

BAB I

PENDAHULUAN

1.1 Latar Belakang

Perkembangan sistem otomasi industri menuntut adanya sistem transportasi material yang fleksibel, dan efisien. Robot mobile telah banyak digunakan dalam sistem manufaktur dan logistik untuk mendukung otomatisasi aliran material. Namun, sebagian besar sistem robot mobile di industri masih mengadopsi konsep navigasi berbasis jalur fisik seperti garis magnetik atau marka lantai, yang menyebabkan keterbatasan fleksibilitas tata letak serta kesulitan dalam re-konfigurasi sistem produksi.

Sebagai solusi dari permasalahan tersebut, diperlukan pendekatan sistem navigasi yang tidak bergantung pada jalur fisik, melainkan berbasis pengambilan keputusan yang diperoleh melalui proses pembelajaran oleh robot. Pendekatan ini membuat robot mampu menentukan jalur secara mandiri pada lingkungan yang kompleks berdasarkan pengalaman yang diperoleh selama proses pembelajaran, sehingga meningkatkan fleksibilitas serta efisiensi operasional dalam lingkungan warehouse.

Seiring berkembangnya kecerdasan buatan, pendekatan berbasis pembelajaran mesin mulai diterapkan dalam sistem navigasi robot otonom. Salah satu paradigma pembelajaran yang relevan adalah *Reinforcement learning* (RL), yaitu metode pembelajaran di mana agen berinteraksi langsung dengan lingkungan untuk memaksimalkan akumulasi *reward* jangka panjang [1]. RL memungkinkan agen mempelajari kebijakan optimal tanpa memerlukan model matematis eksplisit dari lingkungan.

Salah satu algoritma RL yang fundamental adalah *Q-Learning* yang diperkenalkan oleh [2]. *Q-Learning* merupakan algoritma *model-free* yang memperbarui nilai aksi berdasarkan estimasi *reward* masa depan melalui pendekatan iteratif berbasis fungsi nilai Q. Algoritma ini telah terbukti konvergen menuju kebijakan optimal pada kondisi tertentu dan banyak digunakan dalam permasalahan navigasi robot diskrit [3].

Dalam konteks robotika, RL telah diterapkan pada berbagai sistem navigasi otonom.[4] menunjukkan bahwa RL efektif dalam pengembangan sistem kontrol

robot melalui interaksi langsung dengan lingkungan. Selain itu, [5] menunjukkan bahwa pendekatan *deep reinforcement learning* mampu menghasilkan kebijakan navigasi robot mobile yang adaptif terhadap lingkungan kompleks. Meskipun demikian, banyak penelitian tersebut memanfaatkan sensor visual seperti kamera atau sistem pemetaan berbasis SLAM yang memerlukan komputasi tinggi.

Pendekatan lain yang relevan adalah pelatihan dalam simulasi sebelum implementasi pada sistem fisik (*simulation-to-real transfer*). [6] menunjukkan bahwa kebijakan yang dilatih di lingkungan simulasi dapat ditransfer ke sistem nyata dengan pendekatan yang tepat, meskipun terdapat tantangan berupa perbedaan dinamika dan noise sensor. Hal ini menunjukkan pentingnya desain *state* dan *reward* yang stabil untuk menjaga stabilitas kebijakan saat implementasi nyata.

Berbeda dengan penelitian yang menggunakan sistem kompleks, penelitian ini mengembangkan sistem navigasi berbasis *state* diskrit dengan memanfaatkan data encoder untuk merepresentasikan perpindahan posisi robot pada lingkungan grid, IMU untuk menentukan orientasi robot, serta sensor proximity untuk mendeteksi *obstacle* statis. Struktur *state* dalam simulasi Python merepresentasikan posisi, arah robot, dan tujuan (*goal*) yang aktif. Agen dilatih menggunakan algoritma *Q-Learning* untuk menentukan jalur terbaik menuju tujuan dan kembali ke titik awal dengan mempertimbangkan nilai *reward* dan *penalty* yang telah ditentukan. Pendekatan ini menjadi solusi lanjutan dari keterbatasan sistem navigasi berbasis jalur fisik dengan menghadirkan mekanisme navigasi yang lebih sederhana melalui implementasi policy hasil pelatihan *Q-Learning*., tanpa memerlukan sensor mahal maupun komputasi tinggi. Dengan memanfaatkan representasi *state* diskrit dan pembelajaran berbasis *reward*, sistem mampu melakukan pengambilan keputusan secara efisien dalam lingkungan yang telah dimodelkan.

Sebagian besar penelitian sebelumnya berfokus pada simulasi penuh atau lingkungan grid virtual tanpa implementasi langsung pada robot fisik sederhana. Selain itu, banyak sistem navigasi berbasis RL mengandalkan sensor mahal atau komputasi tinggi. Dengan demikian, masih terdapat kesenjangan penelitian dalam implementasi RL berbasis *state* diskrit sederhana yang menggabungkan simulasi Python dan implementasi langsung pada robot fisik [7].

Berdasarkan permasalahan di atas serta keterbatasan pada penelitian sebelumnya, penelitian ini menawarkan solusi berupa pengembangan sistem navigasi robot mobile yang lebih fleksibel, tidak bergantung pada jalur fisik, serta mampu menentukan jalur secara mandiri melalui proses pembelajaran. Dengan menerapkan algoritma *Q-Learning*, robot dapat mempelajari hubungan antara kondisi lingkungan dan aksi yang diambil untuk memperoleh kebijakan navigasi yang optimal. Sistem ini diimplementasikan pada robot nyata dengan memanfaatkan sensor encoder untuk mengidentifikasi perpindahan robot pada setiap grid, IMU untuk menentukan orientasi robot, serta sensor proximity untuk mendeteksi *obstacle* statis selama proses navigasi. Dengan demikian, sistem yang dikembangkan diharapkan mampu menghasilkan navigasi yang stabil dan dapat direplikasi untuk kebutuhan otomasi skala kecil hingga menengah.

Selain memberikan kontribusi pada pengembangan sistem AGV berbasis pembelajaran penguatan, penelitian ini juga memberikan kontribusi terhadap kajian *sim-to-real transfer* pada sistem robot bergerak dengan kompleksitas sensor minimal. Stabilitas kebijakan hasil pelatihan simulasi ketika diterapkan pada robot fisik menjadi fokus utama evaluasi dalam penelitian ini[8].

1.2 Perumusan Masalah

Berdasarkan latar belakang penelitian, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

- a. Bagaimana merancang dan mengimplementasikan algoritma *Q-Learning* untuk sistem navigasi robot mobile pada lingkungan terstruktur tanpa garis pandu fisik?
- b. Bagaimana hasil proses *training* dan *testing* algoritma *Q-Learning* pada lingkungan simulasi berbasis Python dalam menghasilkan *policy* navigasi yang optimal?
- c. Bagaimana integrasi data encoder, dan IMU, dalam membentuk state sehingga robot dapat menjalankan *policy* hasil *Q-Learning*?
- d. Bagaimana kemampuan robot dalam mengikuti *policy* hasil pelatihan algoritma *Q-Learning* pada implementasi di dunia nyata?

1.3 Tujuan

Berdasarkan rumusan masalah yang telah ditetapkan, maka tujuan dari penelitian ini adalah sebagai berikut:

- a. Merancang dan mengimplementasikan sistem navigasi robot mobile berbasis *Reinforcement learning* menggunakan algoritma *Q-Learning* pada lingkungan terstruktur tanpa garis pandu fisik.
- b. Merancang representasi *state*, *action*, dan *reward* pada algoritma *Q-Learning* berdasarkan data odometry, IMU, dan sensor proximity untuk mendukung navigasi robot mobile.
- c. Menganalisis hasil proses *training* dan *testing* algoritma *Q-Learning* pada lingkungan simulasi berbasis Python dalam menghasilkan *policy* navigasi.
- d. Mengimplementasikan *policy* hasil pelatihan pada robot nyata serta mengevaluasi kemampuan robot dalam menjalankan *policy* tersebut.

1.4 Manfaat Tugas Akhir

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

- a. Memberikan kontribusi teoretis dalam pengembangan metode *Reinforcement learning*, khususnya algoritma *Q-Learning*, untuk sistem navigasi robot mobile tanpa garis pandu fisik.
- b. Menjadi referensi dalam perancangan representasi *state*, *action*, dan *reward* yang terintegrasi dengan data odometry, IMU, dan sensor proximity pada sistem navigasi robot.
- c. Memberikan kajian mengenai kestabilan *policy* hasil *training* di simulasi ketika diimplementasikan pada robot nyata dalam konteks simulation-to-real transfer.
- d. Menghasilkan sistem navigasi robot mobile yang mampu bergerak secara otonom antara titik home dan target berdasarkan hasil pembelajaran.
- e. Menjadi dasar pengembangan penelitian lanjutan terkait implementasi *Reinforcement learning* pada robot fisik di lingkungan terstruktur.

1.5 Pembatasan Masalah

Agar penelitian lebih terarah dan tidak melebar dari ruang lingkup yang ditetapkan, maka batasan masalah dalam penelitian ini adalah sebagai berikut:

- a. Lingkungan penelitian berupa lingkungan terstruktur dengan jalur yang dapat dilalui dan jalur yang tidak dapat dilalui yang telah ditentukan sejak awal serta

- digunakan secara konsisten pada tahap *training*, *testing* simulasi, dan implementasi pada robot nyata.
- b. Metode pembelajaran yang digunakan terbatas pada *Reinforcement learning* dengan algoritma *Q-Learning* tanpa membandingkan dengan algoritma lain.
 - c. Proses *training* dan *testing* awal dilakukan pada lingkungan simulasi berbasis Python sebelum *policy* hasil pelatihan diimplementasikan pada robot nyata.
 - d. Representasi *state* dibentuk berdasarkan informasi posisi robot dari odometry dan orientasi robot dari IMU, sedangkan sensor proximity digunakan untuk mendeteksi *obstacle*.
 - e. Evaluasi sistem difokuskan pada hasil *training* dan *testing* algoritma *Q-Learning*, konvergensi proses pembelajaran, total *reward*, serta tingkat keberhasilan robot dalam menjalankan *policy* dan mencapai tujuan.
 - f. Penelitian tidak membahas aspek perancangan mekanik robot maupun optimasi perangkat keras.
 - g. Robot tidak melakukan manuver mundur (*reverse*), sehingga perubahan arah hanya dilakukan melalui kombinasi gerakan maju dan rotasi ke kiri atau ke kanan.
 - h. Sistem kontrol motor menggunakan metode PID untuk mengendalikan pergerakan robot. Penelitian ini tidak membahas optimasi parameter PID maupun perbandingan dengan metode kontrol lainnya.
 - i. Antarmuka (*Graphical User Interface/GUI*) hanya digunakan sebagai media monitoring dan pengoperasian sistem pada Raspberry Pi melalui akses *remote*. Perancangan dan pengembangan antarmuka pengguna tidak menjadi fokus pembahasan dalam penelitian ini.
 - j. Pengujian robot dilakukan pada lintasan dengan permukaan datar tanpa mempertimbangkan pengaruh tanjakan, turunan, maupun permukaan yang tidak rata.

1.6 Sistematika Tugas Akhir

Laporan tugas akhir ini disusun secara sistematis agar pembahasan lebih terstruktur dan mudah dipahami. Adapun sistematika tugas akhir ini adalah sebagai berikut:

BAB I PENDAHULUAN

Bab ini menjelaskan latar belakang mengenai pentingnya pengembangan sistem navigasi robot mobile berbasis kecerdasan buatan, khususnya menggunakan metode *reinforcement learning*. Selain itu, bab ini memuat rumusan masalah, tujuan penelitian, manfaat penelitian, serta batasan masalah yang menjadi ruang lingkup penelitian.

BAB II DASAR TEORI

Bab ini membahas teori-teori yang mendukung penelitian, meliputi konsep Automated Guided Vehicle (AGV), sistem navigasi robot, *reinforcement learning*, serta algoritma *Q-Learning* sebagai metode pembelajaran. Selain itu dijelaskan juga konsep grid environment, state, *action*, *reward*, serta prinsip kerja algoritma dalam navigasi robot

BAB III METODOLOGI PENELITIAN

Bab ini menguraikan tahapan perancangan sistem secara keseluruhan, mulai dari pemodelan lingkungan *grid*, penentuan *state*, *action*, dan *reward*, hingga implementasi algoritma *Q-Learning* dalam simulasi Python. Selain itu, dijelaskan juga arsitektur sistem robot, integrasi perangkat keras, serta tahapan pengujian dan pengambilan data.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari proses simulasi dan implementasi sistem navigasi robot. Pembahasan meliputi hasil *training Q-Table*, *policy* yang dihasilkan, serta performa robot dalam mencapai tujuan dan menghindari *obstacle*. Analisis dilakukan berdasarkan efisiensi jalur, keberhasilan navigasi, serta kemampuan adaptasi robot terhadap lingkungan.

BAB V PENUTUP

Bab ini berisi kesimpulan dari hasil penelitian yang telah dilakukan serta pencapaian tujuan yang telah ditetapkan. Selain itu, diberikan saran untuk pengembangan lebih lanjut, seperti penerapan metode *deep reinforcement learning*, penggunaan sensor nyata, atau pengembangan sistem navigasi pada lingkungan yang lebih kompleks.