

BAB I PENDAHULUAN

1.1 Latar Belakang

Tanaman cabai merupakan salah satu komoditas hortikultura unggulan di Indonesia dengan tingkat produksi yang tinggi, masifnya angka panen sehingga tanaman cabai menempati peringkat tertinggi dibandingkan dengan sayuran lainnya [1]. Indonesia berada pada posisi keempat dunia sebagai negara penghasil cabai dengan menyumbangkan sekitar 5% dari total produksi *global* [2]. Tingginya permintaan cabai baik dalam negeri maupun luar negeri menunjukkan potensi sebagai komoditas dengan keuntungan yang besar, misalnya untuk kebutuhan bumbu masak, industri makanan, dan obat-obatan [1].

Namun, terdapat risiko besar dalam budidaya tanaman cabai seperti gagal panen. Hal ini disebabkan oleh tanaman cabai yang sangat rentan terhadap serangan hama atau penyakit, dan manajemen input pertanian yang buruk [3]. Tantangan semakin kompleks, termasuk perubahan iklim, penurunan sumber daya alam, dan peningkatan kebutuhan pangan sejalan dengan pertumbuhan populasi dunia [3]. Mengoptimalkan hasil pertanian perlu memperhatikan *input* pertanian seperti penggunaan pupuk dan air. Pemakaian pupuk sebagai salah satu *input* utama dalam pertanian harus diperhatikan agar meminimalkan dampak negatif terhadap lingkungan dan memastikan kesuburan jangka panjang tanah pertanian [4][5]. Selain itu pemupukan dan pengairan yang tidak sesuai kebutuhan bisa berdampak pada gangguan pertumbuhan tanaman dan kerentanan terhadap penyakit [5].

Pengairan dan pemupukan yang sesuai kebutuhan tanaman cabai serta adaptif terhadap kondisi fluktuatif lingkungan menjadi salah satu kunci memaksimalkan hasil pertanian. Kebutuhan TDS nutrisi untuk cabai maksimum adalah 1200 – 1540 ppm dan TDS fase vegetatif yang disarankan 600 ppm [6][7]. Teknologi Reinforcement learning (RL) diusulkan dalam pengendalian *Total Dissolved Solids* (TDS) untuk manajemen nutrisi yang adaptif terhadap dinamika lingkungan dengan tingkat akurasi tinggi. Lingkungan yang acak dan masalah yang kompleks dapat dimodelkan secara matematis dengan *Markov Decision Process* (MDP) [8]. Elemen MDP dalam penelitian ini didefinisikan sebagai *state* yaitu kondisi TDS air dan

TDS nutrisi, *action* yaitu tindakan mengatur banyaknya volume air dan nutrisi, dan *reward* sebagai umpan balik yang mengarahkan agen menghasilkan kebijakan terbaik. Algoritma Q-learning dapat diterapkan untuk mencari kebijakan optimal (*optimal policy*) yang memetakan setiap kondisi lingkungan ke aksi pencampuran yang paling akurat[9]. Penelitian menggunakan algoritma Q-learning, dimana model ini dirancang untuk masalah diskret yang dinamis dengan komputasi yang rendah cocok untuk sistem dengan memori terbatas [10]. Tantangan lainnya adalah elemen MDP yang dibaca melalui sensor bernilai kontinu. Hal ini membuat tabel Q pada Q-learning membengkak dan memori komputasi tidak akan mampu memprosesnya. Kekurangan model Q-learning tersebut dapat diatasi dengan menerapkan strategi diskretisasi menggunakan metode *Equal Width Binning* [11]. Metode ini mentransformasi data kontinu dari sensor menjadi bentuk interval diskret (*bins*) dengan lebar yang seragam.

Q-learning dipilih dalam penelitian ini karena kemampuannya untuk belajar dari interaksi dengan lingkungan MDP tanpa memerlukan model lingkungan yang nyata [9]. Meskipun Q-learning memiliki keterbatasan dalam menangani masalah yang terlalu dinamis dan kompleks, penelitian ini mengusulkan strategi diskretisasi dengan *Equal Width Binning* [12][13]. Variabel kontinu didiskretisasi dengan inisialisasi awal *input* lingkungan dan strategi penggunaan interval untuk membaginya kedalam beberapa kondisi, sehingga memungkinkan semua kondisi dinamis dapat dipelajari model [10][12]. Hasilnya adalah model kebijakan optimal penggunaan pupuk dengan metode pengendalian TDS berbasis Q-learning untuk tanaman cabai.

1.2 Penelitian Terdahulu

Pada beberapa tahun terakhir, penelitian-penelitian terkait optimasi *input* pertanian berbasis Reinforcement learning telah banyak dilakukan. Tabel 1.1 berikut menunjukkan penelitian-penelitian tersebut.

Table 1.1 Penelitian terdahulu.

No.	Judul	Peneliti	Tahun
1	Modifikasi Algoritma Q-Learning untuk Pemilihan Jalur Optimal dalam Lingkungan Pertanian	Fitriani, Zahra	2024
2	<i>Nitrogen management with Reinforcement learning and crop growth models</i>	Kallenberg M, Overweg H, van Bree R, dkk.	2023
3	<i>Optimizing Nitrogen Management with Deep Reinforcement learning and Crop Simulations</i>	Wu J, Tao R, Zhao P, dkk.	2022
4	<i>Robot Obstacle Avoidance dengan Algoritma Q-learning</i>	Agustian I, Surapati A, dkk	2020
5	Perancangan Pengatur Kandungan TDS dan PH pada Larutan Nutrisi Hidroponik Menggunakan Metode <i>Fuzzy Logic</i>	Dewa W, Somawirata I, dkk.	2020

Tabel 1.1 adalah beberapa penelitian terdahulu yang berkaitan dengan penelitian ini sebagai penegasan keaslian karya ilmiah yang dibuat agar terciptanya ide-ide baru dalam dunia teknologi yang berkembang sekarang dan menjelaskan perbandingan terhadap riset yang telah dilakukan sebelumnya yang menjadi acuan pembuatan tugas akhir ini.

Penelitian oleh Fitriani Z [14] mengembangkan modifikasi algoritma Q-Learning dengan pendekatan konsep *flow* untuk perencanaan jalur robot pertanian pemanen buah. Studi yang dilakukan di ATP IPB Cikarawang ini bertujuan mengatasi tantangan efisiensi pada lahan terbatas dengan meminimumkan total *state*, jumlah belokan dan total waktu tempuh. Hasil eksperimen menunjukkan bahwa modifikasi tersebut mampu meningkatkan efisiensi secara signifikan, yaitu mereduksi jumlah belokan sebesar 68,42% dan memangkas total waktu tempuh

hingga 21,62% dibandingkan algoritma standar, membuktikan keandalan Q-Learning dalam menyelesaikan masalah optimasi di lingkungan pertanian nyata.

Kallenberg M, Overweg H, van Bree R, dkk [15] dalam papernya memperkenalkan *CropGym*, sebuah lingkungan Gimnasium untuk agen mempelajari kebijakan manajemen pertanian seperti pemupukan menggunakan model pertumbuhan tanaman berbasis proses. Sebagai studi kasus, paper ini melaporkan penemuan strategi penerapan aplikasi pupuk nitrogen pada tanaman gandum di musim dingin yang bertujuan untuk menyeimbangkan, memaksimalkan hasil dan meminimalkan dampak lingkungan. Evaluasi dilakukan pada model dan diperoleh agen RL tahan terhadap perubahan kondisi iklim. Ditemukan bahwa, ketika curah hujan cukup, agen RL tetap mendekati kebijakan optimal. Hasil menunjukkan bahwa strategi yang dipelajari agen RL mendekati optimal dan dapat bersaing dengan praktik standar yang ditetapkan para ahli.

Wu J, Tao R, Zhao P, dkk [16] mengusulkan sistem manajemen nitrogen (N) cerdas menggunakan *Deep Reinforcement learning* dan simulasi tanaman dengan Decision Support System for Agrotechnology Transfer (DSSAT). DSSAT adalah alat atau perangkat lunak yang membantu dalam membuat keputusan terkait transfer teknologi pertanian. Nitrogen (N) merupakan nutrisi penting bagi tanaman yang memainkan peran signifikan terhadap manajemen pertanian, sehingga N dirumuskan sebagai masalah RL. Dengan menggunakan *gym-DSSAT* sebagai lingkungan simulasi agen RL untuk belajar kebijakan optimal manajemen nitrogen menggunakan *Deep Q-Network (DQN)* dan *Soft Actor-Critic (SAC)*. Berdasarkan eksperimen pada kebun jagung di Iowa dan Florida. Hasil menunjukkan efektivitas kebijakan yang dilatih RL dalam mengoptimalkan manajemen N dan meminimalkan dampak lingkungan negatif.

Agustian I, Surapati A, dkk [10] dalam penelitiannya menggunakan algoritma Q-learning pada sistem prototipe robot *obstacle avoidance*. Mikrokontroler ATmega2560 digunakan sebagai pusat kontrol robot yang dilengkapi sensor ultrasonik HC-SR04 dan sensor IR sharp GP2Y0A21YK0F. Percobaan dilakukan sebanyak 300 kali dengan nilai *learning rate* optimal adalah 0,5 dan *discount factor*

di angka 0,9 setelah mencapai percobaan yang ke-250. Berdasarkan eksperimen yang dilakukan, parameter *state space* dibagi menjadi 144 kondisi berdasarkan himpunan interaksi yang dihasilkan pembacaan sensor-sensor, sedangkan *action space* dibagi menjadi lurus, dan belok (kanan dan kiri). Untuk meringankan beban komputasi yang menjadi kelemahan model Q-learning [13], Agustian I, dkk membagi pembacaan sensor menjadi 4 zona berdasarkan rentang jarak. Robot mampu dengan cepat beradaptasi pada medan dengan rintangan statis, tetapi lebih lamban pada medan dengan rintangan yang dinamis.

Dewa W, Somawirata I, dkk [17] mengusulkan sistem kontrol berbasis logika *fuzzy* untuk mengatur tingkat pH dan TDS dalam larutan nutrisi hidroponik. Hidroponik adalah metode pertanian yang menggunakan air sebagai media pertumbuhan dengan larutan nutrisi. Kadar nutrisi pH dan TDS (*Total Dissolved Solids*) sangat penting untuk pertumbuhan tanaman hidroponik. Idealnya agar tanaman tumbuh maksimal, perlu kandungan pH sekitar kisaran 5,5-6,5, dan TDS kisaran 1050-1200 ppm. Untuk menjaga kandungan nutrisi dalam air optimal, diperlukan sistem kontrol otomatis manajemen nutrisi. Makalah ini mengusulkan sistem kontrol otomatis berbasis logika *fuzzy* untuk mengatur tingkat pH dan TDS dalam larutan nutrisi hidroponik. Hasil eksperimen menunjukkan bahwa sistem logika *fuzzy* dapat berfungsi secara efektif, dengan *error rate* 4,83% dalam pengukuran pH dan *error rate* 8,29% dalam pengukuran TDS.

Berdasarkan penelitian terdahulu berbagai metode telah dilakukan dengan hasil yang mendekati optimal. Pada penelitian sebelumnya terkait kontrol nutrisi menggunakan metode *fuzzy logic*, sistem dapat berfungsi secara efektif. Namun metode ini memiliki kekurangan jika diaplikasikan pada lingkungan dengan masalah kompleks. Metode *fuzzy logic* cocok digunakan pada lingkungan ruang diskret dengan keadaan tertentu, contohnya kering, normal, dan lembab untuk menyatakan kondisi tanah. Berbeda dengan metode pembelajaran mesin RL, yang cocok diaplikasikan pada ruang lingkungan yang lebih kompleks. RL memiliki banyak kelebihan dibanding metode *fuzzy*. RL dapat secara dinamis belajar untuk mengoptimalkan kebijakan dengan cara berinteraksi secara langsung dengan lingkungan simulasi. Metode RL ini dapat belajar pola temporal,

mempertimbangkan efek jangka panjang dari mulai *input* pertanian sampai *output* pertanian. Sehingga sangat cocok untuk pertanian cerdas berkelanjutan.

Maka dari itu, penelitian ini akan menggunakan metode RL model algoritma Q-learning untuk manajemen *input* pertanian seperti pemupukan dengan sistem pengendalian TDS untuk tanaman cabai. Berdasarkan penelitian terdahulu mengenai manajemen input pertanian menggunakan RL, lingkungan simulasi untuk agen belajar seperti *gym-DSSAT*, *CropGym*, telah dikembangkan untuk membantu melatih agen *deep* RL membuat kebijakan optimal. *Deep Reinforcement Learning* (DRL) mampu bekerja dengan superior pada ruang keadaan dimensi tinggi, arsitektur jaringan saraf tiruan menuntut sumber daya komputasi dan memori yang masif. Kompleksitas tersebut kurang signifikan untuk implementasi pada mikrokontroler berbiaya rendah seperti ESP32 yang umum digunakan. Model pembelajaran Q-learning dipilih karena memiliki keunggulan dibanding model RL lain yang lebih kompleks. Q-learning lebih membutuhkan sedikit sumber daya komputasi dan memori, sangat cocok untuk diaplikasikan pada sistem atau mikrokontroler dengan daya penyimpanan memori yang rendah [10]. Penelitian Fitriani Z. [14] menegaskan efektivitas algoritma Q-learning pada ruang keadaan diskret, seperti navigasi *grid-based* pada robot pemanen. Temuan ini sekaligus memperkuat karakteristik Q-learning yang bekerja optimal pada lingkungan dengan parameter diskret. Oleh karena itu, pada sistem dengan variabel kontinu seperti pengendalian TDS nutrisi, algoritma Q-learning dengan strategi diskretisasi sangatlah perlu. Metode ini mengubah data sensor kontinu menjadi *state* terbatas (diskret), memungkinkan agen menyusun kebijakan optimal (*optimal policy*) secara efisien tanpa membuat dimensi komputasi bengkak.

1.3 Rumusan Masalah

Adapun rumusan masalah pada penelitian ini yaitu:

1. Bagaimana desain dan implementasi model Q-learning dalam pengendalian TDS penggunaan pupuk yang adaptif terhadap dinamika lingkungan pada budidaya tanaman cabai?
2. Bagaimana kinerja model Q-learning dalam pengendalian TDS penggunaan pupuk yang adaptif terhadap dinamika lingkungan pada budidaya tanaman cabai berdasarkan kebutuhan TDS nutrisi setiap fase tanaman?

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Membuat desain dan implementasi model Q-learning dalam pengendalian TDS penggunaan pupuk yang adaptif terhadap dinamika lingkungan pada budidaya tanaman cabai.
2. Menganalisis kinerja model Q-learning dalam pengendalian TDS penggunaan pupuk yang adaptif terhadap dinamika lingkungan pada budidaya cabai berdasarkan kebutuhan TDS nutrisi setiap fase tanaman.

1.5 Manfaat Penelitian

Adapun manfaat yang diperoleh dari penelitian ini adalah sebagai berikut:

1. Manfaat Akademis: Penelitian ini diharapkan dapat berkontribusi pada pengembangan sistem pemberian nutrisi dengan pengendalian TDS berdasarkan kebutuhan tanaman. Hasil penelitian ini dapat menjadi sumber rujukan dalam pengembangan sistem pertanian cerdas dengan menggunakan kecerdasan buatan.
2. Manfaat Praktis: Pengaplikasian model optimal pemberian pupuk dengan pengendalian TDS berbasis Q-learning untuk tanaman ini, dapat membantu dalam manajemen input pertanian yang lebih akurat. Metode pengendalian TDS nutrisi berbasis Q-learning dapat secara otomatis menentukan pompa menyala berdasarkan aksi (*action*) terbaik secara adaptif berdasarkan informasi lingkungan (*state*) TDS air dan TDS nutrisi yang dinamis.

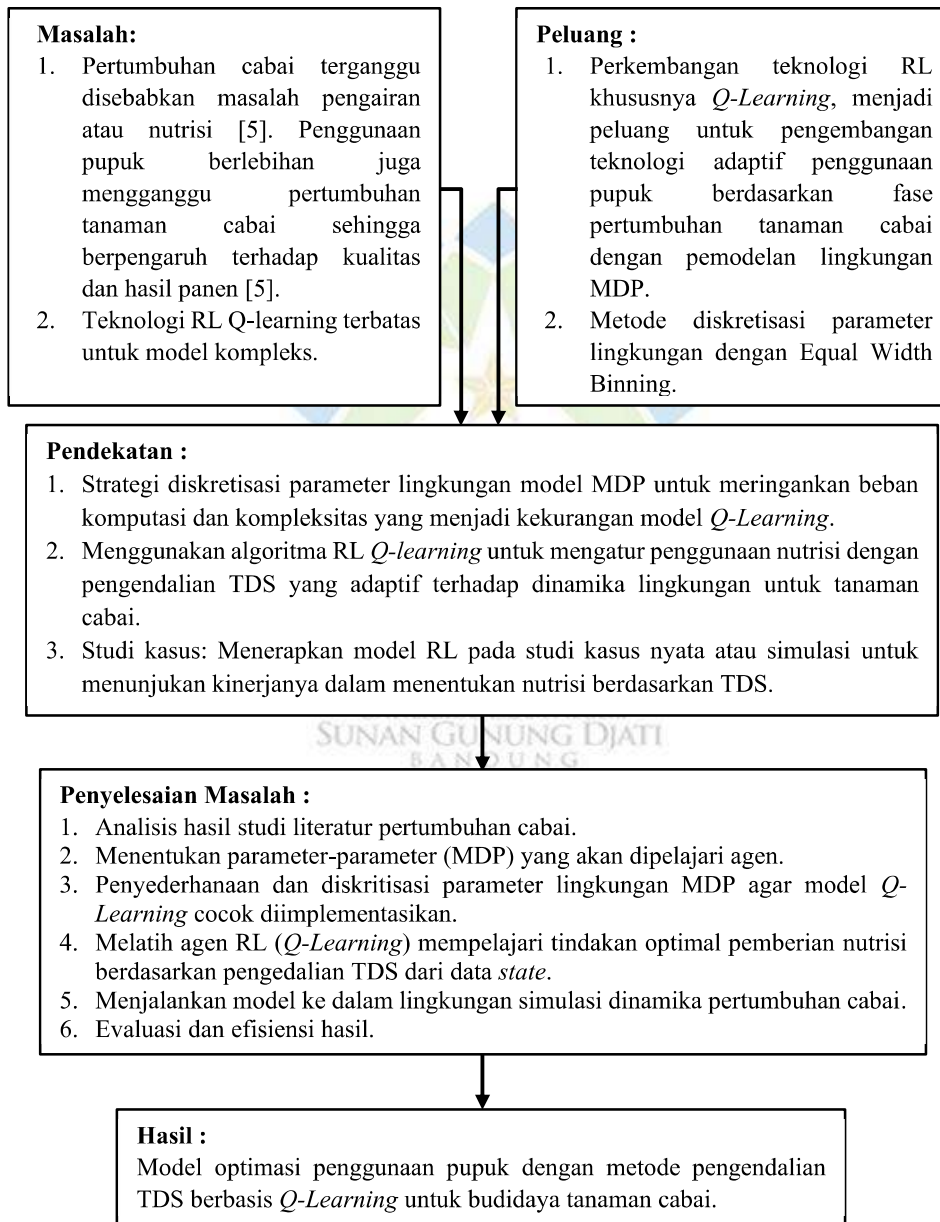
1.6 Batasan Masalah

Ruang lingkup yang berhubungan dengan masalah ini sangat luas, maka dari itu perlu adanya batasan masalah dalam penelitian ini agar lebih spesifik dan terarah. Batasan masalah ini fokus kepada sebagaimana yang diuraikan berikut ini:

1. Penelitian ini berfokus pada model optimasi penggunaan pupuk dan pengendalian TDS untuk tanaman cabai sebagai subjek utama, dengan kebutuhan TDS nutrisi tanaman 600 – 1200 ppm naik secara berkala berdasarkan umur tanaman [6][7]. Detail tentang perancangan sistem, dan pengelolaan sistem tidak termasuk dalam lingkup penelitian ini.
2. Penelitian ini terfokus pada pengembangan algoritma RL model algoritma Q-learning yang akan bekerja berdasarkan data keadaan *input* lingkungan (*state*) berupa nilai TDS, untuk menghasilkan nilai TDS yang telah ditentukan berdasarkan umur tanaman.
3. Pengembangan model algoritma RL pada penelitian ini menggunakan bahasa pemrograman *python*.
4. Model hasil pelatihan akan diuji menggunakan simulasi dinamika kondisi lingkungan (*state*) selama 45 hari di perangkat komputer secara langsung, untuk mengetahui secara langsung kinerja model dalam satu siklus pertumbuhan.
5. Model dalam penelitian ini menggunakan nilai awal TDS air dan nutrisi yang telah dikondisikan dalam rentang tertentu, untuk memastikan tetap berada dalam ruang kondisi (*state space*) yang digunakan selama proses pelatihan. Jika nilai *input* TDS di luar rentang maka diperlukan pelatihan ulang. Namun, dalam ruang lingkup penelitian ini, pembahasan tidak mencakup pelatihan ulang untuk rentang nilai yang berbeda, karena prinsip dan metodologi yang digunakan tetap sama.
6. Hasil utama dari penelitian ini yaitu algoritma Q-learning yang dioptimasi dan penyesuaian model untuk tanaman cabai, dengan tujuan utama menciptakan model pengendalian TDS pupuk yang adaptif terhadap perubahan *state* (TDS air dan TDS nutrisi) yang dinamis.

1.7 Kerangka Berpikir

Kerangka berpikir berisi uraian pemikiran sistematis tentang hasil perumusan masalah penelitian yang diperkirakan dapat diselesaikan melalui pendekatan yang dibutuhkan untuk memudahkan pemahaman mengenai alur logis penelitian, dan bentuk kasar dari struktur penelitian.



Gambar 1.1 Kerangka berpikir penelitian

1.8 Sistematika Penulisan

Dalam mendapatkan struktur penyusunan data dan penulisan yang baik, kerangka dan sistematika laporan ini mengikuti aturan yang telah ditentukan. Sistematika Penulisan tugas akhir ini terdiri dari:

BAB I PENDAHULUAN

Bab ini berisi latar belakang, penelitian terdahulu, rumusan masalah, manfaat, batasan masalah, kerangka berpikir dan sistematika penulisan.

BAB II TEORI DASAR

Pada bab ini menjelaskan tentang hal-hal pokok sebelum melakukan penelitian. Diperlukan pemahaman teori yang dibekali sumber referensi untuk dilakukan pengkajian terhadap bahasan penelitian.

BAB III METODOLOGI

Pada bab ini menjelaskan metode dan tahapan-tahapan yang dilakukan ketika melakukan penelitian diantaranya studi literatur, identifikasi masalah, analisis kebutuhan, perancangan model, implementasi model, pengujian model, dan analisis hasil.

BAB IV PERANCANGAN DAN IMPLEMENTASI

Pada bab ini menjelaskan tahapan-tahapan yang dilakukan untuk merancang model dan mengimplementasikan model Q-learning hasil pelatihan kedalam simulasi pertumbuhan cabai.

BAB V PENGUJIAN DAN ANALISIS

Pada bab ini menjelaskan tentang pengujian yang dilakukan untuk menentukan sejauh mana kinerja model berdasarkan analisis hasil.

BAB VI PENUTUP

Menjelaskan tentang kesimpulan penelitian yang telah dilakukan, serta berisi saran yang dapat menjadi acuan untuk penelitian-penelitian selanjutnya.