



Design and Development of a Hybrid Wheel-Climbing Warehouse Robot Based on Reinforcement Learning

Rancang Bangun Warehouse Hybrid Wheel-Climbing Robot Berbasis Reinforcement Learning

Deni Wisnu^{1*}, Trinovita Zuhara Jingga^{2*}, Perdana Putera³

¹Program Studi Teknologi Rekayasa Komputer, Politeknik Pertanian Negeri Payakumbuh, Indonesia

²Program Studi Teknologi Rekayasa Komputer, Politeknik Pertanian Negeri Payakumbuh, Indonesia

³Program Studi Teknologi Rekayasa Komputer, Politeknik Pertanian Negeri Payakumbuh, Indonesia

*Correspondence: wisnuden181@gmail.com

Abstract

The development of modern warehouse systems requires robots capable of autonomous navigation and obstacle traversal in operational environments. However, conventional wheeled robots still have limitations in overcoming small obstacles that can reduce their mobility. This study aims to design and develop a warehouse hybrid wheel-climbing robot based on Reinforcement Learning. The research employed the ADDIE (Analysis, Design, Development, Implementation, and Evaluation) method. The robot was developed using an Arduino Mega 2560, an HC-SR04 ultrasonic sensor, DC motors, and servo motors as the climbing mechanism. The experimental results showed a climbing success rate of 80%–90%, an average travel time of 18.80 s, an average speed of 13.87 cm/s, and an average climbing duration of 2.58 s. The implementation of Q-Learning produced a simple navigation policy capable of selecting forward and turning actions based on environmental conditions. The results indicate that the integration of the climbing mechanism and Q-Learning has the potential to improve the mobility of warehouse robots.

Article Information

Article History:

Received: 23/07/2026

First Revised: 21/08/2026

Accepted: 22/09/2026

Publication Date: 23/09/2026

Keywords:

Warehouse robot, hybrid wheel-climbing, reinforcement learning, Q-Learning, robot navigation.



Copyright (c) 2026 Deni Wisnu, Trinovita Zuhara Jingga, Perdana Putera

Abstrak

Perkembangan sistem pergudangan modern menuntut penggunaan robot yang mampu melakukan navigasi secara mandiri dan melewati hambatan pada lintasan operasional. Namun, robot beroda konvensional masih memiliki keterbatasan dalam menghadapi *obstacle* kecil yang dapat mengganggu mobilitasnya. Penelitian ini bertujuan merancang dan membangun *warehouse hybrid wheel-climbing robot* berbasis *Reinforcement Learning*. Metode penelitian yang digunakan adalah ADDIE (*Analysis, Design, Development, Implementation, and Evaluation*). Robot dikembangkan menggunakan Arduino Mega 2560, sensor ultrasonik HC-SR04, motor DC, dan motor servo sebagai mekanisme *climbing*. Hasil pengujian menunjukkan tingkat keberhasilan *climbing* sebesar 80%–90%, rata-rata waktu tempuh 18,80 detik, kecepatan rata-rata 13,87 cm/s, dan durasi *climbing* sebesar 2,58 detik. Implementasi *Q-Learning* menghasilkan kebijakan navigasi sederhana yang mampu menentukan aksi maju dan belok berdasarkan kondisi lingkungan. Hasil penelitian menunjukkan bahwa integrasi mekanisme *climbing* dan *Q-Learning* berpotensi meningkatkan mobilitas robot pergudangan.



Copyright (c) 2026 Deni Wisnu, Trinovita Zuhara Jingga, Perdana Putera

Artikel Info**Riwayat Artikel:**

Diterima: 23/07/2026

Direvisi: 21/08/2026

Disetujui: 22/09/2026

Dipublikasikan: 23/09/2026

Kata Kunci:

Warehouse robot, hybrid wheel climbing, reinforcement learning, Q-Learning, navigasi robot.

1. Pendahuluan

Perkembangan perdagangan elektronik atau *e-commerce* dan penerapan konsep Industri 4.0 telah meningkatkan tuntutan terhadap sistem pergudangan yang mampu bekerja secara cepat, akurat, dan efisien. Peningkatan jumlah barang yang harus disimpan, dipindahkan, disortir, dan dikirim menyebabkan aktivitas penanganan material menjadi semakin kompleks. Kondisi tersebut mendorong perusahaan logistik dan manufaktur untuk menerapkan teknologi otomasi yang dapat mengurangi ketergantungan terhadap pekerjaan manual. Salah satu teknologi yang banyak dikembangkan dalam sistem pergudangan modern adalah *Autonomous Mobile Robot* (AMR), yaitu robot bergerak yang mampu melakukan navigasi dan membawa material secara mandiri di dalam lingkungan kerja. Perencanaan dan pengendalian AMR berperan dalam meningkatkan efisiensi transportasi internal, pengambilan barang, pengiriman material, serta koordinasi aktivitas di lingkungan pergudangan (Fragapane et al., 2021). Fleksibilitas tersebut membedakan AMR dari *Automated Guided Vehicle* (AGV), yang pada umumnya mengikuti jalur atau infrastruktur tertentu yang telah ditentukan sebelumnya. AMR dapat memanfaatkan sensor, pengendali, dan perangkat lunak navigasi untuk mengenali kondisi lingkungan dan menentukan gerakan berdasarkan informasi yang diperoleh selama beroperasi (Keith & La, 2024).

Penerapan AMR tidak hanya bertujuan menggantikan tenaga manusia, tetapi juga mendukung manusia dalam pekerjaan yang bersifat berulang, melelahkan, dan membutuhkan perpindahan jarak jauh. Penggunaan AMR dapat mengurangi jarak berjalan operator serta mendukung peningkatan kapasitas pemrosesan barang dalam kegiatan pengambilan pesanan di gudang (Zhen et al., 2025). Selain itu, AMR memiliki keunggulan berupa fleksibilitas terhadap perubahan tata letak karena pergerakannya tidak sepenuhnya bergantung pada rel, garis magnetik, atau penanda fisik. Meskipun demikian, kemampuan AMR sangat dipengaruhi oleh kondisi permukaan dan jalur yang dilaluinya.

Hambatan pada jalur dapat menyebabkan roda kehilangan traksi, badan robot tersangkut, arah gerak berubah, atau robot tidak mampu melanjutkan perjalanan. Kajian terhadap berbagai robot bergerak menunjukkan bahwa kemampuan melewati rintangan masih menjadi salah satu tantangan penting dalam pengembangan robot darat, terutama ketika robot harus bergerak pada permukaan yang tidak seragam (García et al., 2024). Selain kemampuan mekanik, sistem navigasi robot juga harus mampu mendeteksi keberadaan objek dan menentukan tindakan yang sesuai agar tabrakan dapat dihindari. Penghindaran hambatan pada robot beroda menjadi semakin kompleks ketika lingkungan tidak diketahui atau mengalami perubahan selama robot beroperasi (X. Wang et al., 2023).

Keterbatasan robot beroda konvensional mendorong pengembangan berbagai mekanisme lokomosi alternatif. Salah satu pendekatan yang digunakan adalah menggabungkan roda dengan mekanisme tambahan yang dapat membantu robot ketika menghadapi rintangan. (R. Cao et al., 2022). Kemampuan melewati rintangan tidak hanya ditentukan oleh bentuk roda, tetapi juga oleh susunan mekanik, posisi pusat massa, gaya dorong, dan kestabilan robot. Robot roda-kaki yang dilengkapi pengaturan posisi badan dapat memanfaatkan gerakan keseluruhan tubuh untuk melewati hambatan yang lebih tinggi dengan tetap mempertahankan keseimbangan (Li et al., 2022).

Pada penelitian ini, mekanisme hibrida diwujudkan melalui penggabungan penggerak roda dan mekanisme *climbing* berbasis lengan servo. Penggerak roda digunakan untuk menjalankan robot pada lintasan normal, sedangkan lengan servo membantu mengangkat bagian depan badan robot ketika berhadapan dengan hambatan (Zhao et al., 2021). Penggerak roda pada prototipe digunakan untuk menjalankan robot pada lintasan normal, sedangkan lengan servo dirancang untuk membantu mengangkat bagian depan badan robot ketika berhadapan dengan hambatan. (Mohamed et al., 2025). Selain persoalan mekanik, robot pergudangan juga memerlukan kemampuan pengambilan keputusan. Sistem pengendalian berbasis aturan umumnya menggunakan sejumlah kondisi yang ditetapkan sejak awal, misalnya robot bergerak maju ketika jarak aman terpenuhi dan berbelok ketika sensor mendeteksi objek.

Salah satu pendekatan yang dapat digunakan untuk meningkatkan kemampuan adaptasi robot adalah *Reinforcement Learning* (RL) *Q-Learning*. *Q-Learning* merupakan salah satu metode RL yang sesuai untuk permasalahan dengan keadaan dan tindakan diskrit. Metode ini menyimpan nilai untuk setiap pasangan *state* dan *action* dalam sebuah *Q-table*. Nilai tersebut diperbarui berdasarkan penghargaan yang diperoleh dan estimasi nilai keadaan berikutnya (C. Wang et al., 2022). Penerapan *Q-Learning* juga telah dikembangkan dengan penyesuaian fungsi penghargaan dan strategi pemilihan tindakan untuk meningkatkan keberhasilan navigasi pada lingkungan yang memiliki hambatan bergerak (Almazrouei et al., 2023).

Penerapan metode pembelajaran pada robot fisik tetap memiliki beberapa tantangan. Robot harus melakukan eksplorasi berkali-kali sebelum menemukan kebijakan yang baik. Pada tahap awal pembelajaran, tindakan agen belum optimal sehingga robot dapat sering menabrak, berhenti pada posisi yang tidak diinginkan, atau memilih jalur yang terlalu panjang. Pelatihan langsung pada perangkat keras juga dapat mempercepat keausan motor dan komponen mekanik (Choi et al., 2021). Maka dari itu pengujian dalam lingkungan simulasi sering digunakan untuk mengurangi risiko tersebut. Simulasi memungkinkan robot menjalani banyak episode tanpa menimbulkan kerusakan pada perangkat keras. Akan tetapi, hasil dari simulasi belum tentu dapat dipindahkan secara langsung ke robot fisik karena terdapat perbedaan model sensor, gesekan, respons motor, dan kondisi lingkungan. Oleh sebab itu, pengembangan prototipe dasar yang stabil tetap diperlukan sebelum suatu pengendali berbasis pembelajaran diterapkan secara penuh (Ha et al., 2024).

Penelitian lain menunjukkan bahwa *Q-Learning* dapat diterapkan pada robot bergerak untuk mengikuti jalur dan menghindari hambatan secara langsung pada lingkungan nyata (Hanh et al., 2023). Penelitian tersebut memiliki kelebihan dalam menunjukkan kemampuan *Q-Learning* untuk menentukan tindakan robot secara adaptif berdasarkan kondisi lingkungan,

sehingga tidak hanya bergantung pada aturan navigasi yang telah ditentukan sebelumnya. Namun, penerapannya masih berfokus pada robot bergerak beroda dengan mekanisme pergerakan konvensional dan belum mempertimbangkan kemampuan robot dalam melewati hambatan fisik melalui perubahan mekanisme gerak. Di sisi lain, penelitian mengenai mekanisme *hybrid wheel-climbing* menunjukkan bahwa kombinasi roda dan mekanisme pemanjat dapat meningkatkan kemampuan robot dalam melewati permukaan atau hambatan tertentu, tetapi umumnya belum mengintegrasikan metode *Reinforcement Learning* untuk menentukan tindakan navigasi secara adaptif.

Berdasarkan perbandingan tersebut, penelitian terdahulu telah memiliki kelebihan masing-masing, yaitu pengembangan kemampuan navigasi menggunakan *Reinforcement Learning* dan pengembangan mekanisme robot yang mampu melewati hambatan. Akan tetapi, masih terdapat keterbatasan pada integrasi kedua aspek tersebut dalam satu prototipe robot untuk kebutuhan pergudangan. Penelitian ini mengisi kesenjangan tersebut dengan mengintegrasikan mekanisme *hybrid wheel-climbing* dengan metode *Q-Learning* pada robot pengangkut barang untuk lingkungan pergudangan skala laboratorium. Berbeda dengan penelitian terdahulu yang umumnya menggunakan robot beroda standar atau mengevaluasi navigasi melalui simulasi, penelitian ini menguji pengambilan keputusan berbasis *Q-Learning* pada prototipe robot fisik dengan mekanisme roda dan *wheel-climbing* untuk mendukung navigasi menuju rak, melewati hambatan, dan kembali ke titik awal. Dengan demikian, kontribusi penelitian ini terletak pada penerapan *Q-Learning* pada robot fisik yang tidak hanya melakukan navigasi, tetapi juga mengintegrasikan kemampuan pergerakan hibrida sebagai bagian dari sistem robot pengangkut barang untuk lingkungan pergudangan.

Tujuan penelitian ini adalah merancang dan membangun *Warehouse Hybrid Wheel-Climbing Robot* berbasis *Reinforcement Learning* yang mampu bergerak pada lintasan pergudangan serta melewati hambatan menggunakan kombinasi roda dan lengan *climbing* berbasis servo. Selain itu, penelitian ini bertujuan merumuskan kerangka *Q-Learning* diskrit yang terdiri atas *state*, *action*, *reward*, kebijakan eksplorasi, dan mekanisme pembaruan *Q-table* sebagai dasar pengambilan keputusan navigasi robot.

Penelitian-penelitian terdahulu telah menunjukkan bahwa metode *Q-Learning* efektif digunakan untuk navigasi robot bergerak, penghindaran hambatan, dan perencanaan jalur. Di sisi lain, penelitian mengenai robot *wheel-climbing* atau robot hibrida berfokus pada peningkatan kemampuan robot dalam melewati hambatan fisik melalui modifikasi mekanisme gerak. Namun, kedua pendekatan tersebut umumnya masih dikembangkan secara terpisah, sehingga integrasi antara mekanisme *hybrid wheel-climbing* dan *Q-Learning* pada robot pengangkut barang untuk lingkungan pergudangan masih terbatas.

2. Metodologi

Penelitian ini menggunakan metode ADDIE (*Analysis, Design, Development, Implementation, and Evaluation*). Metode ADDIE dipilih karena memiliki tahapan pengembangan yang sistematis, terstruktur, dan fleksibel sehingga sesuai untuk pengembangan sistem robotika berbasis *Reinforcement Learning*. Dibandingkan dengan metode Waterfall yang cenderung bersifat linear dan sulit mengakomodasi perubahan setelah suatu tahap selesai, ADDIE memungkinkan proses evaluasi dan perbaikan pada setiap fase pengembangan. Hal ini penting karena pengembangan robot memerlukan penyesuaian berulang terhadap desain mekanik, perangkat keras, perangkat lunak, serta parameter pembelajaran yang diperoleh dari hasil pengujian.

Selain itu, dibandingkan dengan V-Model yang berfokus pada hubungan antara tahapan pengembangan dan pengujian secara berpasangan, ADDIE memberikan fleksibilitas yang lebih tinggi dalam melakukan penyempurnaan prototipe berdasarkan hasil implementasi dan evaluasi. Karakteristik tersebut sesuai dengan penelitian ini karena proses pengembangan robot tidak hanya mencakup perancangan perangkat keras dan mekanisme *hybrid wheel-climbing*, tetapi juga penyusunan kerangka *Q-Learning* yang memerlukan pengujian dan

penyesuaian parameter secara bertahap. Oleh karena itu, ADDIE dinilai lebih sesuai untuk mendukung pengembangan prototipe robot pergudangan yang mengintegrasikan mekanisme *hybrid wheel-climbing* dan *Reinforcement Learning* melalui proses pengembangan yang iteratif dan berkelanjutan.



Gambar 1. Metodologi Penelitian

2.1. Alat dan Bahan

Sistem ini menggunakan Arduino Mega 2560 sebagai pengendali utama. Satu sensor ultrasonik HC-SR04 yang dipasang di bagian depan memperkirakan jarak ke dinding lintasan. Dua sakelar batas limit switch depan mendeteksi kontak dengan rintangan. Dua motor DC yang digerakkan melalui modul L298N menggerakkan roda, sementara dua motor servo menggerakkan lengan *Climbing*. Baterai dan modul step-down menyuplai serta menstabilkan tegangan operasi.

Pada sisi perangkat lunak, Arduino IDE digunakan untuk mengembangkan, mengompilasi, dan mengunggah program ke mikrokontroler. Algoritma *Reinforcement Learning* digunakan sebagai metode pengambilan keputusan dalam navigasi robot untuk menentukan tindakan yang sesuai berdasarkan kondisi lingkungan. Selain itu, *draw.io* digunakan untuk menyusun diagram alir sistem, diagram blok, dan perancangan penelitian. Seluruh alat dan bahan yang digunakan dalam penelitian ini disajikan pada Tabel 1.


Tabel 1. Spesifikasi Alat dan Bahan

No.	Komponen	Spesifikasi/Kategori	Fungsi
1	Arduino Mega 2560	Mikrokontroler ATmega2560, Tegangan Operasi: 5V, Input Voltage: 7-12V, 54 Pin Digital I/O, 16 Pin Analog Input.	Memproses data sensor dan mengendalikan system Robot
2	Sensor ultrasonik	HC-SR04, tegangan kerja 5V DC, jarak deteksi 2-400 cm, sudut pengukuran <15°	Mendeteksi jarak dinding
3	Limit switch	Micro Switch / Snap Action dengan roller lever, rating 5A 125/250 VAC	Mendeteksi <i>obstacle</i> pada jalur lintasan
4	Motor DC	Motor DC Gearbox, tegangan kerja 12 V DC, kecepatan 100 RPM	Menggerakkan roda kanan dan kiri robot
5	Driver L298N	Modul Dual H-Bridge L298N, tegangan motor 5-35 V, tegangan logika 5 V, arus maksimum 2 A per kanal	Mengendalikan motor DC kanan dan kiri
6	Motor servo	MG996R (Metal Gear), tegangan kerja 4,8-7,2 V, torsi 11 kg.cm (6 V), sudut putar 180°	Menggerakkan lengan <i>climbing</i>
7	Step-down	Modul LM2596 DC-DC Buck Converter	Menstabilkan tegangan
8	Baterai Li-Po	Li-Po 3S (11,1 V), kapasitas 2200 mAh, discharge rate 25C	Sumber daya untuk komponen robot


9	Laptop/PC	Perangkat komputasi	Mendukung pemrograman dan pengolahan data
10	Arduino IDE	Perangkat lunak pemrograman	Menulis dan mengunggah program ke Arduino ATmega2560
11	Draw.io	Perangkat lunak diagram	Membuat rancangan diagram sistem

2.2. Prosedur Pengembangan Sistem

Tahap Development meliputi proses pembuatan prototipe robot, perakitan perangkat keras, pemrograman Arduino Mega 2560 menggunakan Arduino IDE, serta integrasi sensor ultrasonik, motor DC, driver motor L298N, dan motor servo sebagai mekanisme *climbing*. Pada tahap ini juga dilakukan implementasi algoritma Reinforcement Learning dan pengujian awal untuk memastikan seluruh komponen dapat bekerja sesuai dengan rancangan sistem. Diagram blok dan rangkaian sistem masing-masing ditunjukkan pada Gambar 2 dan Gambar 3.



Gambar 2. Diagram Blok




Gambar 3. Rangkaian Perangkat Keras

2.3. Lintasan Pengujian

Prototipe robot diuji pada lintasan berbentuk huruf U dengan dimensi luar sebesar 120 cm × 100 cm, lebar jalur nominal 30 cm, dan total panjang lintasan yang ditempuh sebesar 260 cm. Empat buah *obstacle* yang diberi kode OBS 1 hingga OBS 4 ditempatkan pada posisi yang telah ditentukan. Pengujian dilakukan sebanyak sepuluh kali pengulangan dengan menggunakan urutan kendali dasar (*baseline control sequence*) yang sama pada setiap percobaan. Waktu tempuh diukur sejak robot bergerak dari titik awal hingga mencapai titik tujuan. Kecepatan rata-rata robot dihitung berdasarkan perbandingan antara total jarak tempuh dan waktu tempuh yang diperoleh. Durasi *climbing* diukur mulai dari saat motor

servo diaktifkan hingga robot berhasil melewati *obstacle*. Tingkat keberhasilan dihitung berdasarkan perbandingan antara jumlah keberhasilan robot dalam melewati *obstacle* terhadap jumlah keseluruhan percobaan yang dilakukan. Jalur peta lintasan ditunjukkan pada Gambar 4.



Gambar 4. Jalur Peta Lintasan Robot

2.4. Teknik Pengumpulan Data dan Analisis Data

Data penelitian dikumpulkan melalui metode observasi, eksperimen, dan dokumentasi untuk memperoleh informasi mengenai kinerja sistem robot yang dikembangkan. Observasi dilakukan terhadap kondisi lintasan pengujian, posisi *obstacle*, dan respons robot selama proses navigasi. Pengambilan data dilakukan melalui pengujian langsung terhadap prototipe *warehouse hybrid wheel-climbing robot* pada lintasan berbentuk huruf U yang telah dirancang.

Instrumen yang digunakan dalam pengumpulan data meliputi prototipe robot, lintasan pengujian, *stopwatch* untuk mengukur waktu tempuh dan durasi *climbing*, serta lembar observasi untuk mencatat keberhasilan navigasi dan kemampuan robot melewati hambatan. Dokumentasi dilakukan menggunakan kamera untuk merekam proses pengujian dan memudahkan analisis hasil eksperimen. Pengambilan data dilakukan melalui beberapa kali pengulangan pengujian pada kondisi lintasan yang sama untuk memperoleh hasil yang lebih konsisten dan mengurangi pengaruh kesalahan pengukuran. Parameter evaluasi yang digunakan meliputi tingkat keberhasilan *climbing*, waktu tempuh robot, kecepatan pergerakan, durasi proses *climbing*, dan keberhasilan navigasi berdasarkan keputusan yang dihasilkan oleh algoritma *Q-Learning*. Parameter tersebut dipilih karena dapat merepresentasikan kinerja sistem secara menyeluruh, baik dari aspek mobilitas mekanik maupun kemampuan pengambilan keputusan robot dalam lingkungan perdagangan.

Analisis Waktu Tempuh Keseluruhan (Total Time)

Pengolahan data dilakukan dengan menghitung selisih antara titik waktu saat robot mulai bergerak (waktu awal) hingga titik waktu saat robot mencapai batas akhir lintasan (waktu akhir). Analisis ini dilakukan pada 10 kali repetisi percobaan untuk melihat konsistensi durasi operasional robot. Persamaan yang digunakan adalah:

$$T_{Total} = t_{akhir} - t_{awal}$$

Analisis Kecepatan Rata-rata (V_{avg})

Untuk mendeskripsikan dinamika pergerakan robot secara keseluruhan pada lintasan yang memiliki jarak tetap, digunakan analisis kecepatan rata-rata. Data jarak tempuh konstan (variabel kontrol) dan data T_{total} (variabel terikat) diolah menggunakan prinsip dasar kinematika translasi. Hasil perhitungan ini menjadi indikator seberapa cepat robot dapat mendistribusikan barang.

$$V_{Avg} = \frac{S_{total}}{T_{total}}$$

Analisis Durasi Climbing (T_{climb})

Waktu *climbing* dianalisis dengan mencatat durasi murni yang dibutuhkan oleh mekanisme *hybrid wheel* untuk memanjat dan terbebas dari rintangan. Data dari sejumlah repetisi diekstraksi untuk mencari nilai rata-rata (*mean*). Nilai rata-rata ini digunakan untuk merepresentasikan tren kecepatan respons aktuator robot dalam menghadapi rintangan.

$$T_{climb} = (x + a)^n = \sum_{i=1}^n t_i$$

Analisis Keandalan dan Rasio Keberhasilan (*Success Rate*)

Tingkat keandalan (*reliability*) dari perancangan mekanis diukur menggunakan rasio keberhasilan. Pengujian dilakukan pada berbagai variasi hambatan (Obs 1 hingga Obs 4). Setiap percobaan diklasifikasikan secara biner (Berhasil/Gagal). Data tersebut dikonversi ke dalam bentuk persentase probabilitas sukses.

$$P_{Succes} = \left(\frac{F}{N}\right) \times 100\%$$

3. Hasil dan Pembahasan

3.1. Hasil Perancangan Sistem Robot

Robot yang dikembangkan memiliki dimensi panjang 18 cm dan lebar 12,5 cm. Sistem terdiri atas Arduino Mega 2560 sebagai pengendali utama, sensor ultrasonik HC-SR04 sebagai pendeteksi *obstacle*, motor DC sebagai penggerak utama, dan motor servo sebagai aktuator *climbing*. Hasil perancangan sistem robot ditunjukkan pada Gambar 5.




Gambar 5. Hasil Keseluruhan Robot

3.2. Hasil Pengujian Kecepatan Rata-rata


Berdasarkan sepuluh kali pengujian, waktu tempuh total robot berada pada rentang 17 detik hingga 21 detik. Rata-rata waktu tempuh yang diperoleh adalah 18,80 detik, yang setara dengan kecepatan rata-rata sebesar 13,87 cm/s. Rentang waktu sebesar 4 detik menunjukkan bahwa robot memiliki performa operasional yang relatif konsisten. Namun, masih terdapat beberapa variasi waktu tempuh yang dipengaruhi oleh faktor-faktor seperti gesekan permukaan lintasan, waktu deteksi dinding oleh sensor, serta durasi yang dibutuhkan robot untuk melakukan mekanisme *climbing* pada setiap *obstacle*. Ditunjukkan pada tabel 2.

Tabel 2. Pengujian Kecepatan Rata-rata

Percobaan	Jarak Tempuh (cm)	Waktu Awal (s)	Ttotal (s)	Vavg (cm/s)
1	260	1	21	12,38
2	260	1	18	14,44
3	260	1	19	13,68
4	260	1	18	14,44
5	260	1	17	15,29
6	260	1	19	13,68
7	260	1	20	13,00
8	260	1	19	13,68
9	260	1	18	14,44
10	260	1	19	13,68
Rata-rata	260	-	18,80	13,87



Gambar 6. Waktu Tempuh Total




Gambar 7. Grafik Kecepatan Rata-rata Robot

3.3. Hasil Pengujian Kinerja Climbing

Rata-rata durasi *climbing* untuk OBS 1, OBS 2, OBS 3, dan OBS 4 masing-masing adalah 2,40 detik, 2,60 detik, 2,20 detik, dan 3,10 detik. Secara keseluruhan, rata-rata waktu yang dibutuhkan robot untuk melewati *obstacle* adalah 2,58 detik.

Tabel 3. Pengujian Kinerja Climbing

Percobaan	Tclimb 1 (s)	Tclimb 2 (s)	Tclimb 3 (s)	Tclimb 4 (s)
1	3	2	3	4
2	3	3	1	3
3	2	2	3	3
4	2	2	3	4
5	3	3	1	3
6	2	3	2	3
7	3	4	3	3
8	2	3	2	3
9	2	2	2	3
10	2	2	2	2
Rata-rata	2,40	2,60	2,20	3,10



Gambar 8. Rata-rata Durasi Climbing

Berdasarkan Tabel 3, *obstacle* OBS 4 memerlukan waktu *climbing* paling lama sehingga dapat dianggap sebagai *obstacle* yang paling kritis. Posisi *obstacle* yang berada di dekat segmen akhir lintasan mengurangi jarak yang tersedia bagi robot untuk melakukan koreksi posisi, sehingga meningkatkan sensitivitas terhadap momentum pergerakan dan keselarasan (alignment) badan robot ketika melakukan proses *climbing*.


3.4. Hasil Pengujian Total Waktu Tempuh

Berdasarkan sepuluh kali pengujian, total waktu tempuh robot berada pada rentang 17 detik hingga 21 detik. Rata-rata waktu yang dibutuhkan robot untuk menempuh lintasan dari titik awal hingga mencapai titik tujuan adalah 18,80 detik. Rentang waktu sebesar 4 detik menunjukkan bahwa robot memiliki performa operasional yang relatif konsisten pada setiap percobaan yang ditunjukkan pada tabel 4 dibawah ini.

Tabel 4. Pengujian Total Waktu Tempuh

Percobaan	Waktu Awal (s)	Waktu Akhir (s)	Ttotal(s)
1	1	22	21
2	1	19	18

3	1	20	19
4	1	19	18
5	1	18	17
6	1	20	19
7	1	21	20
8	1	20	19
9	1	19	18
10	1	20	19




Gambar 9. Total Time

3.5. Hasil Pengujian Rasio Keberhasilan *Climbing*

Robot menunjukkan tingkat keberhasilan yang berbeda pada setiap *obstacle*. Secara keseluruhan, robot mampu melewati sebagian besar *obstacle* dengan tingkat keberhasilan yang tinggi. Persentase keberhasilan *climbing* diperoleh dari perbandingan antara jumlah keberhasilan robot dalam melewati *obstacle* terhadap jumlah keseluruhan percobaan yang dilakukan. Hasil pengujian menunjukkan bahwa mekanisme *climbing* yang diterapkan mampu meningkatkan kemampuan mobilitas robot dalam menghadapi hambatan pada lintasan pergudangan. Namun, beberapa kegagalan masih terjadi, terutama pada *obstacle* yang memerlukan waktu *climbing* lebih lama atau memiliki posisi yang mengurangi jarak koreksi robot sebelum melakukan *climbing*. Yang ditampilkan pada tabel 5 dibawah ini.

Tabel 5. Pengujian Rasio Keberhasilan *Climbing*

<i>Obstacle</i>	Jumlah Percobaan	Berhasil	Gagal	Success rate
Obs 1	10	9	1	90%
Obs 2	10	8	2	80%
Obs 3	10	8	2	80%
Obs 4	10	8	2	80%



Gambar 10. Success Rate

3.5. Hasil Pengujian Reinforcement Learning Q-Learning

Pada penelitian ini, parameter awal yang diusulkan adalah $\alpha = 0,10$, $\gamma = 0,90$, dan $\epsilon = 0,10$ untuk eksperimen pendahuluan. Nilai-nilai tersebut merupakan parameter perancangan (design parameters) dan tidak digunakan untuk menghasilkan data dasar (*baseline*) pada pengujian robot fisik yang dilaporkan pada tabel 6 dan tabel 7 (Kormushev et al., 2013).

Nilai Q-value diperbarui menggunakan aturan standar Q-Learning sebagai berikut:


$$Q(s, a) \leftarrow Q(s, a) + \alpha[r + \gamma \max_{a'} Q(s', a') - Q(s, a)]$$

Tabel 6. Q-Table Hasil Pelatihan Reinforcement Learning

State	Maju	Belok Kanan	Aksi Terpilih
Depan Kosong	140,18	119,63	Maju
Dekat Tembok	107,77	188,17	Belok kanan

Tabel 7. Nilai Reward untuk Setiap State dan Action

State	Jumlah Aksi	Reward Maju	Reward Belok Kanan
Depan Kosong	2	5	-5
Dekat Tembok	2	-20	20



Gambar 11. Learning Curve Q-Learning

Persamaan Q-Learning digunakan untuk memperbarui nilai setiap pasangan state dan action berdasarkan pengalaman yang diperoleh agen selama proses interaksi dengan lingkungan. Melalui proses pembelajaran yang berulang, agen diharapkan mampu menemukan kebijakan (*policy*) yang optimal untuk menentukan tindakan yang memberikan *reward* terbesar pada setiap state yang dihadapi.

3.3. Pembahasan

Hasil penelitian menunjukkan bahwa *warehouse hybrid wheel-climbing robot* mampu melewati *obstacle* dengan tingkat keberhasilan sebesar 80%–90%. Temuan ini menunjukkan bahwa penambahan mekanisme *climbing* pada sistem penggerak roda dapat meningkatkan kemampuan robot dalam menghadapi hambatan kecil. Hasil tersebut relevan dengan (Bogue, 2016), (Y. Li et al., 2021), (Niloy et al., 2021), serta (Lackner et al., 2024), yang menjelaskan

bahwa kinerja robot pergudangan dipengaruhi oleh rancangan mekanik, kemampuan beradaptasi terhadap kondisi lintasan, sistem navigasi, dan kompleksitas lingkungan operasional.

Berdasarkan pengujian navigasi, robot memperoleh rata-rata waktu tempuh sebesar 18,80 detik dan kecepatan rata-rata sebesar 13,87 cm/s. Rentang waktu tempuh yang relatif kecil menunjukkan bahwa robot dapat beroperasi secara cukup konsisten. Meskipun demikian, variasi waktu masih dipengaruhi oleh gesekan permukaan, ketepatan pembacaan sensor, keselarasan badan robot, dan waktu aktivasi mekanisme *climbing*. Kondisi tersebut sesuai dengan (Xiao et al., 2022a), (Y. Cao et al., 2024), dan (Le et al., 2024), yang menyatakan bahwa performa navigasi robot bergerak dipengaruhi oleh kualitas persepsi sensor, pengendalian gerak, kondisi *obstacle*, serta kemampuan sistem dalam mengoreksi arah perjalanan.

Implementasi *Q-Learning* menunjukkan bahwa agen mampu mempelajari tindakan berdasarkan *reward* yang diberikan. Pada kondisi depan kosong, nilai *Q* tertinggi diperoleh oleh aksi maju, sedangkan pada kondisi dekat tembok, nilai tertinggi diperoleh oleh aksi belok kanan. Temuan ini memperlihatkan bahwa pembaruan *Q-value* dapat menghasilkan kebijakan navigasi sederhana yang sesuai dengan kondisi lingkungan. Hasil tersebut sejalan dengan (Xiao et al., 2022b), (Le et al., 2024), dan (Tang et al., 2025), yang menjelaskan bahwa Reinforcement Learning memungkinkan robot mempelajari hubungan antara state, action, dan *reward* untuk meningkatkan pengambilan keputusan navigasi.

Implementasi *Reinforcement Learning* dalam penelitian ini masih dilakukan melalui pelatihan berbasis program atau simulasi dan belum digunakan untuk mengendalikan prototipe fisik secara langsung. Pendekatan tersebut dapat mengurangi risiko tindakan eksplorasi yang tidak aman terhadap perangkat keras. (Ibarz et al., 2021), (Brunke et al., 2022), (Gu et al., 2023), dan (Tang et al., 2025) menjelaskan bahwa penerapan RL pada robot nyata menghadapi tantangan berupa kebutuhan data yang besar, perbedaan kondisi simulasi dan lingkungan nyata, keselamatan eksplorasi, waktu pelatihan, serta risiko kerusakan komponen.

Dengan demikian, kebaruan penelitian ini terletak pada penggabungan mekanisme *hybrid wheel-climbing* dan *Q-Learning* dengan state diskrit pada robot pergudangan skala prototipe. Mekanisme *climbing* digunakan untuk meningkatkan kemampuan robot melewati *obstacle*, sedangkan *Q-Learning* digunakan untuk mempelajari pemilihan aksi maju dan belok berdasarkan kondisi lintasan.

4. Simpulan

Penelitian ini menggunakan metode ADDIE (*Analysis, Design, Development, Implementation, and Evaluation*). Metode ADDIE dipilih karena memiliki tahapan pengembangan yang sistematis, terstruktur, dan fleksibel sehingga sesuai untuk pengembangan sistem robotika berbasis *Reinforcement Learning*. Dibandingkan dengan metode Waterfall yang cenderung bersifat linear dan sulit mengakomodasi perubahan setelah suatu tahap selesai, ADDIE memungkinkan proses evaluasi dan perbaikan pada setiap fase pengembangan. Hal ini penting karena pengembangan robot memerlukan penyesuaian berulang terhadap desain mekanik, perangkat keras, perangkat lunak, serta parameter pembelajaran yang diperoleh dari hasil pengujian.

Selain itu, dibandingkan dengan V-Model yang berfokus pada hubungan antara tahapan pengembangan dan pengujian secara berpasangan, ADDIE memberikan fleksibilitas yang lebih tinggi dalam melakukan penyempurnaan prototipe berdasarkan hasil implementasi dan evaluasi. Karakteristik tersebut sesuai dengan penelitian ini karena proses pengembangan robot tidak hanya mencakup perancangan perangkat keras dan mekanisme *hybrid wheel-climbing*, tetapi juga penyusunan kerangka *Q-Learning* yang memerlukan pengujian dan penyesuaian parameter secara bertahap. Oleh karena itu, ADDIE dinilai lebih sesuai untuk mendukung pengembangan prototipe robot pergudangan yang mengintegrasikan mekanisme

hybrid wheel-climbing dan Reinforcement Learning melalui proses pengembangan yang iteratif dan berkelanjutan.

5. Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Politeknik Pertanian Negeri Payakumbuh dan Program Studi Teknologi Rekayasa Komputer yang telah memberikan dukungan serta fasilitas selama pelaksanaan penelitian. Ucapan terima kasih juga disampaikan kepada dosen pembimbing dan seluruh pihak yang telah memberikan arahan serta kontribusi dalam proses penelitian dan penyusunan artikel ini.

6. Daftar Pustaka

- Almazrouei, K., Kamel, I., & Rabie, T. (2023). Dynamic *Obstacle* Avoidance and Path Planning through Reinforcement Learning. *Applied Sciences*, 13(14), 8174. <https://doi.org/10.3390/app13148174>
- Bogue, R. (2016). Growth in e-commerce boosts innovation in the warehouse robot market. *Industrial Robot: An International Journal*, 43(6), 583–587. <https://doi.org/10.1108/IR-07-2016-0194>
- Brunke, L., Greeff, M., Hall, A. W., Yuan, Z., Zhou, S., Panerati, J., & Schoellig, A. P. (2022). Safe Learning in Robotics: From Learning-Based Control to Safe Reinforcement Learning. *Annual Review of Control, Robotics, and Autonomous Systems*, 5(1), 411–444. <https://doi.org/10.1146/annurev-control-042920-020211>
- Cao, R., Gu, J., Yu, C., & Rosendo, A. (2022). *OmniWhег: An Omnidirectional Wheel-Leg Transformable Robot*. <http://arxiv.org/abs/2203.02118>
- Cao, Y., Ni, K., Kawaguchi, T., & Hashimoto, S. (2024). Path Following for Autonomous Mobile Robots with Deep Reinforcement Learning. *Sensors*, 24(2), 561. <https://doi.org/10.3390/s24020561>
- Choi, J., Lee, G., & Lee, C. (2021). Reinforcement learning-based dynamic *obstacle* avoidance and integration of path planning. *Intelligent Service Robotics*, 14(5), 663–677. <https://doi.org/10.1007/s11370-021-00387-2>
- Fragapane, G., de Koster, R., Sgarbossa, F., & Strandhagen, J. O. (2021). Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda. *European Journal of Operational Research*, 294(2), 405–426. <https://doi.org/10.1016/j.ejor.2021.01.019>
- García, J. M., & Duarte, F. G. (2024). Mobile rolling robots designed to overcome *obstacles*: A review. *Forces in Mechanics*, 16, 100283. <https://doi.org/10.1016/j.finmec.2024.100283>
- Gu, S., Kshirsagar, A., Du, Y., Chen, G., Peters, J., & Knoll, A. (2023). A human-centered safe robot reinforcement learning framework with interactive behaviors. *Frontiers in Neurorobotics*, 17. <https://doi.org/10.3389/fnbot.2023.1280341>
- Ha, V. T., & Vinh, V. Q. (2024). Experimental Research on Avoidance *Obstacle* Control for Mobile Robots Using *Q-Learning* (QL) and Deep *Q-Learning* (DQL) Algorithms in Dynamic Environments. *Actuators*, 13(1), 26. <https://doi.org/10.3390/act13010026>
- Hanh, L. D., & Cong, V. D. (2023). Path Following and Avoiding *Obstacle* for Mobile Robot Under Dynamic Environments Using Reinforcement Learning. *Journal of Robotics and Control (JRC)*, 4(2), 157–164. <https://doi.org/10.18196/jrc.v4i2.17368>
- Ibarz, J., Tan, J., Finn, C., Kalakrishnan, M., Pastor, P., & Levine, S. (2021). How to train your robot with deep reinforcement learning: lessons we have learned. *The International Journal of Robotics Research*, 40(4–5), 698–721. <https://doi.org/10.1177/0278364920987859>
- Keith, R., & La, H. M. (2024). *Review of Autonomous Mobile Robots for the Warehouse Environment*. <http://arxiv.org/abs/2406.08333>
- Kormushev, P., Calinon, S., & Caldwell, D. G. (2013). Reinforcement learning in robotics: Applications and real-world challenges. *Robotics*, 2(3), 122–148. <https://doi.org/10.3390/robotics2030122>

- Lackner, T., Hermann, J., Kuhn, C., & Palm, D. (2024). Review of autonomous mobile robots in intralogistics: state-of-the-art, limitations and research gaps. *Procedia CIRP*, 130, 930–935. <https://doi.org/10.1016/j.procir.2024.10.187>
- Le, H., Saeedvand, S., & Hsu, C.-C. (2024). A Comprehensive Review of Mobile Robot Navigation Using Deep Reinforcement Learning Algorithms in Crowded Environments. *Journal of Intelligent & Robotic Systems*, 110(4), 158. <https://doi.org/10.1007/s10846-024-02198-w>
- Li, J., Ma, J., & Nguyen, Q. (2022). *Balancing Control and Pose Optimization for Wheel-legged Robots Navigating High Obstacles*. <http://arxiv.org/abs/2109.09934>
- Li, Y., Chen, K., Collignon, S., & Ivanov, D. (2021). Ripple effect in the supply chain network: Forward and backward disruption propagation, network health and firm vulnerability. *European Journal of Operational Research*, 291(3), 1117–1131. <https://doi.org/10.1016/j.ejor.2020.09.053>
- Mohamed, S., Vellaiyan, V., Kim, K., Kim, Y., & Shin, B. (2025). Development of a Four Omni-Wheeled Mobile Robot Using Telescopic Legs. *Machines*, 13(4), 292. <https://doi.org/10.3390/machines13040292>
- Niloy, Md. A. K., Shama, A., Chakraborty, R. K., Ryan, M. J., Badal, F. R., Tasneem, Z., Ahamed, M. H., Moyeen, S. I., Das, S. K., Ali, M. F., Islam, M. R., & Saha, D. K. (2021). Critical Design and Control Issues of Indoor Autonomous Mobile Robots: A Review. *IEEE Access*, 9, 35338–35370. <https://doi.org/10.1109/ACCESS.2021.3062557>
- Tang, C., Abbatematteo, B., Hu, J., Chandra, R., Martín-Martín, R., & Stone, P. (2025). Deep Reinforcement Learning for Robotics: A Survey of Real-World Successes. *Annual Review of Control, Robotics, and Autonomous Systems*, 8(1), 153–188. <https://doi.org/10.1146/annurev-control-030323-022510>
- Wang, C., Yang, X., & Li, H. (2022). Improved Q-Learning Applied to Dynamic Obstacle Avoidance and Path Planning. *IEEE Access*, 10, 92879–92888. <https://doi.org/10.1109/ACCESS.2022.3203072>
- Wang, X., Sun, Y., Xie, Y., Bin, J., & Xiao, J. (2023). Deep reinforcement learning-aided autonomous navigation with landmark generators. *Frontiers in Neurorobotics*, 17. <https://doi.org/10.3389/fnbot.2023.1200214>
- Xiao, X., Liu, B., Warnell, G., & Stone, P. (2022a). Motion planning and control for mobile robot navigation using machine learning: a survey. *Autonomous Robots*, 46(5), 569–597. <https://doi.org/10.1007/s10514-022-10039-8>
- Xiao, X., Liu, B., Warnell, G., & Stone, P. (2022b). Motion planning and control for mobile robot navigation using machine learning: a survey. *Autonomous Robots*, 46(5), 569–597. <https://doi.org/10.1007/s10514-022-10039-8>
- Zhao, J., Han, T., Wang, S., Liu, C., Fang, J., & Liu, S. (2021). Design and Research of All-Terrain Wheel-Legged Robot. *Sensors*, 21(16), 5367. <https://doi.org/10.3390/s21165367>
- Zhen, L., Tan, Z., de Koster, R., He, X., Wang, S., & Wang, H. (2025). Optimizing Warehouse Operations with Autonomous Mobile Robots. *Transportation Science*, 59(5), 1130–1152. <https://doi.org/10.1287/trsc.2024.0800>