

USULAN PENELITIAN

**DEEP IMAGE PRIOR UNTUK MENINGKATKAN
PERFORMA DEEP REINFORCEMENT LEARNING
SEBAGAI SISTEM KONTROL LAMPU LALU
LINTAS ADAPTIF BERBASIS VISUAL**



DUMAN CARE KHRISNE

**FAKULTAS TEKNIK
UNIVERSITAS UDAYANA
DENPASAR
2023**

USULAN PENELITIAN

**DEEP IMAGE PRIOR UNTUK MENINGKATKAN
PERFORMA DEEP REINFORCEMENT LEARNING
SEBAGAI SISTEM KONTROL LAMPU LALU
LINTAS ADAPTIF BERBASIS VISUAL**



**DUMAN CARE KHRISNE
NIM. 2291011020**

**PROGRAM STUDI DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS UDAYANA
DENPASAR
2023**

HALAMAN PERSETUJUAN PEMBIMBING AKADEMIK

Praproposal Disertasi ini telah disetujui

Pada Tanggal 28 April 2023

Pembimbing Akademik



Dr. Ir. Yenni Ciawi
NIP. 196611182000122001

Mengetahui

Koordinator Program Studi Doktor Ilmu Teknik
Fakultas Teknik Universitas Udayana

Prof. Dewa Made Priyantha Wedagama, ST., MT.. M.Sc., Ph.D.
NIP. 197003031997021005

HALAMAN PENETAPAN TIM PENGUJI

Praproosal Penelitian Disertasi Ini Telah Diuji dan Dinalai

oleh Tim Penguji pada Fakultas Teknik

Universitas Udayana

Pada tanggal

Berdasarkan SK Rektor Universitas Udayana No. :

Tanggal

Panitia Penguji Praproposal Penelitian Disertasi:

Ketua : Dr. Ir. Yenni Ciawi

Anggota : 1. Prof. Dr. Ir. Made Sudarma, MSc., IPU., ASEAN Eng.
2. Prof. Ir. Ida Ayu Dwi Giriantari, M.Eng.Sc.,Ph.D
3. Dr. Dewa Made Wiharta, ST, MT
4. Prof. Ir. Rukmi Sari Hartati, M.T., Ph.D
5. Prof. Ir. Linawati, M.Eng.Sc, Ph.D
6. Prof. Dr. Nyoman Gunantara, ST, MT
7. Wayan Gede Ariastina, S.T., M.Eng.Sc., Ph.D.

DAFTAR ISI

HALAMAN SAMPUL	I
HALAMAN SAMPUL	II
HALAMAN PERSETUJUAN PEMBIMBING AKADEMIK	III
HALAMAN PENETAPAN TIM PENGUJI	IV
DAFTAR ISI.....	V
DAFTAR TABEL.....	VI
DAFTAR GAMBAR	VI
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
1.5 Batasan Penelitian	6
BAB II TINJAUAN PUSTAKA	8
2.1 Tinjauan Mutakhir	8
2.2 Posisi Penelitian terhadap Penelitian Sebelumnya	46
2.3 <i>Roadmap</i> Penelitian	49
2.4 <i>Computer Vision</i>	50
2.5 <i>Deep Learning</i>	51
2.6 Convolutional Neural Network.....	51
2.7 <i>Over-Fitting</i> dan <i>Under-Fitting</i> dalam <i>Supervised Learning</i>	53
2.8 <i>Image Restoration</i>	53
2.9 <i>Image Prior</i>	54
2.10 <i>Deep Image Prior</i>	55
2.11 Strategi Kontrol Sinyal Lalu Lintas (TSC)	55
2.12 Reinforcement Learning (RL).....	57
2.13 Deep Reinforcement Learning (DRL)	59
BAB III KERANGKA BERFIKIR, KONSEP PENELITIAN DAN HIPOTESIS.....	60
3.1 Kerangka Berfikir	60
3.2 Konsep Penelitian	62
3.3 Hipotesis	63
BAB IV METODE PENELITIAN	65
4.1 Rancangan Penelitian.....	65
4.2 Lokasi dan Waktu Penelitian	67
4.3 Ruang Lingkup Penelitian.....	70
4.4 Penentuan Sumber Data	71
4.5 Variable Penelitian.....	71
4.6 Bahan Penelitian	71
4.7 Instrumen Penelitian	72
4.8 Prosedur Penelitian	72
4.9 Teknik Analisis Data.....	74
4.10 Kebaruan (<i>Novelty</i>)	75
DAFTAR PUSTAKA	76

DAFTAR TABEL

Tabel 2.1 Rekapitulasi <i>State of The Art</i>	15
--	----

DAFTAR GAMBAR

Gambar 2.1 Diagram <i>fishbone</i> penelitian pada <i>Traffic Congestion Management</i>	47
Gambar 2.2 Posisi Penelitian Terhadap Penelitian Sebelumnya pada <i>Traffic Congestion Management</i>	48
Gambar 2.3 Posisi Penelitian Terhadap Penelitian Sebelumnya pada cabang <i>real live-data</i>	49
Gambar 2.4 Rodamap Penelitian	50
Gambar 2.5 <i>Convolutional Neural Network</i>	52
Gambar 3.1 Kerangka Berfikir	60
Gambar 3.2 Diagram Konsep Penelitian.....	63
Gambar 4.1 Gambaran Umum Sistem Kontrol Lampu Lalu lintas Adaptif	66
Gambar 4.2 Arsitektur Neural Network <i>Image Prior</i>	66
Gambar 4.3 <i>Flowchart</i> Tahapan Penelitian	73

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam dua dekade terakhir, pertumbuhan yang cepat dan urbanisasi membawa masalah genting di negara-negara berkembang. Salah satu masalah utama yang dihadapi oleh semua lapisan masyarakat adalah masalah transportasi jalan raya. Masalah transportasi masih sering dihadapkan pada fenomena kemacetan arus lalu lintas yang berdampak pada kecelakaan lalu lintas, polusi, dan kerugian ekonomi (Ali *et al.*, 2014). Terdapat tiga faktor kunci yang dapat menyebabkan terjadinya kemacetan (de Souza *et al.*, 2017). Pertama adalah faktor yang berhubungan dengan kejadian-kejadian yang mempengaruhi keadaan lalu lintas secara langsung seperti kecelakaan, kawasan perkantoran, dan kondisi cuaca yang buruk. Faktor yang kedua adalah hal-hal yang berhubungan dengan tuntutan lalu lintas, sebagai contoh fluktuasi kemacetan pada kondisi normal dan waktu-waktu spesial. Faktor terakhir adalah faktor infrastruktur, yang direpresentasikan oleh peralatan pengontrol lalu lintas dan hambatan fisik.

Penelitian terdahulu berhasil merangkum beberapa teknik yang dapat digunakan untuk pemecahan permasalahan lalu lintas. Teknik-teknik tersebut dikelompokkan menjadi solusi jangka panjang, jangka menengah dan jangka pendek berdasarkan waktu penyelesaiannya (Akhtar and Moridpour, 2021). Teknik jangka panjang dilakukan dengan membangun/melakukan perubahan kebijakan transportasi. Teknik jangka menengah dilakukan dengan menyiapkan jalur alternatif atau melakukan analisis jalur jalan. Sedangkan teknik jangka pendek menekankan pada solusi-solusi *real time*. Salah satu teknik jangka pendek atau *real time* dilakukan melalui manajemen yang baik terhadap arus lalu lintas di persimpangan jalan. Arus lalu lintas jangka pendek di persimpangan jalan dapat dikendalikan dengan memanfaatkan sistem lampu lalu lintas (Santoso, Azis and Bode, 2020). Dalam hal manajemen lalu lintas yang menggunakan lampu lalu lintas, sebagian besar persimpangan menggunakan sistem siklus lampu lalu lintas waktu tetap (*fixed-cycle*) untuk mengatur lalu lintas atau menggunakan sensor di

jalan raya (*loop* induktif) untuk memperpanjang atau memperpendek sinyal lampu lalu lintas bila diperlukan.

Sistem *fixed-cycle* bekerja paling baik ketika arus lalu lintas hampir sama di keempat arah. Namun, seringkali dapat ditemui situasi lalu lintas lebih banyak di satu arah dibandingkan arah lainnya. Selain itu, sistem tradisional tidak memiliki manajemen yang cerdas, yang mengakibatkan orang menunggu, terlepas dari tidak adanya kendaraan dari arah yang berlawanan. Waktu tunggu yang tak terhindarkan ini terkadang membuat seseorang resah, yang seringkali berakhir dengan pelanggaran aturan dan kecelakaan. Lebih lanjut, hal ini menyebabkan lebih banyak konsumsi bahan bakar dan menambah polutan ke lingkungan sekitar. Pengendalian lampu lalu lintas secara statis terbukti belum optimal dalam meminimalisir kemacetan arus lalu lintas karena selain alasan yang dipaparkan sebelumnya, terjadi juga peningkatan jumlah kendaraan secara eksponensial yang tidak sejalan dengan perkembangan kapasitas jalan (Guo *et al.*, 2019). Hal ini menyebabkan kondisi arus lalu lintas tidak mudah ditebak (bervariasi). Oleh karena itu, pengendalian lampu lalu lintas cerdas atau dinamis perlu untuk terus ditingkatkan. Metode kontrol sinyal adaptif yang banyak digunakan seperti SCOOT (Hunt *et al.*, 1982) dan SCAT (Sims and Dobinson, 1980) sebagian besar mengandalkan fase sinyal yang dijadwalkan secara manual. Jadwal ini dirancang untuk dipilih secara dinamis sesuai dengan volume lalu lintas yang terdeteksi oleh *loop* induktif. Sensor *loop* induktif pada umumnya ditempatkan di dekat persimpangan dan tidak diaktifkan sampai kendaraan melewatiinya, dan hanya memberikan sebagian informasi tentang kondisi lalu lintas. Akibatnya, sinyal tidak dapat melihat dan bereaksi terhadap perubahan pola lalu lintas secara *real time* dan operator transportasi seringkali harus mengubah fase sinyal secara manual untuk mengikuti perkembangan kondisi lalu lintas (Garg, Chli and Vogiatzis, 2022).

Kecerdasan buatan yang berkembang dalam satu dekade ini memberikan harapan munculnya sistem dengan kecerdasan dan adaptasi yang tinggi. Penelitian (Abdelgawad *et al.*, 2015; Vidhate and Kulkarni, 2017; Wan and Hwang, 2018; Bhave *et al.*, 2019; Sahal *et al.*, 2023) menggunakan pendekatan *reinforcement learning* (RL) untuk memberikan solusi mengatasi kemacetan. Model RL secara

langsung mencoba beradaptasi untuk memecahkan masalah yang dibebankan pada model, termasuk permasalahan kemacetan lalu lintas. Salah satu yang dapat diselesaikan oleh RL adalah adaptasi waktu tunggu kendaraan pada persimpangan bersinyal untuk membangun *adaptive traffic control system* (ATCS). Agar dapat melakukan tugas tersebut sistem memanfaatkan data yang diambil secara *real time* dari kendaraan yang bergerak, banyak teknik yang digunakan untuk melakukan deteksi kendaraan bergerak, *vision-based* dan *sensor-based* (Ata *et al.*, 2018) adalah dua pendekatan teknik tersebut. Teknik pendekatan kendaraan berbasis sensor (*sensor-based*) dilakukan berdasarkan keberadaan fisik kendaraan dan karenanya dianggap sebagai sistem non-komputer (Iftikhar, Dissanayake and Vial, 2014). *Vision-based* adalah teknik deteksi kendaraan yang menggunakan teknik analisis visi komputer (Ata *et al.*, 2018). Jika dibandingkan dengan teknik *sensor-based*, teknik deteksi kendaraan *vision-based* memiliki beberapa nilai dan keuntungan signifikan yaitu, pemasangan dan perawatan yang lebih mudah, fleksibilitas yang lebih tinggi, dan kesederhanaan untuk kendaraan di area yang luas (Ata *et al.*, 2018). Walaupun teknik *vision-based* memiliki banyak keunggulan, adaptasi teknik *vision-based* tetap memiliki tantangan di hadapan lingkungan luar ruangan yang dinamis seperti kondisi cuaca yang berbeda, iluminasi yang beragam, dan kehadiran bayangan atau penghalang. Selain memerlukan sistem untuk mendeteksi kendaraan RL juga memerlukan fitur seperti *state* dan *action* yang biasanya didaftarkan atau dibuat oleh manusia. Hal ini menjadi hambatan yang sangat besar dalam pembuatan lampu lalu lintas adaptif karena jumlah *state* dan *action* pada kondisi lalu lintas *real time*, sangat beragam dan cepat berubah mengakibatkan RL dengan fitur yang dibuat oleh manusia kurang peka terhadap perubahan. Adaptasi yang kurang peka ini tentu menjadi masalah ketika diaplikasikan pada keadaan jalan raya yang sesungguhnya.

Meskipun RL memiliki beberapa keberhasilan di masa lalu, seperti yang telah disebutkan sebelumnya RL masih memiliki kekurangan dalam skalabilitas dan secara inheren terbatas pada masalah dimensi yang cukup rendah. Keterbatasan ini muncul karena algoritma RL memiliki masalah kompleksitas memori, kompleksitas komputasi, dan dalam kasus algoritma pembelajaran mesin, kompleksitas sampel

yang tinggi (Arulkumaran *et al.*, 2017). *Deep Reinforcement Learning* (DRL) adalah salah satu subbidang AI yang sangat berkembang belakangan ini, yang memungkinkan untuk mempelajari perilaku cerdas secara otomatis sambil membuat keputusan secara real time (Zang *et al.*, 2020). DRL digunakan untuk mengatasi beberapa kelemahan yang dimiliki oleh RL konvensional. Salah satu alasan utamanya adalah karena DRL menggunakan *Deep Neural Network* (DNN) yang dapat mengatasi kompleksitas masalah yang lebih tinggi dan merepresentasikan fungsi nilai atau kebijakan yang lebih kompleks. Dengan demikian, DRL dapat mengatasi masalah dengan dimensi yang lebih besar dan lingkungan yang lebih rumit, yang sulit ditangani oleh RL konvensional. Selain itu, jaringan saraf mendalam dalam DRL mampu secara otomatis belajar representasi fitur yang lebih bermakna dari data masukan, memungkinkan agen untuk mengenali pola yang lebih kompleks dan membuat keputusan yang lebih baik. Selain itu, kemampuan transfer learning dari DRL memungkinkan agen untuk menggunakan pengalaman dari tugas sebelumnya dan memanfaatkannya pada tugas-tugas serupa, mengurangi kebutuhan data pembelajaran yang besar. Meskipun DRL memiliki beberapa kelemahan, seperti kebutuhan lebih banyak data pembelajaran dan sumber daya komputasi yang lebih besar, keunggulan-keunggulannya dalam menangani masalah skala besar dan kompleksitas yang tinggi membuatnya menjadi pilihan yang menarik untuk menutupi kelemahan RL konvensional. Pada penelitian untuk membangun sistem kontrol lampu lalu lintas adaptif real time berbasis visual, kemampuan DRL yang paling menarik adalah DRL mampu melatih agen untuk melakukan tugas hanya dari input sensorik, berbeda dari metode RL tradisional mengandalkan fitur yang telah ditentukan sebelumnya dalam pengambilan keputusan. DRL memungkinkan agen untuk mempelajari persepsi sensorik dan kontrol yang secara langsung memetakan input sensorik ke output tindakan (*end-to-end*), menghilangkan kebutuhan untuk rekayasa fitur yang dilakukan oleh manusia/pakar (Gao *et al.*, 2017; Garg, Chli and Vogiatzis, 2022).

Pemaparan kondisi faktual, kebutuhan pada sistem kontrol lalu lintas adaptif serta kelemahan dan keunggulan pendekatan yang ada saat ini, menunjukkan bahwa diperlukan sebuah sistem kontrol lalu lintas adaptif. Maka pada penelitian ini

dibangun sistem kontrol lalu lintas adaptif *end-to-end* yang dapat dilatih yang merespons kondisi lalu lintas aktual secara *real time* menggunakan *Deep Reinforcement Learning* (DRL). Kemampuan optimasi DRL diharapkan dapat mengatur waktu tunggu lampu lalu lintas secara adaptif menyesuaikan keadaan sekitar persimpangan secara langsung. Data yang disuplai ke model DRL dapat diambil secara langsung dari sensor kamera (*vision-based*). Untuk mengatasi kelemahan teknik *vision-based* dalam mendeteksi kendaraan pada lingkungan luar ruangan yang dinamis, pada penelitian ini dibangun juga sebuah kecerdasan buatan untuk memperbaiki visi komputer pada segala kondisi pencahayaan. Sistem kontrol lalu lintas adaptif *end-to-end* ini diharapkan dapat memotong waktu tunggu pada simpangan bersinyal (lampu lalu lintas) yang pada akhirnya diharapkan dapat mengurangi kemacetan.

1.2 Rumusan Masalah

Masalah yang akan dibahas dan diselesaikan dalam penelitian ini adalah sebagai berikut :

1. Menemukan suatu sistem kontrol lalu lintas adaptif *end-to-end* yang dapat dilatih untuk merespons kondisi lalu lintas aktual secara *real time* menggunakan *Deep Reinforcement Learning* menggunakan input data visual pada segala kondisi pencahayaan.
2. Bagaimana performa model *Deep Reinforcement Learning* yang dihasilkan pada saat menimimalisasi waktu tunggu pada persimpangan.

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Mengembangkan sistem kontrol lalu lintas adaptif *end-to-end* yang dapat dilatih yang merespons kondisi lalu lintas aktual secara *real time* menggunakan *Deep Reinforcement Learning* menggunakan input data visual pada segala kondisi pencahayaan.

2. Mengetahui performa model *Deep Reinforcement Learning* yang dihasilkan untuk menimimalisasi waktu tunggu pada persimpangan.

1.4 Manfaat Penelitian

Manfaat dari penelitian yang dilakukan adalah sebagai berikut :

1. Sistem kontrol lalu lintas adaptif diharapkan dapat menjadi solusi kemacetan lalu lintas dengan menekan waktu tunggu di persimpangan jalan bersinyal.
2. Dengan mengetahui performa model *Deep Reinforcement Learning* yang dihasilkan dapat menunjukkan pendekatan baru yang baik untuk menyelesaikan permasalahan waktu tunggu di simpangan bersinyal.

1.5 Batasan Penelitian

Agar penelitian yang dilakukan dapat lebih terarah, maka perlu dilakukan pembatasan masalah yang akan dibahas. Batasan masalah tersebut adalah sebagai berikut.

1. Metode yang digunakan adalah penggunaan kecerdasan buatan, *deep reinforcement learning* untuk melakukan proses ekstraksi fitur keadaan jalan dan optimasi waktu tunggu sebuah lintasan pada persimpangan jalan bersinyal.
2. Jumlah simpangan yang dioptimasi pada penelitian ini adalah sebuah simpangan detail simpangan dan konfigurasi kamera dijelaskan pada BAB 4 sub-bab 4.1.
3. Data input sistem adalah video dan gambar yang didapatkan dari kamera pengawas *Area Traffic Control System* (ATCS) Dinas Perhubungan Provinsi Bali.
4. Input sistem optimasi adalah gambar yang diambil dari video dengan *capture rate* 1 gambar per 1 detik.
5. Model dibangun menggunakan bahasa pemrograman *Python* dengan *library Open-CV* dan *Scikit-Learn*.

6. Model *Deep learning* dibangun dengan *API neural network Keras* dengan *framework Tensor Flow*.
7. Arsitektur yang dibangun adalah deep reinforcement learning gabungan antara deep learning (CNN) yang digunakan untuk melakukan ekstraksi fitur pada video dan reinforcement learning untuk pengambilan keputusan.

BAB II

KAJIAN PUSTAKA

2.1 Tinjauan Mutakhir

Penelitian tentang manajemen lalu lintas yang telah dilakukan sebelumnya dapat dibagi menjadi tiga buah pendekatan, pendekatan jangka panjang, menengah dan pendek (*real time*). Berbagai studi telah dilakukan khususnya untuk memberikan solusi yang secara langsung bisa dirasakan. Tinjauan mutakhir dari penelitian ini tidak terlepas dari penelitian-penelitian tersebut, yang dapat dijabarkan sebagai berikut.

Solusi *real time* terhadap kemacetan salah satunya dapat dicapai dengan melakukan prediksi kemacetan pada suatu ruas jalan. Harapannya pengguna jalan mencari jalan alternatif untuk mencegah bertumpuknya kendaraan pada ruas jalan yang sudah diprediksi macet. Review yang dilakukan oleh (Akhtar and Moridpour, 2021) mendapatkan hasil mengenai teknik prediksi kemacetan secara umum dapat dibagi berdasarkan pendekatan yang dilakukan, menggunakan teknik penalaran probabilistik, menggunakan teknik *shallow machine learning* dan menggunakan teknik *deep machine learning*.

Penelitian (Zheng *et al.*, 2018) menggunakan model *Equilibrium Markov Chain* yang digabungkan dengan membagi posisi GPS (*global positioning system*) pada taxi, untuk melakukan prediksi kemacetan lalu lintas di kota Shenzhen-China. Penelitian ini salah satu contoh penggunaan teknik penalaran probabilistik dalam prediksi kemacetan lalu lintas, penelitian-penelitian (Qi and Ishak, 2014; Jiang and Fei, 2015) juga menggunakan pendekatan yang sama dengan menggunakan *Hidden Markov Model* (HMM).

Teknik lain yang digunakan untuk prediksi kemacetan khususnya pada jalur keluar jalan tol dilakukan oleh (Wang *et al.*, 2015), menggunakan *SVM* dan *KNN* penelitian ini mampu melakukan prediksi volume kendaraan (kemacetan) yang berada pada jalur keluar jalan tol. Penelitian ini adalah salah satu contoh penggunaan *shallow machine learning*.

Teknik *shallow machine learning* yang lain digunakan oleh (Florido *et al.*, 2015) yang melakukan prediksi kemacetan secara *real time*, data yang digunakan adalah data (*time series*) yang dikumpulkan menggunakan sensor yang diletakkan pada di jalan-jalan di spanyol. Mereka berhasil membangun prediksi kemacetan dengan menggunakan gabungan *Decision Tree* (DT), *Artificial Neural Network* (ANN) dan algoritma *Nearest Neighbor* (NN). Penelitian dengan pendekatan yang sama juga dilakukan oleh beberapa peneliti (Gültekin Çetiner, Sari and Borat, 2010; Kumar, Parida and Katiyar, 2013; Muhammad Fakhurifqi, 2013; More *et al.*, 2017), terutama dalam penggunaan *Artificial Neural Network* (ANN) dalam memprediksi kemacetan menggunakan data yang dikumpulkan menggunakan sensor.

Salah satu contoh penggunaan *deep machine learning* dalam prediksi kemacetan lalu lintas adalah penelitian (Xu, Peng and He, 2021), menggunakan gabungan metode *Convolutional Network* dan *LSTM*. Penelitian ini bertujuan untuk melakukan prediksi arus lalu lintas menggunakan tiga karakteristik dari data lalu lintas yaitu karakteristik temporal, karakteristik spasial dan karakteristik periodik untuk melakukan prediksi (*short-term*) kemacetan sebuah jalur.

Penggunaan *deep learning* juga dimanfaatkan dalam prediksi kemacetan lalu lintas oleh (Polson and Sokolov, 2017). Dengan memanfaatkan *deep learning* penelitian ini menghasilkan model yang dapat memperkirakan propagasi kemacetan pada daerah-daerah *bottleneck* dan memberi perkiraan yang akurat untuk kondisi lalu lintas pada keadaan berulang dan tidak berulang.

Penelitian (Chen, Yu and Liu, 2018) menerapkan *deep learning* yang diberi nama PCNN yang memanfaatkan *Convolutional Neural Network* untuk memodelkan data lalu lintas periodik (*Convolutional-based deep Neural Network modeling Periodic traffic data/PCNN*). Model PCNN ini mampu melakukan prediksi dengan melakukan ekstraksi fitur dari data lalu lintas menggunakan teknik konvolusi (CNN) dan berhasil menangkap fitur dependen lokal temporal dan fitur-fitur level tinggi lainnya.

Solusi *real time* lain yang dapat digunakan untuk mengurai kemacetan adalah menggunakan aktuator/sinyal untuk mengendalikan arus lalu lintas.

Penelitian dengan pendekatan ini dapat membantu mengurai kemacetan, terutama mengurangi waktu tunggu pada persimpangan bersinyal.

Optimisasi sinyal lalu lintas juga dilakukan pada penelitian (Bie, Cheng and Liu, 2017) khususnya untuk waktu tunggu *Hook Turn* (HT) pada jalan-jalan di kota Melbourne-Australia. Dengan tujuan meminimalkan delay rata-rata semua kendaraan, model komputer diusulkan untuk masalah pengaturan waktu sinyal yang optimal dari skema HT. Algoritma Genetika (GA) digunakan untuk menyelesaikan model ini, mengingat kompleksitas fungsi tujuannya.

Penelitian (Manandhar and Joshi, 2018) berusaha membangun sistem cerdas yang adaptif terhadap arus lalu lintas pada titik persimpangan. Sistem hybrid yang terdiri dari *Statistical Multiplexing* dan *Particle Swarm Optimization* (PSO) telah dikembangkan untuk mengontrol arus lalu lintas. Kinerja algoritma yang dikembangkan diuji dengan perhitungan lalu lintas yang disimulasikan dari beberapa persimpangan dengan potensi kemacetan di lembah Kathmandu. Teramati bahwa waktu tunggu rata-rata kendaraan di persimpangan berhasil dikurangi dengan adanya sistem ini.

Penelitian (Santoso, Azis and Bode, 2020) menggunakan *Adaptive Neuro Fuzzy Inference System* (ANFIS) untuk mengendalikan lampu lalu lintas pada persimpangan empat ruas. Data pada penelitian ini diambil secara langsung dengan mencatat/observasi terhadap keadaan lalu lintas. Penggunaan ANFIS terbukti mampu mengendalikan lampu-lalu lintas secara dinamis dan mengurangi waktu tunggu rata-rata kendaraan, lebih baik dibandingkan penggunaan lampu-lalu lintas statis. Teknik yang sama (ANFIS) juga digunakan oleh (Araghi, Khosravi and Creighton, 2015) untuk membentuk sistem lampu lalu lintas yang adaptif. Penelitian Araghi dan kawan-kawan menambahkan *Cuckoo Search* (CS) pada ANFIS untuk membantuk membentuk kontrol lalu lintas adaptif yang optimal. Penelitian (Jin, Ma and Kosonen, 2017) juga menggunakan pendekatan *Fuzzy Inference System* (FIS) dalam membentuk TSC adaptif. Penelitian ini menghasilkan sebuah aplikasi yang diberi nama *Fuzzy Intelligent Traffic Signal* (FITS) yang dapat mengontrol lampu lalu lintas yang optimal dalam meningkatkan mobilitas pada persimpangan.

Tulisan berjudul *Indigenous design of a Traffic Light Control system responsive to the local traffic dynamics and priority vehicles* (Bisht *et al.*, 2022) menggunakan pendekatan kontrol lampu lalu lintas (*Traffic Light Control* - TLC) untuk mengatasi kemacetan lalu lintas secara *real time*. Penelitian ini mengusulkan sistem TLC adaptif untuk skenario lalu lintas heterogen (kendaraan roda dua-tiga-empat) yang responsif terhadap kondisi lalu lintas yang ada di persimpangan, dan juga melayani kendaraan prioritas dengan preferensi. TLC adaptif dibangun menggunakan teknik komputer vision (*Object Detection*) seperti YOLO dan RCNN untuk menghitung unit mobil penumpang (*Passenger Car Unit*-PCU) dan melakukan adaptasi waktu tunggu TCL berdasarkan hasil perhitungan PCU yang dipantau melalui kamera.

Penelitian (Osman *et al.*, 2017) melakukan implementasi sistem kontrol lalu lintas (*Traffic Signal Control* -TSC) yang cerdas dan otomatis, memanfaatkan visi komputer dan teknik pemrosesan gambar. Penelitian ini dilakukan dengan mendekripsi jumlah kendaraan di setiap jalan dan menetapkan jumlah waktu tunggu yang dioptimalkan (sinyal lampu merah) dan waktu berjalan (sinyal lampu hijau). Sistem ini adalah sistem yang sepenuhnya otomatis yang dapat menggantikan sistem lalu lintas berbasis waktu tetap konvensional.

Pendekatan *Reinforcement Learning* (RL) digunakan oleh (Vidhate and Kulkarni, 2017) dalam membuat kontrol lalu lintas cerdas. Tujuannya adalah meningkatkan pergerakan transportasi dan mengurangi waktu tunggu rata-rata. Model kontrol lalu lintas berbasis algoritma RL digunakan untuk mendapatkan aturan waktu yang tepat dengan mendefinisikan parameter waktu nyata dari skenario lalu lintas nyata dengan benar.

Reinforcement Learning (RL) juga digunakan oleh (Abdelgawad *et al.*, 2015) dalam simulasi kemacetan lalu lintas untuk menguji performa dari *Traffic Signal Control* (TSC) adaptif. Sistem ini dirancang dan diuji di laboratorium pada dua studi kasus di Kota Burlington, menggunakan data yang diambil secara langsung (*field data*) dan data yang telah dikumpulkan oleh otoritas terkait. Persimpangan dirancang dan dioperasikan menggunakan sistem adaptif dan dibandingkan dengan pengaturan waktu statis yang dioptimalkan dan

dikoordinasikan. Analisis hasil simulasi menunjukkan bahwa secara keseluruhan sistem adaptif mengungguli skenario waktu statis dengan penghematan penundaan hingga 25% di tingkat jaringan (jalan raya). Di sisi lain, hasil dari kedua model *testbed* menunjukkan bahwa kinerja sistem adaptif bervariasi sesuai dengan kondisi/arus persimpangan, konfigurasi jaringan, volume lalu lintas, variabilitas kedatangan arus, dan kedekatan persimpangan satu dengan yang lain.

Genders dan Razavi (Genders and Razavi, 2016) mengusulkan sistem kontrol sinyal lalu lintas memanfaatkan data berkualitas tinggi dengan abstraksi minimal. Penelitian ini menerapkan *Deep Reinforcement Learning* (DRL) untuk membangun agen kontrol sinyal lalu lintas (TSC) yang benar-benar adaptif. Pengkodean status lalu lintas diskrit digunakan sebagai input ke *Deep Convolutional Network*, dilatih menggunakan Q-learning dengan *experience-replay*. Menggunakan pendekatan serupa (Li, Lv and Wang, 2016) melakukan penelitian menggunakan sample data lalu lintas dan membentuk pengaturan waktu untuk sinyal lampu lalu lintas. Penelitian (Mousavi, Schukat and Howley, 2017) menggunakan tambahan *Deep Policy Gradient* (PG) kedalam *Reinforcement Learning* pada sample data lalu lintas untuk menemukan waktu optimal untuk kontrol sinyal lalu lintas. Penelitian (Gao *et al.*, 2017) menggunakan pendekatan *Deep Reinforcement Learning* untuk mengatasi permasalahan yang sama yaitu TSC. *Deep Reinforcement Learning* digunakan untuk mengekstraksi fitur dasar yang dapat terlewatkan jika dilakukan oleh manusia. Dengan memanfaatkan kamera sebagai input penelitian ini melakukan proses optimasi langsung dari data yang diinputkan dari kamera. *Deep Q-learning* juga digunakan oleh (Wan and Hwang, 2018) untuk melakukan optimasi waktu sinyal lampu hijau menyala. Menambahkan *Bellman equation* untuk mengurangi bias pada fungsi *action-value* yang dihasilkan DRL karena efek dari inkonsistensi interval *time-step*. Penelitian (Tan *et al.*, 2019) menggunakan DRL dengan mengamati studi kasus dengan data yang lebih realistik (tidak menggunakan simulasi). Konstrain fisik, sensor dan skenario yang digunakan diambil dari kasus dunia nyata yang digunakan untuk mengurangi waktu henti di persimpangan jalan dan menambahkan mobilitas kendaraan menjadi lebih lancar.

Menggunakan pendekatan *Reinforcement Learning* (RL) yang berbeda, (Liang *et al.*, 2019) menggunakan *Deep Reinforcement Learning* (DRL) untuk mengontrol sinyal lalu lintas (TSC) secara adaptif dari data yang diambil menggunakan *field sensor*/detektor. Menambahkan teknik *Convolutional Neural Network* (CNN) untuk memetakan *states* (keadaan eksisting) ke fungsi *reward* dalam RL.

Pemanfaatan *Deep Reinforcement Learning* juga dilakukan oleh (Wang *et al.*, 2019), dengan menggunakan definisi *state* yang lebih halus, yang merupakan elemen kunci dalam kontrol sinyal lalu lintas berbasis RL. Data berbasis peristiwa beresolusi tinggi, yang bertujuan untuk mencapai kontrol sinyal lalu lintas adaptif yang hemat biaya dan efisien digunakan dalam penelitian ini. Teknik *deep learning* digunakan untuk secara otomatis mengekstraksi fitur yang berguna untuk kontrol sinyal lalu lintas. Metode yang diusulkan mengacu pada dua strategi kontrol sinyal lalu lintas yang umum digunakan, yaitu strategi kontrol waktu tetap dan strategi kontrol dinamis, dan hasil eksperimen mengungkapkan bahwa metode yang diusulkan secara signifikan mengungguli strategi kontrol yang umum digunakan.

Penelitian (Rasheed, Yau and Low, 2020) menggunakan pendekatan Multi-Agent DQN (MADQN) untuk memecahkan masalah kemacetan dengan menempelkan kecerdasan adaptif pada lampu lalu lintas (TSC). Tujuan menggunakan teknik ini adalah mengurangi dimensionalitas dari fitur pada skema jaringan lalu lintas, sehingga lebih mudah untuk melakukan proses perubahan keputusan dalam waktu tunggu persimpangan.

Deep Reinforcement Learning juga digunakan oleh (Garg, Chli and Vogiatzis, 2022) dalam makalah ini, dikembangkan agen DRL berbasis visi yang sepenuhnya otonom yang mencapai kontrol sinyal adaptif dalam menghadapi lingkungan lalu lintas yang kompleks, tidak tepat, dan dinamis. Agen DRL menggunakan data visual langsung (yaitu aliran rekaman RGB *real time*) dari persimpangan untuk melihat secara luas dan selanjutnya bertindak berdasarkan lingkungan lalu lintas. Dengan menggunakan *domain randomization*, kemampuan generalisasi agen diuji dalam berbagai kondisi lalu lintas baik dalam simulasi maupun lingkungan dunia nyata. Dalam kumpulan validasi yang beragam terlepas

dari data pelatihan, agen kontrol lalu lintas secara andal beradaptasi dengan situasi lalu lintas baru dan menunjukkan transfer positif ke persimpangan nyata yang sebelumnya tak terlihat meskipun dilatih sepenuhnya dalam simulasi.

Banyak cara untuk mengatasi kemacetan menggunakan teknik komputer cerdas, khususnya teknik komputer yang berfokus pada teknik *real time*. Tabel 2.1 memperlihatkan rekapitulasi *state of the art* penelitian pada fokus penelitian manajemen kemacetan dengan pendekatan solusi *real time*.

Tabel 2.1 Rekapitulasi *State of The Art*

No	Referensi	Judul	Metode /Tools	Deskripsi	Review	Kesamaan	Perbedaan
1.	(Akhtar and Moridpour , 2021)	A Review of Traffic Congestion Prediction Using Artificial Intelligence	Review Metode Prediksi Kemacetan	Melakukan review penggunaan kecerdasan buatan untuk memprediksi kemacetan lalu-lintas	Hasil review teknik-teknik prediksi kemacetan, ada tiga pendekatan: 1. Penalaran probabilistik, 2. <i>Shallow machine learning</i> 3. <i>deep machine learning</i>	Mencari tahu cara mengatasi kemacetan lalu-lintas menggunakan kecerdasan buatan	Pada penelitian ini hanya mencari informasi bagaimana kecerdasan buatan dapat membantu menyelesaikan permasalahan kemacetan
2.	(Zheng <i>et al.</i> , 2018)	Real-time predication and navigation on traffic congestion model with equilibrium Markov chain	<i>Equilibrium Markov Chain</i>	<i>Equilibrium Markov Chain</i> digabungkan dengan membagi posisi GPS (<i>global positioning system</i>) pada taxi	Model ini dikembangkan untuk memprediksi kemacetan pada keadaan ekuilibrium dan meringankannya dengan model pemandu kendaraan. Karena keadaan ekuilibrium dapat diturunkan dengan cepat, model yang diusulkan dapat memberikan matriks probabilitas transfer yang efektif untuk mencerminkan situasi kemacetan waktu nyata.	Menggunakan solusi jangka pendek (<i>real time</i>)	Tidak menggunakan machine learning (<i>Deep Reinforcement Learning</i>).

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
3.	(Qi and Ishak, 2014)	A Hidden Markov Model for short term prediction of traffic conditions on freeways	HMM	Penggunaan HMM untuk prediksi kemacetan	Model HMM yang diusulkan untuk prediksi kondisi lalu lintas jangka pendek. Algoritma kontrol dapat dirancang untuk antisipasi perubahan kondisi lalu lintas. Teknik ini hanya dapat dicapai jika informasi yang diprediksi tersedia.	Menggunakan solusi jangka pendek (<i>real time</i>)	Diaplikasikan di jalur bebas hambatan (untuk pintu TOL) dan penggunaan teknik prediksi kemacetan

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
4.	(Jiang and Fei, 2015)	Traffic and vehicle speed prediction with neural network and Hidden Markov model in vehicular networks	HMM + NN	Penggunaan HMM untuk prediksi kemacetan	Penelitian ini mengusulkan sistem prediksi kecepatan kendaraan berdasarkan NN dan HMM. Menurut rute mengemudi kendaraan, kecepatan lalu lintas segmen jalan target pertama kali diprediksi oleh NN menggunakan data lalu lintas historis. Selanjutnya, hubungan statistik antara kecepatan lalu lintas dan kendaraan dimodelkan menggunakan HMM	Menggunakan solusi jangka pendek (<i>real time</i>)	Penelitian menggunakan data historis dan mengambil pendekatan prediksi kemacetan

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
5.	(Wang <i>et al.</i> , 2015)	Short Term Prediction of Freeway Existing Volume Based on SVM and KNN	SVM + KNN	menggunakan <i>SVM</i> dan <i>KNN</i> untuk memprediksi kemacetan yang pada jalur keluar jalan tol.	Kinerja <i>KNN</i> dan <i>SVM</i> bervariasi di stasiun yang berbeda. Hasil percobaan menunjukkan bahwa algoritma yang diusulkan layak dan akurat. Rata-rata persentase kesalahan absolut di bawah 10% untuk kedua stasiun tol. Jika dibandingkan dengan <i>KNN</i> dan <i>SVM</i> , hasil model hybrid menunjukkan dapat menjamin tingkat akurasi yang lebih stabil.	Menggunakan solusi jangka pendek (<i>real time</i>)	Diaplikasikan pada jalur bebas hambatan dan mengambil pendekatan prediksi kemacetan

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
6.	(Florido <i>et al.</i> , 2015)	Data mining for predicting traffic congestion and its application to Spanish data	DT + ANN + NN	Prediksi kemacetan dari daya yang dikirimkan oleh sensor menggunakan metode yang telah disebutkan.	Dalam penelitian ini telah dicari pola dan model perilaku dengan menggunakan data yang historis lalu lintas di Spanyol. Ekstraksi pola-pola ini telah digunakan untuk memprediksi kemacetan lalu lintas cukup dini untuk menghindari retensi pada titik tersebut, meminimalkan waktu respons terhadap kejadian ini, dan memberikan alternatif sirkulasi. Algoritma C4.5 memperoleh hasil dengan kesalahan mulai dari 85% sampai 95%, tergantung pada waktu antisipasi dari prediksi yang dibuat. Selain itu, algoritma lain seperti JST atau NN telah berhasil diterapkan tetapi kurang akurat.	Menggunakan teknik machine learning untuk mengatasi kemacetan jangka pendek (<i>real time</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
7.	(Gültekin Çetiner, Sari and Borat, 2010)	A neural network based traffic-flow prediction model	ANN	Prediksi kemacetan menggunakan ANN dari data yang dikumpulkan dari sensor dan nilai yang diambil dari statistik di lapangan	Menggunakan data historis dari sebuah jalur jalan untuk melakukan prediksi kemacetan menggunakan teknik klasifikasi (ANN). Penelitian ini membuktikan volume pada suatu jalur jalan dapat diprediksi dengan 4 faktor kunci yaitu hari dalam suatu minggu, jam, menit dan kasus terakhir pada jalur tersebut.	Menggunakan teknik machine learning (ANN) untuk mengatasi kemacetan jangka pendek (<i>real time</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)
8.	(Kumar, Parida and Katiyar, 2013)	Short Term Traffic Flow Prediction for a Non Urban Highway Using Artificial Neural Network	ANN	Penggunaan Jaringan Syaraf Tiruan (ANN) untuk memprediksi arus lalu-lintas pada jalan raya di luar kota (bukan jalan dalam kota)	Jaringan Syaraf Tiruan memiliki kinerja yang konsisten meskipun interval waktu untuk prediksi arus lalu lintas dinaikkan hingga 15 menit. Hasil juga baik meskipun kecepatan tiap kategori kendaraan dipertimbangkan secara terpisah sebagai variabel input.	Menggunakan teknik machine learning (ANN) untuk mengatasi kemacetan jangka pendek (<i>real time</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
9.	(More <i>et al.</i> , 2017)	Road traffic prediction and congestion control using Artificial Neural Networks	ANN	Penggunaan Jordan Neural Network untuk melakukan prediksi kemacetan	Fokus pada prediksi arus lalu lintas menggunakan <i>Jordan Neural Network</i> dengan akurasi baik dan analisis pada berbagai parameter.	Menggunakan teknik machine learning (ANN) untuk mengatasi kemacetan jangka pendek (<i>real time</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)
10.	(Xu, Peng and He, 2021)	Short-term traffic flow prediction with missing data	Deep Learning	Membangun model prediksi arus lalu-lintas menggunakan deep learning (dengan data yang tidak lengkap)	Membentuk modul Conv-LSTM yang dapat mengekstrak informasi spasial-temporal dari informasi arus lalu lintas. Modul LSTM Bi-directional juga diadopsi untuk menganalisis data arus lalu lintas historis dari titik prediksi untuk mendapatkan fitur periodisitas arus lalu lintas.	Bertujuan mengatasi kemacetan jangka pendek (<i>real time</i>) Menggunakan Deep Learning untuk proses ekstraksi fitur (fitur tidak <i>hand-made/human-made</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
11.	(Polson and Sokolov, 2017)	Deep learning for short-term traffic flow prediction	Deep Learning	<i>Deep learning</i> untuk memprediksi arus lalu lintas.	Kontribusi utamanya adalah pengembangan arsitektur yang menggabungkan model linier yang dipasang menggunakan regularisasi L1 dan lapisan <i>tanh</i> .	Deep Learning untuk proses ekstraksi fitur (fitur tidak <i>hand-made/human-made</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)
12.	(Chen, Yu and Liu, 2018)	PCNN: Deep Convolutional Networks for Short-Term Traffic Congestion Prediction	Deep Learning	PCNN berbasis Deep Convolutional Neural Network untuk prediksi kemacetan.	Penelitian ini menunjukkan 2 prosedur penting pada proses prediksi kemacetan menggunakan CNN (PCNN) yaitu <i>time series folding</i> dan <i>multi-grained learning</i> .	Deep Learning untuk proses ekstraksi fitur (fitur tidak <i>hand-made/human-made</i>)	Tidak menggunakan data berbasis visi komputer (menggunakan data historis) dan tidak melakukan proses optimasi (hanya prediksi kemacetan)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
13.	(Bie, Cheng and Liu, 2017)	Optimization of signal-timing parameters for the intersection with hook turns	GA	Optimasi waktu tunggu pada skema Hook Turn, menggunakan algoritma genetika, berdasarkan data survei nyata pada jam sibuk dan jam tidak sibuk pada pagi hari	Pengujian numerik menunjukkan bahwa dibandingkan dengan keadaan eksisting (lampu lalu-lintas statis pada Hook Turn), hasil optimasi dapat mengurangi rata-rata keterlambatan sebesar 12,05% pada jam sibuk dan 19,96% pada jam tidak sibuk.	Pendekatan sistem lampu-lalu lintas adaptif untuk mengatasi kemacetan	Menggunakan optimasi berbasis algoritma genetika (GA) Tidak menggunakan data visual

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
14.	(Manandhar and Joshi, 2018)	Adaptive Traffic Light Control with Statistical Multiplexing Technique and Particle Swarm Optimization in Smart Cities	<i>Statistical Multiplexing + PSO</i>	Sebuah sistem hybrid yang terdiri dari <i>Statistical Multiplexing</i> dan <i>Particle Swarm Optimization</i> (PSO) dikembangkan untuk mengontrol arus lalu lintas.	hasil penelitian menunjukkan bahwa Algoritma Hybrid memberikan kinerja yang baik dengan waktu tunggu rata-rata (67-89)% lebih sedikit daripada Algoritma Kontrol Waktu Tetap dan (41-84)% waktu tunggu rata-rata lebih sedikit daripada PSO untuk kendaraan dalam percobaan dengan skenario nyata yang dilakukan jam sibuk (puncak).	Pendekatan sistem lampu-lalu lintas adaptif untuk mengatasi kemacetan	Menggunakan optimasi berbasis <i>Particle Swarm</i> (PSO) Tidak menggunakan data visual

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
15.	(Santoso, Azis and Bode, 2020)	Pengendalian Lampu Lalu Lintas Cerdas di Persimpangan Empat Ruas yang Kompleks Menggunakan Algoritma Adaptive Neuro Fuzzy Inference System	ANFIS	Penelitian yang berusaha mereduksi Average Waiting Times (AWT) dengan optimasi waktu lampu lalu-lintas menggunakan ANFIS	Penerapan ANFIS dapat mereduksi AWT sebesar $3,4 \times 10^{-5}$ (menggunakan <i>GaussMf</i>) dan $7,7 \times 10^{-2}$ (menggunakan <i>TrapMf</i>) Menggunakan variabel <i>Arrival Times</i> , <i>Transportation Type</i> , dan <i>Goal Junction</i> lebih mampu mereduksi AWT dan dapat diterapkan untuk pengendalian lampu lalu lintas cerdas/dinamis di persimpangan empat ruas yang kompleks	Pendekatan sistem lampu-lalu lintas adaptif untuk mengatasi kemacetan dan mereduksi AWT	Menggunakan ANFIS untuk proses optimasi bukan menggunakan DRL Tidak menggunakan data visual

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
16.	(Araghi, Khosravi and Creighton, 2015)	Intelligent cuckoo search optimized traffic signal controllers for multi-intersection network	ANFIS	Penelitian untuk melakukan optimasi lampu lalu-lintas menggunakan ANFIS yang ditambahkan <i>cuckoo search</i> (CS).	<i>Cuckoo Search</i> (CS) digunakan untuk melakukan optimalisasi ANFIS dan NN dalam melakukan adaptasi waktu lampu lalu lintas. Hal ini diharapkan dapat membantu memberikan fase lampu yang berbeda sesuai dengan kebutuhan persimpangan.	Pendekatan sistem lampu-lalu lintas adaptif untuk mengatasi kemacetan	Menggunakan ANFIS untuk proses optimasi bukan menggunakan DRL Tidak menggunakan data visual
17.	(Jin, Ma and Kosonen, 2017)	An intelligent control system for traffic lights with simulation-based evaluation	ANFIS	Metode baru Fuzzy Intelligent Traffic Signal (FITS), pada <i>microscopic traffic</i>	Sistem ini diimplementasikan pada perangkat komputasi satu papan yang mampu menerapkan logika kontrolnya sendiri dan mengambil alih keputusan dengan berkomunikasi dengan pengontrol sinyal lalu lintas modern.	Pendekatan sistem lampu-lalu lintas adaptif untuk mengatasi kemacetan	Menggunakan ANFIS untuk proses optimasi bukan menggunakan DRL Tidak menggunakan data visual

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
18.	(Bisht <i>et al.</i> , 2022)	Indigenous design of a Traffic Light Control system responsive to the local traffic dynamics and priority vehicles	YOLO + RCNN	TLC otomatis dengan melihat/menghitung <i>Passenger Car Unit</i> (PSU) menggunakan computer vision.	Dihasilkan solusi TLC adaptif, yang responsif terhadap kondisi lalu lintas dan juga melayani kendaraan prioritas dengan preferensi. Algoritma TLC adaptif diusulkan dengan bantuan lingkungan simulasi komprehensif SUMO untuk mengetahui unjuk kerja. Kinerja sistem TLC adaptif dibandingkan di berbagai kondisi lalu lintas dan kelas lalu lintas yang berbeda termasuk lalu lintas umum, kendaraan prioritas, dan kendaraan darurat, terutama untuk dua pengukuran—waktu perjalanan rata-rata dan waktu tunggu rata-rata.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
19.	(Osman <i>et al.</i> , 2017)	Intelligent traffic management system for cross section of roads using computer vision	Computer Vision Klasik	Computer Vision untuk <i>traffic management</i> yang cerdas. Memberi informasi bahwa kamera adalah solusi yang baik sebagai sensor untuk <i>traffic management</i> cerdas.	Computer Vision untuk <i>traffic management</i> yang cerdas. Memberi informasi bahwa kamera adalah solusi yang baik sebagai sensor untuk <i>traffic management</i> cerdas.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
20.	(Vidhate and Kulkarni, 2017)	Cooperative multi-agent reinforcement learning models (CMRLM) for intelligent traffic control	RL	<i>Traffic Control</i> model berbasis RL digunakan untuk mendapatkan setelan waktu yang baik dengan menggunakan parameter dunia nyata.	Tidak mungkin mengelola kemacetan lalu lintas dan kecelakaan lalu lintas mendadak untuk model pembelajaran Q tanpa kerjasama dengan strategi yang telah ditetapkan. Meskipun CMRLM membutuhkan durasi yang lama untuk menyelesaikan pembelajaran, ia memiliki kemampuan belajar yang baik untuk sistem yang kompleks, memungkinkannya menangani keadaan kompleks yang tidak diketahui dengan baik.	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
21.	(Abdelgawad <i>et al.</i> , 2015)	Assessment of self-learning adaptive traffic signal control on congested urban areas: Independent versus coordinated perspectives	RL	Menggunakan simulasi untuk membandingkan kemampuan lampu sinyal statis dan dinamis (adaptif dengan bantuan RL)	Sistem ini dirancang dan diuji di laboratorium pada dua studi kasus di Kota Burlington. Persimpangan dirancang dan dioperasikan menggunakan sistem adaptif dan dibandingkan dengan rencana pengaturan waktu kasus dasar yang dioptimalkan dan dikordinasikan. Analisis hasil simulasi menunjukkan bahwa secara keseluruhan sistem adaptif mengungguli skenario kasus dasar dengan penghematan penundaan hingga 25% di tingkat jaringan, dan pengurangan emisi CO ₂ sebesar 15%.	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
22.	(Genders and Razavi, 2016)	Using a Deep Reinforcement Learning Agent for Traffic Signal Control	DRL	<i>Q-learning</i> dengan <i>experience replay</i>	Dibangun metode DRL untuk membangun agen kontrol sinyal lalu lintas yang benar-benar adaptif dalam mikrosimulator lalu lintas SUMO. Diusulkan <i>state space</i> baru, yaitu pengkodean status lalu lintas diskrit. Pengkodean status lalu lintas diskrit digunakan sebagai input ke DRL, dan dilatih menggunakan <i>Q-learning</i> dengan <i>experience-replay</i> .	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
23.	(Mousavi, Schukat and Howley, 2017)	Traffic light control using deep policy-gradient and value-function-based reinforcement learning	Deep PG + RL	Penggunaan <i>Deep Policy Gradient</i> pada RL.	<p>Deep policy-gradient (PG) dan agen berbasis <i>value-function</i> dapat memprediksi kemungkinan sinyal lalu lintas terbaik untuk persimpangan lalu lintas.</p> <p>Pada setiap waktu, agen kontrol lampu lalu lintas adaptif ini menerima snapshot dari keadaan simulator lalu lintas grafis dan menghasilkan sinyal kontrol.</p> <p>Agen berbasis PG memetakan pengamatannya langsung ke sinyal kontrol; namun, agen berbasis <i>value-function</i> pertama-tama harus memperkirakan nilai untuk semua sinyal kontrol yang legal.</p>	<p>Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL</p>	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
24.	(Gao <i>et al.</i> , 2017)	Adaptive Traffic Signal Control: Deep Reinforcement Learning Algorithm with Experience Replay and Target Network	DRL	Penggunaan DRL untuk melakukan kontrol waktu lampu lalu-lintas	DRL yang secara otomatis mengekstraksi semua fitur berguna (fitur buatan mesin) dari data lalu lintas <i>real time</i> dan mempelajari kebijakan optimal untuk kontrol sinyal lalu lintas adaptif. Untuk meningkatkan stabilitas diadopsi <i>experience replay</i> .	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
25.	(Wan and Hwang, 2018)	Value-based deep reinforcement learning for adaptive isolated intersection signal control	DRL (Value-based)	Value-based DRL untuk persimpangan terisolasi	Disusulkan <i>dynamic discount factor</i> dalam persamaan Bellman untuk mencegah estimasi bias fungsi nilai tindakan karena efek interval langkah waktu yang tidak konstan. Selain itu, tindakan ditambahkan ke <i>input layer</i> jaringan saraf dalam proses pelatihan. <i>Output layer</i> adalah nilai tindakan yang diestimasi untuk tindakan yang diambil. Kemudian, jaringan saraf terlatih dapat digunakan untuk menghasilkan tindakan yang mengarah ke nilai perkiraan optimal dalam himpunan terbatas sebagai kebijakan agen. Agen terlatih mengungguli rencana waktu tetap dalam semua kasus pengujian dengan mengurangi penundaan total sistem sebesar 20%	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>) Hanya untuk persimpangan terisolasi (tidak heterogen)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
26.	(Tan <i>et al.</i> , 2019)	Deep reinforcement learning for adaptive traffic signal control	DRL	DRL dengan adaptasi skenario dunia nyata.	Kerangka kerja DRL memanfaatkan aliran sensor data dunia nyata yang tersedia untuk mempelajari kebijakan optimal untuk agen di VISSIM. Kami menguji kinerja agen DRL kami pada data lalu lintas nyata selama periode permintaan lalu lintas tinggi. Hasilnya masih perlu diperbaiki	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
27.	(Liang <i>et al.</i> , 2019)	A Deep Reinforcement Learning Network for Traffic Light Cycle Control	DRL	DRL dengan melihat kasus sebagai <i>high-dimension Markov decision</i>	Informasi lalu lintas dikumpulkan dari jaringan kendaraan atau kamera. Tindakan dimodelkan sebagai proses keputusan Markov dan <i>reward</i> adalah perbedaan waktu tunggu kumulatif antara dua siklus. Menggunakan <i>double dueling deep Q network</i> (3DQN) dan <i>experience replay</i> . Dapat mengurangi lebih dari 20% waktu tunggu rata-rata	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak secara spesifik mengatasi kesulitan visi komputer dalam mengatasi kelemahan pengelihatan dalam kondisi cuaca dan pencahayaan yang sulit Tidak menggunakan data visual sebagai input langsung (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
28.	(Wang <i>et al.</i> , 2019)	Deep reinforcement learning-based traffic signal control using high-resolution event-based data	DRL	Menggunakan <i>Event-based data</i> beresolusi tinggi, bersifat informatif dan dapat dikumpulkan langsung dari detektor kendaraan (misalnya, loop induktif) dengan teknologi saat ini. Teknik <i>deep learning</i> digunakan untuk secara otomatis melakukan ekstraksi fitur yang berguna untuk kontrol sinyal lalu lintas dari <i>Event-based data</i> . Hasil eksperimen mengungkapkan bahwa metode yang diusulkan secara signifikan mengungguli strategi kontrol yang umum digunakan (<i>fixed-time control</i> dan <i>actuated control</i>).	<i>Event-based data</i> beresolusi tinggi, bersifat informatif dan dapat dikumpulkan langsung dari detektor kendaraan (misalnya, loop induktif) dengan teknologi saat ini. Teknik <i>deep learning</i> digunakan untuk secara otomatis melakukan ekstraksi fitur yang berguna untuk kontrol sinyal lalu lintas dari <i>Event-based data</i> . Hasil eksperimen mengungkapkan bahwa metode yang diusulkan secara signifikan mengungguli strategi kontrol yang umum digunakan (<i>fixed-time control</i> dan <i>actuated control</i>).	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
29.	(Rasheed, Yau and Low, 2020)	Deep reinforcement learning for traffic signal control under disturbances: A case study on Sunway city, Malaysia	DRL Multi Agent	Multi Agen, dengan data yang lebih banyak, berhasil mengurangi dimensi fitur dan membantu DRL	Secara khusus, dalam simulasi, MADQN mengungguli pendekatan <i>state of the art</i> dengan meningkatkan throughput hingga 70%, serta mengurangi panjang antrian hingga 75% dan waktu tunggu hingga 70%.	Pendekatan sistem lampu-lalu lintas adaptif menggunakan optimasi berbasis RL/DRL	Tidak menggunakan data visual sebagai input (tidak <i>end-to end</i>)
30.	(Frank, Khamis Al Aamri and Zayegh, 2019)	IoT based smart traffic density control using image processing	IOT + Image Processing	Mengontrol lalu lintas dengan menentukan kepadatan lalu lintas di setiap sisi jalan dan mengaktifkan opsi kontrol sinyal lalu lintas kepada pengguna melalui aplikasi perangkat lunak.	Mengontrol lalu lintas dengan menentukan kepadatan lalu lintas di setiap sisi jalan dan mengaktifkan opsi kontrol sinyal lalu lintas kepada pengguna melalui aplikasi perangkat lunak.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
31.	(Li, Zhang and Chen, 2016)	A Self-Adaptive Traffic Light Control System Based on Speed of Vehicles	IOT Vehicle to Infrastructure	Mengubah sinyal lampu lalu lintas secara real time mengikuti kecepatan kendaraan. Sistem ini merupakan turunan dari model komunikasi V2I (Vehicle to Infrastructure). Sistem kontrol lampu lalu lintas ini dapat memaksimalkan jumlah kendaraan yang melewati persimpangan. Algoritma kontrol lampu lalu lintas berdasarkan kecepatan kendaraan dilakukan dalam bentuk simulasi.	Mengubah sinyal lampu lalu lintas secara real time mengikuti kecepatan kendaraan. Sistem ini merupakan turunan dari model komunikasi V2I (Vehicle to Infrastructure). Sistem kontrol lampu lalu lintas ini dapat memaksimalkan jumlah kendaraan yang melewati persimpangan. Algoritma kontrol lampu lalu lintas berdasarkan kecepatan kendaraan dilakukan dalam bentuk simulasi.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
32.	(Putra <i>et al.</i> , 2021)	Adaptive Traffic Light Controller Based on Congestion Detection Using Computer Vision	Object Detection (YOLOv3)	Mekanisme lampu lalu lintas adaptif sederhana dikembangkan berdasarkan kemacetan di jalan yang dideteksi menggunakan <i>computer vision</i>	Sistem deteksi yang digunakan YOLOv3 dengan pretrained weight COCO memiliki true positive value untuk sepeda motor sebesar 60%, mobil 93% dan truk/bus 100%. Kecepatan pemrosesan mini-PC Jetson Nano dengan OpenCV pada GPU 2 kali lebih cepat daripada proses dengan CPU. Dengan menggunakan metode ini, FPS tidak cukup untuk deteksi real-time	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL Tidak dapat dilakukan secara real time

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
33.	(Ata <i>et al.</i> , 2018)	Towards computer vision-based approach for an adaptive traffic control system	Image Processing	Mekanisme lampu lalu lintas adaptif bernama <i>critical state timer</i> dikembangkan berdasarkan level kerumunan/keramaian di jalan yang dideteksi menggunakan computer vision	Dibangun algoritma untuk mendeteksi dan melacak kendaraan dalam video lalu lintas kendaraan. Pelacakan kendaraan memungkinkan untuk mengukur parameter tingkat kepadatan dan kecepatan kendaraan. Parameter ini digabungkan dengan pengatur waktu untuk mengusulkan sistem yang secara adaptif dan dinamis mengontrol lalu lintas di persimpangan.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
34.	(Zaatouri and Ezzedine, 2018)	A Self-Adaptive Traffic Light Control System Based on YOLO	Object Detection (YOLOv3) dan Machine Learning	Mengoptimalkan panjang antrian dan waktu tunggu kendaraan di persimpangan dengan mendekripsi objek kendaraan dan mengubah fase waktu sinyal.	Menggunakan YOLO, untuk memberikan status lalu lintas real-time ke pengontrol (<i>embeded</i>). Lalu dirancang algoritma baru yang mengambil data real-time ini dari YOLO dan mengoptimalkan fase untuk mengurangi waktu tunggu mobil.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
35.	(Gorodokin <i>et al.</i> , 2021)	Optimization of adaptive traffic light control modes based on machine vision	Object Detection (YOLOv4)	Mengoptimalkan panjang antrian dan waktu tunggu kendaraan di persimpangan dengan mendekripsi objek kendaraan dan mengubah fase waktu sinyal.	Ditemukan bahwa antrian kendaraan sebanyak 5 unit mengurangi kapasitas lalu lintas simpang sebesar 15–25%. Teknik yang disajikan memungkinkan untuk menghilangkan atau meminimalkan kemungkinan kemacetan dengan mengubah durasi fase tertentu dan seluruh siklus lampu lalu lintas. Perhitungan tersebut menentukan kapasitas lajur maksimum dan durasi interval lampu hijau pada intensitas arus lalu lintas maksimum yang diketahui.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual	Tidak menggunakan optimasi berbasis RL/DRL

No	Referensi	Judul	Metode <i>/Tools</i>	Deskripsi	Review	Kesamaan	Perbedaan
36.	(Garg, Chli and Vogiatzis, 2022)	Fully-Autonomous, Vision-based Traffic Signal Control: from Simulation to Reality	DRL	Sistem untuk melakukan kontrol sinyal lampu lalu-lintas secara otomatis menggunakan pendekatan <i>End to end</i> dari kamera langsung ke DRL	Didapatkan agen kontrol sinyal lalu lintas otonom <i>end-to-end</i> yang dilatih berbasis visi komputer. Agen mengoptimalkan lalu lintas hanya berdasarkan data lalu lintas visual langsung, tanpa fitur kondisi lalu lintas buatan tangan (<i>human-made</i>). Agen dilatih dengan <i>domain randomisation</i> , yang secara mandiri beradaptasi dengan berbagai jenis persimpangan, distribusi lalu lintas, kondisi cuaca dan pencahayaan.	Pendekatan sistem lampu-lalu lintas adaptif berbasis visual, end to end menggunakan DRL (tidak membangun fitur <i>human-made</i>) yang tahan terhadap segala kondisi cuaca dan pencahayaan	Tidak secara spesifik mengatasi kesulitan visi komputer dalam mengatasi kelemahan pengelihatan dalam kondisi cuaca dan pencahayaan yang sulit

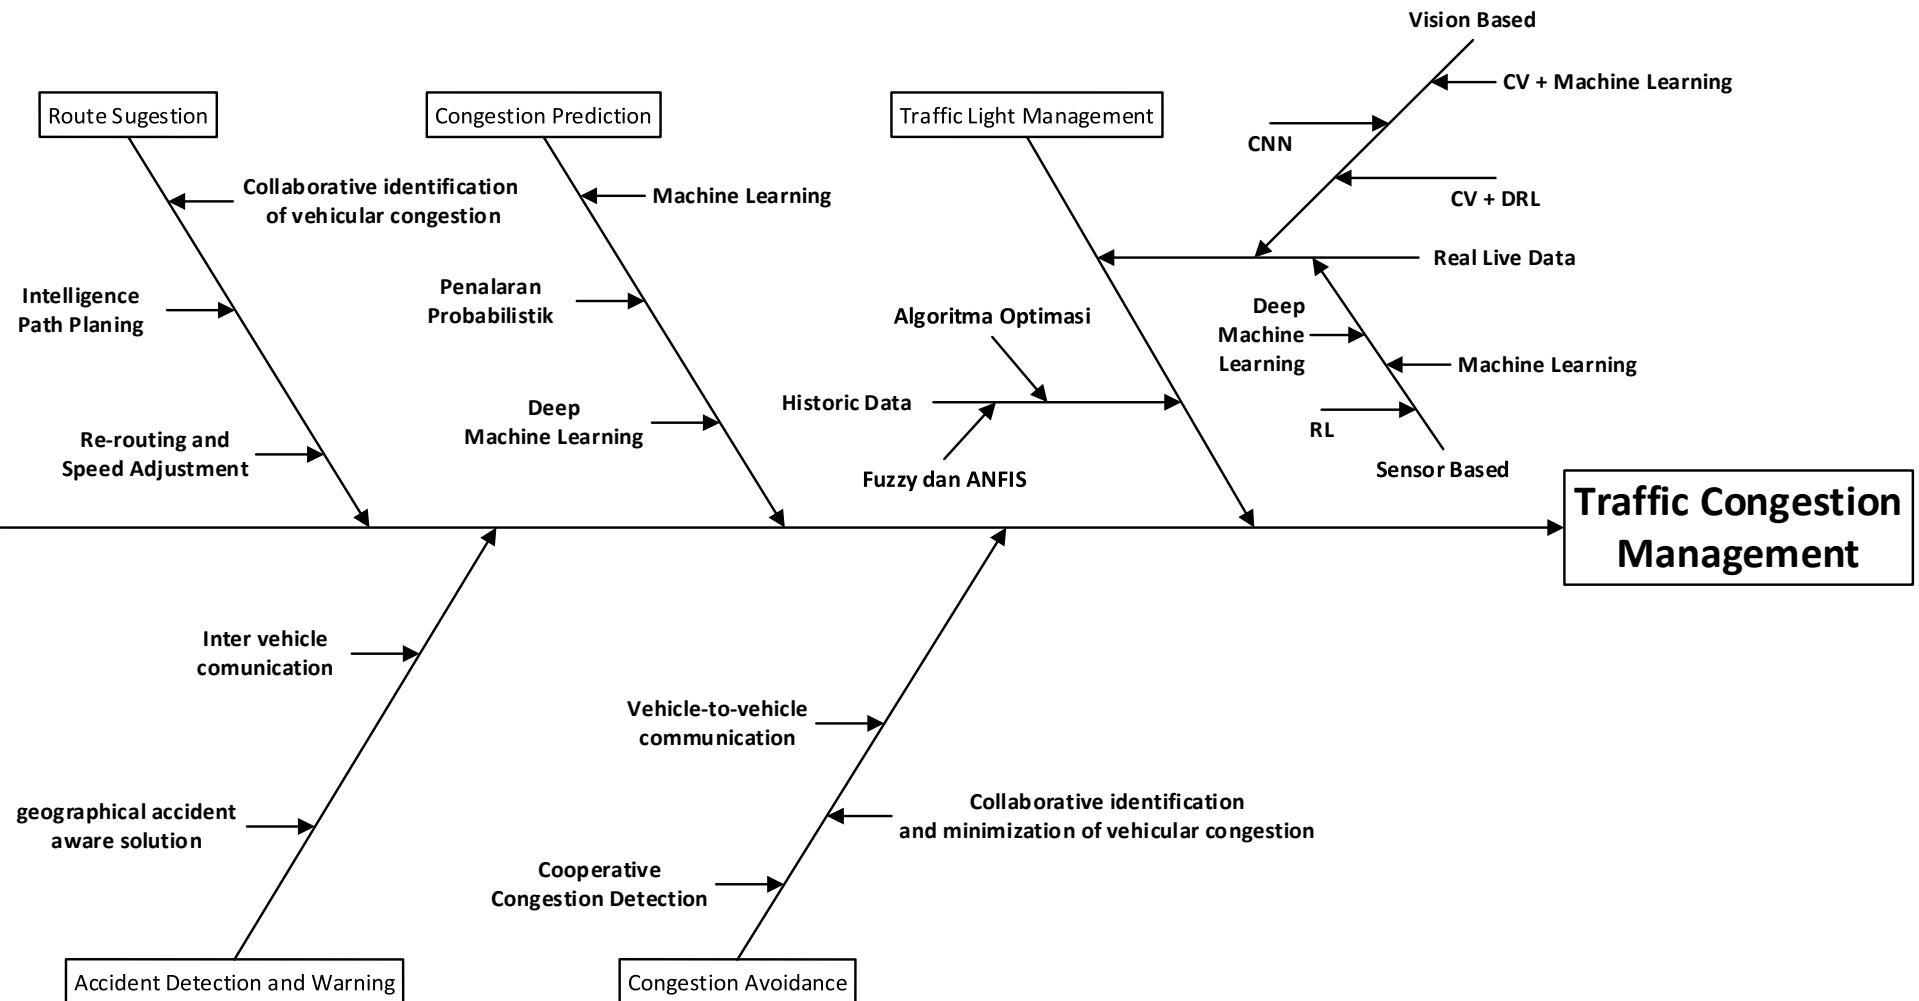
Pendekatan prediksi kemacetan yang digunakan untuk memecahkan permasalahan kemacetan lalu lintas memiliki kelemahan yang cukup diperhatikan oleh para peneliti di bidang kemacetan lalu lintas, karena tujuan dari model prediksi kemacetan adalah untuk membantu pemangku kepentingan dan user dalam pengambilan keputusan jangka pendek mereka. Namun keputusan yang didapatkan dari proses prediksi kemacetan lalu lintas seperti agar user mencari jalur alternatif, mengirimkan petugas lalu lintas ke lokasi tertentu, menggunakan tanda kecepatan variabel di hulu untuk mengalihkan lalu lintas ke jalan alternatif, sepenuhnya ada pada keputusan user dan tidak bergantung pada sistem manajemen lalu lintas yang dibuat. Karena alasan tersebut penelitian untuk mengatasi kemacetan dengan pendekatan kontrol sinyal lalu lintas (TSC) dilakukan. TSC dapat dilakukan dengan memanfaatkan pendekatan komputer cerdas seperti penelaran statistik, *machine learning*, *deep learning*, *reinforcement learning* maupun *deep reinforcement learning*. Jika dilihat dari sumber datanya bisa berasal dari data yang dikumpulkan secara manual (secara statistik), berasal dari *field sensor* atau secara langsung diambil dari kamera pengawas.

Sebagian besar penelitian-penelitian yang melakukan prediksi kemacetan lalu lintas menggunakan data historis yang dikumpulkan dalam rentang waktu yang cukup jauh dari saat model/aplikasi prediksi diaplikasikan. Hal ini membuka pendekatan *real time* dengan sensor yang lebih cepat yaitu kamera. Jika dibandingkan dengan sensor loop induktif/sensor tekan sensor kamera dapat langsung menggunakan kamera pengawas yang telah dipasang di berbagai persimpangan jalan, sehingga tidak diperlukan pemasangan sensor tambahan pada setiap persimpangan. Keuntungan yang kedua adalah kemampuan kamera yang dapat digunakan untuk memantau lalu lintas lebih luas dibandingkan loop induktif yang dapat membantu meningkatkan kualitas pemantauan lalu lintas.

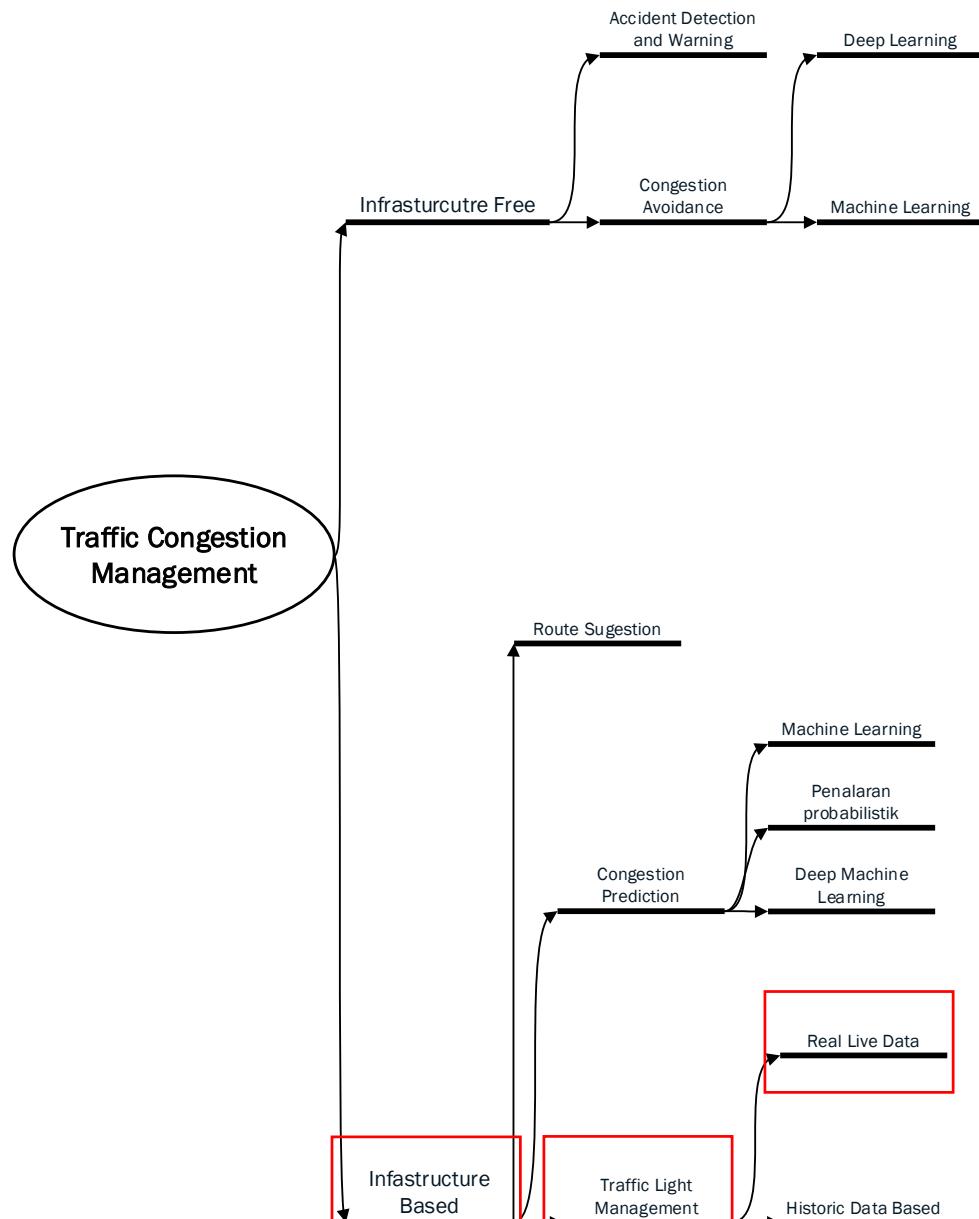
Dari tinjauan mutakhir juga didapatkan kesimpulan bahwa penggunaan DRL adalah cara yang sangat baik jika digunakan sebagai sistem *end-to-end*. Artinya kita tidak perlu melakukan ekstraksi fitur untuk digunakan sebagai input RL, RL sendiri dapat digunakan sebagai salah satu solusi membangun TSC adaptif yang dibuktikan dari beberapa penelitian *state of the art* pada Tabel 2.1.

2.2 Posisi Penelitian terhadap Penelitian Sebelumnya

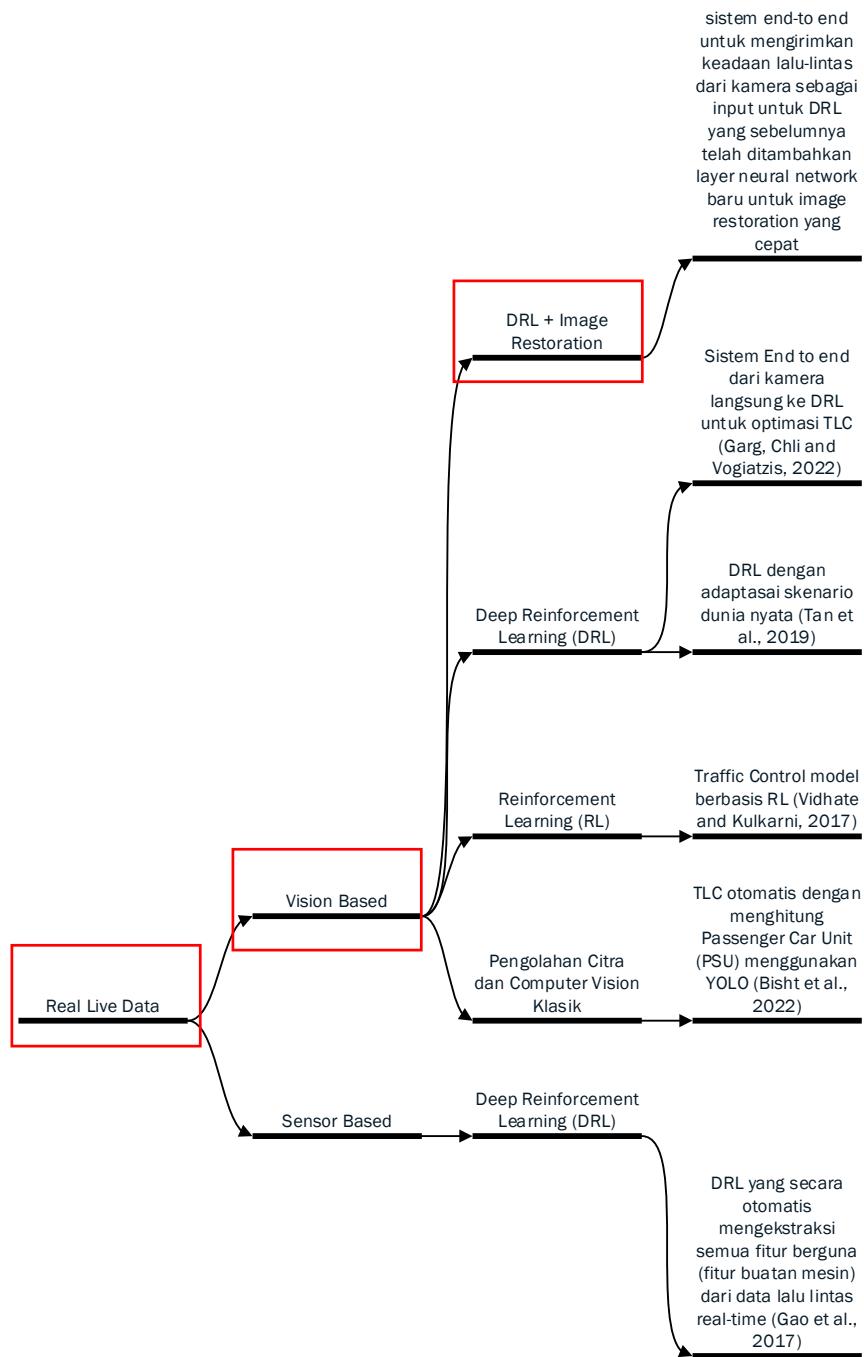
Posisi penelitian yang dibuat dapat digambarkan sesuai dengan yang terlihat pada diagram *fishbone* pada Gambar 2.1 dan diperjelas menggunakan diagram pada Gambar 2.2 dan Gambar 2.3. Sistem manajemen kemacetan umumnya dibagi menjadi dua jenis yaitu sistem tanpa infrastruktur (*Infrastructure Free*) dan sistem yang menggunakan infrastruktur (*Infrastructure Based*). Sistem *Infrastructure Free* adalah sistem yang tidak secara langsung menggunakan infrastruktur jalan raya untuk mengurangi kemacetan, memberikan informasi mengenai keadaan jalan raya, informasi kondisi jalan (yang macet dan jalan yang lebih lancar) adalah contoh pada sistem *Infrastructure Free*. Penelitian disertasi ini menggunakan sistem *Infrastructure Based* khususnya pada *traffic light management* yang menggunakan *real live data*. Input yang digunakan adalah kamera jadi masuk ke dalam penelitian *vision based*. Metode yang digunakan adalah end-to end yang mengubah input sensorik menjadi data untuk sistem RL menggunakan DRL. Kebaruan dalam sistem ini adalah penambahan teknik *Image Restoration* yang ringan dan cepat menggunakan *convolutional network* pada inputan DRL untuk memastikan DRL melakukan ekstraksi keadaan dunia nyata lebih baik di segala kondisi pencahayaan.



Gambar 2.1 Diagram fishbone penelitian pada *Traffic Congestion Management*



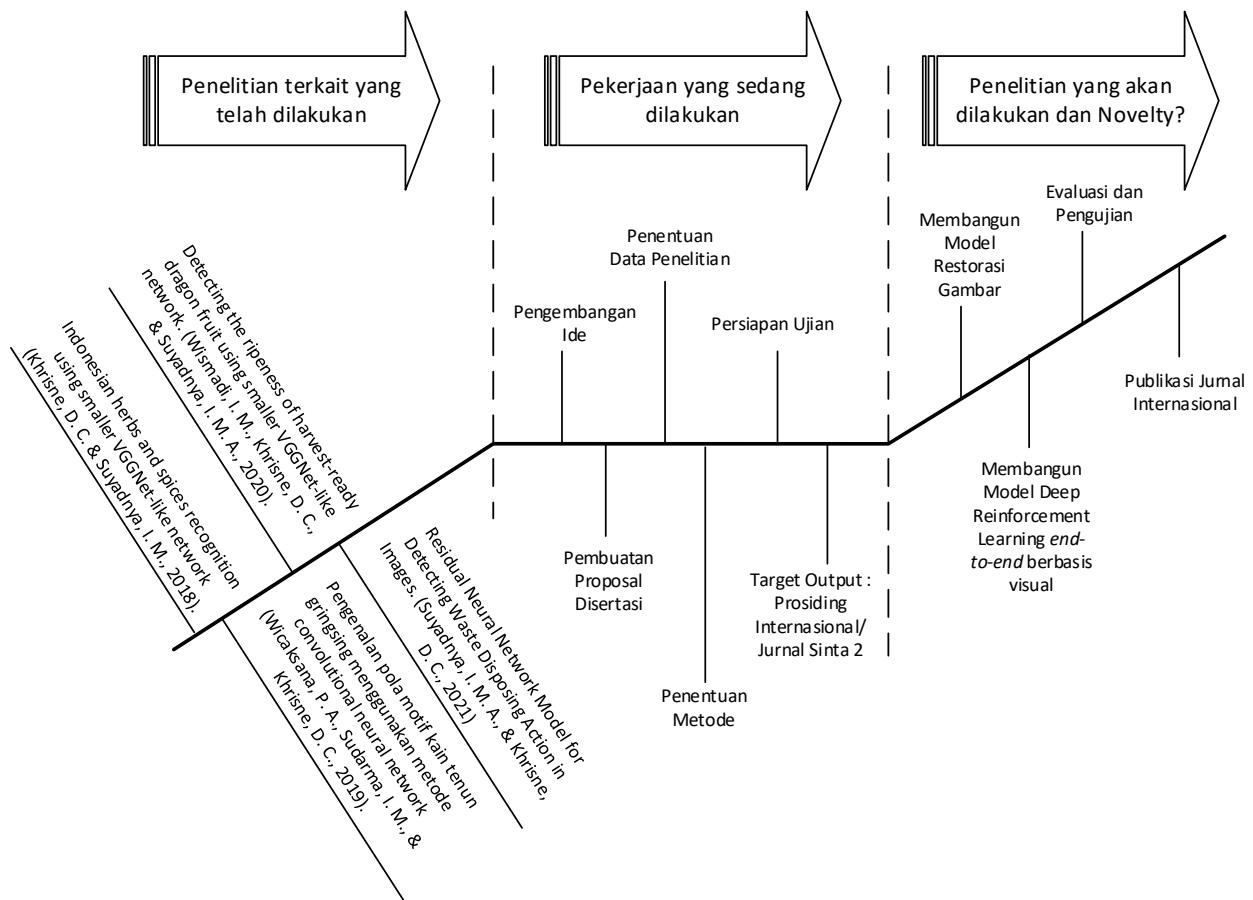
Gambar 2.2 Posisi Penelitian Terhadap Penelitian Sebelumnya pada *Traffic Congestion Management*



Gambar 2.3 Posisi Penelitian Terhadap Penelitian Sebelumnya pada cabang *real live-data*

2.3 *Roadmap* Penelitian

Roadmap penelitian disertasi ini dapat dilihat pada Gambar 2.4



Gambar 2.4 Rodamap Penelitian

2.4 Computer Vision

Computer Vision atau visi komputer memiliki dua tujuan. Dari sudut pandang ilmu biologi, visi komputer bertujuan untuk menghasilkan model komputasi dari sistem penglihatan manusia. Dari sudut pandang teknik, visi komputer bertujuan untuk membangun sistem otonom yang dapat melakukan beberapa tugas yang dapat dilakukan oleh sistem penglihatan manusia (dan bahkan mengunggulinya dalam banyak kasus). Banyak tugas penglihatan terkait dengan ekstraksi informasi 3D dan temporal dari data 2D dengan waktu beragam seperti yang diperoleh oleh satu atau lebih kamera televisi, dan lebih umum lagi pemahaman tentang pemandangan dinamis semacam itu (Huang, 1996). Tentu saja, kedua tujuan tersebut sangat terkait erat. Sifat dan karakteristik sistem penglihatan manusia sering memberi inspirasi kepada para insinyur yang merancang sistem penglihatan komputer.

Sebaliknya, algoritma penglihatan komputer dapat menawarkan wawasan tentang bagaimana sistem penglihatan manusia bekerja.

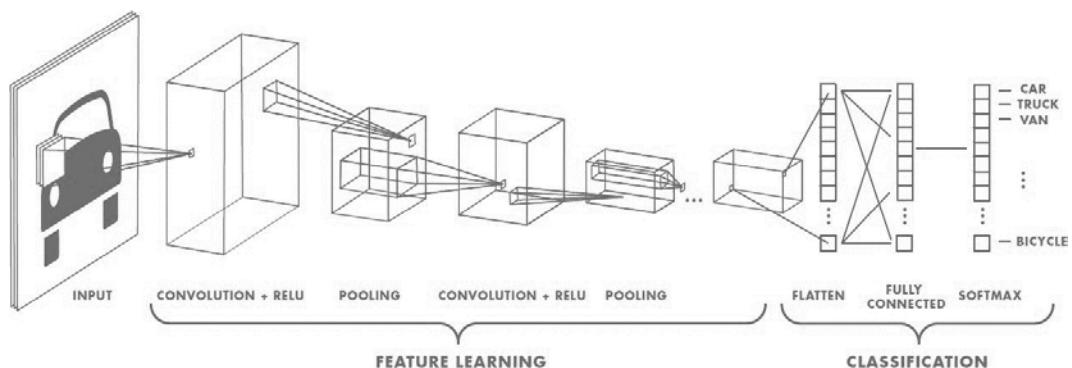
2.5 Deep Learning

Deep Learning memungkinkan model komputasi yang terdiri dari beberapa lapisan pemrosesan untuk mempelajari representasi data dengan berbagai tingkat abstraksi. Metode ini secara dramatis memperbaiki *state of the art* dalam pengenalan suara, pengenalan objek visual, deteksi objek dan banyak domain lainnya seperti penemuan obat dan genomik. Deep learning menemukan struktur yang rumit dalam kumpulan data yang besar dengan menggunakan algoritma backpropagation untuk menunjukkan bagaimana sebuah mesin harus mengubah parameter internalnya yang digunakan untuk menghitung representasi pada setiap lapisan dari representasi pada lapisan sebelumnya. *Deep Convolutional Network* telah membawa terobosan dalam memproses gambar, video, suara dan audio, sedangkan *recurrent nets* lebih menyoroti data sekuensial seperti teks dan ucapan (Lecun, Bengio and Hinton, 2015).

2.6 Convolutional Neural Network

Convolutional network atau yang dikenal dengan *convolutional neural network* (CNN) adalah tipe khusus dari *neural network* untuk memproses data yang mempunyai topologi jala atau *grid-like topology*. Pemberian nama *convolutional neural network* mengindikasikan bahwa jaringan tersebut menggunakan operasi matematika yang disebut konvolusi. Konvolusi sendiri adalah sebuah operasi *linear*. Jadi *convolutional network* adalah *neural network* yang menggunakan konvolusi *minimal* pada salah satu lapisannya (LeCun et al., 2015). *Convolutional neural network* (ConvNets) merupakan *special case* dari *artificial neural network* (ANN) yang saat ini diklaim sebagai model terbaik untuk memecahkan masalah *object recognition* dan *detection*.

Convolutional Neural Network (CNN) termasuk dalam jenis *Deep Neural Network* karena ke dalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Secara teknis, *convolutional network* adalah arsitektur yang bisa di *training* dan terdiri dari beberapa tahap. *Input* dan *output* dari masing-masing tahap adalah beberapa *array* yang disebut *feature map* atau peta fitur. *Output* dari masing-masing tahap adalah *feature map* hasil pengolahan dari semua lokasi pada *input*. Masing masing tahap terdiri dari tiga *layer* yaitu *convolution layer*, *activation layer* dan *pooling layer*



Sumber : <https://ai.plainenglish.io/deep-q-learning-simply-explained>

Gambar 2.5 Convolutional Neural Network

Convolutional Neural Networks merupakan suatu layer yang memiliki susunan neuron 3D (lebar, tinggi, kedalaman). Lebar dan tinggi merupakan ukuran layer sedangkan kedalaman mengacu pada jumlah layer. Secara umum terdapat dua jenis layer pada CNN yang dapat dilihat pada Gambar 2.5, yaitu:

1. *Layer feature learning/ekstraksi fitur gambar*, tersusun atas beberapa *layer* dan setiap *layer* tersusun atas neuron yang terkoneksi pada daerah lokal *layer* sebelumnya. *Layer* jenis pertama adalah *layer konvolusi* dan *layer* kedua adalah *layer pooling*, yang letaknya berselang-seling. Pada *layer* ini menerima input gambar secara langsung dan memprosesnya hingga menghasilkan keluaran vektor untuk diolah pada *layer* berikutnya.
2. *Layer classification/klasifikasi*, tersusun atas beberapa *layer* dimana setiap *layer* tersusun atas neuron yang terkoneksi secara penuh (*fully connected*) dengan *layer* lain. Pada *layer* ini menerima input dari hasil output *layer*

ekstraksi fitur, kemudian ditransformasikan dengan tambahan beberapa *hidden layer*. Hasil keluaran dari *layer* ini adalah berupa skoring kelas untuk klasifikasi.

CNN merupakan metode untuk mentransformasikan gambar original dari *layer* per *layer* berdasarkan nilai piksel dari gambar kedalam skoring kelas untuk klasifikasi. Yang mendasari sebuah CNN adalah adanya *layer* yang melakukan konvolusi atau disebut dengan *layer* konvolusi.

2.7 *Over-Fitting dan Under-Fitting dalam Supervised Learning*

Pada bidang *machine learning*, khususnya pada permasalahan klasifikasi menggunakan jaringan syaraf tiruan (ANN) pada mode pembelajaran terbimbing (*Supervised Learning*), dikenal dua masalah dalam pelatihan yaitu *Over-Fitting* dan *Under-Fitting* (Allamy, 2016).

1. *Over-Fitting* - Adalah salah satu masalah terbesar dalam pelatihan jaringan saraf. *Over-Fitting* berarti bahwa jaringan saraf pada waktu tertentu selama periode pelatihan tidak meningkatkan kemampuannya untuk memecahkan masalah lagi. Tetapi baru mulai mempelajari beberapa keteraturan acak yang terkandung dalam serangkaian pola pelatihan
2. *Under-Fitting* - Adalah kebalikan dari *Over-fitting*. Ini terjadi ketika model tidak mampu menangkap variabilitas data. Klasifikasi yang dihasilkan tidak memiliki kekuatan predikatif juga tidak dapat memetakan data pelatihan dengan benar. Ini adalah hasil dari pemahaman atau upaya untuk menggunakan model yang terlalu sederhana untuk menggambarkan set data yang diberikan.

2.8 *Image Restoration*

Image restoration (restorasi gambar) (Gonzalez and Woods, 2018) adalah teknik untuk memperbaiki gambar yang rusak atau cacat. Teknik ini dapat diterapkan pada gambar digital maupun gambar analog, dengan tujuan untuk memulihkan gambar ke kondisi aslinya atau memperbaiki gambar sehingga terlihat lebih baik.

Dalam konteks pengolahan citra digital, image restoration biasanya melibatkan penggunaan algoritma pengolahan citra untuk memperbaiki gambar yang kabur, rusak, atau terdistorsi. Algoritma ini dapat diterapkan pada berbagai jenis gambar, seperti gambar medis, gambar satelit, atau gambar fotografi.

Teknik image restoration dapat mencakup berbagai macam metode, termasuk noise reduction, sharpening, deblurring, dan inpainting. Noise reduction adalah teknik untuk mengurangi noise atau ketidak sempurnaan pada gambar. Sharpening adalah teknik untuk meningkatkan kejelasan dan detail gambar. Deblurring adalah teknik untuk memperbaiki gambar yang kabur akibat gerakan kamera atau lensa yang tidak stabil. Inpainting adalah teknik untuk memperbaiki gambar yang rusak atau hilang bagian tertentu dengan mengisi kekosongan gambar dengan piksel yang dihasilkan dari analisis konteks sekitarnya.

Image restoration sering digunakan dalam berbagai bidang, seperti fotografi, pengolahan citra medis, dan pengolahan citra satelit. Kualitas hasil image restoration sangat tergantung pada teknik yang digunakan dan kualitas gambar asli.

2.9 *Image Prior*

Image prior adalah informasi sebelumnya atau asumsi tentang bagaimana seharusnya sebuah gambar terlihat. Informasi ini dapat berupa model statistik tentang isi gambar, model fisika tentang pembentukan gambar, atau pengetahuan sebelumnya tentang struktur atau isi yang diinginkan dari gambar. Image prior digunakan dalam proses restorasi gambar untuk membantu memperbaiki kualitas gambar yang rusak atau kurang baik (Gonzalez and Woods, 2018).

Dengan menggunakan informasi sebelumnya tentang bagaimana gambar seharusnya terlihat, proses restorasi gambar dapat dipandu dan membuat hasil akhir lebih baik. Misalnya, jika image prior berisi informasi tentang tingkat kecerahan yang biasanya terdapat dalam jenis gambar tertentu, informasi ini dapat digunakan untuk memandu proses restorasi dan meningkatkan kecerahan dari gambar yang kurang cerah.

Dalam praktiknya, image prior dapat berupa berbagai bentuk, seperti model statistik tentang isi gambar, model fisika tentang pembentukan gambar, atau

pengetahuan sebelumnya tentang struktur atau isi yang diinginkan dari gambar. Tergantung pada bentuk image prior dan persyaratan dari tugas restorasi, metode restorasi gambar yang berbeda dapat digunakan untuk mengintegrasikan image prior dan memulihkan gambar.

2.10 Deep Image Prior

Menurut (Ulyanov, Vedaldi and Lempitsky, 2020), *Deep Image Prior* (DIP) adalah sebuah metode pengolahan citra yang menggunakan jaringan saraf (neural network) untuk menghasilkan citra yang lebih baik tanpa memerlukan data latih (training data). Metode ini didasarkan pada konsep *image prior*, yaitu pengetahuan atau asumsi tentang sifat atau struktur gambar sebelum pengolahan.

Dalam DIP, jaringan saraf yang digunakan tidak dilatih dengan data citra yang sudah ada. Sebaliknya, jaringan saraf ini dioptimalkan untuk memenuhi prior yang diberikan, yaitu asumsi tentang sifat citra yang ingin dihasilkan. Dalam DIP, prior ini diterapkan pada setiap layer dalam jaringan saraf, sehingga menghasilkan citra yang lebih baik secara bertahap.

DIP telah digunakan dalam berbagai aplikasi pengolahan citra, termasuk restorasi citra, super-resolusi citra, dan rekonstruksi citra. Keuntungan utama dari metode ini adalah bahwa tidak diperlukan data latih untuk melatih jaringan saraf, sehingga metode ini dapat digunakan untuk memperbaiki citra yang buruk tanpa memerlukan banyak data citra yang sudah siap.

2.11 Strategi Kontrol Sinyal Lalu Lintas (TSC)

Traffic Signal Control (TSC) adalah teknologi pengaturan lalu lintas jalan raya yang digunakan untuk mengontrol aliran kendaraan di persimpangan jalan yang ramai dengan menggunakan lampu lalu lintas. Tujuan dari TSC adalah untuk memastikan bahwa kendaraan dan pejalan kaki dapat bergerak dengan aman dan efisien di persimpangan jalan, sehingga dapat mengurangi kemacetan dan meningkatkan keselamatan pengguna jalan.

TSC biasanya menggunakan sensor lalu lintas, sistem penginderaan atau sistem kamera untuk mendeteksi jumlah kendaraan dan pejalan kaki di

persimpangan jalan. Berdasarkan informasi ini, sistem TSC akan menentukan kapan dan berapa lama lampu lalu lintas harus dinyalakan untuk mengatur arus lalu lintas.

Terdapat berbagai jenis sistem TSC (Qadri, Gökçe and Öner, 2020), termasuk sistem berbasis waktu dan sistem berbasis volume. Sistem berbasis waktu menggunakan waktu yang sudah ditentukan untuk mengatur lampu lalu lintas, sedangkan sistem berbasis volume menggunakan informasi volume kendaraan aktual untuk menyesuaikan timing lampu lalu lintas secara otomatis.

Penggunaan TSC telah terbukti efektif dalam mengurangi kemacetan dan kecelakaan di persimpangan jalan raya yang padat. Selain itu, teknologi ini juga dapat mengurangi polusi udara dan suara yang disebabkan oleh kendaraan yang berhenti dan bergerak terus menerus di persimpangan jalan.

Strategi kontrol sinyal lalu lintas (TSC – *Traffic Signal Control*) telah diklasifikasikan menjadi strategi kontrol waktu tetap, adaptif, dan digerakkan. Alasan utama di balik klasifikasi ini adalah jenis data dan algoritma yang digunakan untuk mengoptimalkan rencana sinyal lalu lintas.

Strategi TSC waktu tetap terutama sesuai untuk sinyal lalu lintas, di mana arus lalu lintas agak stabil dan konsisten. Berdasarkan data lalu lintas yang diamati sebelumnya, strategi ini menggunakan algoritme pengoptimalan off-line untuk TST dan berakhir dengan panjang siklus yang telah ditentukan, dan rencana pengaturan terpisah. Tujuan utama dari strategi ini adalah untuk mencapai tujuan keseluruhan, seperti meminimalkan delay rata-rata, memaksimalkan kapasitas jaringan, dll. mengembangkan model awal, yang meletakkan dasar strategi kontrol lalu lintas waktu tetap dengan meminimalkan delay rata-rata. Karena sistem lalu lintas sangat dinamis di daerah perkotaan, gangguan kecil apa pun dalam hal tabrakan lalu lintas, pekerjaan konstruksi, dll. Dapat tiba-tiba mengubah volume lalu lintas dan membuat kinerja keseluruhan dari rencana sinyal lalu lintas yang telah ditentukan sebelumnya tidak mencukupi.

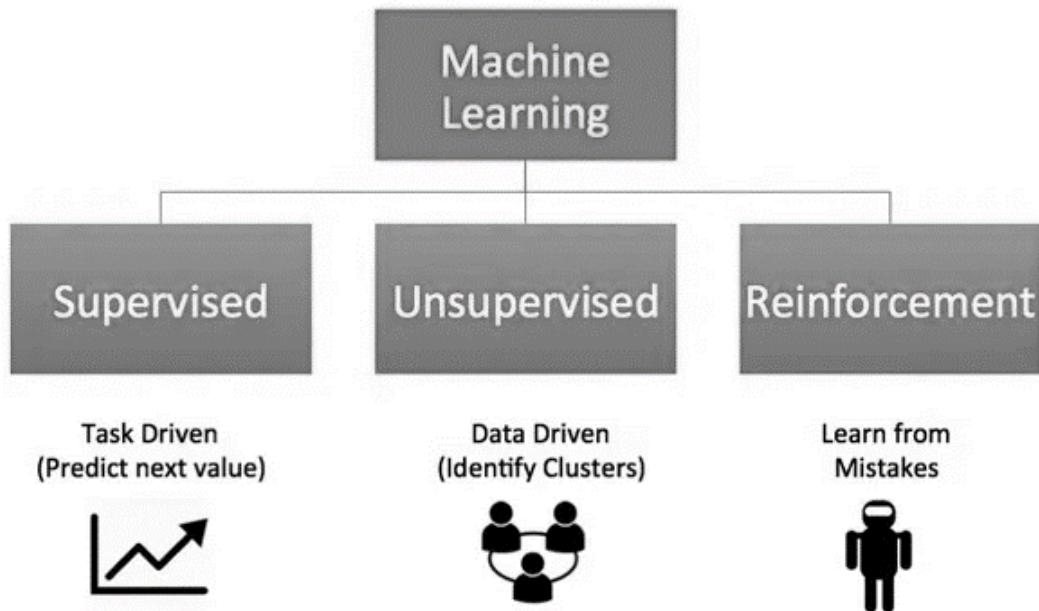
Berlawanan dengan strategi kontrol waktu tetap, tujuan utama dari strategi kontrol adaptif adalah untuk mengoptimalkan rencana TST sesuai dengan situasi lalu lintas saat ini di setiap fase. Oleh karena itu penggunaan teknologi sensor mulai

dipraktikkan. Teknologi sensor awal mampu membedakan keberadaan kendaraan saat mereka melintasinya

Belakangan, sistem visual mulai banyak digunakan. Strategi kontrol yang digerakkan juga menggunakan sensor dan pengontrol yang digerakkan memutuskan panjang siklus berdasarkan informasi sebelumnya. Sedangkan strategi adaptif merupakan modifikasi dari actuated control, yang menggunakan data saat ini untuk memprediksi panjang siklus kondisi lalu lintas *real time*. Sensor ini ditempatkan di setiap jalan dalam batas jaringan bersinyal. Namun, strategi ini tidak dapat melakukan analisis sedetail strategi fixed-time, karena mereka harus mengatur rencana sinyal lalu lintas secara instan. Sistem lalu lintas, terutama di daerah perkotaan, sangat dinamis. Setiap gangguan kecil tiba-tiba dapat mengubah volume lalu lintas. Jadi, lebih menguntungkan jika sistem mampu mengurangi kemacetan lalu lintas secara *real time*. Sekarang di dunia sekarang ini, dengan penggunaan teknologi sensor dan strategi tambahan, pengumpulan data secara *real time* tidak lagi menjadi tugas yang menantang. Dengan banyaknya data dan penggunaan daya komputasi yang tersedia, manajemen lalu lintas instan, atau prediksi skenario lalu lintas dapat dilakukan.

2.12 Reinforcement Learning (RL)

Reinforcement Learning (RL) adalah suatu metode pembelajaran mesin di mana agen belajar berinteraksi dengan lingkungannya untuk mencapai tujuan tertentu melalui percobaan dan kesalahan. Agen menerima umpan balik dalam bentuk *reward* atau *punishment* sebagai respons terhadap tindakan yang diambilnya, sehingga belajar secara mandiri untuk mengidentifikasi tindakan yang paling menguntungkan. RL sering digunakan dalam konteks pembelajaran mesin yang melibatkan pengambilan keputusan sekvensial dan tidak memerlukan data latih yang diawasi (Sutton and Barto, 2015).

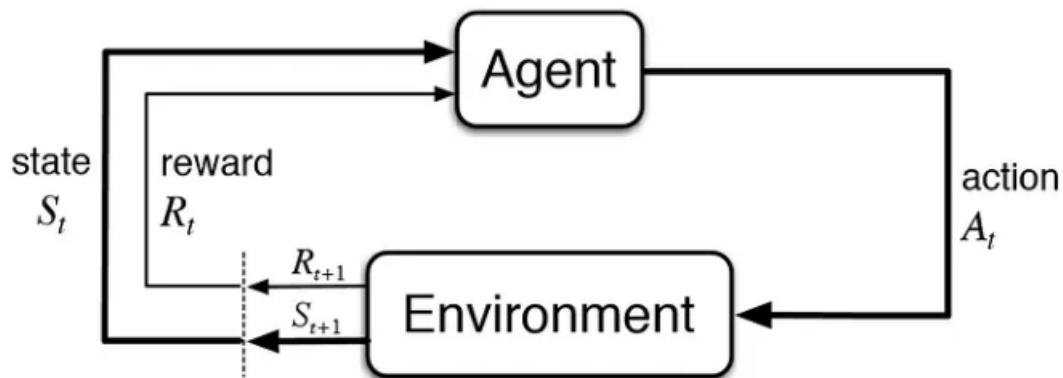


Sumber : <https://towardsdatascience.com/reinforcement-learning-101>

Gambar 2.6 Posisi Reinforcement Learning dalam Machine Learning

Reinforcement Learning memiliki perbedaan jika dibandingkan dengan *Supervised Learning*, meskipun *Supervised Learning* dan RL memanfaatkan dan melakukan pemetaan antara *input* dan *output*. Namun, tidak seperti pada *supervised learning* yang memberikan umpan balik berupa serangkaian data kebenaran (*correct*) pada tugas yang dibebankan, RL menggunakan *reward* dan *punishment* sebagai sinyal untuk perilaku positif (menuju optimal) dan negatif (menjauhi optimal).

Dibandingkan dengan *unsupervised learning*, RL memiliki perbedaan dalam hal tujuan. Tujuan dalam *unsupervised learning* adalah untuk menemukan kesamaan dan perbedaan antara poin data, sedangkan RL, tujuannya adalah untuk menemukan model tindakan sesuai yang akan memaksimalkan total *reward* dari agen. Gambar 2.7 mengilustrasikan loop umpan balik *Action-Reward* dari model RL generik.



Sumber : <https://towardsdatascience.com/reinforcement-learning-101>

Gambar 2.7 Loop Action-Reward pada RL

2.13 Deep Reinforcement Learning (DRL)

Deep Reinforcement Learning (DRL) adalah pendekatan dalam bidang pembelajaran mesin yang menggabungkan konsep dari *reinforcement learning* (RL) dengan jaringan saraf dalam bentuk *neural networks* yang dalam (*deep neural networks*) untuk mengatasi masalah pembelajaran sekuensial yang kompleks. Dengan menggunakan deep neural networks, DRL mampu mengatasi masalah dengan ruang keadaan yang besar dan mempelajari representasi fitur yang lebih abstrak.

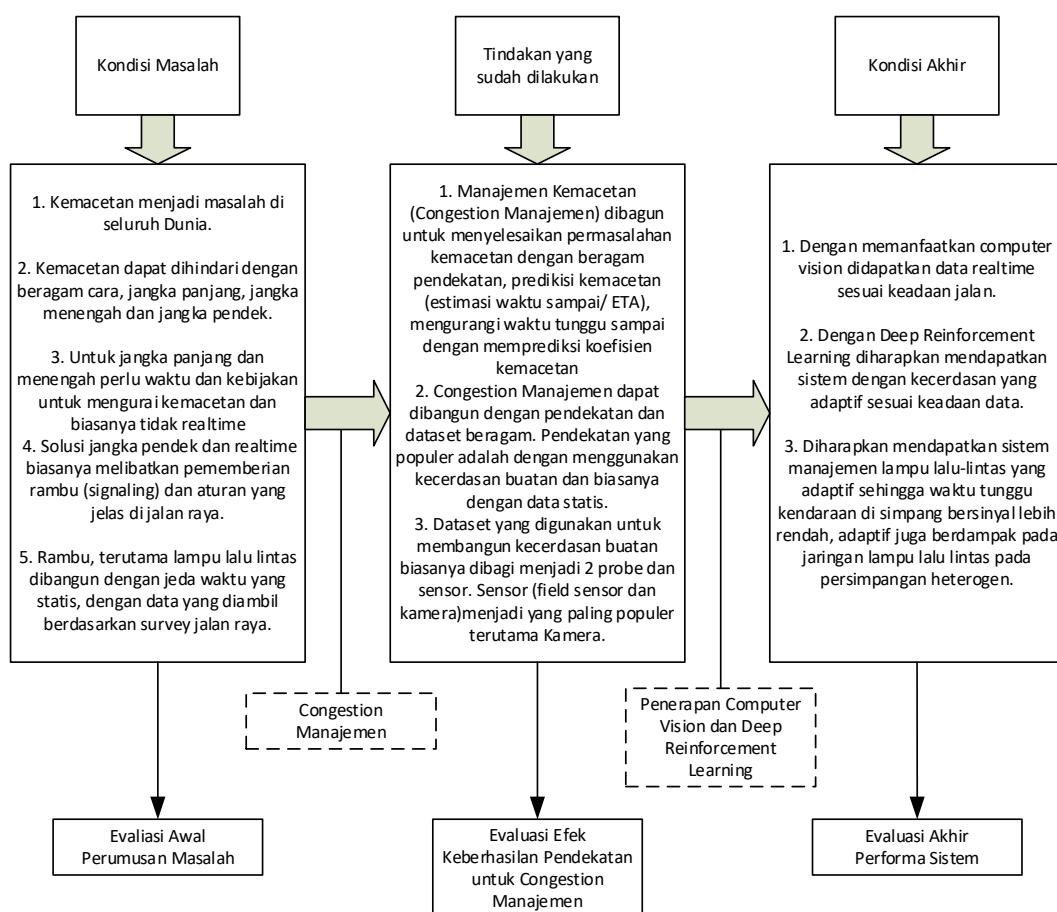
BAB III

KERANGKA BERFIKIR, KONSEP PENELITIAN DAN HIPOTESIS

3

3.1 Kerangka Berfikir

Dalam riset mengenai kemacetan lalu lintas dalam disertasi ini, terdapat kerangka berpikir yaitu berupa kondisi masalah (permasalahan), kondisi saat ini (proses) dan kondisi akhir (solusi yang ditawarkan). Adapun gambaran permasalahan di lapangan, solusi yang ditawarkan dan target yang ingin dicapai dapat dilihat pada Gambar 3.1.



Gambar 3.1 Kerangka Berpikir

Berdasarkan Gambar 3.1 dapat dijelaskan bahwa kemacetan menjadi masalah di seluruh Dunia. Kemacetan dapat dihindari dengan beragam cara, teknik-teknik tersebut dikelompokkan menjadi solusi jangka panjang, jangka menengah dan jangka pendek berdasarkan waktu penyelesaiannya (Akhtar and Moridpour, 2021).

Salah satu solusi yang cukup baik dalam solusi permasalahan kemacetan adalah teknik jangka pendek yang menekankan pada solusi-solusi *real time*. Salah satu solusi *real time* yang saat ini banyak ditawarkan adalah manajemen lampu lalu lintas adaptif (Qadri, Gökçe and Öner, 2020; Rasheed *et al.*, 2020). Pendekatan ini muncul karena jeda waktu statis pada lampu lalu lintas menurut beberapa penelitian jalan raya menunjukkan bahwa lampu lalu lintas dengan data statis adalah salah satu penyebab tersendatnya arus lalu lintas (Qadri, Gökçe and Öner, 2020; Rasheed *et al.*, 2020). Hal ini dikarenakan lampu lalu lintas dengan waktu statis tidak dirancang dengan kemampuan adaptasi terhadap keadaan lalu lintas *real time*, namun di sisi lain perubahan keadaan lalu lintas terutama pada simpang heterogen bersinyal sangatlah dinamis. Pendekatan *real time* yang sering digunakan untuk melakukan manajemen lampu lalu lintas bisa diaplikasikan menggunakan banyak metode. Metode-metode seperti *Fuzzy*, *Deep Learning*, *Reinforcement Learning* dan *Deep Reinforcement Learning* menjadi beberapa metode yang telah berhasil digunakan dalam membangun lampu lalu lintas adaptif.

Deep Reinforcement Learning (DRL) yang memungkinkan perubahan adaptif terhadap waktu sinyal lampu lalu lintas menjadi dasar pada penelitian ini. DRL dibangun dari dua buah metode. Pertama *Deep Convolutional Neural Network* yang digunakan untuk melakukan ekstraksi fitur dari input sensorik (*machine crafted feature*). Kedua *Reinforcement Learning* yang memanfaatkan agen cerdas untuk melakukan aksi yaitu mengganti sinyal lampu lalu lintas, untuk mendapatkan reward berupa hasil optimasi terbaik yang diinginkan oleh sistem.

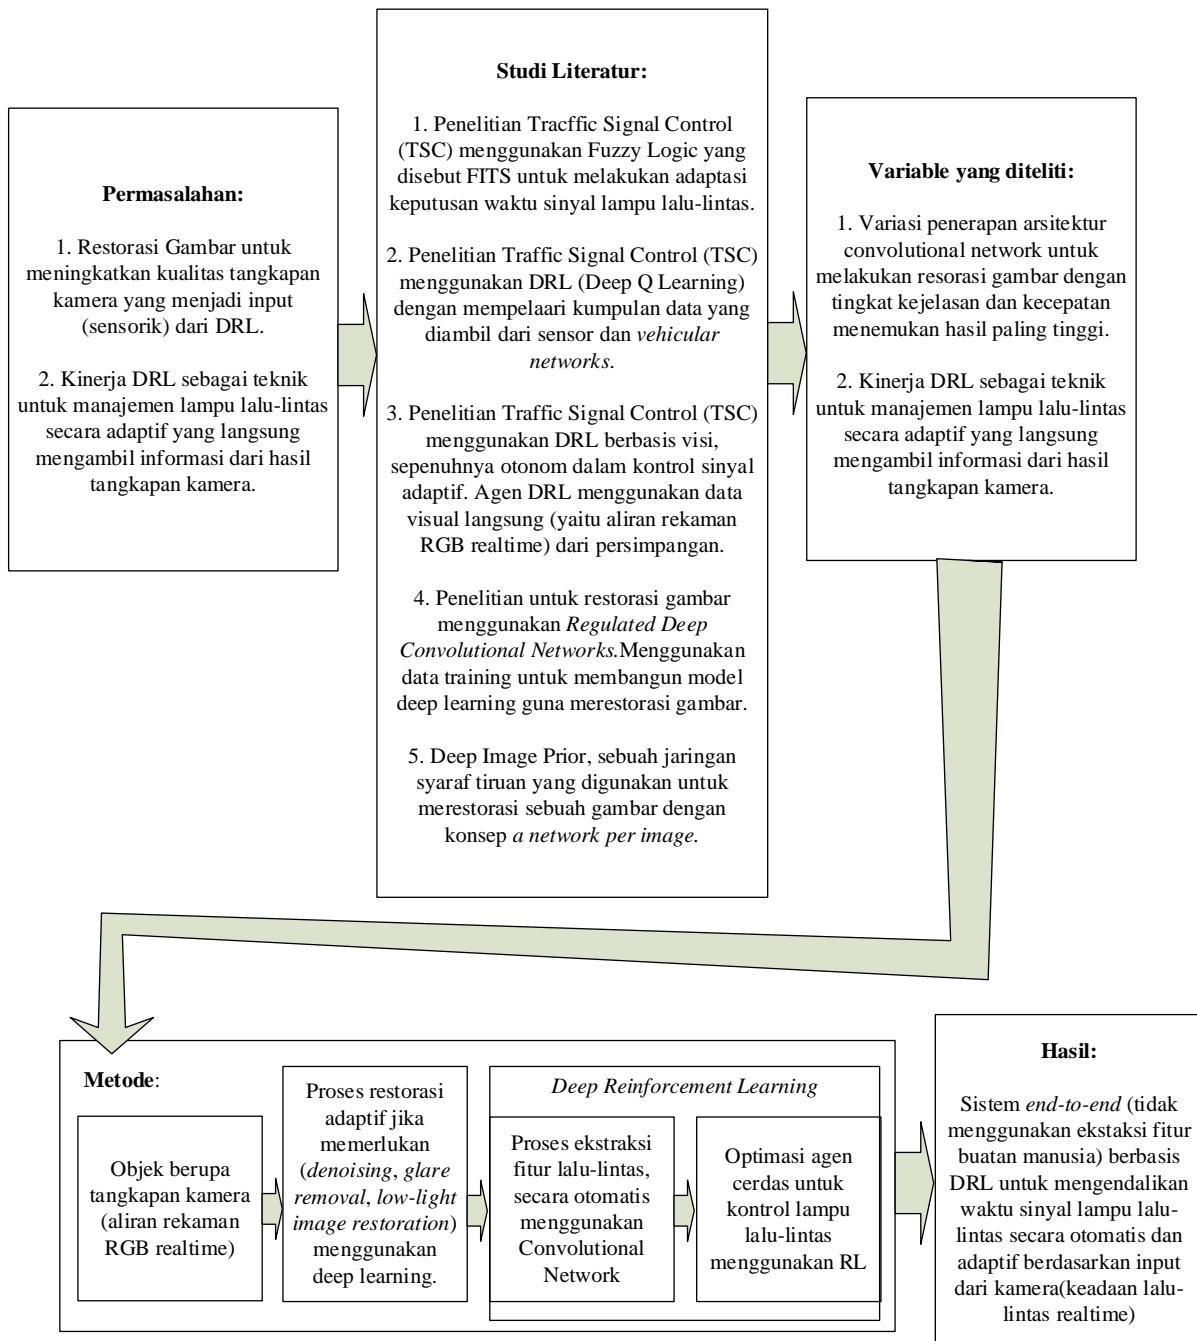
Kelemahan dari sistem *end-to-end* yang memanfaatkan input langsung dari sistem sensorik, dalam hal ini kamera, adalah kemampuan kamera dalam melihat objek sangat dibatasi pada kondisi cahaya pada lingkungan sekitar. Sepanjang pengetahuan penulis belum pernah dilakukan penelitian untuk menambahkan

kemampuan kamera dalam melihat lebih baik di segala kondisi cahaya pada sistem *end-to-end* yang memanfaatkan DRL. Hal tersebut dikarenakan proses restorasi gambar terutama penggunaan *deep learning* untuk restorasi gambar membutuhkan sumber daya dan waktu tambahan untuk menyelesaikan prosesnya. Hal ini membuat *bottle-neck* pada proses DRL untuk adaptasi lampu lalu lintas yang membutuhkan kecepatan yang cukup tinggi.

Pada penelitian ini dilakukan pembuatan sistem cerdas untuk lampu lalu lintas adaptif menggunakan DRL menggunakan pendekatan *end-to-end* dengan sensor berupa kamera, untuk memastikan kemampuan kamera dalam melihat lingkungan sekitar dengan baik DRL ditambahkan *Deep Image Restoration* dengan arsitektur baru yang lebih cepat.

3.2 Konsep Penelitian

Permasalahan mengenai bagaimana DRL yang ditambahkan Deep Image Restoration dan bagaimana mengatur kecepatan restorasi gambar dan pembentukan agen cerdas untuk pengaturan lalu-intas adaptif menjadi dasar Konsep Penelitian pada penelitian ini, yang ditunjukkan pada Gambar 3.2.



Gambar 3.2 Diagram Konsep Penelitian

3.3 Hipotesis

Hipotesis penelitian ini berdasarkan studi pustaka mengenai permasalahan pengendalian lampu lalu lintas (TSC) menggunakan *Deep Reinforcement Learning* dan teknik restorasi citra menggunakan *Deep Learning*, yaitu dengan menggunakan DRL waktu tunggu kendaraan pada simpang heterogen bersinyal diperkirakan

menurun. Penambahan teknik restorasi citra diharapkan menambah kemampuan DRL mengambil keputusan berdasarkan data sensorik yaitu kamera dengan lebih baik di segala kondisi pencahayaan.

BAB IV

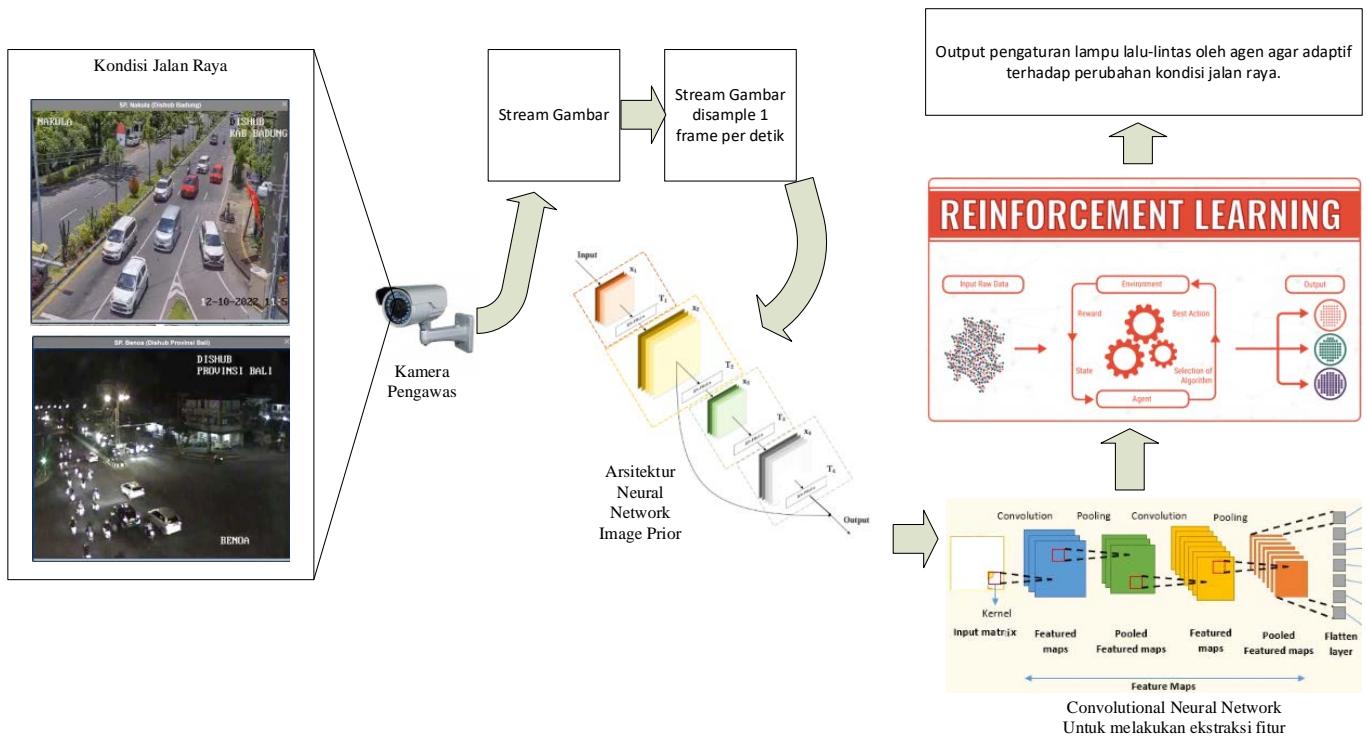
METODE PENELITIAN

4.1 Rancangan Penelitian

Secara umum aplikasi yang dibangun akan melalui 3 tahap utama yaitu :

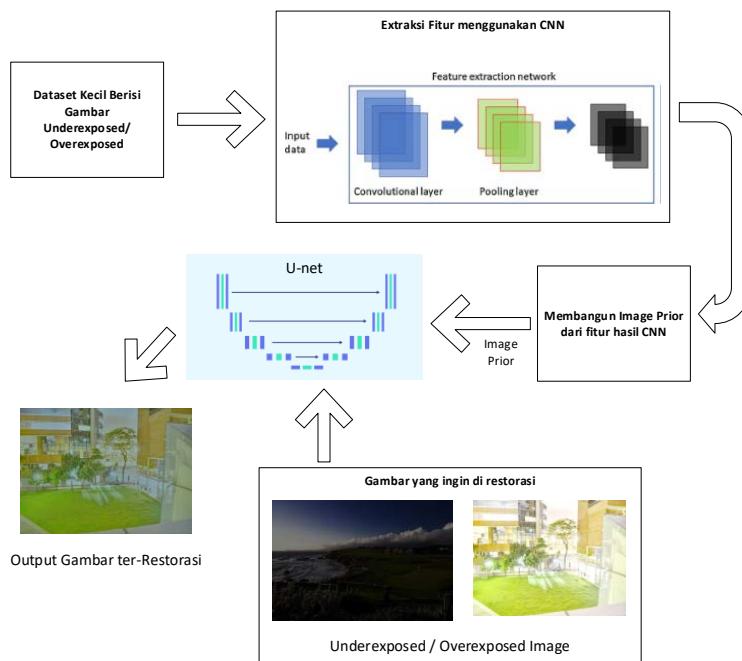
1. Membangun aplikasi restorasi citra menggunakan *image prior* dengan kecepatan yang lebih tinggi. Dengan rincian tahapan sebagai berikut:
 - a. Mendapatkan *region of interest* (ROI) dari semua jalur yang menunjukkan antrian menuju lampu lalu lintas yang ada pada sebuah simpangan.
 - b. Mengambil gambar antrian kendaraan dalam ROI dan melakukan restorasi untuk dikirimkan pada model DRL
2. Membangun model DRL dengan tahapan:
 - a. Membangun *Convolutional Network* untuk melakukan proses ekstraksi fitur kondisi lalu lintas pada simpang bersinyal heterogen. Data untuk tahapan ini adalah gambar yang didapat dari output *image prior*
 - b. Membangun agen cerdas dengan melatih sebuah *Reinforcement Learning* untuk dapat mengganti waktu sinyal (lampu merah, lampu kuning dan lampu hijau) secara adaptif, menggunakan input dari fitur yang dibuat oleh layer *Convolutional Network* pada tahap sebelumnya.
3. Tahap uji coba sistem dengan menggunakan simulasi terhadap output model yang dihasilkan pada tahap 2.

Gambaran umum dari sistem yang dibangun ditunjukkan pada Gambar 4.1.



Gambar 4.1 Gambaran Umum Sistem Kontrol Lampu Lalu lintas Adaptif

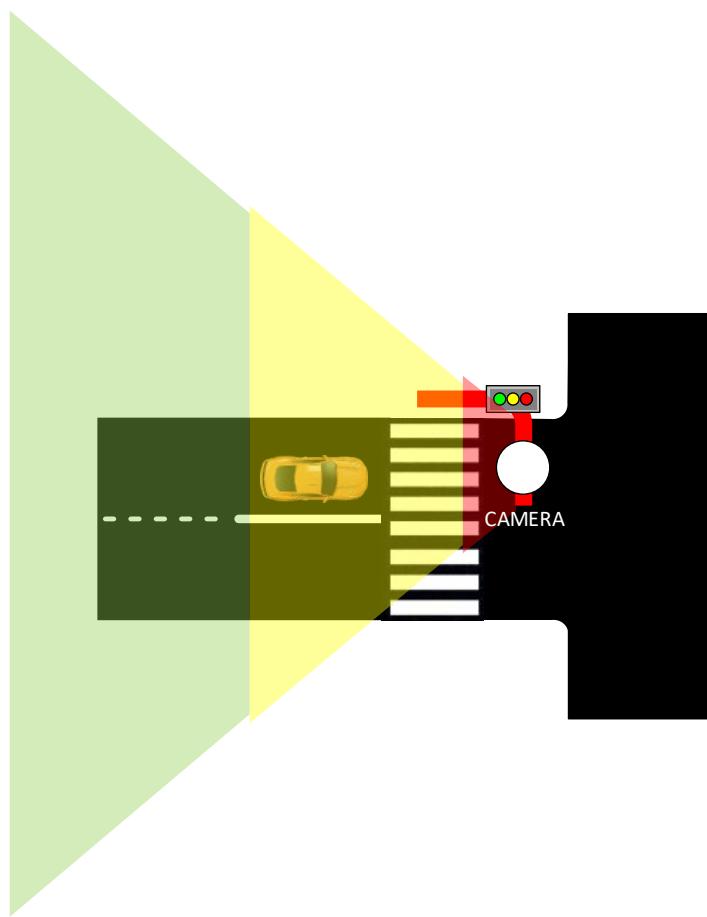
Secara lebih detail untuk membangun Arsitektur Neural Network *Image Prior* yang tercantum pada gambar 4.1 dapat dijabarkan kembali seperti yang ditunjukkan pada Gambar 4.2.



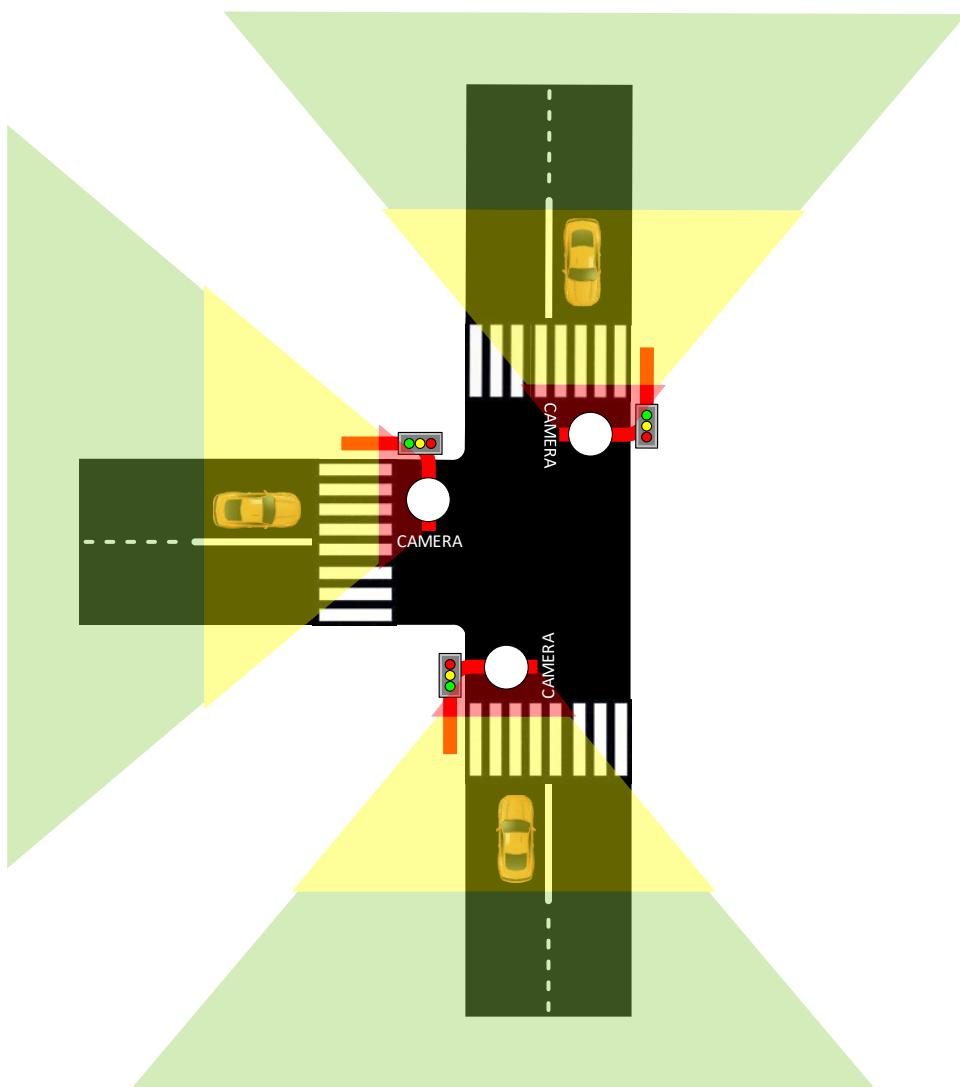
Gambar 4.2 Arsitektur Neural Network *Image Prior*

Tahapan awal saat kamera pengawas melakukan tangkapan gambar dapat dirinci kembali kedalam tahapan-tahapan berikut:

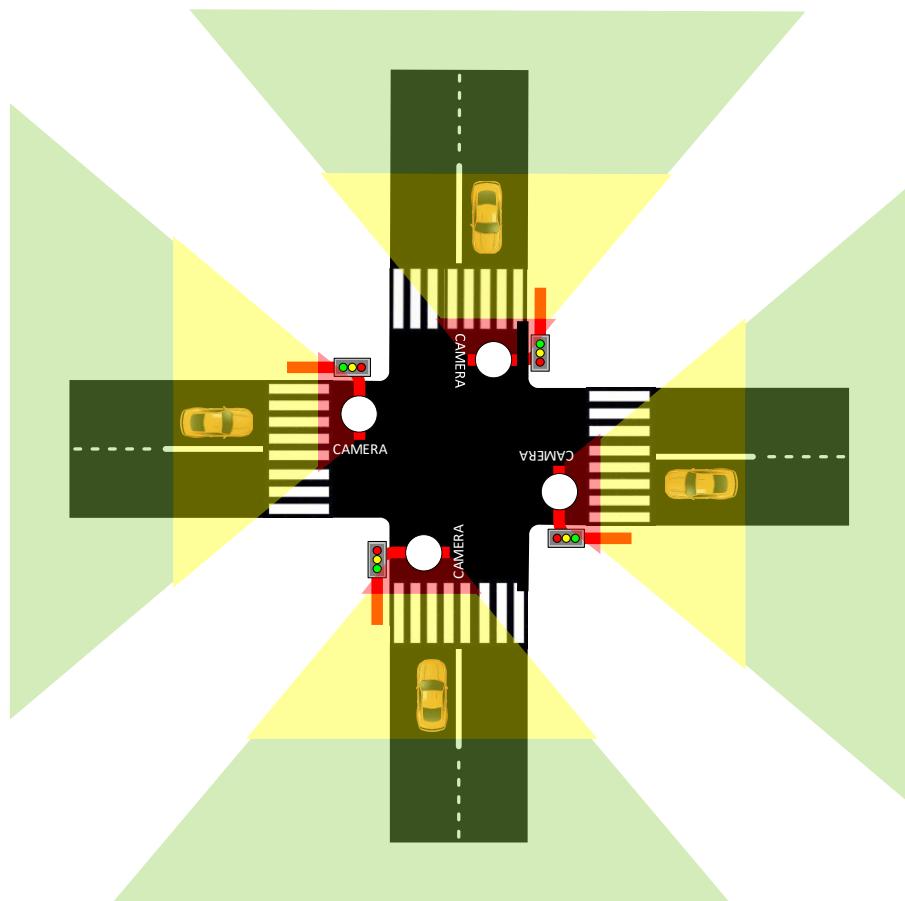
1. Penentuan posisi kamera, posisi kamera memberikan fungsi pandangan dan menentukan seberapa luas *Field of View* (FOV) dari sistem berbasis visual. Pada penelitian ini ilustrasi penempatan kamera terhadap 1 ruas jalan, 3 ruas jalan dan empat ruas jalan pada persimpangan dapat dilihat pada Gambar 4.3, Gambar 4.4 dan Gambar 4.5 berturut-turut.



Gambar 4.3 Posisi Kamera dan *field of view* pada satu ruas jalan



Gambar 4.4 Posisi Kamera dan *field of view* pada tiga ruas jalan



Gambar 4.5 Posisi Kamera dan *field of view* pada empat ruas jalan

Seperti yang dapat dilihat pada gambar 4.3 selain penempatan kamera terdapat juga 3 jenis FOV yang terjadi akibat efek penempatan kamera, yaitu level hijau yang memberikan pandangan paling luas namun dengan kejelasan detail yang kecil, level kuning dengan pandangan yang kurang luas dari level hijau namun memiliki detail lebih jelas dan level merah yang memberi pandangan paling sempit namun juga memberi detail paling jelas.

2. Penentuan ROI, *region of interest* (ROI) dibutuhkan sistem visual untuk menentukan bagian mana pada input sensor (dalam hal ini video) yang digunakan sebagai gambar input untuk sistem. Pada penelitian ini ROI akan dilakukan dengan melakukan penentuan ruang ROI secara manual untuk setiap

persimpangan, dengan konfigurasi ROI selalu memilih sebuah jalur yang melakukan antrian menuju ke lampu lalu lintas.

3. Pengambilan Gambar, tahapan terakhir pada pemrosesan input adalah tahap pengambilan gambar. Gambar yang digunakan sebagai input sistem adalah gambar yang diambil dari aliran RGB pada sebuah frame yang diambil setiap detik dari aliran gambar yang dikirimkan (video) dari kamera. Hal ini menyebabkan terdapat 1 gambar input yang digunakan sebagai input sistem setiap detiknya (1 FPS).

4.2 Lokasi dan Waktu Penelitian

Penelitian Sistem Kontrol Lalu lintas Adaptif Berbasis Visual Menggunakan Deep Reinforcement Learning ini dilakukan di Laboratorium Komputer Program Studi Teknik Elektro, Fakultas Teknik, Universitas Udayana Badung – Bali. Waktu penelitian dilakukan dari Januari 2023 hingga 2025.

4.3 Ruang Lingkup Penelitian

Ruang lingkup Penelitian ini seperti yang diuraikan pada batasan masalah adalah:

1. Sistem yang menggunakan gambar yang diambil dari kamera untuk pengenalan kondisi jalan raya.
2. Obyek yang diteliti adalah persimpangan bersinyal (memiliki lampu lalu lintas) *heterogen* (dengan kendaraan roda 2, roda 3 dan roda 4).
3. Metode restorasi gambar yang digunakan adalah metode *convolutional neural network* terutama *image prior*
4. Agen cerdas dibangun menggunakan teknik *Deep Reinforcement Learning* yang memanfaatkan input dengan fitur buatan mesin (*machine crafted feature*).
5. Output pengendalian lampu lalu lintas adalah waktu sinyal lampu merah, kuning dan hijau yang adaptif terhadap keadaan jalan, yang bertujuan agar gerakan lalu lintas lebih halus (lancar).

4.4 Penentuan Sumber Data

Data adalah sumber referensi yang sangat penting yang digunakan dalam penelitian. Ada dua faktor yang perlu diperhatikan dalam melaksanakan penelitian ini yaitu sumber data dan jenis data penelitian. Penelitian ini memperoleh data yang bersumber dari studi literatur dan wawancara dengan pakar. Studi literatur yang digunakan diperoleh dari penelitian terdahulu, jurnal ilmiah, buku, e-book, forum, dan paper publikasi dari sumber-sumber internet. Data kondisi lalu lintas yang digunakan bersumber dari Dataset *AAU RainSnow Traffic Surveillance Dataset*. Dataset ini memiliki secara total, 2.200 gambar yang dianotasi, berisi 13.297 objek. Dataset yang digunakan pada penelitian ini dapat diakses daring di <https://www.kaggle.com/datasets/aalborguniversity/aau-rainsnow>.

Untuk pelatihan image prior digunakan dataset gambar under dan over exposure yang berjudul *LOW Light paired dataset* (LOL). Dataset ini memiliki 500 buah gambar bertipe .jpg. Dataset ini dapat diunduh pada halaman https://drive.google.com/file/d/157bjO1_cFuSd0HWDUuAmcHRJDVyWpOxB/view

4.5 Variable Penelitian

Variabel penelitian yang digunakan dalam penelitian ini adalah:

1. Arsitektur neural network untuk restorasi gambar untuk mempercepat pengenalan lingkungan.
2. Agen cerdas yang dilatih menggunakan reinforcement learning yang fitur latihnya didapatkan dari *convolutional neural network*.

4.6 Bahan Penelitian

Bahan penelitian yang digunakan diambil dari literatur berupa buku-buku tentang Lalu lintas, restorasi gambar dan *Deep Reinforcement Learning* dari berbagai macam sumber.

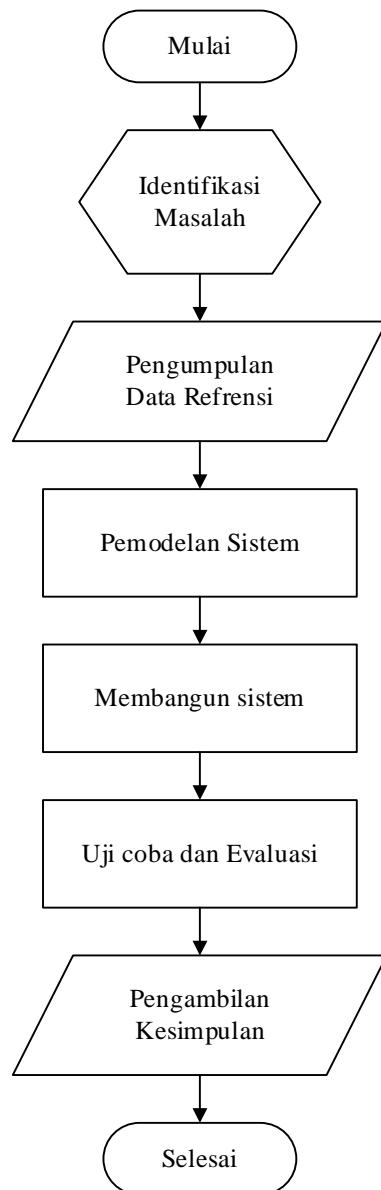
4.7 Instrumen Penelitian

Dalam penelitian ini digunakan perangkat keras dan perangkat lunak sebagai berikut :

1. Perangkat keras (*hardware*), Laptop dengan spesifikasi Prosessor Intel(R) Core(TM) i7-10750H CPU @ 2.60GHz, RAM 16 GB, dan Kapasitas Hardisk 160 GB.
2. Perangkat lunak (*software*)
 - a. Sistem Operasi yang ter-*install* pada PC atau laptop adalah Microsoft Windows 10 64-bit (*Minimum requirement* untuk *Tensor Flow* adalah prosesor 64-bit)
 - b. Aplikasi *python* versi 3.6.4 (*Keras* dan *Tensor Flow* hanya dapat dijalankan dengan *python* versi 3.5 atau yang lebih baru), *library Open CV 3.3* yang memiliki modul *DNN* (*Deep Neural Network*) dan *library Scikit-Learn*.

4.8 Prosedur Penelitian

Penelitian ini mengenai sistem kontrol lalu lintas berbasis visual menggunakan *Deep Reinforcement Learning*. Bagan alir penelitian dapat dilihat pada Gambar 4.3.



Gambar 4.6 Flowchart Tahapan Penelitian

Penjelasan dari bagan alir pada Gambar 4.3 adalah sebagai berikut :

1. Identifikasi masalah, mengidentifikasikan masalah yang ada, dalam penelitian ini diketahui bahwa diperlukan sebuah sistem adaptif untuk mengatur sinyal lampu lalu lintas agar adaptif. Salah satu jalan yang dapat digunakan adalah menggunakan agen cerdas yang dilatih menggunakan deep reinforcement learning, namun tidak cukup sampai disana, karena permasalahan kamera sebagai sensor input untuk mendapatkan gambaran keadaan lalu lintas,

kemampuan kamera akan dibekali restorasi gambar berbasis *convolutinal network*.

2. Pengumpulan data referensi, mengumpulkan referensi yang dibutuhkan untuk menunjang penelitian yang dilakukan terutama mengenai *Deep Reinforcement Learning* dan restorasi gambar berbasis *convolutinal network*.
3. Pemodelan sistem, tahap pemodelan sistem merancang elemen input-output dan proses dari aplikasi. Teknik membangun *Image Prior* (Restorasi gambar berbasis *convolutinal network*), membangun dan melatih *Deep Reinforcement Learning*, serta evaluasi agen adalah permasalahan utama yang ingin dicapai dalam aplikasi ini.
4. Membangun sistem, proses yang dilakukan untuk membangun serta membuat suatu sistem kendali lampu lalu lintas adaptif berbasis *deep reinforcement learning* yang diuji coba dan dievaluasi keberhasilannya.
5. Proses pengujian dan evaluasi, pada proses ini dilakukan pengujian dengan melakukan simulasi menggunakan aplikasi simulator lalu lintas. Sebelumnya hasil restorasi dan kecepatannya harus dioptimasi terlebih dahulu dan dilanjutkan dengan mengukur performa agen cerdas hasil pelatihan arsitektur DRL untuk memberikan waktu tunggu paling kecil di persimpangan bersinyal.
6. Pengambilan kesimpulan, tahapan pengambilan kesimpulan dari data hasil pengujian yang sudah dilakukan untuk menarik kesimpulan dari penelitian.

4.9 Teknik Analisis Data

Teknik analisis dan pengolahan data yang dilakukan adalah dengan cara sebagai berikut:

1. Restorasi gambar untuk meningkatkan kualitas pada gambar dengan cahaya kurang (*low light*), menghilangkan silau (*glare*) untuk gambar kelebihan cahaya, menghilangkan noise dan inpainting untuk kondisi gambar hujan dan berkabut. Seluruh restorsai gambar dilakukan menggunakan arsitektur *image prior*. Arsitektur yang dikembangkan dibandingkan kecepatannya dengan *image prior* biasa atau *image restoration* menggunakan CNN.

2. Melakukan analisis terhadap *image prior* yang dihasilkan dengan membandingkan hasil *image prior* dengan anotasi per pixel yang telah disediakan oleh dataset
3. Melatih agen cerdas menggunakan *Deep Reinforcement Learning* dengan input berupa matriks (representasi gambar) dari output *image prior*. Hasil optimasi waktu tunggu yang dilakukan oleh agen dibandingkan menggunakan aplikasi simulasi.

4.10 Kebaruan (*Novelty*)

Kebaruan yang diharapkan dari penelitian ini adalah:

1. Deep Reinforcement Learning (DRL) yang memungkinkan perubahan adaptif terhadap waktu sinyal lampu lalu lintas menjadi salah satu novelty pada penelitian ini. DRL dibangun dari dua buah metode. Pertama Deep Convolutional Neural Network yang digunakan untuk melakukan ekstraksi fitur dari input sensorik (*machine crafted feature*) berupa kamera. Kedua Reinforcement Learning yang memanfaatkan agen cerdas untuk melakukan aksi yaitu mengganti sinyal lampu lalu lintas, untuk mendapatkan reward berupa hasil optimasi terbaik yang diinginkan oleh sistem.
2. Penelitian ini menambahkan kemampuan kamera agar dapat melihat lebih baik di segala kondisi cahaya pada sistem end-to-end yang memanfaatkan *Deep Image Prior*. Untuk mengatasi kelemahan dari sistem end-to-end yang memanfaatkan input langsung dari sistem sensorik, dalam hal ini kamera, yang sangat bergantung pada kondisi cahaya lingkungan sekitar.

DAFTAR PUSTAKA

- Abdelgawad, H. *et al.* (2015) 'Assessment of self-learning adaptive traffic signal control on congested urban areas: Independent versus coordinated perspectives', *Canadian Journal of Civil Engineering*, 42(6), pp. 353–366. Available at: <https://doi.org/10.1139/cjce-2014-0503>.
- Akhtar, M. and Moridpour, S. (2021) 'A Review of Traffic Congestion Prediction Using Artificial Intelligence', *Journal of Advanced Transportation*, 2021. Available at: <https://doi.org/10.1155/2021/8878011>.
- Ali, M.S. *et al.* (2014) 'Estimation of traffic congestion cost - A case study of a major arterial in Karachi', *Procedia Engineering*, 77, pp. 37–44. Available at: <https://doi.org/10.1016/j.proeng.2014.07.030>.
- Allamy, H.K. (2016) 'METHODS TO AVOID OVER-FITTING AND UNDER-FITTING IN SUPERVISED METHODS TO AVOID OVER-FITTING AND UNDER-FITTING IN SUPERVISED MACHINE LEARNING (COMPARATIVE STUDY)', *ComputerScience, Communication & Instrumentation Devices* [Preprint], (December 2014).
- Araghi, S., Khosravi, A. and Creighton, D. (2015) 'Intelligent cuckoo search optimized traffic signal controllers for multi-intersection network', *Expert Systems with Applications*, 42(9), pp. 4422–4431. Available at: <https://doi.org/10.1016/j.eswa.2015.01.063>.
- Arulkumaran, K. *et al.* (2017) 'Deep reinforcement learning: A brief survey', *IEEE Signal Processing Magazine*, 34(6), pp. 26–38. Available at: <https://doi.org/10.1109/MSP.2017.2743240>.
- Ata, M.M. *et al.* (2018) 'Towards computer vision-based approach for an adaptive traffic control system', *Imaging Science Journal*, 66(7), pp. 419–432. Available at: <https://doi.org/10.1080/13682199.2018.1498624>.
- Bhave, N. *et al.* (2019) 'Smart Signal - Adaptive Traffic Signal Control using Reinforcement Learning and Object Detection', *Proceedings of the 3rd International Conference on I-SMAC IoT in Social, Mobile, Analytics and Cloud, I-SMAC 2019*, pp. 624–628. Available at: <https://doi.org/10.1109/I-SMAC47947.2019.9032589>.
- Bie, Y., Cheng, S. and Liu, Z. (2017) 'Optimization of signal-timing parameters for the intersection with hook turns', *Transport*, 32(2), pp. 233–241. Available at: <https://doi.org/10.3846/16484142.2017.1285813>.
- Bisht, A. *et al.* (2022) 'Indigenous design of a Traffic Light Control system responsive to the local traffic dynamics and priority vehicles', *Computers and Industrial Engineering*, 171(July), p. 108503. Available at: <https://doi.org/10.1016/j.cie.2022.108503>.
- Chen, M., Yu, X. and Liu, Y. (2018) 'PCNN: Deep Convolutional Networks for Short-Term Traffic Congestion Prediction', *IEEE Transactions on Intelligent Transportation Systems*, 19(11), pp. 3550–3559. Available at: <https://doi.org/10.1109/TITS.2018.2835523>.
- Florida, E. *et al.* (2015) 'Data mining for predicting traffic congestion and its application to Spanish data', *Advances in Intelligent Systems and Computing*, 368(June), pp. 341–351. Available at: <https://doi.org/10.1007/978-3-319->

- 19719-7_30.
- Frank, A., Khamis Al Aamri, Y.S. and Zayegh, A. (2019) ‘IoT based smart traffic density control using image processing’, *2019 4th MEC International Conference on Big Data and Smart City, ICBDSC 2019*, pp. 1–4. Available at: <https://doi.org/10.1109/ICBDSC.2019.8645568>.
- Gao, J. *et al.* (2017) ‘Adaptive Traffic Signal Control: Deep Reinforcement Learning Algorithm with Experience Replay and Target Network’, pp. 1–10. Available at: <http://arxiv.org/abs/1705.02755>.
- Garg, D., Chli, M. and Vogiatzis, G. (2022) ‘Fully-Autonomous, Vision-based Traffic Signal Control: from Simulation to Reality’, *Proceedings of the International Joint Conference on Autonomous Agents and Multiagent Systems, AAMAS*, 1, pp. 454–462.
- Genders, W. and Razavi, S. (2016) ‘Using a Deep Reinforcement Learning Agent for Traffic Signal Control’, pp. 1–9. Available at: <http://arxiv.org/abs/1611.01142>.
- Gonzalez, R.C. and Woods, R.E. (2018) *Digital Image Processing*. 4th edn. New York: Pearson.
- Gorodokin, V. *et al.* (2021) ‘Optimization of adaptive traffic light control modes based on machine vision’, *Transportation Research Procedia*, 57, pp. 241–249. Available at: <https://doi.org/10.1016/j.trpro.2021.09.047>.
- Gültekin Çetiner, B., Sari, M. and Borat, O. (2010) ‘A neural network based traffic-flow prediction model’, *Mathematical and Computational Applications*, 15(2), pp. 269–278. Available at: <https://doi.org/10.3390/mca15020269>.
- Guo, Y. *et al.* (2019) ‘Dynamic identification of urban traffic congestion warning communities in heterogeneous networks’, *Physica A: Statistical Mechanics and its Applications*, 522, pp. 98–111. Available at: <https://doi.org/10.1016/j.physa.2019.01.139>.
- Huang, T.S. (1996) ‘Computer Vision : Evolution and Promise’, in *19th CERN School of Computing*. Geneva: CERN, pp. 21–25.
- Hunt, P.B. *et al.* (1982) ‘THE SCOOT ON-LINE TRAFFIC SIGNAL OPTIMISATION TECHNIQUE’, *Traffic Engineering & Control*, 23(4), pp. 190–192.
- Iftikhar, Z., Dissanayake, P. and Vial, P. (2014) ‘for Multi-track Freeways’, pp. 339–340.
- Jiang, B. and Fei, Y. (2015) ‘Traffic and vehicle speed prediction with neural network and Hidden Markov model in vehicular networks’, *IEEE Intelligent Vehicles Symposium, Proceedings*, 2015-Augus(Iv), pp. 1082–1087. Available at: <https://doi.org/10.1109/IVS.2015.7225828>.
- Jin, J., Ma, X. and Kosonen, I. (2017) ‘An intelligent control system for traffic lights with simulation-based evaluation’, *Control Engineering Practice*, 58(September 2016), pp. 24–33. Available at: <https://doi.org/10.1016/j.conengprac.2016.09.009>.
- Kumar, K., Parida, M. and Katiyar, V.K. (2013) ‘Short Term Traffic Flow Prediction for a Non Urban Highway Using Artificial Neural Network’, *Procedia - Social and Behavioral Sciences*, 104, pp. 755–764. Available at:

- [https://doi.org/10.1016/j.sbspro.2013.11.170.](https://doi.org/10.1016/j.sbspro.2013.11.170)
- Lecun, Y., Bengio, Y. and Hinton, G. (2015) ‘Deep learning’. Available at: <https://doi.org/10.1038/nature14539>.
- Li, J., Zhang, Y. and Chen, Y. (2016) ‘A Self-Adaptive Traffic Light Control System Based on Speed of Vehicles’, *Proceedings - 2016 IEEE International Conference on Software Quality, Reliability and Security-Companion, QRS-C 2016*, pp. 382–388. Available at: <https://doi.org/10.1109/QRS-C.2016.58>.
- Li, L., Lv, Y. and Wang, F.Y. (2016) ‘Traffic signal timing via deep reinforcement learning’, *IEEE/CAA Journal of Automatica Sinica*, 3(3), pp. 247–254. Available at: <https://doi.org/10.1109/JAS.2016.7508798>.
- Liang, X. et al. (2019) ‘A Deep Reinforcement Learning Network for Traffic Light Cycle Control’, *IEEE Transactions on Vehicular Technology*, 68(2), pp. 1243–1253. Available at: <https://doi.org/10.1109/TVT.2018.2890726>.
- Manandhar, B. and Joshi, B. (2018) ‘Adaptive Traffic Light Control with Statistical Multiplexing Technique and Particle Swarm Optimization in Smart Cities’, *Proceedings on 2018 IEEE 3rd International Conference on Computing, Communication and Security, ICCCS 2018*, pp. 210–217. Available at: <https://doi.org/10.1109/CCCS.2018.8586845>.
- More, R. et al. (2017) ‘Road traffic prediction and congestion control using Artificial Neural Networks’, *International Conference on Computing, Analytics and Security Trends, CAST 2016*, pp. 52–57. Available at: <https://doi.org/10.1109/CAST.2016.7914939>.
- Mousavi, S.S., Schukat, M. and Howley, E. (2017) ‘Traffic light control using deep policy-gradient and value-function-based reinforcement learning’, *IET Intelligent Transport Systems*, 11(7), pp. 417–423. Available at: <https://doi.org/10.1049/iet-its.2017.0153>.
- Muhammad Fakhurifqi, R.W. (2013) ‘Perbandingan Algoritma Nearest Neighbour, C4.5 dan LVQ untuk Klasifikasi Kemampuan Mahasiswa’, *Indonesian Journal of Computing and Cybernetics Systems*, 7(July), pp. 145–154. Available at: <https://doi.org/ISSN: 1978-1520>.
- Osman, T. et al. (2017) ‘Intelligent traffic management system for cross section of roads using computer vision’, *2017 IEEE 7th Annual Computing and Communication Workshop and Conference, CCWC 2017* [Preprint]. Available at: <https://doi.org/10.1109/CCWC.2017.7868350>.
- Polson, N.G. and Sokolov, V.O. (2017) ‘Deep learning for short-term traffic flow prediction’, *Transportation Research Part C: Emerging Technologies*, 79, pp. 1–17. Available at: <https://doi.org/10.1016/j.trc.2017.02.024>.
- Putra, R.G. et al. (2021) ‘Adaptive Traffic Light Controller Based on Congestion Detection Using Computer Vision’, *Journal of Physics: Conference Series*, 1845(1). Available at: <https://doi.org/10.1088/1742-6596/1845/1/012047>.
- Qadri, S.S.S.M., Gökçe, M.A. and Öner, E. (2020) ‘State-of-art review of traffic signal control methods: challenges and opportunities’, *European Transport Research Review*, 12(1), pp. 1–23. Available at: <https://doi.org/10.1186/s12544-020-00439-1>.
- Qi, Y. and Ishak, S. (2014) ‘A Hidden Markov Model for short term prediction of traffic conditions on freeways’, *Transportation Research Part C: Emerging*

- Technologies*, 43, pp. 95–111. Available at:
<https://doi.org/10.1016/j.trc.2014.02.007>.
- Rasheed, F. *et al.* (2020) ‘Deep Reinforcement Learning for Traffic Signal Control: A Review’, *IEEE Access*, 8, pp. 208016–208044. Available at:
<https://doi.org/10.1109/ACCESS.2020.3034141>.
- Rasheed, F., Yau, K.L.A. and Low, Y.C. (2020) ‘Deep reinforcement learning for traffic signal control under disturbances: A case study on Sunway city, Malaysia’, *Future Generation Computer Systems*, 109, pp. 431–445. Available at: <https://doi.org/10.1016/j.future.2020.03.065>.
- Sahal, M. *et al.* (2023) ‘Smart Traffic Light Using YOLO Based Camera with Deep Reinforcement Learning Algorithm’, *JAREE (Journal on ...*, 7(1), pp. 13–19. Available at:
<http://jaree.its.ac.id/index.php/jaree/article/view/335%0Ahttp://jaree.its.ac.id/index.php/jaree/article/viewFile/335/143>.
- Santoso, B., Azis, A.I.S. and Bode, A. (2020) ‘Pengendalian Lampu Lalu Lintas Cerdas di Persimpangan Empat Ruas yang Kompleks Menggunakan Algoritma Adaptive Neuro Fuzzy Inference System’, *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 6(1), p. 29. Available at:
<https://doi.org/10.26418/jp.v6i1.37311>.
- Sims, A.G. and Dobinson, K.W. (1980) ‘The Sydney Coordinated Adaptive Traffic (SCAT) System Philosophy and Benefits’, *IEEE Transactions on Vehicular Technology*, 29(2), pp. 130–137. Available at:
<https://doi.org/10.1109/T-VT.1980.23833>.
- de Souza, A.M. *et al.* (2017) ‘Traffic management systems: A classification, review, challenges, and future perspectives’, *International Journal of Distributed Sensor Networks*, 13(4). Available at:
<https://doi.org/10.1177/1550147716683612>.
- Sutton, R.S. and Barto, A.G. (2015) *Reinforcement Learning: An Introduction*. MIT Press. Available at: <https://doi.org/10.4018/978-1-60960-165-2.ch004>.
- Tan, K.L. *et al.* (2019) ‘Deep reinforcement learning for adaptive traffic signal control’, *ASME 2019 Dynamic Systems and Control Conference, DSCC 2019*, 3. Available at: <https://doi.org/10.1115/DSCC2019-9076>.
- Ulyanov, D., Vedaldi, A. and Lempitsky, V. (2020) ‘Deep Image Prior’, *International Journal of Computer Vision*, 128(7), pp. 1867–1888. Available at: <https://doi.org/10.1007/s11263-020-01303-4>.
- Vidhate, D.A. and Kulkarni, P. (2017) ‘Cooperative multi-agent reinforcement learning models (CMRLM) for intelligent traffic control’, *Proceedings - 1st International Conference on Intelligent Systems and Information Management, ICISIM 2017*, 2017-Janua, pp. 325–331. Available at:
<https://doi.org/10.1109/ICISIM.2017.8122193>.
- Wan, C.H. and Hwang, M.C. (2018) ‘Value-based deep reinforcement learning for adaptive isolated intersection signal control’, *IET Intelligent Transport Systems*, 12(9), pp. 1005–1010. Available at: <https://doi.org/10.1049/iet-its.2018.5170>.
- Wang, S. *et al.* (2019) ‘Deep reinforcement learning-based traffic signal control using high-resolution event-based data’, *Entropy*, 21(8), pp. 1–16. Available

- at: <https://doi.org/10.3390/e21080744>.
- Wang, X. *et al.* (2015) ‘Short Term Prediction of Freeway Exiting Volume Based on SVM and KNN’, *International Journal of Transportation Science and Technology*, 4(3), pp. 337–352. Available at: <https://doi.org/10.1260/2046-0430.4.3.337>.
- Xu, D., Peng, P. and He, D. (2021) ‘Short-term traffic flow prediction with missing data’, *Gaojishu Tongxin/Chinese High Technology Letters*, 31(9), pp. 934–941. Available at: <https://doi.org/10.3772/j.issn.1002-0470.2021.09.004>.
- Zaatouri, K. and Ezzedine, T. (2018) ‘A Self-Adaptive Traffic Light Control System Based on YOLO’, *2018 International Conference on Internet of Things, Embedded Systems and Communications, IINTEC 2018 - Proceedings*, pp. 16–19. Available at: <https://doi.org/10.1109/IINTEC.2018.8695293>.
- Zang, X. *et al.* (2020) ‘MetaLight: Value-based meta-reinforcement learning for traffic signal control’, *AAAI 2020 - 34th AAAI Conference on Artificial Intelligence*, pp. 1153–1160. Available at: <https://doi.org/10.1609/aaai.v34i01.5467>.
- Zheng, Y. *et al.* (2018) ‘Real-time predication and navigation on traffic congestion model with equilibrium Markov chain’, *International Journal of Distributed Sensor Networks*, 14(4). Available at: <https://doi.org/10.1177/1550147718769784>.