

## **BAB II KAJIAN PUSTAKA**

### **2.1 Dasar Teori**

Dalam penelitian ini pengembangan sistem otonom memerlukan machine learning yang lebih baik yang memungkinkan UAV belajar secara independen dari lingkungan sekitarnya. Dengan kemampuan algoritma reinforcement learning dapat mengoptimalkan navigasi secara dinamis berdasarkan lingkungan (Barto, 2021). Berbeda dengan pendekatan konvensional yang mengandalkan pemrograman deterministik, kerangka teori dalam penelitian ini membangun fondasi untuk sistem yang memiliki kapasitas adaptasi dinamis terhadap lingkungan yang sulit diprediksi (Nguyen et al., 2023).

Di penelitian (Haryanti & Fierza, 2024) menunjukkan bahwa transformasi digital menjadi faktor kunci dalam mempercepat adaptasi sistem dan meningkatkan efisiensi operasional di berbagai sektor, terutama di negara berkembang. Transformasi ini mencakup penerapan teknologi cerdas, otomasi, dan integrasi sistem, yang memungkinkan sistem tradisional berkembang menjadi sistem adaptif dan responsif terhadap lingkungan. (Haryanti et al., 2023) memperkenalkan kerangka kerja maturity transformation yang menekankan pentingnya kesiapan aspek teknologi, struktur, dan proses menunjukkan bahwa keberhasilan transformasi sangat bergantung pada integrasi menyeluruh.

Penelitian ini mengembangkan kerangka teori sensor fusion yang berakar pada prinsip biologis, di mana sistem visual manusia mengintegrasikan informasi kedalaman, tekstur, dan struktur spasial secara simultan untuk memahami lingkungan secara menyeluruh (Nugroho et al., 2023). Pendekatan ini diadaptasi ke dalam sistem navigasi UAV dengan menggabungkan data LiDAR dan kameran RGB-D dalam proses pemetaan lingkungan secara hierarkis.

Langkah pertama dalam penelitian ini adalah mengumpulkan data untuk simulasi lingkungan UAV, yang meliputi pemodelan perilaku dinamis UAV dan pengukuran halangan. Kumpulan data yang digunakan dapat berupa akses terbuka, seperti AirSim (Zhong et al., 2021) atau Gazebo (Mengacci et al., 2021), yang menyediakan lingkungan virtual yang realistis untuk pelatihan RL. Data ini

meliputi informasi tentang posisi UAV, kecepatan, jarak tempuh, dan kondisi lingkungan (Hong et al., 2021).

Data citra kedalaman (Depth image) dari kamera RGB-D diproses sebagai grid 2 dimensi dan diubah menjadi vektor fitur numerik untuk digunakan oleh algoritma Reinforcement Learning. Sementara itu, data LiDAR dalam bentuk point cloud dikonversi menjadi jarak polar 360 (Shimada et al., 2022) untuk memberikan informasi spasial mengenai jarak dan keberadaan halangan disekitar UAV.

Setelah pengumpulan data, dilakukan pre-processing untuk memastikan kompatibilitas dengan framework RL, seperti PyTorch atau TensorFlow. Selanjutnya, tahap pelatihan (training) untuk mengoptimalkan navigasi. setelah itu evaluasi dilakukan seperti tingkat keberhasilan penghindaran halangan, waktu tempuh, dan konsumsi energi.

### 2.1.1 Navigasi UAV

Navigasi UAV adalah proses pergerakan dan pengendalian UAV untuk mencapai tujuan tertentu secara mandiri atau dengan campur tangan manusia (Mohsan et al., 2022). Pada **Gambar 2** menunjukkan arsitektur umum sistem UAV, yang terdiri dari platform penerbangan UAV, sensor pencitraan, pengendali jarak jauh, serta komputer sebagai unit pengolah data. UAV membawa berbagai jenis sensor pencitraan, kemudian data hasil akuisisi ditransmisikan ke sistem. Operator manusia menggunakan perangkat kendali untuk mengontrol pergerakan UAV sekaligus memantau transmisi data secara real-time. Selain dikendalikan secara manual, UAV dapat menjalankan tugas secara otonom (G. Zhao et al., 2023).



**Gambar 2** Arsitektur sistem UAV

Dalam Pengumpulan data dengan bantuan UAV memiliki keunggulan kelincahan tinggi, fleksibilitas tinggi, dan biaya rendah. Selain itu, UAV dapat mengumpulkan data dalam jarak dekat dengan sensor. Kombinasi UAV dan IoT memfasilitasi pengumpulan data yang tepat waktu dan efektif, terutama di lingkungan yang kompleks, keras, atau terpencil (Li et al., 2022).

Penelitian yang digunakan oleh (Haq, 2024) mengembangkan sistem area melalui analisis citra udara. Studi tersebut menunjukkan bahwa UAV memiliki potensi besar ketika dikombinasikan dengan kecerdasan buatan, khususnya dalam pengolahan visual untuk mendukung pemantauan otomatis. Namun, penelitian tersebut masih berfokus pada akuisisi dan analisis citra, tanpa membahas kemampuan navigasi otonom.

UAV biasanya memahami lingkungan secara real time berdasarkan sensor seperti lidar, kamera stereo (Jiang et al., 2022). Lidar khususnya memainkan peran penting dalam mengembangkan representasi 3D di daerah sekitar UAV, memungkinkan deteksi akurasi tinggi objek seperti bangunan, pohon, atau hambatan dinamis. Reinforcement Learning memungkinkan UAV untuk secara mandiri memeriksa kebijakan navigasi yang optimal untuk menghindari hambatan dan pada saat yang sama mencapai tujuan mereka (Gao et al., 2024). Sistem RL dilatih menggunakan data sensor untuk menilai keadaan dan untuk memilih jalur yang bebas dari kesalahan (Wei et al., 2022). Teknologi ini memungkinkan UAV untuk beradaptasi dengan lingkungan yang kompleks dan dinamis.

### 2.1.2 Halangan rintangan

Keselamatan terbang UAV sangat bergantung pada kemampuan sistem untuk mendeteksi hambatan di sekitarnya dan mengeksekusi manuver penghindaran secara tepat waktu. Salah satu parameter fundamental dalam sistem penghindaran tabrakan adalah jarak aman (minimum safe distance / separation distance) antara UAV dan objek/obstacle di lingkungan terbang (Karampinis et al., 2024). Jarak ini tidak dapat dianggap konstan secara universal melainkan harus ditentukan berdasarkan sensor, dinamika UAV, dan ketidakpastian lingkungan yang dihadapi.

Dalam berbagai penelitian mengenai persepsi UAV, kemampuan sensor dalam mendeteksi rintangan menjadi faktor utama yang menentukan batas minimal jarak aman. Beberapa studi eksplisit menyebutkan jarak deteksi maksimal sensor yang digunakan. Misalnya, dalam penelitian (Asmoro et al., 2025), sensor LiDAR 3D yang digunakan mampu melakukan deteksi obstacle hingga 100-m, sehingga memungkinkan UAV melakukan perencanaan manuver lebih awal. Rentang deteksi yang sangat panjang ini memberikan buffer yang besar sebelum UAV memasuki zona bahaya, meskipun penelitian tersebut tetap menekankan bahwa jarak aman operasional harus mempertimbangkan dinamika drone dan waktu reaksi sistem.

Sebaliknya, penelitian berbasis kamera RGB saja (Wang et al., 2025) menunjukkan bahwa sistem vision murni memiliki jangkauan deteksi yang jauh lebih pendek, yakni sekitar 8-m dalam kondisi ideal. Jangkauan ini cukup untuk UAV berkecepatan rendah hingga sedang, namun menuntut respons kontrol yang lebih cepat dan strategi navigasi yang lebih konservatif terhadap obstacle karena buffer keselamatan jauh lebih sempit dibandingkan sistem LiDAR. Sedangkan studi lain juga menekankan perbedaan signifikan antar sensor (Kim et al., 2023). Kamera depth atau RGB-D umumnya memiliki effective range antara 0.5-5 m, tergantung pada pencahayaan dan tekstur lingkungan, sehingga sering digunakan untuk navigasi jarak dekat dan pemetaan lokal. Sementara itu, LiDAR 2D/3D kelas ringan (lightweight UAV LiDAR) biasanya memiliki range 20-70 m, cukup untuk deteksi menengah dan pembuatan peta lingkungan secara real-time.

Perbedaan kemampuan sensor-sensor tersebut menunjukkan bahwa jarak deteksi yang dilaporkan dalam penelitian bukanlah “jarak aman final”, melainkan batas fisik persepsi sensor. Dalam sistem penghindaran tabrakan, jarak aman yang sesungguhnya harus dihitung lebih besar dari jarak deteksi efektif sensor, dengan mempertimbangkan latensi pemrosesan, kecepatan UAV, kemampuan manuver, serta ketidakpastian lingkungan. Oleh karena itu, setiap penelitian umumnya menentukan jarak aman yang *sensor-dependent*, bukan universal karena performa persepsi drone sangat bergantung pada karakteristik hardware yang digunakan.

Kemampuan UAV dalam mendeteksi sekeliling dan mengenali rintangan melibatkan tiga tahapan penting yaitu persepsi, pengambilan keputusan, dan kontrol tindakan. Pada tahap persepsi memerlukan pengumpulan data dengan sensor seperti lidar, atau kamera RGB (Y. Zhao et al., 2023). Sangat penting untuk memproses data ini guna memperoleh informasi yang berguna mengenai rintangan. UAV harus memutuskan apa yang harus dilakukan berdasarkan persepsinya terhadap sekelilingnya. Pembelajaran penguatan berguna dalam situasi ini. Saat menghindari tabrakan, UAV belajar membuat keputusan yang akan meningkatkan peluangnya untuk mencapai sasarannya.

UAV harus melakukan tindakan yang dipilih saat pilihan telah dibuat. Untuk memodifikasi lintasan UAV, hal ini memerlukan pengelolaan aktuatornya, termasuk motor dan permukaan kontrolnya (Gryech et al., 2024). Tujuannya adalah untuk mengembangkan UAV yang dapat berfungsi secara efektif dan aman dalam berbagai situasi tanpa memerlukan bantuan manusia. Tuntutan berbagai aplikasi, seperti penyelamatan darurat dan fotografi udara dan menavigasi medan yang menantang seperti kota atau lanskap alam, adalah yang memotivasi penelitian ini (Kanellakis & Nikolakopoulos, 2017). Jaringan saraf dalam sering digunakan dalam komponen pembelajaran penguatan untuk memungkinkan UAV menggeneralisasi pembelajarannya dan menyesuaikan diri dengan pengaturan baru atau yang berubah.

### 2.1.3 Metode/ Teori/ Algoritma (kekurangan metode/teori/algoritma yang lain, dan alasan menggunakan metode tersebut dalam penelitian)

Penelitian ini menggunakan Reinforcement learning (RL) karena kemampuannya untuk melakukan pembelajaran melalui interaksi pasif dengan lingkungan, termasuk situasi yang kompleks. Mengingat bahwa UAV beroperasi dalam tiga dimensi dan sering menghadapi berbagai jenis rintangan, masalah ini dapat diklasifikasikan dalam domain kontrol robotik dan perencanaan jalur cerdas, yang terkait erat dengan pengambilan keputusan dinamis dan persepsi lingkungan (Gugan & Haque, 2023).

RL merupakan pembelajaran mesin yang memungkinkan sebuah agent belajar melalui mekanisme *trial-and-error* dalam lingkungan dinamis. RL diformalkan menggunakan Kerangka Markov Decision Process (MDP), yang terdiri dari *state* (S), *action* (A), *transition probability* (P), *Reward* (R) (Barto, 2021). Pada konteks navigasi UAV, state merepresentasikan informasi posisi UAV, jarak halangan, serta data sensor.

Pada RL, tujuan agent adalah memaksimalkan reward kumulatif dengan mempelajari kebijakan (Policy)  $\pi(a/s)$  yang menentukan tindakan optimal pada setiap keadaan nilai kualitas suatu diukur melalui fungsi  $Q(s,a)$ , yang dihitung berdasarkan persamaan Bellman :

$$Q(s, a) = r + \gamma \max_{a'} Q(s', a') \quad (1)$$

Persamaan ini menjadi dasar bagi algoritma berbasis nilai (value-based), seperti Deep Q-Network (DQN) dan variannya (Chang et al., 2021). RL sangat sesuai untuk navigasi UAV karena tidak membutuhkan model lingkungan secara eksplisit, mampu beradaptasi dalam kondisi tidak pasti, dan dapat belajar pengalaman sensorik secara langsung.

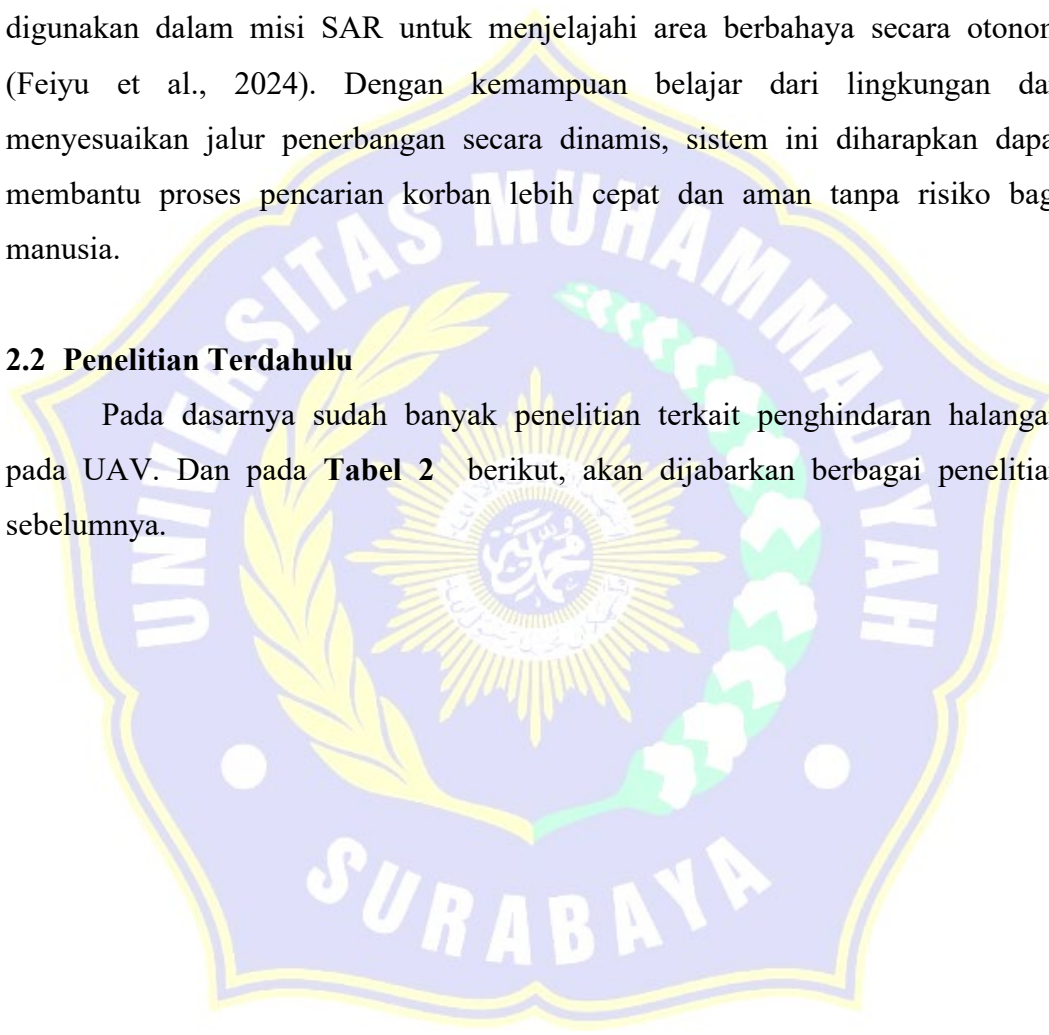
Penghindaran halangan memerlukan sistem navigasi yang mampu merespons perubahan lingkungan secara real-time. Metode tradisional, seperti A\*, DWA (Dynamic Window Approach), atau RRT\*, seringkali tidak memadai karena keterbatasannya dalam menyesuaikan diri dengan perubahan mendadak di lingkungan operasi (Aldao et al., 2022; He et al., 2024). Pendekatan tersebut juga kurang efektif dalam situasi kompleks seperti misi SAR, dimana kondisi medan berubah cepat dan informasi lingkungan sering kali tidak lengkap. Selain tiga

pendekatan tersebut, metode berbasis object detection seperti YOLOX juga banyak digunakan untuk mendeteksi halangan secara visual (Li et al., 2023). Model ini unggul dalam mendeteksi dan melokalisasi objek dengan akurasi tinggi secara real-time, namun fokusnya terbatas pada persepsi visual, bukan pada pengambilan keputusan navigasi.

Untuk mengatasi keterbatasan tersebut, penelitian ini mengusulkan pengembangan sistem UAV berbasis Reinforcement Learning yang dapat digunakan dalam misi SAR untuk menjelajahi area berbahaya secara otonom (Feiyu et al., 2024). Dengan kemampuan belajar dari lingkungan dan menyesuaikan jalur penerbangan secara dinamis, sistem ini diharapkan dapat membantu proses pencarian korban lebih cepat dan aman tanpa risiko bagi manusia.

## 2.2 Penelitian Terdahulu

Pada dasarnya sudah banyak penelitian terkait penghindaran halangan pada UAV. Dan pada **Tabel 2** berikut, akan dijabarkan berbagai penelitian sebelumnya.



**Tabel 2** Penelitian Terdahulu Terkait Penghindaran Halangan

No	Judul	Metode	Hasil	Perbedaan dengan Penelitian Ini	Kekurangan Penelitian
1	A new method for unmanned aerial vehicle path planning in complex environments(He et al., 2024)	Metode A* dan Dynamic Window Approach (DWA).	Panjang jalur lebih pendek 29.1% dan sudut belok lebih kecil, cocok untuk kondisi penerbangan UAV.Mampu menghindari rintangan dinamis secara real-time dengan kecepatan linear meningkat 67.3%.	Menggunakan dua tahap A* (node optimization) dan DWA untuk lintasan lokal. Fokus pada optimasi pergerakan UAV berdasarkan grid map. Tidak membahas integrasi dengan sensor real-time.	Mengandalkan peta lingkungan yang telah diketahui. Belum diuji pada kondisi outdoor nyata. Perubahan lingkungan cepat atau noise sensor tidak dipertimbangkan. Algoritma juga masih bergantung pada discretization grid sehingga presisi lintasan terbatas.
2	Design and Application of a UAV Autonomous Inspection System for High-Voltage Power Transmission Lines (Li et al., 2023)	Metode model YOLOX.	Meningkatkan efisiensi inspeksi dengan waktu inspeksi bersih hanya 5 menit per menara.Model YOLOX yang ditingkatkan meningkatkan metrik mAP0.5,0.95 sebesar 2.22 poin persentase untuk deteksi sarang burung.Sistem mampu melakukan penggantian baterai otomatis dalam waktu <3 menit.	Fokus pada sistem inspeksi (kamera, YOLOX defect detection, sliding mode control). Bukan penelitian perencanaan jalur. Jalur ditentukan berdasarkan struktur tower.	Skema navigasi bersifat terstruktur sehingga tidak fleksibel untuk ruang bebas. Sistem bergantung pada titik-titik inspeksi yang sudah ada. Tidak membahas respons UAV terhadap perubahan mendadak di lingkungan.

No	Judul	Metode	Hasil	Perbedaan dengan Penelitian Ini	Kekurangan Penelitian
3	Dynamic Path Planning of AGV Based on Kinematical Constraint A* Algorithm and Following DWA Fusion Algorithms (Li et al., 2023)	Kinematical Constraint A* dan Dynamic Window Approach (DWA)	Panjang jalur berkurang 3.6%, waktu tempuh berkurang 6.7%, dan jumlah belokan berkurang 25% dibanding metode tradisional. Jalur global lebih pendek dan mulus, sementara jalur lokal mampu menghindari rintangan dinamis.	Fokus pada AGV di lingkungan datar 2D. Menggabungkan A* dengan DWA untuk memperhalus jalur dan meningkatkan kestabilan gerak. Tidak membahas navigasi udara atau manuver ruang 3D.	Lingkungan pengujian statis dan tidak mempertimbangkan halangan yang bergerak. Model dinamika AGV sederhana. Pengujian dilakukan di lingkungan terkontrol, belum dibuktikan pada kondisi lapangan yang kompleks.
4	FPGA-Based CNN for Real-Time UAV Tracking and Detection (Hobden et al., 2022)	Menggunakan CNN terkuantisasi INT8 di FPGA Zynq UltraScale dan algoritma background differencing untuk pelacakan.	Akurasi deteksi 82%, berjalan pada kecepatan frame penuh. Mengurangi penggunaan sumber daya FPGA dengan teknik kuantisasi INT8.	Fokus pada deteksi & tracking UAV menggunakan CNN di FPGA. Bukan perencanaan jalur atau navigasi.	Deteksi bergantung pada kualitas kamera dan kondisi cahaya. Sistem hanya memantau UAV dari luar, tidak mengatur navigasi UAV itu sendiri. Tracking dapat gagal pada objek kecil atau saat latar belakang sangat kompleks.
5	MOD-RRT*: A Sampling-Based Algorithm for Robot Path Planning in Dynamic Environment (Qi et al., 2021)	MOD-RRT* (Multiobjective Dynamic RRT*)	Menghasilkan jalur lebih pendek dan lebih halus dibanding RRT* tradisional. Mampu menghindari rintangan dinamis dengan waktu replanning <300ms.	Fokus pada path planning berbasis sampling, bukan penghindaran halangan UAV modern atau multi-sensor.	Tidak optimal di lingkungan sangat kompleks; kualitas jalur sangat bergantung pada sampling dan kurang adaptif terhadap perubahan cepat.

No	Judul	Metode	Hasil	Perbedaan dengan Penelitian Ini	Kekurangan Penelitian
6	RDT-RRT: Real-time double-tree rapidly-exploring random tree path planning for autonomous vehicles (Yu et al., 2024)	Real-time Double-Tree RRT (RDT-RRT) dengan CNN untuk deteksi tabrakan	Mengurangi 92% dan 88% perubahan kelengkungan kumulatif dalam skenario tanpa rintangan dan dengan rintangan statis. Frekuensi pembaruan meningkat dari 1.1 Hz menjadi 5.5 Hz dengan komputasi paralel.	Ditujukan untuk kendaraan darat, bukan UAV; tidak menggunakan data sensor atau pembelajaran untuk hindar halangan.	Kinerja real-time menurun jika constraint bertambah; koneksi antar-tree sulit dan kurang stabil pada banyak obstacle.
7	Real time object detection using LiDAR and camera fusion for autonomous driving (Liu et al., 2023)	LiDAR-camera fusion dengan Siamese Network dan YOLO-v5	Mencapai mAP 89.26% pada dataset KITTI, unggul dalam deteksi objek kecil dan tertutup. Waktu pemrosesan 0.03 detik per frame.	Fokus pada deteksi objek, bukan navigasi atau path planning UAV.	Akurasi menurun pada cuaca ekstrem dan objek terhalang; pemrosesan data besar menyebabkan beban komputasi tinggi.
8	Visual-SLAM Classical Framework and Key Techniques: A Review (Jia et al., 2022)	Visual-SLAM	Merangkum perkembangan V-SLAM, termasuk sensor visual, odometri visual, optimasi backend, deteksi loop, dan pemetaan. Menyoroti tantangan dan kebutuhan pengembangan di bidang V-SLAM.	Membahas pemetaan & lokalisasi, bukan sistem navigasi penghindaran halangan.	Kurang akurat di kondisi cahaya buruk; proses optimasi berat sehingga real-time sulit; rentan terhadap noise pada single-camera.

No	Judul	Metode	Hasil	Perbedaan dengan Penelitian Ini	Kekurangan Penelitian
9	Quadrotor Path Planning Using A* Search Algorithm and Minimum Snap Trajectory Generation (Hong et al., 2021)	Menggabungkan algoritma pencarian A* dan minimum snap trajectory untuk perencanaan jalur UAV.	Mampu menghasilkan jalur yang bebas tabrakan dan layak secara dinamis dalam waktu nyata. Kecepatan maksimum 3.22 m/s di lingkungan hutan yang padat, dengan tingkat keberhasilan 89.7% dalam simulasi Monte Carlo.	Fokus pada pembuatan trajectory halus (minimum snap) setelah A*. Penelitian menitikberatkan pada kehalusan lintasan, bukan adaptasi terhadap kondisi lingkungan.	A* menghasilkan rute piecewise linear sehingga tetap butuh banyak penyempurnaan. Minimum snap bekerja baik pada jalur yang telah diketahui, namun sensitif terhadap perubahan lingkungan. Tidak diuji dengan obstacle bergerak atau peta dinamis.
10	Efficient Path Planning for Automated Guided Vehicles Using A* Algorithm Incorporating Turning Costs in Search Heuristic (Fransen & van Eekelen, 2023)	A* (Astar) dengan heuristic	Heuristik baru mengurangi iterasi hingga 68% untuk menemukan jalur optimal. Heuristik terbukti monoton dan admissible, cocok untuk berbagai struktur graf. Studi komparatif menunjukkan peningkatan efisiensi dibanding metode lain.	Fokus pada AGV dalam ruang 2D dengan tambahan biaya belokan untuk mengurangi sudut tajam. Tidak relevan untuk lintasan ruang udara 3D.	Algoritma tidak mampu mempertimbangkan kemiringan, ketinggian, dan dinamika 3D. Lingkungan pengujian tetap bersifat grid statis. Pergerakan obstacle tidak dipertimbangkan. Turning cost yang terlalu besar dapat membuat jalur menjadi tidak optimal.

### 2.3 Analisa Kebaruan Penelitian

Tujuan utama dari penelitian ini adalah untuk mengevaluasi algoritma Reinforcement Learning (RL) komparatif untuk navigasi UAV otonom, khususnya dalam konteks penghindaran rintangan dinamis. Tujuannya adalah untuk menyelidiki bagaimana pengembangan algoritma RL dapat meningkatkan kinerja UAV di lingkungan yang tidak terstruktur.

Dengan menggabungkan perbandingan algoritma, fusi sensor, penelitian ini tidak hanya berkontribusi pada pengembangan teori RL untuk UAV, tetapi juga memberikan solusi praktis yang lebih mudah beradaptasi dan hemat biaya untuk aplikasi seperti pengelolaan lahan atau otonomi.

Data dari kamera kedalaman (RGB-D) akan digabungkan dengan sensor LiDAR untuk memperoleh pengukuran jarak yang lebih kuat, khususnya dalam skenario yang kompleks seperti atap yang rusak atau objek transparan. Teknik ini berbeda dari metode tradisional yang hanya menggunakan LiDAR, dengan harapan dapat meningkatkan deteksi halangan.

