

BAB I

PENDAHULUAN

Pengelolaan lalu lintas yang efisien menjadi salah satu tantangan utama dalam sistem transportasi perkotaan. Peningkatan jumlah kendaraan yang pesat di kota-kota besar sering kali menyebabkan kemacetan lalu lintas yang memengaruhi mobilitas masyarakat, meningkatkan konsumsi bahan bakar, serta menciptakan dampak negatif terhadap kualitas udara. Salah satu solusi yang telah diterapkan dalam mengatasi kemacetan adalah sistem pengendalian sinyal lalu lintas adaptif yang dapat menyesuaikan waktu lampu hijau berdasarkan kondisi lalu lintas secara *real-time*. Namun, meskipun banyak metode telah dikembangkan, masih banyak tantangan dalam mengoptimalkan pengendalian sinyal lalu lintas secara otomatis dan efisien, terutama dalam kondisi lalu lintas yang dinamis dan padat.

Bab I berisikan pendahuluan yang membahas tentang latar belakang penelitian, rumusan masalah, tujuan penelitian, manfaat penelitian dan luaran dari penelitian. Pendahuluan yang disampaikan pada bab ini menjelaskan secara rinci gambaran umum terkait penelitian yang akan dilakukan.

1.1 Latar Belakang Masalah

Efisiensi jaringan transportasi perkotaan sangat penting bagi kegiatan ekonomi dan kualitas hidup di kota-kota modern (Allirani & Verma, 2025; Lieberthal dkk., 2024; Phan dkk., 2025). Namun, laju urbanisasi yang tidak seimbang dengan pengembangan infrastruktur yang memadai telah mengakibatkan masalah kemacetan lalu lintas yang parah (Pandey dkk., 2025; Sun dkk., 2020). Kemacetan bukan lagi sekadar masalah ketidaknyamanan, melainkan sebuah isu kompleks dengan dampak yang luas. Dampak ini mencakup pemborosan waktu produktif (Khoirunni'mah & Brilianti, 2025), peningkatan biaya logistik, serta penurunan kualitas udara akibat emisi kendaraan yang terperangkap dalam antrean panjang (Zhao et al., 2024). Titik kunci dari jaringan transportasi perkotaan adalah persimpangan berlampu lalu lintas, yang pengelolaannya menjadi faktor penting untuk mengurangi kemacetan (Eom & Kim, 2020; Qadri dkk., 2020). Kegagalan

dalam mengelola titik-titik ini secara efektif akan menyebabkan dampak berantai yang mengganggu seluruh jaringan jalan (Terra dkk., 2021).

Secara historis, pengendalian sinyal lalu lintas mengandalkan pendekatan konvensional, seperti strategi waktu tetap (*fixed-time*) dan teraktuasi (*actuated*). Sistem waktu tetap, meskipun sederhana dan dapat diprediksi, pada dasarnya bersifat statis. Sistem ini tidak mampu merespons perubahan volume lalu lintas yang terjadi secara *real-time* (J. Gao dkk., 2017; R. Gao dkk., 2020). Sistem teraktuasi menawarkan kemampuan adaptasi yang lebih baik dengan menggunakan detektor untuk memperpanjang fase hijau. Namun, kemampuannya terbatas pada kondisi lokal dan seringkali kurang optimal untuk aliran lalu lintas secara menyeluruh (Rasheed dkk., 2020a). Keterbatasan sistem-sistem ini untuk beradaptasi dengan sifat lalu lintas yang dinamis dan stokastik menjadi penyebab utama inefisiensi di persimpangan perkotaan modern (Cederle dkk., 2025).

Menanggapi keterbatasan ini, paradigma *adaptive traffic signal control* (ATSC) yang didukung oleh Kecerdasan Buatan (AI) telah menjadi salah satu arah penelitian utama. Di antara berbagai teknik AI, *deep reinforcement learning* (DRL) telah menunjukkan potensi yang besar dan menjadi metode termutakhir (*state-of-the-art*) dalam pengembangan ATSC (Schumacher dkk., 2023; Xiao dkk., 2025; Zheng dkk., 2022). DRL menawarkan pendekatan berbasis data yang memungkinkan agen (pengontrol sinyal) untuk mempelajari kebijakan kontrol yang optimal secara mandiri melalui interaksi langsung dengan lingkungannya (lalu lintas). Kemampuannya untuk memproses data berdimensi tinggi dari sensor dan belajar dari pengalaman tanpa memerlukan model lalu lintas yang eksplisit, menjadikannya pendekatan yang sangat cocok untuk menangani masalah pengambilan keputusan sekuensial yang kompleks dalam manajemen lalu lintas (Mnih dkk., 2015). Pendekatan DRL *single-objective* awal banyak menggunakan DQN standar (Gao dkk., 2017; Muresan dkk., 2019), sementara penelitian DRL lanjutan mengadopsi DDQN, dan arsitektur D3QN untuk meningkatkan stabilitas dan efisiensi (Cai & Wei, 2024; Phan dkk., 2025).

Meskipun DRL memiliki potensi besar, implementasi awalnya dalam ATSC seringkali fokusnya terbatas. Sebagian besar penelitian awal hanya fokus pada

optimalisasi satu tujuan (*single-objective*), biasanya metrik efisiensi operasional seperti meminimalkan waktu tunda rata-rata atau panjang antrean (D. H. Kim dkk., 2020; Zhao dkk., 2024). Pendekatan ini tidak mempertimbangkan bahwa manajemen lalu lintas modern pada dasarnya adalah masalah multi-objektif (Fang dkk., 2023; Gong dkk., 2020; G. Zhang dkk., 2024). Kebijakan pengendalian sinyal yang terlalu menitikberatkan pada pengurangan panjang antrean dapat berdampak pada peningkatan konsumsi bahan bakar dan emisi kendaraan, terutama apabila kebijakan tersebut memicu frekuensi berhenti dan berjalan kembali (*stop-and-go*) yang lebih tinggi (Gong dkk., 2020). Dengan demikian, diperlukan pengembangan kerangka kerja DRL yang secara eksplisit mampu mengakomodasi dan menyeimbangkan tujuan-tujuan pengendalian lalu lintas yang berpotensi saling bertentangan, terutama antara peningkatan efisiensi operasional dan pencapaian keberlanjutan lingkungan (Jia & Ji, 2025; Mirbakhsh & Azizi, 2024; G. Zhang dkk., 2024). Pendekatan curriculum learning juga telah dicoba untuk mengatasi tantangan *single-objective* (Zheng dkk., 2022).

Lebih lanjut, sebagian besar penelitian yang telah dilakukan, termasuk pendekatan yang berorientasi multi-objektif, masih cenderung berfokus pada skenario persimpangan tunggal. Padahal, optimalisasi kinerja pada satu persimpangan secara terisolasi tidak selalu menghasilkan peningkatan kinerja jaringan secara keseluruhan, bahkan berpotensi memindahkan beban kemacetan ke persimpangan terdekat. Kondisi ini dikenal sebagai permasalahan suboptimalitas lokal atau *local selfishness* (Zheng dkk., 2022). Oleh karena itu, peningkatan efisiensi jaringan lalu lintas secara menyeluruh memerlukan mekanisme koordinasi yang efektif antar persimpangan (Wong dkk., 2023). Kebutuhan tersebut mendorong pergeseran pendekatan dari DRL berbasis agen tunggal menuju *multi-agent reinforcement learning* (MARL) (Li dkk., 2021). Dalam kerangka MARL, setiap persimpangan dimodelkan sebagai agen otonom yang tidak hanya belajar mengoptimalkan keputusan lokalnya, tetapi juga perlu mempertimbangkan dampak keputusannya terhadap kondisi persimpangan lain dalam jaringan (Zhou dkk., 2022). Namun demikian, salah satu tantangan utama dalam penerapan MARL adalah perancangan mekanisme komunikasi dan koordinasi yang efektif, sehingga

setiap agen dapat bertukar informasi yang relevan dan menghasilkan keputusan pengendalian sinyal yang selaras dengan tujuan optimasi jaringan secara keseluruhan (Fang dkk., 2023; Wong dkk., 2023).

Selain tantangan konseptual, terdapat pula tantangan teknis pada algoritma DRL itu sendiri. Algoritma dasar seperti *deep Q-network* (DQN) diketahui memiliki bias estimasi nilai yang berlebihan (*value overestimation bias*), yang dapat menyebabkan ketidakstabilan selama pelatihan dan konvergensi ke kebijakan yang sub-optimal (Anschel dkk., 2017; Ly dkk., 2022). Selain itu, melatih agen pada fungsi *reward* yang kompleks, seperti pada kasus multi-objektif, bisa jadi lebih sulit dan tidak efisien. Agen sering mengalami kesulitan pada tahap awal eksplorasi (masalah *cold-start*) atau bahkan menemukan "jalan pintas" untuk mengeksploitasi fungsi *reward* tanpa benar-benar memecahkan masalah yang dimaksud (*reward hacking*) (Z. Chu dkk., 2023; Wei dkk., 2025). Hal ini menunjukkan adanya kebutuhan akan arsitektur DRL yang lebih stabil dan strategi pelatihan yang lebih efektif untuk memandu proses pembelajaran.

Dalam konteks Indonesia, pengendalian lalu lintas adaptif mulai berkembang melalui penerapan Area Traffic Control System (ATCS) di berbagai daerah. ATCS digunakan untuk mengoordinasikan pengaturan lampu lalu lintas pada beberapa persimpangan dalam satu kawasan, dengan tujuan mengoptimalkan kinerja jaringan jalan melalui pengaturan sinyal secara terpusat dan berbasis teknologi informasi. Beberapa pemerintah daerah telah mengembangkan ATCS untuk memantau kondisi lalu lintas, mengatur siklus lampu lalu lintas, memberikan prioritas pada kondisi tertentu, serta menyediakan data lalu lintas sebagai dasar evaluasi operasional. Penerapan ATCS di Indonesia menunjukkan bahwa kebutuhan terhadap sistem pengendalian sinyal yang lebih responsif semakin penting, karena pengaturan lampu lalu lintas dengan waktu siklus tetap dinilai kurang efektif dalam menghadapi volume kendaraan yang berubah-ubah.

Namun, sebagian implementasi ATCS di Indonesia masih berfokus pada pemantauan, koordinasi, dan pengaturan sinyal berbasis pusat kendali, sehingga peluang pengembangan menuju sistem yang lebih adaptif, otonom, dan berbasis pembelajaran mesin masih terbuka. Beberapa daerah telah mulai menerapkan

teknologi sinyal yang dapat menyesuaikan waktu siklus secara otomatis berdasarkan volume kendaraan, tetapi pengembangan pendekatan berbasis deep reinforcement learning dan multi-agent coordination masih perlu diteliti lebih lanjut agar sistem mampu belajar dari dinamika lalu lintas dan menghasilkan keputusan sinyal yang lebih optimal.

Dengan demikian, penelitian ini diposisikan untuk mengatasi celah-celah penelitian yang saling terkait ini. Latar belakang masalah ini menggarisbawahi kebutuhan akan sebuah pendekatan holistik yang tidak hanya mampu menyeimbangkan berbagai tujuan di tingkat persimpangan tunggal, tetapi juga dapat diskalakan untuk mencapai koordinasi yang efektif di tingkat jaringan. Oleh karena itu, penelitian ini akan mengusulkan, mengembangkan, dan mengevaluasi serangkaian kerangka kerja DRL canggih yang secara sistematis mengatasi tantangan stabilitas algoritma, kompleksitas *reward* multi-objektif, dan koordinasi multi-agen dalam sistem pengendalian sinyal lalu lintas.

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang telah diuraikan, dapat diidentifikasi beberapa permasalahan mendasar dalam bidang pengendalian sinyal lalu lintas adaptif yang menjadi fokus dalam penelitian ini. Permasalahan-permasalahan tersebut adalah sebagai berikut:

1. Ketidakmampuan sistem konvensional: Sistem pengendalian sinyal lalu lintas konvensional, seperti metode waktu tetap (*fixed-time*) dan teraktuasi (*actuated*), tidak mampu beradaptasi secara efektif terhadap fluktuasi volume lalu lintas yang bersifat dinamis dan stokastik, sehingga seringkali menyebabkan inefisiensi, antrean panjang, dan waktu tunda yang tidak perlu di persimpangan perkotaan (Gao et al., 2017; Rasheed et al., 2020).
2. Keterbatasan optimisasi tujuan tunggal (*single-objective*): Sebagian besar penelitian awal yang menerapkan *deep reinforcement learning* (DRL) untuk ATSC memiliki fokus yang terlalu sempit pada optimalisasi satu metrik saja, yaitu efisiensi operasional (misalnya, meminimalkan waktu tunda). Pendekatan ini mengabaikan aspek-aspek krusial lainnya dari manajemen lalu lintas modern, terutama keberlanjutan lingkungan, yang seringkali

memiliki tujuan yang bertentangan dengan efisiensi murni (Fang et al., 2023; Schumacher et al., 2023).

3. Instabilitas algoritma DRL standar: Algoritma DRL fundamental seperti *Deep Q-Network* (DQN) diketahui rentan terhadap *overestimation bias*, yang dapat menyebabkan proses pelatihan yang tidak stabil, konvergensi yang lambat, dan kegagalan dalam menemukan kebijakan kontrol yang benar-benar optimal, terutama dalam lingkungan lalu lintas yang kompleks (Phan et al., 2025; Cai & Wei, 2024).
4. Tantangan pelatihan pada *reward* yang kompleks: Implementasi fungsi *reward* multi-objektif yang kompleks dapat menyulitkan proses pembelajaran agen. Agen seringkali mengalami kesulitan pada tahap awal eksplorasi (masalah *cold-start*) atau terjebak pada optima lokal dengan hanya mengoptimalkan salah satu komponen *reward*, sehingga gagal mencapai keseimbangan yang holistik (Freitag et al., 2025; Ibrahim et al., 2024).
5. Masalah skalabilitas dan koordinasi multi-agen: Pengoptimalan sinyal pada satu persimpangan secara terisolasi dapat menimbulkan suboptimalitas lokal, yaitu ketika keputusan yang optimal secara lokal justru menurunkan kinerja persimpangan tetangga. Oleh karena itu, efisiensi jaringan memerlukan koordinasi antar-persimpangan. Namun, perancangan mekanisme komunikasi dan koordinasi yang efektif dalam kerangka *multi-agent reinforcement learning* (MARL) masih menjadi tantangan penelitian yang aktif (Li et al., 2022; Zhou et al., 2025).

Identifikasi masalah-masalah ini menegaskan adanya kebutuhan mendesak untuk mengembangkan kerangka kerja ATSC yang tidak hanya cerdas dan adaptif, tetapi juga multi-objektif, stabil, efisien dalam pelatihan, dan dapat diskalakan untuk aplikasi jaringan yang lebih besar.

1.3 Perumusan Masalah

Berdasarkan identifikasi masalah yang telah dipaparkan sebelumnya, terlihat adanya kesenjangan yang signifikan antara kemampuan sistem pengendalian lalu lintas saat ini dengan tuntutan mobilitas perkotaan modern yang kompleks dan

multi-objektif. Keterbatasan konseptual dan teknis dari pendekatan yang ada, mulai dari sistem konvensional hingga DRL generasi awal, menjadi dasar untuk merumuskan masalah utama yang akan dijawab dalam penelitian ini. Dengan demikian, perumusan masalah dalam penelitian ini dapat dirinci ke dalam pertanyaan-pertanyaan penelitian berikut:

1. Bagaimana merancang sebuah kerangka kerja *deep reinforcement learning* (DRL) yang mampu secara simultan mengoptimalkan tujuan-tujuan yang saling bertentangan (*conflicting objectives*) di persimpangan lalu lintas, yaitu efisiensi operasional dan keberlanjutan lingkungan?
2. Bagaimana mengintegrasikan arsitektur DRL yang canggih (*state-of-the-art*) dengan strategi pelatihan yang cerdas untuk mengatasi masalah ketidakstabilan konvergensi dan inefisiensi pembelajaran saat dihadapkan pada fungsi *reward* yang kompleks?
3. Bagaimana kerangka kerja DRL yang telah dikembangkan untuk persimpangan tunggal dapat diperluas dan diskalakan menjadi sistem multi-agen (*multi-agent reinforcement learning*-MARL) yang memungkinkan koordinasi efektif antar beberapa persimpangan untuk meningkatkan kinerja lalu lintas di tingkat jaringan?
4. Bagaimana validitas dan efektivitas dari keseluruhan kerangka kerja yang diusulkan (baik agen-tunggal maupun multi-agen) dapat dievaluasi dan dibuktikan secara kuantitatif jika dibandingkan dengan metode-metode *baseline* konvensional dan DRL standar?

1.4 Tujuan Penelitian

Berdasarkan perumusan masalah yang telah diuraikan, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi solusi komprehensif untuk pengendalian sinyal lalu lintas adaptif (ATSC) berbasis *deep reinforcement learning* (DRL). Secara spesifik, tujuan-tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

1. Merancang dan mengembangkan sebuah kerangka kerja *multi-objective deep reinforcement learning* (MODRL) untuk ATSC pada persimpangan

tunggal yang mampu secara simultan mengoptimalkan dua tujuan utama: efisiensi operasional (diukur dari metrik seperti waktu tunda dan panjang antrean) dan keberlanjutan lingkungan (diukur dari metrik proksi seperti konsumsi bahan bakar).

2. Mengintegrasikan arsitektur DRL canggih, yaitu *dueling double deep Q-network* (D3QN), dengan strategi pelatihan *curriculum learning* (CL). Tujuan integrasi ini adalah untuk meningkatkan stabilitas, mempercepat konvergensi, dan meningkatkan efektivitas pembelajaran agen dalam menavigasi lanskap *reward* multi-objektif yang kompleks.
3. Mengembangkan ekstensi dari kerangka kerja yang telah dibuat menjadi sebuah sistem MARL yang terkoordinasi. Tujuan ini berfokus pada perancangan mekanisme yang memungkinkan beberapa agen (pengontrol sinyal) di persimpangan yang berbeda untuk bekerja sama demi meningkatkan kinerja lalu lintas di tingkat jaringan.
4. Mengevaluasi dan menganalisis secara kuantitatif kinerja dari kerangka kerja yang diusulkan (baik untuk skenario agen-tunggal maupun multi-agen). Evaluasi ini dilakukan melalui simulasi di bawah berbagai kondisi lalu lintas dan membandingkan hasilnya dengan metode-metode *baseline*, termasuk pengendali konvensional dan pendekatan DRL standar.

Pencapaian tujuan-tujuan ini diharapkan dapat menghasilkan sebuah solusi ATSC yang tidak hanya unggul dalam performa, tetapi juga lebih robust, holistik, dan dapat digeneralisasi untuk aplikasi di dunia nyata.

1.5 Kebaruan (*Novelty*)

Kebaruan utama dari penelitian ini tidak terletak pada penemuan satu algoritma tunggal yang terisolasi, melainkan pada pengembangan dan validasi sebuah kerangka kerja holistik yang secara sinergis mengintegrasikan beberapa metodologi canggih untuk memecahkan tantangan multifaset dalam sistem pengendalian sinyal lalu lintas adaptif (ATSC). Berdasarkan tinjauan literatur yang komprehensif, kebaruan penelitian ini dapat dirinci ke dalam poin-poin berikut:

1. Sinergi antara strategi pelatihan dan arsitektur agen untuk optimisasi multi-objektif.

Sementara penelitian sebelumnya telah mengeksplorasi *multi-objective deep reinforcement learning* (MODRL), arsitektur DRL yang stabil seperti D3QN, dan *curriculum learning* (CL) secara terpisah, penelitian ini adalah salah satu yang pertama kali menginvestigasi dan membuktikan sinergi kritis di antara ketiganya dalam domain ATSC. Kebaruannya terletak pada hipotesis bahwa stabilitas arsitektur D3QN saja tidak cukup untuk menangani lanskap *reward* multi-objektif yang kompleks secara efisien dari awal. Penelitian ini menunjukkan bahwa *curriculum learning* berfungsi sebagai faktor pemungkin yang krusial (*critical enabler*) yang memandu agen untuk menemukan kebijakan yang seimbang secara superior, sebuah interaksi metodologis yang belum dieksplorasi secara mendalam dalam literatur ATSC sebelumnya.

2. Kerangka kerja yang dapat diskalakan dari agen-tunggal multi-objektif ke multi-agen terkoordinasi.

Penelitian ini menyajikan sebuah alur pengembangan yang logis, dimulai dari perancangan kerangka kerja agen-tunggal yang dioptimalkan untuk masalah multi-objektif di satu persimpangan, hingga ekstensinya menjadi sebuah sistem *multi-agent deep reinforcement learning* (MADRL) yang terkoordinasi. Kebaruannya terletak pada desain mekanisme koordinasi yang memungkinkan agen-agen yang telah dilatih dengan pemahaman multi-objektif untuk bekerja sama secara efektif di tingkat jaringan, mengatasi masalah suboptimalitas lokal (*local selfishness*) yang seringkali menjadi keterbatasan pada penelitian yang hanya berfokus pada satu tingkat (agen-tunggal atau multi-agen) saja.

3. Validasi empiris melalui studi ablasi yang komprehensif.

Berbeda dengan banyak penelitian yang hanya membandingkan model usulan dengan *baseline* konvensional, penelitian ini menyajikan studi ablasi (*ablation study*) yang mendalam. Dengan secara sistematis menghilangkan setiap komponen inovasi (pendekatan multi-objektif dan *curriculum learning*), memberikan bukti kuantitatif yang kuat bahwa kinerja superior dari kerangka kerja ini adalah hasil langsung dari integrasi

sinergis seluruh komponennya, bukan hanya kontribusi dari satu bagian saja. Validasi semacam ini memberikan pemahaman yang lebih dalam tentang "mengapa" metode yang diusulkan berhasil.

Secara ringkas, kebaruan ini terletak pada perancangan sebuah solusi *end-to-end* yang koheren—mulai dari stabilitas algoritma, strategi pelatihan cerdas, hingga skalabilitas jaringan—untuk masalah ATSC multi-objektif yang kompleks, yang divalidasi melalui serangkaian eksperimen yang dirancang secara teliti.

1.6 Manfaat Penelitian

Penyelesaian penelitian ini diharapkan dapat memberikan serangkaian manfaat yang signifikan, baik bagi komunitas ilmiah maupun bagi para pemangku kepentingan di bidang manajemen transportasi perkotaan. Manfaat-manfaat tersebut dapat diklasifikasikan ke dalam dua kategori utama: manfaat teoretis dan manfaat praktis.

1.6.1 Manfaat Teoretis

1. Pengembangan ilmu di bidang kecerdasan buatan.

Penelitian ini berkontribusi pada pengembangan ilmu di bidang *deep reinforcement learning* (DRL), khususnya dengan menunjukkan bagaimana integrasi sinergis antara arsitektur agen yang canggih (*dueling double DQN*) dan strategi pelatihan cerdas (*curriculum learning*) dapat secara efektif mengatasi masalah optimisasi pada lingkungan yang kompleks dengan fungsi *reward* multi-objektif.

2. Memperkaya literatur ATSC.

Penelitian ini memperkaya literatur di bidang ATSC dengan menyajikan sebuah kerangka kerja holistik. Hasil penelitian memberikan bukti empiris yang kuat mengenai efektivitas pendekatan multi-objektif dalam menyeimbangkan efisiensi dan keberlanjutan, serta menyajikan solusi untuk tantangan stabilitas dan efisiensi pelatihan DRL.

3. Landasan untuk penelitian koordinasi multi-agen.

Dengan mengembangkan ekstensi ke dalam kerangka kerja MADRL, penelitian ini menyediakan landasan dan wawasan baru mengenai desain

mekanisme koordinasi yang dapat diskalakan untuk sistem kontrol terdistribusi, yang dapat menjadi acuan bagi penelitian-penelitian di masa depan.

1.6.2 Manfaat Praktis

1. Peningkatan efisiensi mobilitas perkotaan.

Implementasi dari kerangka kerja yang diusulkan berpotensi untuk secara signifikan mengurangi waktu tunda rata-rata dan panjang antrean di persimpangan, yang secara langsung diterjemahkan menjadi waktu perjalanan yang lebih singkat dan alur lalu lintas yang lebih lancar bagi masyarakat.

2. Kontribusi terhadap pembangunan kota berkelanjutan.

Dengan secara eksplisit mengoptimalkan pengurangan konsumsi bahan bakar, penelitian ini memberikan solusi konkret yang mendukung tujuan pembangunan kota yang lebih hijau dan berkelanjutan (*green city*). Pengurangan emisi kendaraan akan berkontribusi pada peningkatan kualitas udara dan kesehatan masyarakat.

3. Dasar pengembangan sistem transportasi cerdas (ITS).

Kerangka kerja dan algoritma yang dihasilkan dari penelitian ini dapat menjadi cetak biru (*blueprint*) bagi para praktisi dan pengambil kebijakan (misalnya, dinas perhubungan) dalam merancang dan mengimplementasikan sistem transportasi cerdas generasi berikutnya di Indonesia, yang mampu beradaptasi dengan kondisi lalu lintas lokal secara dinamis.

1.7 Pembatasan Masalah

Untuk memastikan bahwa penelitian ini tetap terfokus, mendalam, dan dapat dilaksanakan dalam batasan sumber daya yang tersedia, maka ditetapkan beberapa batasan masalah yang jelas. Batasan-batasan ini tidak mengurangi nilai dari temuan penelitian, melainkan mendefinisikan ruang lingkup di mana hasil dan kesimpulan yang ditarik menjadi valid. Pembatasan masalah dalam penelitian ini adalah sebagai berikut.

1. Lingkungan simulasi.

Seluruh eksperimen, pengembangan, dan evaluasi model dilakukan dalam lingkungan simulasi mikroskopis SUMO (*Simulation of Urban Mobility*). Penelitian ini tidak mencakup tahap implementasi atau pengujian pada perangkat keras (*hardware-in-the-loop*) maupun di persimpangan lalu lintas dunia nyata. Fokusnya adalah pada validasi algoritma dan kerangka kerja dalam lingkungan yang terkontrol.

2. Topologi persimpangan dan jaringan.

Penelitian ini menggunakan model topologi persimpangan yang terstandarisasi, yaitu persimpangan tunggal dengan empat lengan dan jaringan grid untuk skenario multi-agen. Topologi yang lebih kompleks atau tidak beraturan (misalnya, persimpangan dengan lebih dari empat lengan, bundaran, atau geometri asimetris) berada di luar cakupan penelitian ini.

3. Fokus objektif optimisasi.

Tujuan optimisasi dalam kerangka kerja yang diusulkan terbatas pada dua domain utama: efisiensi operasional (waktu tunda, panjang antrean) dan keberlanjutan lingkungan (konsumsi bahan bakar). Aspek-aspek penting lainnya seperti keselamatan lalu lintas (misalnya, analisis potensi konflik kendaraan), kenyamanan pengemudi, atau pergerakan pejalan kaki dan pengendara sepeda tidak secara eksplisit dimodelkan sebagai tujuan optimisasi.

4. Komposisi dan perilaku lalu lintas.

Model simulasi tidak mencakup semua kemungkinan variabilitas lalu lintas dunia nyata. Faktor-faktor seperti kendaraan darurat, perilaku mengemudi yang agresif atau tidak menentu, keberadaan pejalan kaki di penyeberangan, serta kejadian tak terduga seperti kecelakaan atau penutupan jalan tidak diikutsertakan dalam skenario evaluasi.

5. Asumsi komunikasi multi-agen.

Dalam pengembangan kerangka kerja MARL, diasumsikan bahwa saluran komunikasi antar agen (persimpangan) adalah ideal, artinya tidak ada latensi (latency) atau kehilangan data (packet loss). Fokus penelitian ini adalah pada logika koordinasi, bukan pada tantangan rekayasa infrastruktur komunikasi.