dan data akusisi. [1]. Teknologi sensor pada mobil otonom sangat memegang peranan penting, ada beberapa sensor yang umum digunakan di mobil otonom antara lain LIDAR, radar, kamera, GPS, dll. Gambar 1 memperlihatkan sensor sensor yang digunakan pada mobil otonom.



Gambar 2. Sensor sensor pada mobil otonom [5]


Mobil otonom pada dasarnya merupakan sistem yang terbagi atas tiga bagian yaitu lingkungan, hardware dan software. Software terbagi lagi atas perception, planning, dan control, serta fungsinya masing masing yang dijabarkan pada gambar 3. Perception adalah sistem yang mengumpulkan informasi dan men-ekstrak data dari lingkungan melalui sensor. Sistem planning adalah proses membuat keputusan yang membawa mobil ber navigasi dari titik poin keberangkatan menuju destinasi dengan selamat dan menghindari adan hambatas yang ada di jalan serta memaksimalkan kemampuan untuk ber navigasi tersebut sehingga

mencapai tujuan dengan cepat. Sedangkan, control adalah kemampuan mobil otonom untuk meng-eksekusi keputusan yang dikelola dibagian planning [6].



Gambar 3. Sistem mobil otonom yang umum dan bidang bidang kompetensi nya [6]

Meski mobil otonom telah ada dipasaran, problem yang ada pada mobil otonom masih cukup luas dan membutuhkan lapangan riset yang cukup besar pula. Masalah yang terdapat pada mobil otonom mencakup bidang teknis, no-teknis, aturan, dan social. Gambar 4 memperlihatkan skema problematika yang dihadapi mobil otonom saat ini dan yang akan datang. Namun riset ini hanya akan membahas bagian teknis dari mobil otonom saja khususnya bagian perancangan kendali untuk mobil otonom.



Gambar 4 Problem pada mobil otonom saat ini dan yang akan datang [1]

2.1.2. KENDALI BERBASIS LEARNING PADA MOBIL OTONOM

Pada sistem navigasi, sistem yang *robust* dan kendali yang stabil merupakan syarat utama kendaraan otonom untuk bernavigasi mengikuti jalur. Kendali longitudinal didesain untuk mengatur kecepatan mobil dan jarak antar mobil/obyek di jalan raya agar tidak terjadi kecelakaan. Sedangkan kendali lateral didesain untuk mengendalikan sistem kemudi kendaraan agar mengikuti/melacak jalur yang telah direncanakan (*path tracking*) serta menjaga kestabilan kendaraan selama *tracking* [7]. Oleh karena itu, sistem kendali kemudi (*lateral control*) pada mobil otonom sangat erat kaitannya dengan perencanaan jalur berkendara (*path planning*) dan pelacakan jalur (*path tracking*).

Dalam mendesain kendali lateral dan longitudinal, pemilihan algoritma yang tepat sangatlah penting. Umumnya kendali lateral dan longitudinal didesain dengan menggunakan algoritma kendali optimal, kendali nonlinear, kendali adaptive, dll. Namun dekade terakhir ini, penggunaan algoritma kecerdasan buatan juga sering digunakan pada desain gerak lateral dan longitudinal. Hal ini disebabkan kecerdasan buatan dapat digunakan untuk menyelesaikan berbagai macam persoalan yang kompleks seperti; membuat ruang keadaan estimasi; mengenal obyek, *tracking*, dll. Selain daripada itu, algoritma kecerdasan buatan mampu memproses data dalam jumlah besar. [3].

Deep learning merupakan salah satu teknologi terdepan pada mobil otonom, disebabkan oleh kemampuan algoritma ini dalam memproses data gambar/video dari kamera.. Perkembangan pesat processor, graphic cards, dan memori untuk menampung data yang sangat besar mempercepat terwujudnya mobil otonom. Ada beberapa bagian utama dari penggunaan deep learning pada mobil otonom, antara lain persepsi, lokalisasi, prediksi, dan pengambilan keputusan.

a. Perception

Sistem persepsi pada mobil otonom berfungsi untuk membantu mobil otonom “melihat” lingkungan yang ada disekitarnya melalui pengenalan, deteksi, dan klasifikasi obyek. Mobil otonom harus mampu mengklasifikasi lampu lalu lintas, pedestrian, tanda jalan, zebra cross, slot parkir, batas jalan, dll. Persepsi juga memiliki kemampuan untuk menentukan jarak antara mobil otonom dan obyek lainnya dan mengambil keputusan apakah akan mempercepat atau memperlambat kendaraan. Tiga jenis sensor yang umum digunakan pada mobil otonom adalah, LIDAR, radar, dan kamera.[8]

b. Localization

Localization di mobil otonom dapat berarti menghitung posisi dan orientasi dari mobil otonom selama bernavigasi melintasi jalur. Deep learning meningkatkan performa dari

localization dan meng-klasifikasi-kan obyek. Data yang diperoleh digunakan untuk mengestimasi posisi dan arah daripada mobil otonom [8].

c. Prediksi

Mobil mampu menerima informasi atau data dari lingkungan menggunakan berbagai macam sensor. Deep learning berperan untuk menginterpretasi gambar/video yang diperoleh dari sensor, menentukan posisi dan arah daripada mobil, dan meng-aktuasi gerak kinematic pada mobil [8].

d. Decision Making

Decision Making pada mobil otonom merupakan sebuah proses hirarki yang terdiri atas empat bagian, antara lain [8]

- a) Path Planning, mobil otonom harus membuat perencanaan dari posisi sekarang ke posisi tujuan dengan baik, dan yang diharapkan adalah solusi paling optimal dari banyak solusi.
- b) Behaviour Arbitration, setelah mobil membuat path planning, maka selanjutnya membuat behaviour arbitration, dimana mobil mengenal semua static environment seperti zebra cross, pedestrian, rambu rambu jalan, batas tepi. Tetapi mobil tidak mengenal obyek atau user menggunakan jalan tersebut, dan bagaimana sikap dari para pengguna jalan tersebut, juga perlu menjadi bagian penting dari perencanaan.
- c) Motion planning, merupakan langkah selanjutnya, yaitu bagaimana mobil otonom akan ber navigasi melalui jalur yang telah ditentukan. Motion planning dapat berupa lane changing, lane keeping, obstacle avoidance, lane detection, lane keeping, object detection, lane following dan masih banyak lagi.
- d) Vehicle Control, merupakan hasil dari motion planning dimana mobil mengeluarkan output yang sesuai dengan reference path.

Namun seringkali kendali berbasis learning membutuhkan waktu yang lama dalam memproses training data yang menyebabkan pada penundaan dan biaya tambahan pada produksi mobil gerak mandiri. Namun, bagi mobil gerak mandiri penggunaan data yang lengkap sangat diperlukan untuk membangun sistem yang terpercaya dan *robust*. Oleh karena mobil *autonomous* diharapkan mampu berkendara dalam segala skenario sehingga dibutuhkan data yang tidak sedikit. [2]. Penyajian data itu sendiri masih merupakan problematika, karena jaringan learning hanya mempelajari berdasarkan apa yang disajikan oleh perpustakaan data, namun adakalanya manusia melakukan aksi mengemudi yang tidak ada di database [9]. Kelemahan yang lain daripada control based learning adalah waktu komputasi yang cukup

Sistem autonomous perception merupakan bagian utama dari model daripada gambar 6. Pada sistem ini didesain algoritma kecerdasan buatan yang dapat menjadi pengendali bagi model kinematik/dinamik mobil.





Figure 1: High-level view of the data collection system.

Gambar 7. Data Collection System [12]

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*. Contoh adalah *DAVE-2* seperti yang terlihat pada gambar 7. Data training diaugmentasikan dengan gambar tambahan yang memperlihatkan mobil dari shift yang berbeda terlihat dari tengah jalur dan rotasi dari arah jalan [12].

Gambar 8 memperlihatkan sistem autonomous perception pada DAVE 2. Gambar dimasukkan ke Convolutional Neural Network (CNN), yang kemudian menghitung *proposed steering command*. Perintah ini dibandingkan dengan *desired command* untuk mendapatkan *weight* dari CNN yang sesuai, sehingga CNN output hampir mendekati *desired output*. [12].



Gambar 8. Arsitektur Sistem Autonomous Perception [12].

Bentuk data collection berupa training data dikumpulkan dari mengemudi pada berbagai macam model jalanan dan kondisi cuaca. Sedangkan Weight dari jaringan dilatih untuk meminimasi mean squared error antara keluaran *steering command* dan perintah dari sopir manusia atau perintah kemudi yang disesuaikan. [12]

2.1.3. PEMODELAN KINEMATIK/DINAMIK

Model kinematic yang digunakan adalah model 3 DOF, olehkarena scenario jalan yang digunakan tergolong jalan yang mulus dengan sudut kecuraman $\pm 20^\circ$.




Fig. 1. Diagram of kinematic car model. System state is $q = (x, y, \theta)$ and inputs are u_s and u_ϕ , which correspond to commanded velocity and commanded steering respectively.

Gambar.9. Model 3 DoF dari mobil otonom [13]

Bentuk ruang keadaan dari model kinematik ini, adalah sebagai berikut [13] :

$$\dot{x} = v \cos \theta \quad (1)$$

$$\dot{y} = v \sin \theta \quad (2)$$

$$\dot{\theta} = \frac{v}{L} \tan \phi \quad (3)$$

Dimana X,Y adalah element dari koordinat ruang

θ adalah sudut azimuth dari koordinat ruang $(0, 2\pi)$

L adalah Panjang dasar mobil

$U(u_s, u_\phi) =$ input kendali


$u_s =$ input kecepatan

$u_\phi =$ input sudut kemudi

2.1.4. Desain Kendali Berbasis Reaktif

2.1.4.1. State Feedback Linearization With Ackerman Formula

Pada riset ini kendali reaktif berbasis model yang digunakan adalah state feedback linearization dengan PD Observer.



Gambar 10. Arsitektur State Feedback Linearization

Mobil otonom dengan 3 DOF dalam bentuk state vector sebagai berikut:

$$q = [\dot{x}, \dot{y}, \dot{\theta}] \quad (4)$$

$$\dot{x}_1 = x_2; \quad (5)$$

$$\dot{x}_2 = v \cos \theta = u \quad (6)$$

$$\dot{y}_1 = y_2; \quad (7)$$

$$\dot{y}_2 = v \sin \theta = u \quad (8)$$

$$\dot{\theta}_1 = \theta_2 \quad (9)$$

$$\dot{\theta}_2 = \frac{v}{L} \tan \psi = u \quad (10)$$

Jika persamaan (5) – (10) ditransformasikan dalam bentuk matriks, sebagai berikut:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u \quad (11)$$

$$\begin{bmatrix} \dot{y}_1 \\ \dot{y}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u \quad (12)$$

$$\begin{bmatrix} \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u \quad (13)$$

dengan $A = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}; B = \begin{bmatrix} 0 \\ 1 \end{bmatrix}; C = [0 \quad 1];$

Maka, desain *control feedback* untuk memenuhi *control law* adalah sebagai berikut:

$$u = -Kx \quad (14)$$

dimana state variable feedback matrix sebagai berikut:

$$K = [K1, K2]$$

Pertimbangkan juga reference K input (r), sehingga control law formula menjadi

$$u = -Kx + r \quad (15)$$

Kemudian desain characteristic equation sebagai berikut

$$\partial^2 + 2\delta\omega_n\partial + \omega_n^2 = 0 \quad (16)$$

dimana δ is overshoot dan ω_n is natural frequency

Metode State feedback linearization ini di desain berdasarkan ref [14] dan [15] Sistem menyesuaikan gain dari state feedback gain sehingga dapat mencapai stabilitas dan titik equilibrium berdasarkan desired overshoot and natural frequency, ,

Ackerman formula pada juga diaplikasikan pada 3 DoF vehicle model, jika model nya controllable [15]. Persamaan karakteristik yang baru menjadi :

$$L(A) = A^2 + 2\zeta\omega_n^2 A + \omega_n^2 I + \alpha_n I \quad (17)$$

Kemudian, desain a state feedback gain matrix sebagai berikut:

$$K = [0 \ 1]C_M^{-1}L(A) \quad (18)$$

dimana C_M is controllability matrix

Desain controller K untuk sesuai dengan overshoot dan natural frequency.

2.1.4.2. State Feedback Linearization With Observer For Autonomous Vehicle

Jika kita menambahkan observer pada sistem, maka terbentuk full state observer system, sebagai berikut :

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u \quad (19)$$

$$y = [0 \ 1]x \quad (20)$$


Desain estimates state dari x , sehingga diperoleh $\hat{\dot{x}}$

$$\begin{bmatrix} \dot{\hat{x}}_1 \\ \dot{\hat{x}}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \hat{x}_1 \\ \hat{x}_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u + \begin{bmatrix} L_1 \\ L_2 \end{bmatrix} \hat{y} \quad (21)$$

$$\hat{y} = y - [0 \ 1]\hat{x} \quad (22)$$

dimana $C = [0 \ 1]$

dimana $\hat{\dot{x}}$ adalah estimates state x dan L adalah observer gain.



Gambar 11. State Feedback Linearization dengan PD Observer

Desain observer gain yang sesuai dengan overshoot dan natural frequency, untuk desired coordinates $(\dot{x}_d, \dot{y}_d)$, maka actual coordinates $(\dot{x}, \dot{y})$ adalah sebagai berikut :

$$\dot{x} = \dot{x}_d + k_x x_e \quad (23)$$

$$\dot{y} = \dot{y}_d + k_y y_e \quad (24)$$

dimana

$$x_e = x_d - x \quad (25)$$

$$y_e = y_d - y \quad (26)$$

Persamaan 23 dan 24 dapat ditulis dalam bentuk

$$\begin{bmatrix} \dot{x}_e \\ \dot{y}_e \end{bmatrix} + \begin{bmatrix} k_x & 0 \\ 0 & k_y \end{bmatrix} \begin{bmatrix} x_e \\ y_e \end{bmatrix} = 0 \quad (27)$$

Lyapunov function menentukan stabilitas sistem dengan unique equilibrium point pada titik asal dan positive definite [3], sebagai berikut :

$$V = \frac{1}{2} e^T e, e > 0 \quad (28)$$

Where:

$$e = \begin{bmatrix} x_e \\ y_e \end{bmatrix} \quad (29)$$

$$\dot{e} = - \begin{bmatrix} k_x x_e \\ k_y y_e \end{bmatrix} \quad (30)$$

maka derivative adalah negative definite [3], sebagai berikut:

$$\dot{V} = e^T \cdot \dot{e} = -k_x x_e^2 - k_y y_e^2 < 0 \quad (31)$$

Sistem ini didesain untuk asymptotically stable dan the error selalu converges ke zero. Pengendali baru dihitung untuk membangkitkan sudut kemudi sehingga mobil mampu bernavigasi terhadap desired trajectory.

2.2. PENELITIAN TERKAIT

2.2.1. Dalam Negri

Beberapa penelitian dari dalam negri yang berkaitan dengan mobil gerak mandiri antara lain sebagai berikut :

- a. Deteksi Halangan Menggunakan Metode R-CNN pada Mobil Otonom ; oleh Adrian Aryaputra Firmansyah, Rusdhianto Effendie AK, Ari Santoso, Jurnal Teknik ITS [16]
- b. Deteksi Objek Pada Mobil Otonom dengan Kamera Termal Inframerah; oleh Mannarul Hidayah, Astria Nur Irfansyah, dan Djoko Purwanto; JURNAL TEKNIK ITS [17]
- c. Pengaturan Kemudi yang Robust terhadap Ketidakpastian Parameter Internal pada Mobil Otonom; oleh Ryan Aditya, Achmad Jazidie, dan Eka Iskandar; Jurnal Teknik ITS. [18]
- d. Deteksi Ruang Kosong pada Jalan Menggunakan Semantic Segmentation pada Mobil Otonom; oleh Agil Bintang Pratama, Rusdhianto Effendi Abdul Kadir, dan Mohamad Abdul Hady Departemen Teknik Elektro, Institut Teknologi Sepuluh Nopember (ITS); Jurnal Teknik ITS. [19]
- e. Pengendalian Robot Mobil Otonom Pemotong Rumput Menggunakan Metode Logika Fuzzy; oleh Muhammad Firdaus¹ , Mohd Syaryadhi² , Aulia Rahman; Jurnal Online Teknik Elektro [20].


2.2.2. Luar Negri

Beberapa penelitian dari luar negri yang berkaitan dengan mobil gerak mandiri antara lain;

- a. Deep-Neural-Network-BasedModelling of Longitudinal-Lateral Dynamics to Predict the Vehicle States for Autonomous Driving ; oleh Xiaobo Nie¹, Chuan Min¹, Yongjun Pan^{1,2,*} , Ke Li³ and Zhixiong Li⁴; sensors [21].
- b. Nonlinear cascade strategy for longitudinal control in automated vehicle guidance; Rachid Attia¹, Rodolfo Orjuelaⁿ, Michel Basset; control engineering practice [22].
- c. A Convolutional Neural Network-Based End-to-End Self-Driving Using LiDAR and Camera Fusion: Analysis Perspectives in a Real-World Environment; Mingyu Park¹, Hyeonseok Kim¹ and Seongkeun Park^{2,*}; electronics [23].

- d. End-to-End Deep Neural Network Architectures for Speed and Steering Wheel Angle Prediction in Autonomous Driving; oleh Pedro J. Navarro 1, Leanne Miller 1 , Francisca Rosique 1, Carlos Fernández-Isla 1 and Alberto Gila-Navarro; electronics.[24].
- e. A robust fuzzy control approach for path-following control of autonomous vehicles; oleh Ardashir Mohammadzadeh1 · Hamid Taghavifar; Soft Computing [25].

Penelitian terkait mobil otonom yang lebih lengkap diperlihatkan pada gambar 12.



Gambar 12. Aplikasi deep learning pada mobil otonom [26]

2.3.STATE OF THE ART

Beberapa penelitian sebelumnya mengenai tracking control pada mobil otonom menggunakan kendali berbasis learning telah pernah dilakukan. Tabel memperlihatkan perbandingan, kekuatan dan kelemahan masing masing algoritma learning dan non-learning serta hasil yang telah dicapai.[9]

Tabel 1. Klasifikasi dari tracking control pada mobil otonom

Category	Strenghts/Weaknesses	Overall Approach	Contributions
Methods based on convolutional neural networks	Strengths: • good at learning spatial, shape and geometric features • reduced computational load compared to regular neural networks • translation invariance Weaknesses: • cannot determine temporal dependencies in sequence data without additional mechanisms	Tracking from features directly learned by simple single-stream convolutional layers	[8,16,18]
		Dual-stream CNNs with data associations performed by additional model components	[6,19,28,37]
		Tracking using responses from convolutional features processed through correlation filters	[2-5,22,23]
		Multistream CNNs that determine similarities between multiple ROIs and target templates	[14]
		Models that determine appearance descriptors or that generate appearance representations from convolutional features	[1,13,25,27,32]
		Convolutional models that account for temporal coherence using a multi-network pipeline	[24]
		Tracking from features learned by fusing responses from dual stream convolutional layers (Siamese CNNs)	[26,30,31,38]
		Models that generate features from convolutional layers and use attention mechanisms for temporal coherence and matching	[15,39-41]
		Multi-stream convolutional layers used for detecting pedestrian poses	[17]
		Siamese networks combining convolutional features with complementary features from image processing	[33]
Methods based on recurrent neural networks	Strengths: • good for processing data series • good for learning temporal features and dependencies, and for ensuring temporal coherence Weaknesses: • cannot deduce interactions without additional mechanisms • generally more difficult to train	Models based on LSTM cell configurations that directly predict vehicle/obstacle occupancy	[44,49]
		Model for motion prediction based on vehicle maneuvers	[45]
		LSTM-based architectures that generate appearance and motion models and learn interaction information over extended sequences	[43,47,51]
		Multi-layer GRU-based architecture which splits and reconnects tracklets generated from convolutional features	[46]
		Basic RNN that encodes information from multiple frame sequences	[42,48]
		LSTM layers that focus on learning and interpreting actor intentions	[52,53]
		LSTM-based object detection and tracking adapted for sequences of higher-dimensional data	[55]
		LSTM models that encode relationships between actors using graph representations	[56,57]
		LSTM model that uses multidimensional internal representations of data sequences	[54]


Methods not relying on neural networks	Strengths: - designing a working model is more straightforward compared to neural networks - most are not training data-dependent Weaknesses: - traditional, classic methods do not model sequence dependencies as effectively as many RNN-based solutions	Models that represent and predict actor relationships using flow-networks and graphs	[83,85,89,90]
		Models relying on geometric representations, kinematics and pose estimations	[74,75,77,91]
		Models that ensure detection coherence using adaptive partitioning of the problem space	[71,86]
		Methods relying on Markov models and Markov decision processes	[66–68]
		Methods that build appearance models and/or use appearance similarity metrics	[72,73,87,88]
		Methods using a multi-stage tracking pipeline incorporating filtering, segmentation, clustering and/or data association	[76,78]
		Methods relying on lightweight filtering and optimization for high-speed high-performance applications	[63,64,80,84]

Dari Tabel 1 terlihat bahwa kendali berbasis learning masih membutuhkan sistem tambahan untuk memperbaiki mekanisme kerjanya yang tergantung pada database dan memiliki proses komputasi yang lambat. Sementara kendali berbasis non-learning tidak tergantung pada database, namun merupakan kendali klasik/tradisional sehingga tidak efektif khususnya bila menghadapi kondisi yang kompleks. Olehkarena itu penggabungan antara kendali berbasis learning dan non-learning dapat memperbaiki kinerja daripada sistem mobil otonom karena saling melengkapi. Pada sistem kendali yang dimodifikasi ini direncanakan untuk memiliki kemampuan unggul dari kendali berbasis learning yang mampu mengatasi kendala mobil otonom ketika berjalan di dynamic environment, Namun juga mampu mengambil keputusan yang cepat dan tepat ketika kondisi sedang darurat membutuhkan pengambilan keputusan dibawah 3 detik.

Sistem kendali mobil otonom yang dimodifikasi yang terdiri dari kendali berbasis learning (Convolutional Neural Network) dan kendali reaktif berbasis model yaitu state feedback linearization dengan PD observer.


Sistem ini mengkoreksi/optimasi sudut kemudi dan kecepatan mobil otonom sehingga mampu berinteraksi dengan lingkungan yang bersifat dinamis. Gambar 13 memperlihatkan arsitektur sistem kendali mobil autonomous yang direncanakan.

Algoritma CNN yang dimodifikasi akan diterapkan pada pengendalian gerak lateral mobil dan longitudinal. Gerak lateral mobil adalah gerak yang menentukan posisi dan arah mobil. Tujuan dari penggunaan algoritma ini untuk mengelola data dari sensor untuk menentukan sudut kemudi dan kecepatan yang sesuai bagi mobil. Keluaran dari algoritma ini juga akan bertindak sebagai pengendali bagi model mobil. CNN memproses data training cukup lama. Oleh karena bagian kendali based learning lebih ditujukan untuk memberi prediksi (t_{-1}) kondisi berkendara yang tidak tergesa dan bisa diproses dalam waktu yang cukup. Namun jika sensor mendeteksi bahwa mobil otonom perlu pengambilan keputusan yang cepat maka, sistem akan men-switch ke reaktif control based model yang mampu memproses data sensor karena lebih cepat karena tidak membutuhkan data training yang besar. Selain daripada itu, kedua sistem (control based learning maupun control based model) akan saling mengkoreksi/men-optimasi keluaran dari sistem yang lain, sehingga diperoleh output yang lebih baik dan mampu di kondisikan dalam segala situasi.



Gambar 13. Arsitektur Kendali Mobil Otonom yang diusulkan

2.4.KERANGKA PIKIR PENELITIAN



BAB III

METODE PENELITIAN

3.1. TAHAPAN PENELITIAN

Tahapan penelitian yang digunakan terangkum dalam tabel 2.

Tabel 2. Tahapan Penelitian

Tahapan	Kegiatan	Indikator Capaian	Keluaran
Pengumpulan data	Pengumpulan data set rekaman steering angle dan posisi/arah mobil yang akan dilatih	Mendapatkan data set rekaman yang sesuai dengan skenario jalan yang ingin dibuat	Data set rekaman steering angle dan posisi/arah mobil
<i>Control based Learning Design</i>	Pembuatan skenario	Memperoleh skenario jalan yang sesuai dengan salah satu rute di makassar yang dipilih	Skenario jalan
	Percobaan sensing pada skenario jalan	Memperoleh data images dari simulasi sensor kamera yang digunakan untuk skenario ini	Data images
	Image processing untuk mengukur pergeseran dan rotasi	Memperoleh data posisi dan arah dari proses images processing	Data posisi dan arah
	Pengujian Deep Learning	Memperoleh data steering angle yang sesuai	Data steering angle sebagai masukan kendali
	Perbandingan desired steering angle dan velocity dengan steering angle command dan velocity hasil deep learning	Memperoleh weight yang merupakan error dari perbandingan	Weight atau error adalah indikator kesuksesan simulasi
Pembuatan model dan trajectory	Pembuatan trajectory Planning	Penyesuai steering angle dengan trajectory	Data steering angle yang disesuaikan dengan trajectory planning
	Penentuan Model Kinematik/Dinamik	Penyesauain model dinamik/kinematic dengan skenario	Model kinematic/dinamik yang disesuaikan dengan skenario jalan
Desain Kendali	Desain Kendali	Memperoleh input	input kendali

Longitudinal	Longitudinal	kendali untuk kecepatan mobil yang stabil	untuk kecepatan mobil
Verifikasi dan Integrasi	Verifikasi dan integrasi	Memperoleh analisis respon transien yang stabi dan sesuai dengan kriteria desain sehingga mendapatkan performa yang robust dan stabil	Respon transien
	Analisis Response		

3.2. WAKTU DAN LOKASI PENELITIAN

Waktu Penelitian : April 2023 – Juni 2024

Lokasi Penelitian : Laboratorium Elektronika dan Devais
Laboratorium Kendali dan Instrumentasi
Prodi S3 Teknik Elektro
Fakultas Teknik Unhas


3.3. JENIS PENELITIAN

Jenis Penelitian : Simulasi komputer menggunakan software Matlab

3.4. PERANCANGAN SISTEM

- menggunakan beberapa macam tipe sensor ; proprioceptive sensor, tracking sensor, object detection sensor, dan vision sensor
- AI data training berasal dari kaggle data set for autonomous vehicle
- control based learning yang digunakan adalah convolutional neural network
- reactive control based model yang digunakan adalah state feedback linearization control dengan sebuah PD observer
- trajectory and speed generation menggunakan autonomous vehicle scenario yang ada pada simulink matlab
- seluruh sistem di simulasi menggunakan software matlab

sistem yang akan dirancang sesuai dengan blok diagram dibawah ini



3.5. SUMBER DATA

[Peking University/Baidu - Autonomous Driving | Kaggle](#)

https://github.com/HamdiTarek/Self_Driving_Car.git

[Peking University/Baidu - Autonomous Driving | Kaggle](#)

[Self-driving car tutorial - YouTube](#)

[Scenario Generation from Recorded Vehicle Data - MATLAB & Simulink](#)

[\(mathworks.com\)](#)

[Collect and Analyze Data Using MATLAB and Raspberry Pi - Video - MATLAB](#)

[\(mathworks.com\)](#)

[Tutorial : Computer Vision for Automated Driving in MATLAB -- Part 1 - YouTube](#)

[Basic Operations on Images: Making Vehicles and Robots See Video - MATLAB](#)

[\(mathworks.com\)](#)

Matlab document **Track Pedestrians from a Moving Car**

3.6. INSTRUMENTASI PENELITIAN

- Software Matlab
- Kamera

3.7. JADWAL PENELITIAN

TAHUN 2023

KEGIATAN	1	2	3	4	5	6	7	8	9	10	11	12
Pengumpulan Data Lapangan												
Pengumpulan Data dari Machine Learning Database												

Desain sistem control based model												
Membangun skenario jalan dan sensing terhadap lingkungan via matlab												
Desain Deep Learning												
Konferensi												
Integrasi dan Verifikasi												
Submit dan Review publikasi ilmiah												

DAFTAR PUSTAKA

Bibliography

- [1] 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.
- [2] 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.
- [3] D. Fenyese, B. Nemeth, and P. Gaspar, "LPV-based autonomous vehicle control using the results of big data analysis on lateral dynamics," *Proc. Am. Control Conf.*, vol. 2020-July, pp. 2250–2255, 2020, doi: 10.23919/ACC45564.2020.9147548.
- [4] M. Hirz and B. Walzel, "Sensor and object recognition technologies for self-driving cars," *Comput. Aided. Des. Appl.*, vol. 15, no. 4, pp. 501–508, 2018, doi: 10.1080/16864360.2017.1419638.
- [5] S. Grigorescu, B. Trasnea, T. Cocias, and G. Macesanu, "A survey of deep learning techniques for autonomous driving," *J. F. Robot.*, vol. 37, no. 3, pp. 362–386, 2020, doi: 10.1002/rob.21918.
- [6] S. D. Pendleton *et al.*, "Perception, planning, control, and coordination for autonomous vehicles," *Machines*, vol. 5, no. 1, pp. 1–54, 2017, doi: 10.3390/machines5010006.
- [7] 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.
- [8] N. Barla, "Self-Driving Cars With Convolutional Neural Networks (CNN)," *MLOPs*

- Blog*, 2023. <https://neptune.ai/blog/self-driving-cars-with-convolutional-neural-networks-cnn>.
- [9] F. Leon and M. Gavrilescu, "A review of tracking and trajectory prediction methods for autonomous driving," *Mathematics*, vol. 9, no. 6, p. na, 2021, doi: 10.3390/math9060660.
 - [10] Y. Zhou, H. Hu, Y. Liu, S. W. Lin, and Z. Ding, "A distributed method to avoid higher-order deadlocks in multi-robot systems," *Automatica*, vol. 112, p. 108706, 2020, doi: 10.1016/j.automatica.2019.108706.
 - [11] 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.
 - [12] M. Bojarski *et al.*, "End to End Learning for Self-Driving Cars," pp. 1–9, 2016, [Online]. Available: <http://arxiv.org/abs/1604.07316>.
 - [13] E. A. Olson, N. Risso, A. M. Johnson, and J. Sprinkle, "Fuzzy control of an autonomous car using a smart phone," *2017 Chil. Conf. Electr. Electron. Eng. Inf. Commun. Technol. CHILECON 2017 - Proc.*, vol. 2017-Janua, pp. 1–6, 2017, doi: 10.1109/CHILECON.2017.8229692.
 - [14] S. Bacha, M. Y. Ayad, R. Saadi, O. Kraa, A. Aboubou, and M. Y. Hammoudi, "Autonomous Vehicle Path Tracking Using Nonlinear Steering Control and Input-Output State Feedback Linearization.," *Proc. 2018 3rd Int. Conf. Electr. Sci. Technol. Maghreb, Cist. 2018*, pp. 1–6, 2019, doi: 10.1109/CISTEM.2018.8613365.
 - [15] S. A. Ahmed and M. G. Petrov, "Trajectory Control of Mobile Robots using Type-2 Fuzzy-Neural PID Controller," *IFAC-PapersOnLine*, vol. 48, no. 24, pp. 138–143, 2015, doi: 10.1016/j.ifacol.2015.12.071.
 - [16] A. A. Firmansyah, R. E. AK, and A. Santoso, "Deteksi Halangan Menggunakan Metode Stereo R-CNN pada Mobil Otonom," *J. Tek. ITS*, vol. 9, no. 2, 2021, doi: 10.12962/j23373539.v9i2.53687.
 - [17] M. Hidayah, A. N. I. Irfansyah, and D. Purwanto, "Deteksi Objek Pada Mobil Otonom dengan Kamera Termal Infra Merah," *J. Tek. ITS*, vol. 11, no. 3, 2022, doi: 10.12962/j23373539.v11i3.94793.
 - [18] R. Aditya, A. Jazidie, and E. Iskandar, "Pengaturan Kemudi yang Robust terhadap Ketidakpastian Parameter Internal pada Mobil Otonom," *J. Tek. ITS*, vol. 11, no. 3, 2022, doi: 10.12962/j23373539.v11i3.98266.
 - [19] A. B. Pratama, R. E. Abdul Kadir, and M. A. Hady, "Deteksi Ruang Kosong pada Jalan Menggunakan Semantic Segmentation pada Mobil Otonom," *J. Tek. ITS*, vol. 11, no. 1, 2022, doi: 10.12962/j23373539.v11i1.81667.
 - [20] M. Firdaus *et al.*, "Pengendalian Robot Mobil Otonom Pemotong Rumput

- Menggunakan Metode Logika Fuzzy,” *Kitektro*, vol. 2, no. 2, pp. 36–43, 2017.
- [21] X. Nie, C. Min, Y. Pan, K. Li, and Z. Li, “Deep-Neural-Network-Based Modelling of Longitudinal-Lateral Dynamics to Predict the Vehicle States for Autonomous Driving,” *Sensors*, vol. 22, no. 5, pp. 1–16, 2022, doi: 10.3390/s22052013.
 - [22] R. Attia, R. Orjuela, and M. Basset, “Nonlinear cascade strategy for longitudinal control in automated vehicle guidance,” *Control Eng. Pract.*, vol. 29, pp. 225–234, 2014, doi: 10.1016/j.conengprac.2014.02.003.
 - [23] M. Park, H. Kim, and S. Park, “A convolutional neural network-based end-to-end self-driving using lidar and camera fusion: Analysis perspectives in a real-world environment,” *Electron.*, vol. 10, no. 21, 2021, doi: 10.3390/electronics10212608.
 - [24] P. J. Navarro, L. Miller, F. Rosique, C. Fernández-Isla, and A. Gila-Navarro, “End-to-end deep neural network architectures for speed and steering wheel angle prediction in autonomous driving,” *Electron.*, vol. 10, no. 11, pp. 1–21, 2021, doi: 10.3390/electronics1011266.
 - [25] A. Mohammadzadeh and H. Taghavifar, “A robust fuzzy control approach for path-following control of autonomous vehicles,” *Soft Comput.*, vol. 24, no. 5, pp. 3223–3235, 2020, doi: 10.1007/s00500-019-04082-4.
 - [26] B. Ben Elallid, N. Benamar, A. S. Hafid, T. Rachidi, and N. Mrani, “A Comprehensive Survey on the Application of Deep and Reinforcement Learning Approaches in Autonomous Driving,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 9, pp. 7366–7390, 2022, doi: 10.1016/j.jksuci.2022.03.013.