

BAB I PENDAHULUAN

1.1 Latar Belakang Masalah

Wireless Sensor Network (WSN) merupakan sistem terdistribusi yang terdiri dari node sensor mandiri yang mendapatkan daya dari sistem energi terbarukan, yaitu panel surya. Energi yang dihasilkan oleh panel surya disimpan dalam baterai isi ulang dan kemudian digunakan untuk mengoperasikan unit-node WSN. Setiap node WSN terdiri atas tiga komponen utama yaitu *sensing unit*, *processing unit*, dan *communication unit* (Sadeq dkk., 2022a), (Zhao, T. dkk., 2020). Unit sensor bertugas mengumpulkan data dari lingkungan menggunakan sensor yang terhubung dengan konverter analog-ke-digital (ADC). Data yang dihimpun oleh unit sensor kemudian diteruskan ke unit pemrosesan yang terdiri dari prosesor dan memori untuk melakukan analisis awal dan pengolahan data. Setelah data diproses, unit komunikasi akan mentransmisikan data tersebut ke node lain atau ke pusat pengendali melalui perangkat transceiver dan receiver (Khalifeh dkk., 2021), (Sibi & Annabel, 2024a). WSN beroperasi secara mandiri di lokasi terpencil, menggunakan energi matahari dan baterai cadangan untuk menjaga operasional. Struktur modular ini memungkinkan pemantauan lingkungan secara *real-time*, hemat energi, dan berkelanjutan.

Penempatan node yang tidak optimal dapat menyebabkan masalah seperti cakupan yang tidak merata dan area mati (*coverage hole*), konsumsi energi yang tidak seimbang, overlapping sensing dan redundansi data, gangguan konektivitas jaringan, ketidakmampuan beradaptasi dengan perubahan lingkungan (Mottaki dkk., 2023; P. Anusuya, C. N. Vanitha, Jaehyuk Cho, 2024). WSN menggunakan energi terbarukan dari panel surya untuk beroperasi secara mandiri. Energi matahari ditangkap oleh panel surya, dikontrol oleh PWM/MPPT untuk efisiensi maksimum, lalu dikonversi melalui DC-DC converter dan disimpan dalam baterai isi ulang yang mendukung operasi node WSN. Masalah utama adalah ketergantungan pada sinar matahari, sehingga operasi terganggu saat cuaca mendung atau di lokasi kurang cahaya. Efisiensi konversi daya yang rendah pada DC-DC converter dan pengontrol

MPPT dapat mengakibatkan baterai tidak terisi secara maksimal (Prauzek dkk., 2020). Degradasi baterai akibat siklus pengisian yang berulang dapat menjadi masalah, terutama jika tidak didukung oleh manajemen daya yang baik (Han dkk., 2019; Vennam dkk., 2022). Komponen komunikasi dalam WSN sangat boros energi dan dapat menguras daya jika tidak diatur dengan baik. Ketidakseimbangan beban antara sensor, prosesor, dan komunikasi dapat menyebabkan kegagalan fungsi saat daya rendah (Areibi, 2016; Sadeq dkk., 2022b). Selain itu, sistem mungkin tidak dapat beradaptasi dengan kondisi lingkungan yang ekstrem, sehingga mempengaruhi keandalan operasional jangka panjang. Integrasi semua komponen dalam satu node menghadirkan tantangan dalam hal sinkronisasi dan efisiensi kerja (Yujiang Li, 2024).

Konsumsi energi dalam Jaringan sensor nirkabel (WSN) dipengaruhi oleh beberapa faktor, termasuk transmisi data, pemrosesan, dan penginderaan. Namun, sumber utama konsumsi energi adalah kegiatan komunikasi, seperti pengiriman dan penerimaan data, yang memerlukan daya jauh lebih besar dibandingkan dengan tugas pengindraan dan pemrosesan. Transmisi dan penerimaan data merupakan faktor utama dalam penggunaan energi, bahkan melebihi operasi lainnya, sehingga menjadi area penting untuk dioptimalkan (Jyoti & Pal, 2023), (Mutombo dkk., 2021), (Sadeq dkk., 2022b). Selain itu, kepadatan penempatan node yang berlebihan dapat meningkatkan konsumsi daya akibat tumpang tindih area penginderaan dan transmisi data yang tidak efisien. Pentingnya pemilihan protokol perutean juga tidak bisa diabaikan. Memilih protokol yang dapat menyesuaikan rute secara dinamis berdasarkan tingkat energi dan kondisi jaringan terbukti mampu mengurangi pengeluaran energi secara keseluruhan (G.N & C.D, 2019), (Kumar & Asbe, 2023). Terakhir, implementasi penjadwalan tidur (*sleep scheduling*) dengan cara mematikan radionya secara berkala terbukti sangat efektif dalam mengurangi konsumsi energi, terutama pada skenario dengan lalu lintas data yang rendah (Sinde dkk., 2020).

Optimalisasi konsumsi energi melalui strategi perutean, agregasi data, dan mode tidur adalah metode yang signifikan dalam mengurangi penggunaan energi.

Protokol perutean yang cerdas secara efisien dapat mengidentifikasi jalur optimal dengan mempertimbangkan sisa energi pada node, keandalan tautan, dan kemampuan agregasi data. Sebagai ilustrasi, metodologi perutean berbasis Q-learning secara dinamis menentukan jalur terbaik berdasarkan metrik efisiensi energi, sebagaimana ditunjukkan oleh penelitian (Kumar & Asbe, 2023), (Su dkk., 2023). Selain itu, teknik agregasi data memainkan peranan krusial. Dengan menggabungkan informasi dari berbagai sumber, metode ini mampu mengurangi volume total data yang ditransmisikan, sehingga meminimalkan pengiriman data yang berlebihan (Jyoti Jyoti, 2023), (Yun & Yoo, 2021). Terakhir, teknik mode tidur memiliki efektivitas tinggi. Node dapat dikonfigurasi untuk memasuki mode tidur selama periode tidak aktif, yang secara signifikan mengurangi konsumsi energi. Algoritma deep reinforcement learning yang canggih bahkan mampu mengoptimalkan jadwal tidur dengan menggunakan data historis dan menyesuaikannya dengan kebutuhan jaringan (Ergun dkk., 2022), (Li, Y. & Cao, 2024), (Singh dkk., 2023).

Strategi penempatan node merupakan aspek penting dalam pengembangan Jaringan Sensor Nirkabel (WSN) yang efisien dan dapat diandalkan. Tujuan utama dari strategi ini adalah untuk memastikan cakupan wilayah yang optimal serta konektivitas antar-node yang kuat, sambil mengurangi konsumsi energi secara bersamaan. Mencapai keseimbangan tersebut adalah tantangan kompleks, terutama karena setiap node memiliki keterbatasan sumber daya dan penempatan yang kurang tepat dapat menyebabkan pemborosan energi yang signifikan (Sreekala, 2024; Zhang, L., dkk., 2024). Berbagai teknik telah dikembangkan untuk mengoptimalkan penempatan node. Salah satunya adalah pengelompokan (clustering) node, di mana satu node ditunjuk sebagai kepala kluster (cluster head). Kepala kluster mengumpulkan data dari anggota node, melakukan agregasi data, kemudian mengirimkannya ke stasiun pangkalan. Pendekatan ini mengurangi transmisi data langsung dan menghemat energi. Algoritma seperti Grey Wolf Optimizer (GWO) sering digunakan untuk mengoptimalkan pengelompokan dan

pemilihan kepala klaster agar penggunaan energi lebih efisien (Devika & Shaby, 2024; Shabbir dkk., 2024; Shobana & Samraj, 2024).

Kemajuan dalam kecerdasan buatan, khususnya pembelajaran penguatan (reinforcement learning), menghadirkan solusi yang bersifat dinamis. Algoritma seperti Q-learning memberikan kemampuan kepada node untuk belajar dan menyesuaikan posisinya secara adaptif berdasarkan metrik kinerja jaringan, termasuk cakupan serta tingkat energi. Dengan memanfaatkan kemampuan belajar dari pengalaman dan imbalan yang diterima, node mampu menemukan konfigurasi optimal yang dapat meningkatkan performa keseluruhan jaringan (Yao dkk., 2024). Algoritma metaheuristik memberikan pendekatan untuk menemukan posisi node yang optimal. Algoritma seperti Intelligent Satin Bower Bird Optimizer (ISBO) menggunakan perilaku alamiah untuk menjelajahi ruang solusi, mencari penempatan node terbaik yang dapat meningkatkan cakupan area yang dipantau dan memperkuat konektivitas di seluruh jaringan. Kombinasi strategi ini memungkinkan perancangan WSN yang efektif dalam pengumpulan data dan berkelanjutan dalam operasi jangka panjang melalui manajemen energi yang efisien (Kusuma dkk., 2024).

Integrasi antara Generative Adversarial Networks (GAN) dan Q-learning menyediakan pendekatan untuk manajemen energi pada Jaringan sensor Nirkabel (WSN). Kerangka kerja GAN-Q-Learning ini berfungsi dalam mengoptimalkan konsumsi energi dan strategi penempatan node. Pada dasarnya, GAN mencakup generator dan diskriminator sebagai simulasi cerdas. Generator menghasilkan sampel data sintesis mengenai skenario manajemen energi di WSN, seperti pola konsumsi daya, lalu lintas data, atau perubahan kondisi lingkungan. Diskriminator bertugas membedakan antara data asli dan data yang dihasilkan generator, memastikan kualitas tinggi dan realistis dari data sintesis tersebut (Li, J. & Feng, 2024), (N. Alsalmi, K. Navaie, 2024). Q-learning adalah algoritma pembelajaran penguatan bebas model yang bertujuan menemukan kebijakan optimal dengan cara memaksimalkan hadiah kumulatif. Dalam konteks WSN, penggunaan Q-learning memungkinkan optimasi berbagai keputusan, seperti perutean data yang efisien,

strategi penempatan node adaptif, dan alokasi energi yang cerdas. Kombinasi antara GAN dan Q-learning dapat memberikan kepada agen Q-learning data atau skenario lingkungan yang kaya dan realistis (Anusuya dkk., 2024). Ini memungkinkan agen Q-learning untuk berlatih dan menguji kebijakan manajemen energinya dalam beragam kondisi hipotetis yang dihasilkan oleh GAN, tanpa perlu menguras energi node fisik atau menghabiskan waktu pada eksperimen dunia nyata. Hasilnya adalah kebijakan manajemen energi yang lebih adaptif, tangguh, dan efisien, yang mampu merespons perubahan dinamis dalam kondisi jaringan dan lingkungan secara real-time, sehingga memperpanjang lifetime dan meningkatkan performa WSN secara signifikan.

Berdasarkan kondisi tersebut, penelitian ini mengusulkan AEMGQ (*Adaptive Energy Model Based on GAN-Q-Learning*) sebagai kerangka model energi adaptif untuk optimalisasi efisiensi energi, peningkatan kinerja, dan perpanjangan umur jaringan pada WSN. Pada model ini, Q-learning digunakan sebagai inti mekanisme pengambilan keputusan adaptif karena mampu mempelajari kebijakan terbaik dari interaksi berulang dengan lingkungan. Dalam konteks WSN, pendekatan ini relevan untuk menentukan aksi operasional seperti *sleep*, *harvest*, *transmit*, *relay*, dan *transfer* berdasarkan kondisi jaringan, ketersediaan energi, dan kebutuhan komunikasi secara dinamis. Agar agen pembelajaran tidak hanya bergantung pada data nyata yang terbatas, AEMGQ juga mengintegrasikan Generative Adversarial Networks (GAN) untuk menghasilkan data lingkungan sintetik yang realistis dan beragam. Pendekatan generatif ini penting karena kondisi ekstrem pada WSN, seperti rendahnya energi panen atau lonjakan trafik mendadak, sering kali jarang muncul pada data aktual, namun sangat menentukan kualitas kebijakan yang dipelajari. GAN telah dikenal sebagai kerangka yang kuat untuk pembangkitan data realistis, khususnya pada domain dengan keterbatasan data, sehingga integrasinya dengan Q-learning diharapkan mampu memperkaya ruang pelatihan dan meningkatkan robustitas model adaptif.

Integrasi langsung antara model generatif dan *reinforcement learning* untuk membangun model energi adaptif WSN yang berorientasi pada keberlanjutan

operasi. Berbeda dengan studi terdahulu yang cenderung memisahkan optimasi routing, sleep scheduling, atau energy harvesting ke dalam modul-modul yang berdiri sendiri, AEMGQ memadukan pembangkitan data sintetis berbasis GAN dengan kebijakan pengambilan keputusan berbasis Q-learning dalam satu kerangka yang saling mendukung. Dengan demikian, agen tidak hanya belajar dari kondisi historis, tetapi juga dari variasi kondisi sintetis yang disusun untuk memperluas pengalaman belajar pada skenario yang lebih kompleks (Feng & Li, 2023; Savaglio dkk., 2019; Sibi & Annabel, 2024; Su dkk., 2023). Selain itu, desain ruang keadaan dan tujuan optimasi yang lebih komprehensif. AEMGQ tidak hanya mempertimbangkan energi tersedia secara langsung, tetapi juga mengintegrasikan konteks lingkungan, intensitas trafik data, SoC, serta SoH baterai dalam proses pembentukan kebijakan. Pendekatan ini menggeser orientasi model dari sekadar meminimalkan konsumsi energi menuju pengelolaan energi jangka panjang yang memperhitungkan kesehatan sumber daya dan stabilitas performa jaringan. Dengan kata lain, kontribusi konseptual penelitian ini adalah mempertemukan *energy efficiency*, *performance awareness*, dan *lifetime extension* dalam satu model pembelajaran yang adaptif.

Penelitian ini diarahkan pada beberapa indikator kinerja utama, yaitu konsumsi energi rata-rata, masa pakai jaringan, stabilitas konvergensi agen, efisiensi pengambilan keputusan, serta dampaknya terhadap performa jaringan seperti keterlambatan, reliabilitas rute, dan efisiensi transmisi data. Selain membandingkan AEMGQ dengan pendekatan konvensional, evaluasi juga penting untuk menguji apakah integrasi GAN benar-benar meningkatkan ketangguhan kebijakan Q-learning ketika model dihadapkan pada kondisi yang jarang muncul pada data nyata. Kerangka evaluasi seperti ini sejalan dengan tren studi mutakhir yang menilai efektivitas metode adaptif bukan hanya dari satu metrik energi, melainkan juga dari performa jaringan secara menyeluruh.

Pengembangan model energi cerdas untuk WSN yang menghubungkan tiga ranah yang selama ini relatif terpisah, yaitu manajemen pengambilan energi, *reinforcement learning*, dan pemodelan data generatif. Secara praktis, AEMGQ

diharapkan menjadi dasar bagi perancangan node dan protokol WSN yang lebih efisien, tangguh, dan berkelanjutan, terutama pada aplikasi IoT yang menuntut operasi jangka panjang dengan intervensi minimal. Dengan demikian, penelitian ini tidak hanya menawarkan solusi teknis untuk optimasi energi, tetapi juga memperkuat arah baru pengembangan WSN menuju sistem otonom yang mampu “belajar menjaga keberlangsungan energinya sendiri”.

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang telah diuraikan, berikut adalah identifikasi masalah utama dalam penempatan node pada Wireless Sensor Network (WSN):

1. Strategi penempatan node yang statis dan tidak adaptif. Metode penempatan node konvensional biasanya bersifat statis dan kurang mampu beradaptasi dengan perubahan kondisi lingkungan atau jaringan. Selain itu, metode ini juga tidak mampu melakukan penyesuaian posisi node secara dinamis berdasarkan fluktuasi energi, kualitas sinyal, atau kegagalan node.
2. Ketidakseimbangan konsumsi energi akibat penempatan yang tidak optimal. Node yang ditempatkan di posisi strategis, seperti sebagai cluster head atau relay, menghadapi beban komunikasi yang tinggi sehingga cepat menghabiskan energi. Tidak ada mekanisme untuk merotasi peran node yang berguna untuk menyebarkan beban energi secara seimbang.
3. Cakupan area yang tidak merata dan adanya *coverage holes*. Penempatan node yang tidak terencana dengan baik mengakibatkan area yang tidak terpantau (*coverage holes*), mengurangi efektivitas sistem. Kurangnya kemampuan untuk mendeteksi dan memperbaiki *coverage holes* secara otomatis.
4. Keterbatasan data lingkungan untuk pelatihan sistem cerdas. Data lingkungan nyata seringkali terbatas dan tidak mencakup skenario ekstrem, sehingga menghambat pelatihan model AI yang robust. Tidak adanya simulasi kondisi lingkungan yang dinamis dan realistis untuk mengoptimalkan strategi.
5. Tidak terintegrasinya pengetahuan domain dalam pengambilan keputusan. Model penempatan node yang ada belum memanfaatkan pengetahuan domain

- seperti karakteristik baterai, efisiensi panel surya, dan pola trafik data secara optimal. Kurangnya integrasi antara model fisik perangkat dengan algoritma.
6. Rendahnya kemampuan prediktif terhadap perubahan lingkungan. Sistem penempatan konvensional tidak mampu memprediksi perubahan lingkungan (seperti cuaca, interferensi) yang dapat memengaruhi kinerja jaringan. Tidak adanya mekanisme untuk mengantisipasi kegagalan node atau penurunan konektivitas.
 7. Belum adanya integrasi antara generative ai dan reinforcement learning (q-learning) untuk penempatan node. Potensi Generative Adversarial Network (GAN) untuk menghasilkan data lingkungan sintetis yang realistis belum dimanfaatkan dalam konteks penempatan node. Q-Learning sebagai algoritma adaptif belum diintegrasikan dengan GAN untuk membentuk sistem penempatan node yang mampu belajar dari skenario simulasi dan nyata.

1.3 Perumusan Masalah

Belum tersedia model energi adaptif pada WSN yang mampu merespons dinamika lingkungan dan kondisi operasional jaringan secara cerdas, efisien, dan berkelanjutan. Metode pengelolaan energi yang ada umumnya masih bersifat statis atau terbatas adaptasinya, sehingga belum optimal dalam menghadapi fluktuasi energi hasil harvesting, variasi trafik data, serta penurunan kondisi baterai yang memengaruhi keberlangsungan operasi node. Di sisi lain, keterbatasan data nyata yang mencakup kondisi ekstrem menyebabkan proses pelatihan sistem pembelajaran menjadi kurang robust. Oleh sebab itu, penelitian ini diarahkan pada pengembangan AEMGQ (*Adaptive Energy Model Based on GAN-Q-Learning*) sebagai model energi adaptif yang memanfaatkan GAN untuk menghasilkan data sintetis realistis dan Q-Learning untuk membangun kebijakan keputusan yang adaptif berdasarkan kondisi lingkungan, SoC, dan SoH baterai, guna mengoptimalkan efisiensi energi, meningkatkan kinerja jaringan, dan memperpanjang umur jaringan pada WSN.

1.4 Maksud Dan Tujuan Penelitian

1.4.1 Maksud Penelitian

Penelitian ini dimaksudkan untuk mengembangkan AEMGQ (Adaptive Energy Model Based on GAN-Q-Learning) sebagai model energi adaptif pada Jaringan Sensor Nirkabel (*Wireless Sensor Networks*/WSN) yang mampu merespons dinamika lingkungan dan kondisi operasional jaringan secara cerdas, efisien, dan berkelanjutan. Model ini dirancang melalui integrasi *Generative Adversarial Networks* (GAN) dan Q-Learning agar sistem tidak hanya mampu menyesuaikan keputusan energi secara adaptif, tetapi juga memiliki ketangguhan yang lebih tinggi melalui pemanfaatan data sintetik realistis, sehingga dapat meningkatkan efisiensi energi, memperbaiki kinerja jaringan, dan memperpanjang umur operasional WSN pada kondisi nyata yang kompleks dan dinamis.

1.4.2 Tujuan Penelitian

1. Mengembangkan model AEMGQ sebagai model energi adaptif berbasis GAN-Q-Learning untuk mendukung pengelolaan energi yang efisien pada WSN.
2. Merancang arsitektur GAN yang mampu menghasilkan data lingkungan sintetik yang realistis, seperti suhu, kelembapan, radiasi matahari, dan trafik data, guna memperluas ruang pelatihan dan merepresentasikan kondisi operasional normal maupun ekstrem pada WSN.
3. Merancang agen Q-Learning yang adaptif untuk mempelajari kebijakan pengambilan keputusan energi secara optimal berdasarkan interaksi dengan lingkungan yang dinamis, meliputi aksi seperti sleep, harvest, transmit, relay, dan transfer.
4. Mengintegrasikan data sintetik hasil GAN ke dalam proses pelatihan Q-Learning agar agen memperoleh pengalaman belajar yang lebih beragam, sehingga kebijakan yang dihasilkan menjadi lebih robust dan kontekstual
5. Merancang representasi state dan fungsi reward yang mengintegrasikan pengetahuan domain, seperti karakteristik baterai, State of Charge (SoC), State of Health (SoH), efisiensi panel surya, dan pola trafik data, agar proses

pengambilan keputusan sesuai dengan karakteristik fisik dan operasional WSN.

6. Mengevaluasi kinerja model AEMGQ menggunakan metrik efisiensi energi, kinerja jaringan, dan umur operasional, seperti konsumsi energi, SoH baterai, Packet Delivery Ratio (PDR), delay, throughput, dan network lifetime, serta membandingkannya dengan pendekatan konvensional.
7. Menghasilkan model pengelolaan energi adaptif yang dapat diterapkan pada berbagai skenario nyata WSN, seperti pemantauan lingkungan, pertanian presisi, dan sistem IoT berskala luas, dengan orientasi pada efisiensi, ketangguhan, dan keberlanjutan operasi jaringan.

1.5 Kebaruan (*Novelty*)

Penelitian ini memiliki kebaruan utama pada pengembangan AEMGQ (Adaptive Energy Model Based on GAN-Q-Learning) sebagai model energi adaptif untuk jaringan sensor nirkabel yang mengintegrasikan GAN-Q-Learning dan pengetahuan domain energi ke dalam satu kerangka pengambilan keputusan yang utuh. Berbeda dari penelitian terdahulu yang umumnya hanya berfokus pada satu aspek, seperti sleep scheduling, routing, data aggregation, atau optimasi berbasis reinforcement learning saja, penelitian ini mengusulkan pendekatan yang lebih holistik untuk mengoptimalkan efisiensi energi, meningkatkan kinerja jaringan, dan memperpanjang umur jaringan pada kondisi operasional yang dinamis. Adapun kebaruan penelitian ini dapat dirumuskan sebagai berikut:

1. Integrasi GAN dan Q-Learning dalam Model Energi Adaptif WSN.

Integrasi sinergis antara GAN dan Q-Learning dalam satu kerangka model energi adaptif untuk WSN. Pada penelitian ini, GAN tidak hanya digunakan sebagai teknik data augmentation biasa, tetapi sebagai pembangkit data lingkungan sintetik yang realistis dan beragam untuk memperluas ruang pelatihan agen Q-Learning. Dengan demikian, agen pembelajaran tidak hanya belajar dari data nyata yang terbatas, tetapi juga dari variasi kondisi sintetik yang merepresentasikan dinamika lingkungan secara lebih kaya.

2. *Domain Knowledge Infused Reinforcement Learning*. Integrasi expert knowledge (model baterai, karakteristik panel surya, degradasi komponen) secara langsung ke dalam fungsi reward dan representasi state Q-Learning. Berbeda dengan pendekatan RL umum yang hanya mempertimbangkan reward berbasis kinerja, penelitian ini mengembangkan physics-aware reward shaping yang memastikan keberhasilan pengambilan keputusan energi sesuai dengan constraint perangkat.
3. *Adaptive Training dengan Extreme Scenario Synthesis*. Pemanfaatan GAN untuk menghasilkan skenario langka tetapi kritis (kondisi ekstrem cuaca, lonjakan lalu lintas, kegagalan node) yang tidak cukup terwakili dalam data riil. Metode ini memungkinkan pelatihan agen RL yang robust terhadap anomaly dan kondisi edge case, yang belum diatasi dalam penelitian.
4. *Dual Time Scale Adaptation Mechanism*. Pengembangan model yang mampu beradaptasi pada dua skala waktu, yaitu jangka pendek untuk respons langsung terhadap perubahan lingkungan, dan jangka panjang untuk optimisasi umur baterai. Integrasi prediksi jangka pendek (berdasarkan GAN) dengan optimasi jangka panjang (Q-Learning) dalam satu kerangka terpadu.
5. *Context-Aware Multi-Objective Optimisation*. Formulasi masalah manajemen energi sebagai optimisasi multi-obyektif dinamis yang menyeimbangkan trade-off antara efisiensi energi, throughput jaringan, dan umur baterai berdasarkan konteks lingkungan. Fungsi reward yang dapat menyesuaikan secara dinamis sesuai prioritas yang berubah sesuai kondisi operasional.

Penelitian ini menggabungkan AI generatif, pembelajaran penguatan, dan rekayasa pengetahuan domain dalam konteks WSN. Berbeda dari studi sebelumnya yang hanya fokus pada satu aspek, pendekatan holistik yang diusulkan menciptakan paradigma baru dalam perancangan sistem WSN otonom yang mampu belajar, beradaptasi, dan memprediksi dalam lingkungan yang dinamis dan tidak pasti. Kontribusi ini tidak hanya sebatas integrasi teknologi, tetapi juga dalam

pengembangan sistem pengelolaan energi yang mandiri, menjadi fondasi untuk WSN generasi berikutnya yang lebih pintar, efisien, dan berkelanjutan.

1.6 Manfaat Penelitian

1.6.1 Manfaat penelitian untuk:

1) Ilmu Pengetahuan

1. Mengembangkan teori integrasi sistem kecerdasan buatan generatif (GAN) dengan reinforcement learning (Q-Learning) dalam manajemen energi WSN.
2. Memberikan kontribusi pada pengembangan model adaptif untuk sistem nonstasioner dalam jaringan sensor nirkabel.
3. Memajukan penelitian di bidang energy harvesting dan optimalisasi konsumsi energi pada perangkat IoT.

2) Masyarakat

1. Menawarkan solusi teknologi yang dapat digunakan dalam sistem pemantauan lingkungan, pertanian presisi, dan sistem peringatan dini.
2. Mengurangi biaya operasional sistem monitoring dengan meningkatkan efisiensi energi dan umur perangkat.
3. Meningkatkan adopsi teknologi IoT yang lebih efisien energi dan berkelanjutan.

3) Objek Penelitian

1. Memperpanjang umur WSN hingga 40% melalui manajemen energi yang bersifat adaptif.
2. Mengoptimalkan performa jaringan melalui peningkatan rasio pengiriman Paket (PDR) dan penurunan latensi.
3. Memperpanjang umur baterai dengan strategi pengelolaan energi yang efisien.

1.6.2 Manfaat penelitian secara:

1) Teoritis

1. Mengembangkan kerangka konsep Model Manajemen Energi Adaptif (MEMA) yang terintegrasi.
2. Berperan dalam pengembangan algoritma hybrid GAN-Q-learning untuk sistem dinamis.
3. Memperluas kajian mengenai penggunaan digital twin dalam peningkatan WSN melalui data sintetik.

2) Praktis

1. Menghasilkan prototipe sistem manajemen energi yang dapat diimplementasikan pada node sensor komersial.
2. Menyediakan solusi ready-to-use untuk optimasi energi pada aplikasi WSN berbasis energi terbarukan.
3. Memberikan panduan implementasi sistem cerdas berbasis AI untuk industri IoT lokal.

1.7 Pembatasan Masalah

Berdasarkan identifikasi masalah yang telah diuraikan, penelitian ini dibatasi pada variabel-variabel berikut untuk menjaga fokus dan kedalaman analisis:

1. Pembatasan pada Ruang Lingkup Algoritma.
 - a. Penelitian hanya mengimplementasikan integrasi Generative Adversarial Network (GAN) dan Q-Learning
 - b. Tidak termasuk algoritma reinforcement learning lainnya seperti DDPG, PPO, atau A3C.
 - c. GAN difokuskan untuk generasi data lingkungan sintetik
2. Pembatasan Variabel Lingkungan.
 - a. Variabel input dibatasi pada: suhu, kelembaban, intensitas radiasi matahari, dan trafik data. Keempat variabel ini memiliki pengaruh paling dominan terhadap efisiensi panel surya dan degradasi baterai berdasarkan literatur (Bose dkk., 2023;

Lakshmanan dkk., 2022; Tsiropoulos dkk., 2022; Ummah, 2019)

- b. Tidak memasukkan variabel lingkungan lain seperti tekanan udara, kecepatan angin, atau curah hujan.

3. Pembatasan Arsitektur Sistem

- a. Studi terbatas pada WSN dengan node stasioner dan sumber energi hibrida (baterai + panel surya).
- b. Tidak membahas WSN dengan node mobile atau flying ad-hoc networks.
- c. Aplikasi difokuskan pada monitoring lingkungan statis.

4. Pembatasan Metrik Evaluasi

- a. Kinerja sistem hanya diukur berdasarkan: konsumsi energi, lifetime baterai, PDR, delay, dan throughput.
- b. Tidak mengukur aspek keamanan (security) atau quality of service komprehensif lainnya.

5. Pembatasan Skala Implementasi

- a. Validasi dilakukan melalui simulasi dan prototipe terbatas.
- b. Tidak mencakup implementasi skala besar dengan ratusan node di lapangan.

Pembatasan ini dimaksudkan untuk memastikan penelitian dapat diselesaikan dengan maintain kedalaman analisis dan validitas hasil, sementara tetap memberikan kontribusi signifikan dalam pengembangan sistem manajemen energi adaptif untuk WSN.

1.8 Sistematika Penulisan.

Disertasi ini disusun dengan sistematika penulisan yang terdiri dari lima bab utama dengan rincian sebagai berikut:

BAB I PENDAHULUAN

Bab ini merupakan landasan konseptual penelitian yang berisi:

1. Latar Belakang: Menguraikan permasalahan mendasar dalam manajemen energi WSN dan urgensi pengembangan model adaptif berbasis AI.
2. Identifikasi Masalah: Menjelaskan titik-titik kritis yang menjadi fokus penanganan dalam penelitian.
3. Perumusan Masalah: Menyatakan pertanyaan penelitian secara spesifik dalam bentuk paragraf statement.
4. Tujuan Penelitian: Memaparkan sasaran yang ingin dicapai melalui pengembangan model MEMA.
5. Manfaat Penelitian: Menguraikan kontribusi penelitian bagi ilmu pengetahuan, masyarakat, dan objek penelitian.
6. Novelty Penelitian: Menjelaskan kebaruan dan orisinalitas pendekatan yang diusulkan.
7. Pembatasan Masalah: Menetapkan batasan ruang lingkup penelitian untuk menjaga fokus dan kedalaman analisis.
8. Sistematika Penulisan: Memberikan gambaran menyeluruh tentang organisasi disertasi.

BAB II TINJAUAN PUSTAKA DAN DASAR TEORI

Bab ini membahas state-of-the-art dan fondasi teoritis penelitian:

1. Tinjauan Pustaka: Analisis komprehensif terhadap penelitian terdahulu meliputi:
 - 1.1 WSN dan energi terbarukan
 - 1.2 Permasalahan konsumsi energi pada WSN
 - 1.3 Strategi efisiensi energi (routing, sleep scheduling, aggregation)
 - 1.4 Penempatan node dan optimasi cakupan
 - 1.5 Q-Learning dalam manajemen energi WSN
 - 1.6 Peran GAN dalam simulasi data
 - 1.7 Integrasi GAN-Q-Learning untuk optimasi energi WSN
2. Dasar Teori: Fondasi ilmiah yang meliputi:
 - 2.1 Arsitektur WSN dan permasalahan energi.

- 2.2 Model Markov multivariabel untuk prediksi energi.
- 2.3 Reinforcement Learning dan Q-Learning.
- 2.4 Generative Adversarial Networks (GAN).
- 2.5 Integrasi GAN-Q-Learning dan implementasinya dalam WSN.

BAB III METODE PENELITIAN

Bab ini menguraikan metodologi penelitian secara sistematis:

1. Bahan dan Alat Penelitian: Spesifikasi data, parameter sistem, dan perangkat yang digunakan
2. Prosedur Penelitian: Tahapan penelitian dari studi literatur hingga analisis hasil
3. Diagram Alir Sistem: Representasi visual proses pengambilan keputusan energi adaptif
4. Implementasi Teknis: Detail teknis implementasi GAN, Q-Learning, dan integrasinya.

BAB IV HASIL PENELITIAN DAN PEMBAHASAN

Bab ini menyajikan temuan penelitian dan analisis mendalam:

1. Hasil Pengembangan Sistem: Deskripsi arsitektur sistem yang dibangun
2. Hasil Prediksi Model GAN: Validasi data sintetik dan kemampuan generasi kondisi ekstrem
3. Hasil Pembelajaran Agen Q-Learning: Analisis konvergensi, strategi aksi, dan adaptasi
4. Evaluasi Kinerja Sistem: Pengukuran comprehensive terhadap efisiensi energi, lifetime baterai, dan performa jaringan
5. Komparasi dengan Sistem Konvensional: Analisis perbandingan untuk memvalidasi keunggulan model
6. Pembahasan Mendalam: Interpretasi hasil dan kaitannya dengan teori yang mendasari.


BAB V KESIMPULAN DAN SARAN

Bab ini merangkum temuan utama dan implikasi penelitian:

1. Kesimpulan: Ringkasan pencapaian penelitian dan jawaban atas rumusan masalah.
2. Saran: Rekomendasi untuk pengembangan penelitian lanjutan dan implementasi praktis.

Bagian Akhir

1. Daftar Pustaka: Referensi akademik yang digunakan dalam penelitian.
2. Lampiran: Data tambahan, kode program, dan dokumentasi pendukung.



SEKOLAH PASCASARJANA