

BAB II KAJIAN PUSTAKA

2.1 Tinjauan Pustaka

2.1.1 Wireless Sensor Network (WSN) dan Energi Terbarukan.

Wireless Sensor Network (WSN) merupakan sistem jaringan nirkabel terdistribusi yang terdiri dari node sensor yang bertugas untuk mendeteksi dan mengirim data lingkungan secara real-time. Penggunaan sumber energi terbarukan seperti panel surya memungkinkan sistem ini beroperasi secara mandiri di lokasi terpencil (Sadeq dkk., 2022b), (Zhao, Y. dkk., 2024). Namun, keterbatasan suplai energi dan degradasi baterai menjadi tantangan utama yang memerlukan sistem manajemen energi yang efisien (Michal Prauzek et al., 2020).

Ada beberapa strategi manajemen energi yang sudah dilakukan oleh penelitian sebelumnya seperti yang telah dilakukan oleh (Garg & Garg, 2020), (Masood dkk., 2024) telah melakukan Sistem pemanenan energi hibrida (*Hybrid energy harvesting systems*) menggabungkan berbagai sumber energi terbarukan, termasuk energi matahari dan angin, untuk menjamin penyediaan energi yang konsisten. Sistem semacam itu menunjukkan efektivitas dalam konteks ketergantungan pada satu sumber energi dapat menjadi kurang andal. Sebagai contoh, sistem hibrida yang menggabungkan tenaga surya dan angin mampu mengurangi variabilitas energi surya saat cuaca mendung dengan memanfaatkan tenaga angin sebagai sumber alternatif. Integrasi sistem hibrida dalam Jaringan Sensor Nirkabel (WSNs) memerlukan penerapan algoritma penjadwalan yang efisien untuk menyeimbangkan pembangkitan dan konsumsi energi. Algoritma ini berperan krusial dalam memastikan bahwa energi yang dipanen dari berbagai sumber dimanfaatkan secara optimal, sehingga tercapai kondisi netral energi, di mana energi yang dihasilkan sebanding dengan energi yang digunakan (Wang, C. dkk., 2022).

Protokol routing hemat energi dirumuskan dengan cermat untuk meningkatkan pemanfaatan energi di Jaringan Sensor Nirkabel (WSNs) dengan mempertimbangkan cadangan energi yang tersisa dan ketersediaan sumber energi

terbarukan. Algoritma Renewable Energy-Based Routing (REBORN) mencontohkan pendekatan ini, karena mengintegrasikan metrik energi residual dan energi terbarukan yang dapat diakses yang dihasilkan dari sumber-sumber seperti sel fotovoltaik (Junior dkk., 2021). Metodologi ini menjamin bahwa penentuan routing didasarkan pada kondisi energi jaringan yang berlaku, akibatnya memperpanjang durasi operasional jaringan.

Pengelompokan merupakan metodologi umum dalam Jaringan Sensor Nirkabel (WSNs) yang bertujuan untuk meningkatkan efisiensi energi. Melalui agregasi node sensor ke dalam cluster diskrit, konsumsi energi keseluruhan dapat didistribusikan secara merata ke seluruh jaringan. Algoritma metaheuristik, termasuk *Grasshopper Optimization Algorithm* (GOA), *Bat Algorithm* (BA), dan *Whale Optimization Algorithm* (WOA), telah digunakan untuk menyempurnakan proses yang terkait dengan pengelompokan (Flayyih & Nickray, 2024). Algoritma ini memfasilitasi identifikasi kepala cluster yang optimal dan memastikan distribusi pengeluaran energi yang seragam, sehingga memperpanjang umur operasional jaringan.

Energi surya sering jadi pilihan utama untuk Jaringan Sensor Nirkabel (WSN) berkat kepadatan energinya yang tinggi. Akan tetapi, ketidakpastiannya menjadi kendala besar dalam manajemen daya. Oleh karena itu, diciptakan algoritma peramalan energi surya profil plus untuk memprediksi pasokan energi mendatang. Algoritma ini bekerja dengan meninjau data historis dan pola meteorologi terkini (Wang, N. C. dkk., 2024a). Prediksi ini penting untuk menerapkan strategi manajemen energi yang fleksibel, memungkinkan penyesuaian penjadwalan tugas demi netralitas energi, dan menjamin operasional jaringan yang berkelanjutan.

Integrasi pembelajaran mesin (*Machine Learning*) dan metodologi pembelajaran penguatan (*Reinforcement Learning*) telah secara signifikan mengubah praktik manajemen energi dalam Jaringan Sensor Nirkabel (WSNs). Kerangka kerja Aktor-Kritik, yang mewakili sintesis pendekatan pembelajaran penguatan berbasis kebijakan dan berbasis nilai, dengan mahir memodifikasi strategi alokasi energi sesuai dengan kebijakan yang ditetapkan (Sibi & Annabel,

2024b). Teknik Q-learning dan Proximal Policy Optimization (PPO) telah digunakan untuk mengoptimalkan laju transmisi dan siklus tugas dalam WSN bertenaga surya, sehingga meningkatkan throughput data sambil memastikan keseimbangan energi (Liu, S. dkk., 2024).

Sistem pemanenan energi sering mengharuskan penerapan solusi penyimpanan canggih yang dirancang khusus untuk secara efektif mengelola karakteristik intermiten yang secara inheren terkait dengan berbagai sumber energi terbarukan. Untuk mengatasi tantangan ini, teknik inovatif seperti pelacakan titik daya maksimum (MPPT) dan strategi manajemen penyimpanan energi yang cermat telah dikembangkan dan disempurnakan dengan cermat untuk mengoptimalkan proses pemanenan energi dan penyimpanan selanjutnya (Javaid dkk., 2024). (Nguyen dkk., 2023) dalam penelitiannya menjelaskan metodologi untuk memastikan bahwa energi yang telah dipanen tidak hanya disimpan dengan efisiensi tinggi tetapi juga digunakan dengan cara yang meminimalkan kehilangan energi, sekaligus meningkatkan keandalan keseluruhan dan stabilitas infrastruktur jaringan. Dengan menerapkan strategi tersebut, potensi untuk menciptakan sistem manajemen energi yang lebih berkelanjutan dan efisien menjadi jauh lebih terjangkau, sehingga berkontribusi pada tujuan konservasi energi dan pemanfaatan sumber daya terbarukan yang lebih luas.

Terlepas dari kemajuan signifikan yang telah dibuat di bidang strategi manajemen energi, masih ada banyak tantangan yang terus menghambat kemajuan dan kemandirian dalam domain ini. Integrasi yang berhasil dari sumber energi terbarukan ke dalam Jaringan Sensor Nirkabel (WSNs) memerlukan pertimbangan yang cermat dan menyeluruh dari berbagai faktor kritis, yang meliputi, tetapi tidak terbatas pada, mekanisme penyimpanan energi, protokol manajemen daya, dan implementasi protokol komunikasi, seperti yang disorot dalam karya ilmiah (Masood dkk., 2024), (Mushtaq dkk., 2025). Mengingat tantangan ini, upaya penelitian yang dilakukan diarahkan pada pengembangan teknik pemanenan energi yang lebih efisien, peningkatan algoritma prediksi yang dapat meningkatkan akurasi, dan

kemajuan fitur skalabilitas dan keamanan sistem manajemen energi untuk memastikan ketahanan dan efektivitasnya.

Penggabungan sumber energi terbarukan ke dalam Jaringan Sensor Nirkabel (WSNs) telah secara nyata meningkatkan manajemen energi, memfasilitasi fungsionalitas jaringan yang diperluas, dan meningkatkan keandalan. Pendekatan seperti pemanenan energi hibrida, protokol routing sadar energi, teknik pengelompokan, peramalan energi matahari, aplikasi pembelajaran mesin, dan metode pengoptimalan penyimpanan yang canggih telah terbukti penting dalam mengurangi tantangan terkait kelangkaan energi di WSN. Seiring kemajuan WSN dalam pengembangannya, penelitian yang akan dilakukan adalah mengembangkan metodologi untuk pencapaian praktik manajemen energi yang berkelanjutan dan efisien. Seperti yang dapat dilihat pada tabel 1.

Table 2. 1 GAP Penelitian Bidang WSN dan Energi Terbarukan

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2025, Xinqing Xiao, Agriculture. Q1.	Sustainable Agriculture with Self-Powered Wireless Sensing.	WSN, AI, 5G Surya, EMG, TEG, PZG, TENG, MFC	Sistem sensor mandiri untuk pertanian berkelanjutan
2025, Muhammad Umer Mushtaq, Hein S. Venter, Avinash Singh, Muhammad Owais, hardware. Q1.	Advances in Energy Harvesting for Sustainable Wireless Sensor Networks: Challenges and Opportunities.	EH-WSN, PLS, AI Surya, Termal, RF, Kinetik	Optimalisasi efisiensi spektrum dan keamanan fisik jaringan
2025, Manisha Sahu, V. M. Victor, International Journal of Environment and Climate Change.	Enhancing Agriculture through Wireless Sensor Networks	ZigBee, Bluetooth Surya	Pemantauan lingkungan untuk irigasi otomatis
2024, Rashmita Sahu, Priyanka Tripathi, International	Enhancing Energy Efficiency in Smart Agriculture: GA based Optimization	LoRaWAN, Genetic Algorithm Surya	Optimasi routing dan pengelompokan node skala besar

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Conference on Automation, Computing and Renewable Systems (ICACRS).	for Large-Scale LoRaWAN Networks		
2024, N.G.P.R Premachandra, Sampath Edirisinghe, Proceedings of the SLIIT International Conference on Engineering and Technology.	Battery-Less Sensor Node Design with Solar Panels and LoRa for Wireless Sensor Networks	LoRa, Surya (Supercapacitor)	Node hemat energi tanpa baterai dengan jangkauan luas.
2024, Dian Chen, Qisheng Zhang, Ing-Ray Chen, Dong Sam Ha, Jin-Hee Cho, IEEE Internet of Things Journal. Q1.	Energy-Adaptive and Robust Monitoring for Smart Farms Based on Solar-Powered Wireless Sensors	DRL, Transfer Learning	Adaptasi energi dan monitoring berkualitas tinggi pada smart farm
2023, Mohammed Ayad Saad, Adnan A. AbdulRazak, Ahmed Hashim Rashid, Hassaan Th. H. Thabet, Mohammed Al Essa, Sameer Alani, International Engineering Conference on Electrical, Energy, and Artificial Intelligence (EICEEAI).	Enhanced Energy Efficiency in Wireless Sensor Networks through Harvesting Technologies	Nash Equilibrium, Sleep Mode	Manajemen energi dan keseimbangan data packet drop
2023, Yovanka Davincy Setiawan, Bryan Ghilchrist, G. Giovan, Mochammad Haldi Widiyanto, International Journal of Reconfigurable &	Development of IoTs-based instrument monitoring application for smart farming using solar panels as energy source	ESP8266, HTTP, Thingspeak	Aplikasi monitoring berbasis IoT dan energi terbarukan

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Embedded Systems (IJRES).			
Schoenecker (2023)	A low-cost Platform for an Environmental Smart Agriculture Monitoring System Based on Arduino and Renewable Energies	Arduino, DHT11, pH Meter	Platform murah monitoring variabel pertanian
2025.Deden Ardiansyah.	Peningkatan Lifetime Dan Performa Wireless Sensor Network Melalui Model Manajemen Energi Adaptif Menggunakan Gan Dan Q-Learning	WSN, AI.	1. GAN (Generative Adversarial Network) untuk menghasilkan state lingkungan sintesis berbasis pola data historis sensor seperti suhu, kelembaban, dan iradiasi surya. 2. Q-Learning untuk membentuk routing policy adaptif berbasis reward efisiensi energi dan kondisi node.

Tinjauan enam puluh studi yang sudah dilakukan sebagian besar menunjukkan konsensus kuat terhadap pentingnya penggunaan energi terbarukan, seperti tenaga surya dan angin, sebagai sumber daya utama untuk memperpanjang umur node sensor dan mengurangi ketergantungan pada baterai konvensional (Mushtaq dkk., 2025), (Xiao, 2025). Namun, meskipun pemanfaatan energi terbarukan telah menjadi arus utama, penerapan pendekatan cerdas berbasis *adaptive learning* seperti AI, machine learning, atau reinforcement learning masih terbatas jumlahnya (Premachandra & Edirisinghe, 2024), (Sushil Lekhi, 2024a). Hal ini mengindikasikan bahwa potensi pemanfaatan kecerdasan buatan dalam pengambilan keputusan adaptif pada WSN belum sepenuhnya dioptimalkan oleh mayoritas peneliti.

Selain itu, studi yang menguji implementasi sistem secara fisik di lapangan masih tergolong sedikit, sehingga validasi dunia nyata terhadap efektivitas

teknologi yang diusulkan belum luas dilakukan. Fitur seperti *routing optimization* hanya muncul dalam sebagian kecil studi, padahal sangat krusial untuk efisiensi transmisi data dan manajemen energi (Flayyih & Nickray, 2024), (Hamouda, 2023). Sementara itu, konsep sensor node tanpa baterai, yang memiliki potensi besar untuk menciptakan Wireless Sensor Network (WSN) yang benar-benar berkelanjutan, masih sangat minim penelitian. Oleh karena itu, penelitian saya bertujuan mengisi kekurangan tersebut dengan mengembangkan kerangka kerja Smart Adaptive Routing berbasis integrasi GAN dan Q-Learning. Framework ini tidak hanya mampu memprediksi kondisi lingkungan secara sintetik dan adaptif, tetapi juga dirancang untuk meningkatkan efisiensi energi dan pengambilan keputusan berbasis reward dinamis.

2.1.2 Permasalahan Konsumsi Energi pada WSN

Komunikasi antar node merupakan penyumbang konsumsi daya terbesar dalam WSN, jauh melebihi proses sensing dan pemrosesan data (Jyoti Jyoti, 2023), (Mutombo, 2021). Ketidakseimbangan beban antar node, kepadatan penempatan, serta perutean statis dapat menyebabkan pemborosan energi dan memperpendek umur jaringan. Oleh karena itu, diperlukan optimasi perutean dan jadwal operasi komponen node agar lebih hemat energi (Areibi, 2016), (Vennam dkk., 2022). Konsumsi energi merupakan tantangan yang signifikan, terutama dalam konteks node sensor yang terletak di lingkungan tidak terjangkau. Dalam Penelitian ini membahas tiga dimensi mendasar konsumsi energi dalam Jaringan Sensor Nirkabel (WSNs) yaitu efisiensi perangkat keras (*Hardware Efficiency in WSNs*), protokol transmisi data (*Data Transmission Protocols*), dan parameter lingkungan (*Environmental Conditions and Their Impact on Energy Consumption*) (Sachidhanandam dkk., 2024).

Efisiensi perangkat keras dalam Jaringan Sensor Nirkabel (WSNs) meningkat secara nyata melalui penggabungan metodologi pemanenan energi. Metodologi itu memfasilitasi node sensor untuk mengekstrak energi dari lingkungannya, sehingga mengurangi ketergantungan pada baterai konvensional. Sumber energi yang digunakan meliputi energi matahari, angin, panas, dan getaran.

Pemanen energi getaran piezoelektrik telah ditunjukkan untuk meningkatkan umur operasional node sensor dengan faktor hingga sembilan ketika digunakan sebagai sumber daya tambahan (Bouhedma dkk., 2024). Kerangka kerja pemanenan energi multisource yang menggabungkan energi matahari, angin, dan panas telah menunjukkan kemampuan untuk memenuhi permintaan catu daya yang bertahan lama dari node WSN tanpa memerlukan baterai (Deng dkk., 2019).

Desain node sensor berdaya rendah merupakan aspek penting lainnya dalam efisiensi perangkat keras. Kemajuan dalam optimasi perangkat keras telah menghasilkan pengembangan node sensor hemat energi yang meminimalkan konsumsi daya selama mode siaga. Sebagai contoh, penggunaan sistem energi hibrida, seperti yang menggabungkan baterai dengan sel surya dan pemanen energi getaran, telah terbukti menghemat energi node dan memperpanjang masa pakai jaringan. Selain itu, implementasi algoritma manajemen daya, seperti siklus tugas cerdas (*intelligent duty cycling*), semakin meningkatkan efisiensi perangkat keras dengan mengoptimalkan aktivitas sensor (*active mode*) dan mode tidur (*sleep mode*) (Sivasankar dkk., 2024). Solusi penyimpanan energi, seperti superkapasitor, memainkan peran penting dalam menstabilkan pasokan daya untuk node Jaringan Sensor Nirkabel (WSN). Solusi ini sangat berguna dalam pemanenan energi intermiten, misalnya di lingkungan dengan kondisi surya atau angin yang bervariasi. Hasil eksperimen menunjukkan bahwa integrasi modul penyimpanan energi dapat secara signifikan meningkatkan keandalan dan otonomi node sensor (Deng dkk., 2019).

Protokol transmisi data berkontribusi besar terhadap konsumsi energi di WSN. Teknik perutean sadar energi, seperti protokol *Centroid Direction of Arrival Routing* (CDAR), telah dikembangkan untuk mengoptimalkan jalur transmisi data dan mengurangi konsumsi energi. Protokol CDAR menyeimbangkan konservasi energi dan transmisi data yang andal, sehingga sangat mudah beradaptasi dengan kepadatan *node* dan kondisi lingkungan yang bervariasi (Bhukya dkk., 2023). Serupa dengan itu, Skema Penginderaan dan Perutean Data Hemat Energi (*Energy-Efficient Data Sensing and Routing Scheme - EEDSRS*) mengintegrasikan

penginderaan dan perutean data untuk memaksimalkan utilitas jaringan sambil meminimalkan penggunaan energi (Lu dkk., 2018).

Strategi transmisi data adaptif sangat penting untuk mengurangi konsumsi energi di lingkungan yang dinamis. Misalnya, penggunaan penyesuaian *backoff* sadar saluran dan algoritma transmisi berbasis keputusan biner memastikan bahwa data ditransmisikan hanya dalam kondisi saluran yang menguntungkan, menghindari pemborosan energi yang tidak perlu. Strategi ini dilengkapi dengan teknik manajemen energi prediktif, seperti yang menggunakan algoritma pembelajaran mesin untuk memperkirakan kebutuhan energi dan mengoptimalkan jadwal transmisi data (Ren, X. dkk., 2024). Protokol *Medium Access Control* (MAC) adalah komponen penting lain dari transmisi data hemat energi. Protokol RFMAC, yang dirancang untuk sensor pemanen energi RF, mengoptimalkan pengiriman energi ke *node* sensor sambil memastikan komunikasi data yang efisien (Nintanavongsa dkk., 2013). Selain itu, teknik optimasi *cross-layer* menggabungkan program di seluruh tingkat *stack* protokol jaringan, memungkinkan arsitektur jaringan yang terukur dan adaptif yang secara efisien mengelola penggunaan energi (Sivasankar dkk., 2024).

Kondisi lingkungan memainkan peran penting dalam efisiensi sistem pemanenan energi. Misalnya, WSN yang ditenagai surya sangat bergantung pada kondisi cuaca, dengan tutupan awan dan bayangan yang secara signifikan memengaruhi ketersediaan energi. Untuk mengatasi hal ini, algoritma yang memprediksi energi yang dipanen menggunakan deteksi bayangan lingkungan telah dikembangkan, memungkinkan *node* sensor untuk menyesuaikan rencana penjadwalan mereka (Jiayuan Wei, Xingyu Miao, 2021). Serupa dengan itu, sistem pemanenan energi angin dan termal harus dirancang untuk beradaptasi dengan kondisi lingkungan yang bervariasi, seperti fluktuasi suhu dan kecepatan angin (Bengheni dkk., 2019), (Mazunga & Nechibvute, 2021).

Pada lingkungan yang ekstrem, seperti yang memiliki suhu ekstrem atau kelembaban tinggi, konsumsi energi dapat semakin diperparah oleh kebutuhan daya tambahan untuk menjaga fungsionalitas *node* sensor. Contohnya, dalam aplikasi pemantauan kesehatan struktural, pemanen energi getaran harus dioptimalkan

untuk menangani berbagai tingkat tekanan mekanis sambil meminimalkan konsumsi daya. Selain itu, keandalan saluran komunikasi nirkabel di lingkungan tersebut dapat memengaruhi efisiensi energi, karena kondisi saluran yang buruk dapat menyebabkan transmisi ulang dan peningkatan penggunaan energi (Bhargavi dkk., 2024), (Bouhedma dkk., 2024), (Wang, Zhen & Duan, 2025).

Ketidakpastian sumber energi lingkungan, seperti surya dan angin, menimbulkan tantangan dalam analisis penundaan untuk WSN. Studi menunjukkan bahwa pertimbangan biaya energi penginderaan dan transmisi mengarah pada *trade-off* antara usia pembaruan dan siklus pembaruan, dengan pembaruan yang lebih sering menghasilkan informasi yang kurang tepat waktu di *sink* (Daanouné dkk., 2020). Ini menyoroti perlunya metode optimasi pemantauan adaptif, seperti yang didasarkan pada algoritma *deep Q-network* (DQN), untuk menangani kondisi lingkungan dinamis secara efektif (Bao dkk., 2023).

Konsumsi energi dalam Jaringan Sensor Nirkabel (WSN) dipengaruhi oleh kombinasi efisiensi perangkat keras, protokol transmisi data, dan kondisi lingkungan. Kemajuan dalam teknik pemanenan energi, desain perangkat keras berdaya rendah, dan strategi transmisi data adaptif telah secara signifikan meningkatkan efisiensi energi WSN. Namun, sifat dinamis kondisi lingkungan menghadirkan tantangan yang berkelanjutan, sehingga memerlukan pengembangan sistem prediktif dan adaptif. Dengan mengintegrasikan strategi-strategi ini, WSN dapat mencapai keberlanjutan dan keandalan yang lebih lama dalam berbagai aplikasi seperti yang akan dilakukan dalam penelitian ini yang dijelaskan dalam table 2.

Penelitian mengenai efisiensi energi dalam *Wireless Sensor Network* (WSN) telah berkembang signifikan dalam satu dekade terakhir, khususnya pada pendekatan pengelompokan node dan optimasi routing. Berbagai algoritma seperti LEACH, EE-SEP, hingga optimasi berbasis *Ant Colony* dan *Genetic Algorithm* telah digunakan untuk memaksimalkan umur jaringan dan mengurangi konsumsi energi (Ballary & Hegde, 2025), (Barbudhe dkk., 2024), (Suryawanshi, 2024). Beberapa studi terbaru mulai mengadopsi teknologi kecerdasan buatan seperti fuzzy logic, machine learning, dan reinforcement learning untuk mengatasi

permasalahan adaptasi routing terhadap dinamika lingkungan dan status energi node.

Tabel 2. 2 GAP Penelitian Permasalahan Konsumsi Energi Pada WSN

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2025, Ramachandra Ballary, Rajeshwari Hegde, International Journal of Communication Systems.Q2.	An Advanced Energy Efficient Resource Allocation for Software- Defined WSN Using Hybrid Optimization Algorithm	Hybrid Election- based Ladybird Beetle Optimization (HELBO). Hybrid	Metode HELBO secara empiris terbukti jauh lebih unggul dibandingkan algoritma yang ada dalam mengoptimalkan alokasi bandwidth dan daya, mencapai Rasio Signal- to-Interference-plus- Noise (SINR) yang cukup tinggi sambil tetap memenuhi batasan kualitas layanan
2024, Amit Kumar Jain, Sushil Kumar Jain, Garima Mathur, Engineering research express,Q2.	Optimizing wireless sensor network routing with Q-learning: enhancing energy efficiency and network longevity	K-Means, Q Learning. Battery	Penilaian terhadap algoritma Q-Learning mengungkapkan peningkatan pada metrik utama seperti tingkat kehabisan energi, durasi node, dan rasio pengantaran paket, yang menunjukkan efektivitasnya dalam meningkatkan umur dan efisiensi jaringan sensor nirkabel
2024, Vishwajit K. Barbudhe, Shraddha N. Zanjat, Bhavana S. Karmore, Advances in computer and electrical engineering book series,.	Energy Optimization of Routing Protocol in Wireless Sensor Network	Routing Protocol in Wireless Sensor Network. Battery	Metode optimisasi juga mengurangi konsumsi energi secara keseluruhan sekitar 20%, secara efektif meningkatkan pemanfaatan energi di antara kepala klaster dan berkontribusi pada proses komunikasi data yang lebih efisien dalam jaringan

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2024, Tadele A. Abose, Venumadhav Tekulapally, Diriba C. Kejela, Ketema T. Megersa, Samuel T. Daka, Kehali A. Jember, IEEE Access,.	Optimized Cluster Routing Protocol with Energy-Sustainable Mechanisms for Wireless Sensor Networks	IMP-RES-EL dan EE-SEP. Battery	Penggunaan algoritma peningkatan energi residual LEACH (IMP-RES-EL) menghasilkan peningkatan umur jaringan sebesar 36% dalam putaran, peningkatan 44% dalam jumlah paket data yang dikirimkan dari kepala kluster ke stasiun dasar, dan peningkatan 20% dalam total paket data yang dikirimkan ke stasiun dasar, sekaligus meminimalkan dissipasi energi dan transmisi antara node sensor dengan stasiun dasar atau kepala kluster
2024, Sushil Lekhi , Satvir Singh, Journal of Electrical Systems.	Enhancing Energy Efficiency in Wireless Sensor Networks through I-LEACH: A Data Clustering and Routing Protocol	Wireless Sensor Networks through I-LEACH: Battery	Protokol I-LEACH yang diusulkan beroperasi dalam dua tahap: menghitung nilai Threshold baru untuk memilih kepala kluster dan menerapkan mekanisme fusi data berdasarkan model energi untuk meminimalkan transfer energi yang redundan, sekaligus mengatasi masalah terkait konsumsi energi dan kehilangan paket
2024, Supriyan Sen, Laxminarayan Sahoo, Sumanta Lal Ghosh, Journal of Industrial	Lifetime Extension of Wireless Sensor Networks by Perceptive Selection of Cluster Head	application of the Einstein Weighted Averaging Aggregation (EWA) operator. Battery	Studi ini menyoroti pentingnya pemilihan CH secara strategis berdasarkan parameter seperti energi tersisa dan kedekatan node, yang secara signifikan

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Intelligence (JII).	Using K-Means and Einstein Weighted Averaging Aggregation Operator under Uncertainty		meningkatkan efisiensi energi dan mendorong keberlanjutan penerapan WSN, sehingga memastikan pemanfaatan sumber daya yang terbatas secara optimal.
2024, Shanker MC, D. Saraswathi, R. Deepalakshmi, S. Jacily Jemila, A. Sathishkumar, International Conference on Cybernation and Computation (CYBERCOM).	Optimizing Energy-Efficient Routing in Wireless Sensor Networks via Genetic Algorithm for Enhanced Performance	Wireless Sensor Networks via Genetic Algorithm. Battery	Kinerja algoritma ditingkatkan dengan memperbesar ukuran populasi dan mengoptimalkan tingkat mutasi, menunjukkan bahwa parameter-parameter ini berperan penting dalam efektivitas Algoritma Genetik untuk routing dalam Jaringan Sensor Nirkabel.
2024, Mohammed Al-Farouni, D. Sharmila, K. S. Kumar, Sangeetha Suresh Harikantha, G. V. Shanker, International Conference on Integrated Circuits and Communication Systems (ICICACS).	An Effective Dynamic Cross Propagation Clustering in Wireless Sensor Network using Improved RFCM	Dynamic Cross Propagation Clustering in Wireless Sensor Network using Improved RFCM Battery	Metode ini menghasilkan waktu jaringan sebesar 5900 dan First Node Death (FND) sebesar 1700, menunjukkan peningkatan signifikan dalam pengelompokan dinamis dan kinerja jaringan secara keseluruhan, terutama dengan jumlah node sebanyak 300 dibandingkan teknik yang ada seperti CSC-TC dan MCR-UWSN.
2024, Amit Kumar Jain, Sushil Kumar Jain, Garima Mathur,	Optimizing wireless sensor network routing with Q-learning: enhancing	Q-learning: enhancing energy efficiency and network longevity. Battery	Penilaian terhadap algoritma Q-Learning mengungkapkan peningkatan pada metrik utama seperti

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Engineering research express,Q2.	energy efficiency and network longevity		tingkat kehabisan energi, durasi node, dan rasio pengantaran paket, yang menunjukkan efektivitasnya dalam meningkatkan umur dan efisiensi jaringan sensor nirkabel
Deden Ardiansyah, 2025.	Peningkatan Lifetime Dan Performa Wireless Sensor Network Melalui Model Manajemen Energi Adaptif Menggunakan Gan Dan Q- Learning	Lifetime Dan Performa Wireless Sensor Network Melalui Model Manajemen Energi Adaptif. Surya	GAN (Generative Adversarial Network) untuk menghasilkan state lingkungan sintetis berbasis pola data historis sensor seperti suhu, kelembaban, dan iradiasi surya. Q-Learning untuk membentuk routing policy adaptif berbasis reward efisiensi energi dan kondisi node.

Namun, tinjauan terhadap enam puluh studi menunjukkan bahwa sebagian besar riset masih bersifat simulatif, belum mengintegrasikan model generatif untuk memperkaya data lingkungan, dan belum menerapkan pembelajaran adaptif berbasis reward secara penuh. Bahkan, pemanfaatan *battery-less architecture*, yang secara potensial dapat menghilangkan ketergantungan terhadap sumber daya penyimpanan energi, masih sangat terbatas (hanya <2% dari total studi). Selain itu, hanya sebagian kecil penelitian seperti (Jain dkk., 2024) yang mulai memanfaatkan Q-Learning, dan belum ada yang mengintegrasikannya dengan pendekatan *generative synthesis* seperti GAN untuk memperluas spektrum state input yang relevan terhadap konteks pengambilan keputusan adaptif.

Posisi penelitian ini berada pada persimpangan unik antara *AI generatif* dan *reinforcement learning adaptif* untuk efisiensi energi pada *Wireless Sensor Network*

(WSN), area yang masih belum banyak dieksplorasi. Kami mengusulkan sebuah *framework* baru yang disebut *Smart Adaptive Routing*, yang secara inovatif mengintegrasikan *Generative Adversarial Network* (GAN) untuk menciptakan data kondisi lingkungan sintetis (seperti suhu, kelembaban, dan intensitas radiasi) dengan *Q-Learning* untuk mengembangkan strategi *routing* adaptif yang didasarkan pada *reward* energi dan performa komunikasi. Pendekatan ini tidak hanya meningkatkan kemampuan sistem untuk beradaptasi dengan fluktuasi lingkungan, tetapi juga mengatasi keterbatasan data aktual yang sering terjadi pada jaringan sensor berbasis energi terbarukan.

2.1.3 Strategi Efisiensi Energi: Routing, Sleep Scheduling, dan Aggregation.

Efisiensi energi adalah perhatian utama dalam Jaringan Sensor Nirkabel (WSN) dan aplikasi *Internet of Things* (IoT), di mana masa pakai baterai yang terbatas dan konsumsi energi yang tinggi menimbulkan tantangan signifikan. Berbagai strategi efisiensi energi telah dikembangkan, seperti perutean berbasis energi, penggabungan data (data aggregation), dan sleep scheduling. Protokol perutean cerdas mampu menyesuaikan jalur berdasarkan sisa energi dan kondisi jaringan (Rai & Asbe, 2023). Sleep scheduling secara berkala mematikan komponen komunikasi saat idle untuk menghemat energi (Faiz, 2023). Data aggregation juga berperan dalam mengurangi beban transmisi data yang berlebihan (Murthy dkk., 2024).

Protokol *Low Energy Adaptive Clustering Hierarchy* (LEACH) adalah salah satu protokol hemat daya yang paling banyak digunakan di WSN. LEACH membagi jaringan menjadi *cluster*, masing-masing dengan *Cluster Head* (CH) yang bertanggung jawab untuk agregasi data dan transmisi ke *Base Station* (BS). Pendekatan ini mengurangi konsumsi energi dengan meminimalkan transmisi data yang redundan dan menyeimbangkan beban di seluruh *node* (Hiremath dkk., 2024), (Qamar dkk., 2024), (Rizky dkk., 2022). Beberapa peningkatan pada LEACH telah diusulkan untuk lebih meningkatkan efisiensi energi. Misalnya, Protokol Perutean Multi-hop Hemat Energi Berbasis LEACH (*Energy Saving Multi-hop Routing Protocol Based on LEACH*) menggabungkan model transmisi multi-hop,

mengoptimalkan efisiensi penyebaran data dan secara signifikan mengurangi penggunaan energi dibandingkan dengan LEACH tradisional (Sumithra dkk., 2024). Demikian pula, protokol I-LEACH memperkenalkan nilai ambang batas baru untuk pemilihan CH. Ini menerapkan mekanisme fusi data untuk mengurangi transfer energi yang redundan, sehingga meningkatkan energi sisa dan masa pakai jaringan (Sushil Lekhi, 2024a).

Selain LEACH, protokol lain seperti *Threshold-sensitive Energy-Efficient sensor Network* (TEEN) dan protokol *Hierarchical Energy-Efficient Distributed* (HEED) telah dikembangkan. TEEN sangat efektif dalam aplikasi yang sensitif terhadap waktu, karena hanya mengirimkan data ketika nilai yang dirasakan melebihi ambang batas tertentu, mengurangi transmisi yang tidak perlu. HEED, di sisi lain, memilih CH berdasarkan energi sisa dan biaya komunikasi, memastikan distribusi konsumsi energi yang seimbang di seluruh jaringan (Mythili & Duraisamy, 2024), (Yasotha dkk., 2025). Perutean multi-hop adalah strategi kunci untuk komunikasi hemat energi di WSN. Dengan membagi jalur transmisi menjadi beberapa *hop* yang lebih pendek, energi yang dibutuhkan untuk transmisi jarak jauh berkurang secara signifikan. Protokol seperti Protokol Perutean Multi-Hop Hemat Energi (*Energy-Efficient Multi-Hop Routing Protocol*) dan Metode Perutean Multi-Hop Acak Dinamis (*Dynamic Random Multi-Hop Routing Method* - DRMRM) telah dikembangkan untuk mengoptimalkan jalur transmisi data dan mengurangi konsumsi energi (Asiedu dkk., 2024), (Yang dkk., 2024).

Teknik perutean lanjut, seperti yang menggunakan Algoritma Genetika (GA), telah dieksplorasi untuk mengoptimalkan perutean hemat energi di WSN. Algoritma ini mencari rencana rute terbaik yang meminimalkan konsumsi energi sambil mempertahankan laju transmisi data yang tinggi. Integrasi GA dengan teknik optimasi lainnya, seperti Optimasi Kawanan Partikel (*Particle Swarm Optimization* - PSO) dan Optimasi Koloni Semut (*Ant Colony Optimization* - ACO), juga telah diselidiki untuk meningkatkan efisiensi perutean (MC dkk., 2024).

Reinforcement learning (RL) dan *deep learning* (DL) telah muncul sebagai alat yang ampuh untuk mengoptimalkan perutean di WSN. Misalnya, Algoritma Optimasi Kupu-Kupu Berbantuan *Deep Reinforcement Learning* (DRL-BOA)

mengintegrasikan RL dengan Algoritma Optimasi Kupu-Kupu (BOA) untuk secara dinamis memilih *cluster head* dan rute optimal (Devika & Shaby, 2024). Pendekatan ini mengurangi konsumsi energi sebesar 22% dibandingkan dengan protokol MOD-LEACH tradisional. Demikian pula, algoritma *Adaptive Reinforcement Learning* (ARL-DARO) menggunakan *Q-learning* untuk mengoptimalkan rute berdasarkan efisiensi energi, keamanan, dan keandalan tautan, mencapai pengurangan konsumsi energi sebesar 45% (Shobana & Samraj, 2024). Metode berbasis *deep learning*, seperti Jaringan Saraf Tiruan Konvolusional Hierarkis Pohon (*Tree Hierarchical Deep Convolutional Neural Network*), juga telah diusulkan untuk mengidentifikasi *Cluster Head* (CH) yang optimal dan meningkatkan efisiensi perutean (Rahmani dkk., 2023). Metode ini memanfaatkan fungsi *fitness* multi-objektif yang mempertimbangkan faktor-faktor seperti kepadatan *cluster*, laju lalu lintas, dan tingkat energi untuk meningkatkan masa pakai dan *throughput* jaringan.

Federated Deep Reinforcement Learning (FDRL) adalah pendekatan inovatif lain untuk perutean di WSN yang mendukung IoT. Dengan memungkinkan pengambilan keputusan terdistribusi dan perutean adaptif, FDRL menyeimbangkan beban jaringan dan pemanfaatan sumber daya secara efektif (Suresh dkk., 2024). Metode ini membagi beban data menjadi pasangan *cluster*, memastikan kinerja jaringan yang optimal sambil mengurangi konsumsi energi dan latensi. Algoritma metaheuristik hibrida, seperti kombinasi Algoritma Predator Laut (*Marine Predators Algorithm* - MPA) dan Algoritma Kawin Burung Pelatuk (*Woodpecker Mating Algorithm* - WMA), telah digunakan untuk mengoptimalkan protokol perutean (Rahmani dkk., 2023). Algoritma ini meningkatkan kepercayaan, konektivitas, dan parameter Kualitas Layanan (*Quality of Service* - QoS), menghasilkan penundaan minimal dan rasio pengiriman yang lebih tinggi di WSN.

Protokol perutean sadar energi (*Energy-Aware Routing*) memprioritaskan rute yang meminimalkan konsumsi energi. Protokol ini sering mempertimbangkan metrik seperti energi sisa, jarak transmisi, dan kualitas tautan. Misalnya, Protokol Perutean Klaster Sentris Energi (*Energy Centric Clustering Routing Protocol* - EC2RP) menggunakan energi sisa dan parameter jarak untuk memilih rute optimal, mengurangi konsumsi energi, dan memperpanjang masa pakai jaringan (Reddy dkk.,

t.t.). Demikian pula, Algoritma Perutean Sadar Energi dan Pemanenan Energi (*Energy-Harvesting and Energy-Aware Routing Algorithm* - EHEARA) mengintegrasikan pemanenan energi surya dengan klasterisasi dinamis untuk menyeimbangkan penggunaan energi di seluruh *node* (Saleh dkk., 2021).

Perutean Berbasis Klaster (*Cluster-Based Routing*) adalah teknik perutean yang banyak digunakan di WSN. Ini melibatkan pengelompokan *node* ke dalam *cluster*, dengan setiap *cluster* memiliki kepala *cluster* (CH) yang bertanggung jawab untuk agregasi data dan transmisi ke stasiun basis. Algoritma Klasterisasi Hemat Energi (*Energy-Efficient Clustering Algorithm* - EHEARA) secara dinamis menyesuaikan pembentukan *cluster* berdasarkan ketersediaan energi, memastikan konsumsi energi yang seimbang (Saleh dkk., 2021). Pendekatan lain, protokol Perutean Agregasi Data Berbasis Klaster (*Cluster-Based Data Aggregation Routing* - CDAR), meminimalkan konsumsi energi dengan mengoptimalkan konstruksi *cluster* dan pohon agregasi data (Wen & Lin, 2007). Protokol *clustering* berbasis logika *fuzzy* telah diusulkan untuk meningkatkan efisiensi energi di WSN (Bian, 2023). Protokol ini mempertimbangkan faktor-faktor seperti kepadatan *node*, status energi, dan struktur jaringan untuk memilih *cluster head* secara dinamis, memastikan distribusi energi yang seimbang dan stabilitas jaringan yang lebih baik.

Protokol perutean geografis menggunakan informasi lokasi untuk membuat keputusan perutean. Protokol Perutean Geografis Sadar Energi (*Energy-Aware Geographic Routing Protocol* - EA-TPGF-SS) menggabungkan perutean geografis dengan penjadwalan tidur untuk mengurangi konsumsi energi. Ini menggunakan mekanisme tidur tersinkronisasi dan umpan balik pada tingkat energi *node* relai untuk meningkatkan masa pakai jaringan dan efisiensi pengiriman (Alafeef dkk., 2017). Algoritma perutean terinspirasi bio berasal dari fenomena alam, seperti intelijen *swarm*, untuk mengoptimalkan efisiensi energi. Misalnya, algoritma Penjadwalan dan Perutean Sadar Energi terinspirasi bio menggunakan perilaku evolusioner untuk meminimalkan konsumsi energi di lapisan MAC dan jaringan (Honguntikar dkk., 2018).

Manajemen masa pakai baterai di WSN melibatkan optimasi perangkat keras dan perangkat lunak. Optimasi perangkat keras berfokus pada pengembangan *node*

sensor hemat energi dengan komponen berdaya rendah. Selain itu, sistem energi hibrida yang menggabungkan daya baterai dengan teknik pemanenan energi, seperti sel surya atau pemanen energi getaran, telah diusulkan untuk memperpanjang masa pakai jaringan (Mookhambika & Raja, 2024), (Sivasankar dkk., 2024). Algoritma perangkat lunak memainkan peran penting dalam mengelola masa pakai baterai. Teknik-teknik seperti manajemen siklus tugas cerdas dan algoritma perutean yang sadar daya mengoptimalkan aktivitas sensor dan jadwal tidur, mengurangi pemborosan energi (D. V. D. Hemanand Rajalakshmi S, 2024), (Sivasankar dkk., 2024). Metode agregasi dan kompresi data juga berkontribusi pada konservasi energi dengan meminimalkan jumlah data yang ditransmisikan (Archana & Prakasam, 2024), (Sivasankar dkk., 2024).

Strategi tidur sadar energi memanfaatkan data historis dan pola lalu lintas untuk memprediksi periode aktivitas rendah, di mana perangkat dapat masuk ke mode tidur (Jenitha dkk., 2024). Strategi ini menyeimbangkan antara konservasi energi dan kinerja jaringan, memperpanjang masa pakai operasional perangkat IoT. Siklus tidur-bangun adaptif, dikombinasikan dengan metode berbasis logika *fuzzy*, telah diusulkan untuk mengoptimalkan penggunaan energi di WSN (Surenter dkk., 2024). Metode ini secara dinamis menyesuaikan jadwal tidur berdasarkan konektivitas *node* dan energi sisa, memastikan manajemen energi yang efisien. Teknik *machine learning* (ML) telah banyak diterapkan untuk mengoptimalkan penjadwalan tidur pada perangkat IoT. Misalnya, pendekatan berbasis Jaringan Saraf Tiruan Konvolusional (*Convolutional Neural Network* - CNN) secara dinamis menyesuaikan jadwal tidur berdasarkan tingkat aktivitas jaringan yang diprediksi (Hema dkk., 2024). Metode ini memastikan penghematan energi sambil menjaga responsivitas, membuatnya cocok untuk perangkat *Narrowband IoT* (NB-IoT) di jaringan 5G.

Penjadwalan tidur (*sleep scheduling*) merupakan strategi kunci untuk menghemat energi di WSN. Dengan secara berkala menempatkan *node* ke dalam kondisi tidur berdaya rendah, mekanisme ini mengurangi *idle listening* dan transmisi yang tidak perlu. Penjadwalan tidur tersinkronisasi memastikan bahwa *node* bangun pada interval yang telah ditentukan untuk berkomunikasi. Protokol

Perutean Sadar Energi dengan Penjadwalan Tidur (*Energy-Aware Routing Protocol with Sleep Scheduling* - EARP) menggunakan pendekatan berbasis pohon, di mana *node* internal tetap terjaga sementara *node* daun tidur. Metode ini memastikan perutean data yang andal sambil mengurangi konsumsi energi (Swain dkk., 2010). Mekanisme tidur asinkron memungkinkan *node* untuk tidur secara independen tanpa sinkronisasi yang ketat. Algoritma Perutean Hemat Energi (*Energy-Saving Routing Algorithm* - ERSE) menggunakan model tidur asinkron, memaksa *node* berenergi rendah ke dalam keadaan tidur yang diperpanjang untuk menghemat energi (Chunyue dkk., 2019). Siklus tugas melibatkan pergantian antara status aktif dan tidur. Protokol Perutean Hemat Energi Oportunistik (*Opportunistic Energy-Efficient Routing Protocol* - OEERP) secara dinamis menyesuaikan jadwal tidur berdasarkan energi sisa dan laju aliran, memastikan efisiensi energi sambil mempertahankan kinerja jaringan (Suresh dkk., 2022).

Teknik agregasi dan kompresi data sangat penting untuk mengurangi volume data yang ditransmisikan di WSN. Teknik-teknik ini tidak hanya meminimalkan transmisi data yang redundan tetapi juga menurunkan energi yang dibutuhkan untuk memproses dan mengirimkan data. Misalnya, protokol I-LEACH menggunakan mekanisme fusi data untuk mengurangi transfer energi yang redundan, sementara protokol lain menggunakan algoritma kompresi untuk lebih mengoptimalkan transmisi data (Sivasankar dkk., 2024), (Sushil Lekhi, 2024b). Protokol hemat energi seperti *Energy-Efficient Time Division Multiple Access* (EETDMA) dan *Energy-Efficient Bit Map-Assisted* (EEBMA) telah dikembangkan untuk aplikasi pemantauan berkelanjutan dan berbasis *event* secara berurutan (AlZahrani dkk., 2023). Protokol ini mengoptimalkan agregasi dan transmisi data, mengurangi konsumsi energi sambil mempertahankan *throughput* yang tinggi.

Teknik fusi data berbasis *deep learning*, seperti Jaringan Saraf Tiruan Berulang (*Recurrent Neural Network* - RNN) dengan Memori Jangka Pendek Panjang (*Long Short-Term Memory* - LSTM), telah digunakan untuk meningkatkan agregasi data di WSN (Mahmood dkk., 2024). Metode ini mengurangi redundansi data dan meningkatkan penyeimbangan beban di pusat fusi, yang mengarah pada latensi dan konsumsi energi yang lebih rendah. Algoritma optimasi multi-objektif,

seperti algoritma Agregasi Data Laju Pengambilan Sampel yang Dioptimalkan (*Optimized Sampling Rate Data Aggregation - OSRDA*), telah dirancang untuk menjaga konsistensi data sambil meminimalkan konsumsi energi (AlZahrani dkk., 2023). Algoritma ini mengklasifikasikan *node* ke dalam kategori pemantauan *event* dan berkelanjutan serta mengoptimalkan laju pengambilan sampel yang sesuai.

Agregasi data berbasis *cluster* melibatkan pengumpulan dan pemrosesan data di kepala *cluster* sebelum mentransmisikannya ke stasiun basis. Protokol Perutean Agregasi Data Berbasis Klaster (*Cluster-Based Data Aggregation Routing - CDAR*) mengoptimalkan konstruksi *cluster* dan pohon agregasi untuk meminimalkan konsumsi energi (Wen & Lin, 2007). Demikian pula, protokol Perutean Agregasi Data Hemat Energi (*Energy-Efficient Data Aggregation Routing - EEDAR*) menggunakan rentang transmisi dinamis dan siklus tugas untuk lebih mengurangi penggunaan energi. Algoritma kompresi digunakan untuk mengurangi ukuran data sebelum transmisi, menurunkan konsumsi energi (Wen dkk., 2014). Model matematika canggih, seperti logika *fuzzy* dan jaringan saraf tiruan *backpropagation* (BPNN), telah diusulkan untuk meningkatkan efisiensi fusi data. Kerangka kerja terintegrasi menggunakan logika *fuzzy* untuk pemilihan kepala *cluster* dan BPNN untuk fusi data, mengurangi transmisi yang redundan dan meningkatkan kinerja jaringan (Komal, 2024).

Perutean, penjadwalan tidur, dan agregasi data adalah mekanisme penting untuk mencapai efisiensi energi dalam Jaringan Sensor Nirkabel (WSN). Strategi-strategi ini, yang didukung oleh algoritma canggih, protokol, dan implementasi perangkat keras, secara kolektif meminimalkan konsumsi energi dan memperpanjang masa pakai jaringan. Penelitian di masa depan harus berfokus pada integrasi AI, peningkatan pemanenan energi, dan memastikan skalabilitas serta keandalan sistem.

Tabel 2. 3 GAP Penelitian Strategi Efisiensi Energi: Routing, Sleep Scheduling, dan Aggregation

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2025, K. Yasotha, K. Meenakshi	Optimizing Energy Efficiency and	HEED, LEACH, TEEN + Chaotic	CFA efektif mitigasi malicious

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Sundaram, J. Vandarkuzhali, International journal of computational and experimental science and engineering, Q3.	Network Performance in Wireless Sensor Networks: An Evaluation of Routing Protocols and Swarm Intelligence Algorithm	Firefly Menggunakan AI (Swarm Intelligence) Tidak Menggunakan Bateray	route & latency sehingga Performance WSN meningkat.
2024, Yang Liu, Damin Zhang, Lun Li, Qiang He, Scientific Reports, Q1.	Energy Efficient Cluster-Based Routing Protocol for WSN using Multi-Strategy Fusion Snake Optimizer and Minimum Spanning Tree	MSSO + Minimum Spanning Tree Menggunakan AI (Metaheuristik + Fuzzy C-means) Tidak Menggunakan Bateray	Energy saving 26%, lifetime naik 52%
2024, Veeresh M. Hiremath, Sidlingappa Kerur, Anand Gudnavar, Indonesian Journal of Electrical Engineering and Computer Science, Q2.	Energy efficient routing protocol for enhancing the network lifetime in wireless sensor network	LEACH + Multihop + Sectoring Tidak Menggunakan Bateray	Lifetime meningkat 515%
2024, Tadele A. Abose, Venumadhav Tekulapally, Diriba C. Kejela, Ketema T. Megersa, Samuel T. Daka, Kehali A. Jember, IEEE Access,.	Optimized Cluster Routing Protocol with Energy-Sustainable Mechanisms for Wireless Sensor Networks	IMP-RES-EL + EE-SEP Tidak Menggunakan Bateray	Peningkatan lifetime 36%, throughput 44%
2024, Sushil Lekhi, Satvir Singh, Journal of Electrical Systems.	Enhancing Energy Efficiency in Wireless Sensor Networks through I-LEACH: A Data Clustering and Routing Protocol	I-LEACH + Data Fusion Tidak Menggunakan Bateray	Threshold baru + trust data fusion
2024, Shanker MC, D. Saraswathi, R. Deepalakshmi, S. Jacily Jemila, A.	Optimizing Energy-Efficient Routing in Wireless Sensor	Genetic Algorithm (GA) Tidak Menggunakan Bateray	Rute optimal berbasis kromosom

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Sathishkumar, International Conference on Cybernation and Computation (CYBERCOM).	Networks via Genetic Algorithm for Enhanced Performance		
2024, Sachidhanandam P, Sakthivel M, Gomathi A, U. G, ICTACT Journal on Communication Technology	Energy-efficient routing in wireless sensor networks using deep belief networks and lstm for mobile sink path optimization and cluster head selection	Deep Belief Network + LSTM Menggunakan AI Deep Learning. Tidak Menggunakan Bateray	Lifetime +40%, efisiensi +25%

Berdasarkan Tabel 2.3. analisis kritis terhadap berbagai studi optimasi *routing* pada *Wireless Sensor Network* (WSN), teridentifikasi bahwa sebagian besar penelitian masih terpaku pada algoritma klasik dan metaheuristik seperti LEACH, HEED, *Genetic Algorithm*, dan *Deep Belief Network* seperti yang dilakukan oleh (Liu, N. dkk., 2025), (Liu, Y. dkk., 2024), (Sushil Lekhi, 2024a). Meskipun fokus utama mereka adalah efisiensi energi melalui pengelompokan *node* dan optimalisasi rute komunikasi, sangat sedikit studi yang secara eksplisit memanfaatkan kecerdasan buatan, dan yang lebih penting, belum ada yang menerapkan *generative modeling* seperti *Generative Adversarial Network* (GAN) untuk memperkaya representasi data lingkungan. Kami juga belum menemukan adanya integrasi antara GAN dengan *reinforcement learning* (RL), seperti *Q-Learning*, padahal kombinasi ini menawarkan potensi besar untuk menciptakan sistem *routing* yang sangat adaptif dan responsif terhadap dinamika lingkungan nyata, seperti perubahan suhu, kelembaban, dan kondisi energi.

Penelitian ini secara strategis mengisi kekosongan tersebut dengan mengembangkan kerangka kerja Smart Adaptive Routing yang menggabungkan GAN dan Q-Learning. Dalam pendekatan ini, GAN berperan dalam mensintesis data lingkungan yang realistis berdasarkan data sensor sebelumnya, sementara Q-Learning digunakan untuk merancang strategi routing berbasis reward yang

mempertimbangkan efisiensi energi, kestabilan koneksi, dan status node. Dengan cara ini, penelitian ini tidak hanya bertujuan meningkatkan performa jaringan dalam simulasi, tetapi juga membuka jalan baru dalam penerapan WSN cerdas berbasis pembelajaran adaptif dan pemodelan generatif. Pendekatan inovatif ini sangat relevan untuk aplikasi dunia nyata seperti pertanian presisi, pemantauan bencana, dan pengelolaan energi berbasis sensor.

2.1.4 Penempatan Node dan Optimasi Cakupan

Optimalisasi penempatan *node* merupakan tantangan krusial dalam jaringan nirkabel, jaringan sensor, dan pusat data. Memastikan cakupan maksimum sambil menjaga konektivitas dan meminimalkan konsumsi energi sangat penting untuk operasi yang efisien dari jaringan-jaringan ini. Berbagai faktor teknologi dan algoritma optimasi telah dieksplorasi untuk mengatasi tantangan ini. Tanggapan ini memberikan analisis komprehensif tentang faktor-faktor teknologi dan membandingkan efektivitas berbagai algoritma optimasi, termasuk algoritma genetik (GA), optimasi kawanan partikel (PSO), dan pendekatan *machine learning*. Metode seperti *clustering* dan algoritma metaheuristik seperti Grey Wolf Optimizer (GWO) banyak digunakan untuk mengoptimalkan posisi node dan pemilihan kepala kluster (Feng-Lin Liu, Ning Ding, Guodi Zheng, 2024), (Shobana V, 2024). Penempatan node yang buruk dapat menyebabkan tumpang tindih cakupan dan pemborosan energi.

Cakupan dan konektivitas merupakan dua tantangan mendasar dalam jaringan sensor nirkabel (WSN). Penempatan *node* harus memastikan bahwa seluruh area yang diminati tercakup sambil menjaga konektivitas antar *node* untuk memfasilitasi transmisi data. Penelitian telah menunjukkan bahwa algoritma yang terinspirasi alam, seperti GA, PSO, *Ant Colony Optimization* (ACO), dan *Artificial Bee Colony* (ABC), dapat efektif dalam mengatasi tantangan ini (Vu dkk., 2023).

Algoritma ini sangat berguna di lingkungan yang tidak beraturan dengan hambatan, di mana strategi penempatan tradisional mungkin gagal. Dalam WSN berbasis *cluster*, penempatan *relay node* (RN) sangat penting untuk memastikan cakupan dan konektivitas. Algoritma evolusi multi-objektif (EA), seperti *differential evolution* (DE), PSO, DE multi-objektif (MODE), dan PSO multi-objektif

(MOPSO), telah diusulkan untuk mengoptimalkan penempatan RN. Algoritma ini mempertimbangkan beberapa tujuan yang saling bertentangan, seperti cakupan, konektivitas, dan efisiensi energi, dan telah terbukti mengungguli pendekatan tradisional (Harizan dkk., 2023).

Efisiensi energi salah satu faktor penting lainnya dalam optimalisasi penempatan *node*. Dalam WSN, konsumsi energi menjadi perhatian signifikan karena keterbatasan pasokan daya *node* sensor. Algoritma hibrida, seperti kombinasi DE dan *Quantum-Behaved Particle Swarm Optimization* (DE-QPSO), telah diusulkan untuk memaksimalkan cakupan sambil meminimalkan konsumsi energi. Algoritma ini telah terbukti memberikan konfigurasi jaringan yang andal dan meningkatkan efisiensi energi (Banerjee dkk., 2021). Di pusat data, penempatan *server* nirkabel memerlukan optimasi yang cermat untuk meminimalkan konsumsi energi sambil menjaga cakupan dan konektivitas. Algoritma evolusi multi-objektif (MOEA) telah digunakan untuk mengoptimalkan penempatan *server* nirkabel, dengan mempertimbangkan faktor-faktor seperti cakupan, intensitas propagasi, dan intensitas interferensi (Cao dkk., 2020).

Lingkungan dengan hambatan, penempatan *node* menjadi lebih menantang. Algoritma hibrida, seperti kombinasi PSO dan *Grey Wolf Optimization* (GWO), telah diusulkan untuk meningkatkan cakupan di lingkungan tersebut. Algoritma ini telah terbukti mencapai tingkat cakupan yang lebih tinggi dibandingkan dengan algoritma tradisional (Kou & Wei, 2023). Algoritma genetik banyak digunakan untuk optimasi penempatan *node* karena kemampuannya menangani masalah multi-objektif. Dalam WSN, GA telah digunakan untuk memaksimalkan cakupan sambil meminimalkan jumlah *node* aktif dan konsumsi energi. Integrasi GA dengan algoritma lain, seperti PSO, telah terbukti meningkatkan kecepatan konvergensi dan menghindari *local optima* (Chen, T. & Bu, 2019). Pada pusat data, GA telah digunakan untuk mengoptimalkan penempatan *server* nirkabel, dengan mempertimbangkan berbagai tujuan seperti cakupan, intensitas propagasi, dan intensitas interferensi. Hasilnya menunjukkan bahwa GA dapat memberikan solusi efisien untuk masalah optimasi yang kompleks (Cao dkk., 2020).

PSO telah dikombinasikan dengan algoritma lain, seperti ACO dan ABC, untuk meningkatkan cakupan dan konektivitas. Algoritma hibrida ini telah terbukti mengungguli PSO tradisional dalam hal tingkat cakupan dan kecepatan konvergensi (Vu dkk., 2023). Pada pusat data, PSO telah digunakan untuk mengoptimalkan penempatan *server* nirkabel, dengan mempertimbangkan berbagai tujuan seperti cakupan, intensitas propagasi, dan intensitas interferensi. Hasilnya menunjukkan bahwa PSO dapat memberikan solusi efisien untuk masalah optimasi yang kompleks (Cao dkk., 2020). Pendekatan *machine learning*, seperti *K-Nearest Neighbors* (KNN), telah digunakan untuk mendukung optimasi penempatan *node*. Dalam WSN, KNN telah digunakan untuk memperkirakan kekuatan sinyal dan mengoptimalkan posisi *node* menggunakan algoritma metaheuristik, seperti Algoritma Burung Hitchcock Terintensifikasi (*Intensified Hitchcock Bird-Inspired Algorithm* - I-HBIA). Pendekatan hibrida ini telah terbukti memberikan prediksi sinyal yang akurat dan proposisi penempatan yang efisien (Poggi dkk., 2022).

Pada pusat pendekatan *machine learning* telah digunakan untuk mengoptimalkan penempatan *server* nirkabel, dengan mempertimbangkan faktor-faktor seperti cakupan, intensitas propagasi, dan intensitas interferensi. Pendekatan ini telah terbukti memberikan solusi efisien untuk masalah optimasi yang kompleks (Cao dkk., 2020). Pendekatan hibrida, yang menggabungkan algoritma berbeda, telah diusulkan untuk mengatasi keterbatasan algoritma individual. Misalnya, kombinasi PSO dan GWO telah terbukti meningkatkan cakupan di lingkungan berhambatan. Algoritma hibrida telah terbukti mencapai tingkat cakupan yang lebih tinggi dibandingkan dengan algoritma tradisional (Kou & Wei, 2023). Kombinasi GA dan PSO telah digunakan untuk mengoptimalkan penempatan *node*. Algoritma hibrida telah terbukti meningkatkan kecepatan konvergensi dan menghindari *local optima*, memberikan cakupan yang lebih baik dan efisiensi energi. Algoritma hibrida, seperti DE-QPSO, juga telah digunakan untuk mengoptimalkan penempatan *server* nirkabel. Algoritma ini telah terbukti memberikan konfigurasi jaringan yang andal dan meningkatkan efisiensi energi (Banerjee dkk., 2021).

Meskipun telah ada kemajuan dalam optimasi penempatan *node*, beberapa tantangan masih tetap ada. Ini termasuk kebutuhan akan algoritma yang lebih

efisien untuk menangani jaringan berskala besar, integrasi pendekatan machine learning dengan algoritma metaheuristik, dan pengembangan algoritma yang dapat menangani lingkungan dinamis. Penelitian yang akan dilakukan berfokus pada pengembangan algoritma hibrida yang menggabungkan kekuatan berbagai teknik optimasi. Selain itu, integrasi pendekatan machine learning dengan algoritma metaheuristik harus dieksplorasi lebih lanjut untuk memberikan prediksi yang lebih akurat dan proposisi penempatan yang lebih efektif.

Tabel 2. 4 Gap Penelitian Penempatan Node

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2025, Zhilan Chen, Jiatang Cheng, Ming He, Evolutionary Intelligence.Q2.	Coverage Optimization in Wireless Sensor Network Based on Multi-Strategy Dung Beetle Optimization Algorithm	multi-strategy dung beetle optimization algorithm (MsDBO) Menggunakan AI Beetle Optimization Algorithm. dengan Fokus pada penempatan WSN.	Algoritma optimasi kumbang kotoran multi-strategi (MsDBO) menunjukkan peningkatan yang signifikan dalam cakupan, dengan kenaikan sebesar 12,97% dan 11,64% dalam skenario dua dimensi (2D) dibandingkan algoritma optimasi kumbang kotoran (DBO) tradisional. Dalam skenario tiga dimensi (3D), MsDBO juga tampil lebih baik, dengan peningkatan cakupan sebesar 2,38% dan 2,77% dibandingkan algoritma DBO.
2025, Monica Gunjal, Pramodkumar H. Kulkarni, International Journal of Power Electronics and Drive Systems.Q3	A novel competitive cuckoo search algorithm for node placement in wireless sensor networks	competitive Cuckoo search algorithm (CCSA) Tidak menggunakan AI atau ML	Penelitian menyoroiti bahwa CCSA meningkatkan konvergensi dan memperluas variasi solusi dengan memanfaatkan populasi elit dan mengintegrasikan algoritma pengelompokan fuzzy C-

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
			mean, yang mengoptimalkan pengelompokan berdasarkan faktor-faktor seperti energi kepala klaster, kepadatan, dan lokasi.
2025, Jin Ren, Yibo Li, IEEE Internet of Things Journal. Q1.	Energy-Efficient Coverage Enhancement Strategy for WSNs Based on a Competitive Learning Optimizer	multi-objective competitive learning optimizer (MOCLO), Tidak menggunakan AI atau ML	Optimasi Pembelajaran Kompetitif Multi-Tujuan (MOCLO) Multi-objective competitive learning optimizer (MOCLO) terbukti efektif dalam mengatasi masalah peningkatan cakupan yang efisien energi (energy-efficient coverage enhancement - EEC). Algoritma ini mengonsumsi lebih sedikit energi dan mencapai cakupan yang lebih tinggi dibandingkan dengan tiga algoritma optimasi multi-tujuan populer lainnya.
2024, S. Kusuma, K. N. Veena, B. P. V. Kumar, E. Naresh, Lobo Athena Marianne, SN computer science.	Meta Heuristic Technique with Reinforcement Learning for Node Deployment in Wireless Sensor Networks	Intelligent Satin Bower Bird Optimizer with reinforcement learning (ISBO-RL). Tidak menggunakan AI atau ML	ISBO-RL menggunakan metode Penentuan Posisi Optimum (OPF) untuk mengidentifikasi lokasi node sensor utama, sehingga penempatan sensor dapat dioptimalkan dan disesuaikan berdasarkan kinerja serta kondisi yang berubah-ubah, yang pada akhirnya berkontribusi pada penghematan daya dan perpanjangan umur jaringan.

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2024, Peng Wang, Yonghua Xiong, Future Internet.	A Method to Optimize Deployment of Directional Sensors for Coverage Enhancement in the Sensing Layer of IoT	improved particle swarm optimization (IPSO). Tidak menggunakan AI atau ML	Metode ini juga mengurangi konsumsi energi selama proses redeploy, sehingga meningkatkan efisiensi keseluruhan jaringan sensor dalam lingkungan IoT.
2024, Kondisetty Venkata Naga Aruna Bhargavi, Gottumukkala Partha Saradhi Varma, I. Hemalatha, Ravilla Dilli, Sensors.	An Enhanced Particle Swarm Optimization-Based Node Deployment and Coverage in Sensor Networks	enhanced particle swarm optimization (EPSO) Tidak menggunakan AI atau ML	Fungsi kecocokan dari algoritma EPSO mencapai hasil konvergen dengan rata-rata jumlah iterasi sebanyak 78, 82, dan 80 pada pita frekuensi 3,6 GHz, 26 GHz, dan 38 GHz, masing-masing, menunjukkan bahwa kondisi cakupan yang dibutuhkan terpenuhi dengan radius komunikasi sebesar 4 meter, yang jauh lebih efisien dibandingkan karya-karya sebelumnya yang memiliki radius komunikasi berkisar antara 6 hingga 120 meter.
2024, Jie Song, Yongmao Hu, Yanbi Luo, IEEE sensors journal.	Wireless Sensor Network Coverage Optimization Based on the Novel Enhanced Hunter-Prey Optimization Algorithm	novel enhanced hunter-prey optimization (NEHPO). Tidak menggunakan AI atau ML	Hasil simulasi menunjukkan bahwa algoritma NEHPO menunjukkan daya adaptasi yang lebih tangguh dalam mengoptimalkan penempatan node di lingkungan yang memiliki rintangan, secara efektif mengatasi masalah terkait optimisasi lokal dan

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
			meningkatkan kinerja cakupan secara keseluruhan dalam jaringan sensor nirkabel.
2024, Georgios Siamantas, Dionisis Kandris, Electronics.	Particle Swarm Optimization for k-Coverage and 1-Connectivity in Wireless Sensor Networks	Particle Swarm Optimization Menggunakan ML PSO	Hasil dari algoritma dibandingkan dengan algoritma relatif, menyoroti efektivitas dan potensi keunggulannya dalam mengoptimalkan cakupan dan konektivitas dalam aplikasi dunia nyata.
Deden Ardiansyah, 2025		GAN + Q-Learning	Prediksi state lingkungan + reward-based routing adaptif

Mayoritas studi penempatan node dan optimasi cakupan pada *Wireless Sensor Networks (WSN)* masih berpusat pada pendekatan **metaheuristik**, seperti Particle Swarm Optimization (PSO), Artificial Bee Colony (ABC), Cuckoo Search, Lion Swarm Optimization (LSO), hingga kombinasi hybrid dengan Reinforcement Learning (seperti ISBO-RL) (Chen, Z. dkk., 2025), (Gunjal & Kulkarni, 2025), (Kusuma dkk., 2024), (Ren, J. & Li, 2025), (Wang, P. & Xiong, 2024). Studi-studi ini menunjukkan pencapaian signifikan dalam aspek coverage dan efisiensi energi, dengan peningkatan cakupan rata-rata di atas 90% dan pengurangan jumlah node aktif secara substansial. Namun, sebagian besar algoritma tersebut bersifat deterministik dan berbasis pemodelan heuristik tanpa kemampuan prediksi terhadap dinamika lingkungan, serta jarang mengakomodasi adaptasi real-time berdasarkan reward atau umpan balik lingkungan aktual.

Belum ditemukan satu pun studi yang menggabungkan model generatif (seperti GAN) untuk menyintesis kondisi lingkungan atau *Q-Learning adaptif* berbasis reward energi dan performa jaringan dalam konteks penempatan atau perutean node. Hal ini menciptakan peluang strategis bagi penelitian Anda, yang

mengusulkan integrasi *Generative Adversarial Network (GAN)* dan *Q-Learning* untuk membentuk sistem routing adaptif yang mampu belajar dari lingkungan dinamis. Dengan menggabungkan sintesis data lingkungan dan strategi pengambilan keputusan berbasis *reinforcement*, penelitian ini tidak hanya mampu mengisi gap metodologis dalam literatur, tetapi juga membuka jalur menuju penerapan WSN yang lebih otonom, efisien energi, dan tahan terhadap perubahan kontekstual di dunia nyata.

2.1.5 Q-Learning dalam Manajemen Energi WSN

Q-learning merupakan algoritma pembelajaran penguatan (*reinforcement learning*) yang dapat digunakan untuk mengambil keputusan secara dinamis dalam kondisi tidak pasti. Dalam konteks WSN, Q-learning mampu mengoptimalkan rute komunikasi, mode tidur, dan penempatan node berdasarkan reward fungsi efisiensi energi (Kumar & Asbe, 2023). Namun, pelatihan Q-learning di dunia nyata terbatas oleh keterbatasan data dan risiko konsumsi daya selama eksperimen.

Kontrol Transmisi Dinamis Q-Learning telah berhasil diterapkan untuk mengoptimalkan transmisi data di WSN. Misalnya, protokol SEES-QL secara dinamis menyesuaikan periode *on/off transceiver* radio berdasarkan riwayat transmisi dan kepentingan *node*, secara signifikan mengurangi konsumsi energi dan meningkatkan masa pakai jaringan sebesar 41% dibandingkan dengan metode tradisional (Abdul-Qawy dkk., 2024a). Optimasi Protokol MAC Protokol QX-MAC menggabungkan Q-Learning dengan teknik adaptif lalu lintas untuk meningkatkan efisiensi energi dan QoS di WSN. Dengan menyesuaikan parameter MAC secara dinamis, QX-MAC mencapai pengurangan konsumsi energi sebesar 23,23% dibandingkan dengan X-MAC dan 79,91% dibandingkan dengan B-MAC. (Afroz & Braun, 2021). Perutean Hemat Energi Beberapa penelitian telah memanfaatkan Q-Learning untuk mengembangkan protokol perutean hemat energi. Contohnya, algoritma Q-Learning menggunakan sistem *reward* berdasarkan properti jaringan dinamis untuk memilih rute optimal, mengurangi konsumsi energi hingga 53% sambil mempertahankan *packet loss* yang rendah (Kumar & Asbe, 2023).

Penyebaran Data Sadar Daya (*Power-Aware Data Dissemination*) Protokol PADD-QL menggunakan Q-Learning untuk memilih jalur penyebaran data yang optimal, mempertimbangkan arah horizontal dan vertikal. Pendekatan ini meningkatkan masa pakai jaringan sebesar 66% dibandingkan dengan protokol TTDD tradisional (Wang, N. C. dkk., 2024b). Manajemen Pemanenan Energi (*Energy Harvesting Management*) Dalam WSN pemanen energi (EH-WSN), Q-Learning telah digunakan untuk mengoptimalkan penyimpanan dan konsumsi energi. Misalnya, strategi manajemen energi berbasis Q-Learning di ACES-QL mengurangi konsumsi energi sebesar 18,07% dan meningkatkan energi sisa sebesar 3,40% dibandingkan dengan pendekatan Q-Learning tradisional (Jiayuan Wei, Xingyu Miao, 2021). Optimasi *Cross-Layer* Protokol CBT dan CBFT menggunakan Q-Learning untuk mengadaptasi keputusan transmisi berdasarkan status saluran dan *buffer*, menghindari pemborosan energi dari transmisi yang gagal. Pendekatan ini secara signifikan memperpanjang masa pakai jaringan (Savaglio dkk., 2019). Kontrol Siklus Tugas (*Duty Cycle Control*) Dalam WSN bertenaga surya, Q-Learning telah diterapkan untuk mengoptimalkan siklus tugas. Contohnya, strategi siang/malam berbasis Q-Learning memperpanjang jumlah siklus pengukuran/transmisi sebesar 12,7% dibandingkan dengan penelitian sebelumnya (Michal Prauzek, Jaromir Konecny, 2022).

Klasterisasi Hemat Energi (*Energy-Efficient Clustering*) Protokol CRLM menggabungkan Q-Learning dengan algoritma metaheuristik untuk mengoptimalkan klasterisasi dan perutean. Pendekatan ini mencapai peningkatan signifikan dalam masa pakai jaringan, mengungguli LEACH sebesar 140,7%. (Wang, Zhendong dkk., 2023). Manajemen Energi di IoT Kerangka kerja Q-EMS menggunakan Q-Learning untuk menyeimbangkan pasokan dan konsumsi energi di WSN berbasis IoT. Pendekatan ini mempertimbangkan sumber energi berbasis baterai, berbasis transfer, dan pemanenan, mengoptimalkan strategi manajemen energi untuk skenario yang berbeda (Ardiansyah dkk., 2024).

Q-Learning telah terbukti menjadi alat yang serbaguna dan efektif untuk manajemen energi di WSN. Dengan mengoptimalkan kontrol transmisi, perutean, klasterisasi, dan pemanenan energi, strategi berbasis Q-Learning secara signifikan

meningkatkan masa pakai dan efisiensi jaringan. Seiring dengan terus berkembangnya WSN, penelitian ini dilakukan untuk mengatasi skalabilitas, konvergensi, dan kendala perangkat keras.

Tabel 2. 5 Q-Learning dalam Energi manajemen WSN

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2025, Zhen Wang, Jin Duan, Entropy.	An Unequal Clustering and Multi-Hop Routing Protocol Based on Fuzzy Logic and Q-Learning in WSNs	Fuzzy-Q Learning (FQ-UCR) Menggunakan Mesin Learning dan tidak menggunakan GAN. Fokusnya pada Clustering & Routing	Efisiensi energi & mitigasi hotspot
2024, Sampoorna Bhimshetty, Agughasi Victor Ikechukwu, Indonesian Journal of Electrical Engineering and Computer Science.	Energy-efficient deep Q-network: reinforcement learning for efficient routing protocol in wireless internet of things	Deep Q-Network (DQN) Menggunakan Mesin Learning dan tidak menggunakan GAN. Fokusnya pada Routing protokol hemat energi.	Lifetime lebih tinggi dari LEACH dan FCM
2024, S. Kusaladharma, Raviraj S. Adve, M. Liyanage, IEEE International Conference on Communications.	A Q-Learning-Based Transmission Management Strategy for Energy Harvesting Sensors	Q-Learning + Markov Decision. Menggunakan Mesin Learning dan tidak menggunakan GAN. Fokus pada Manajemen transmisi energi harvesting.	Mengurangi outage, optimalisasi power
2024, Qiao Gang, Wazir Ur Rahman, Feng Zhou, Muhammad Bilal, Wasiq Ali, Sajid Ullah Khan, Muhammad Ilyas Khattak, Electronics.	A Q-Learning-Based Approach to Design an Energy-Efficient MAC Protocol for UWSNs Through Collision Avoidance	Q-Learning MAC Protocol (UWSN). Menggunakan Mesin Learning dan tidak menggunakan GAN. Fokus pada MAC protokol & collision avoidance.	Throughput +23%, PDR tinggi
2024, Neng Chung Wang, Chao-Yang Lee, Ming-Fong Tsai, H. Y. Fu, Wei-Jung Hsu, ICGEC	A Q-Learning-Based Power-Aware Data Dissemination Protocol for	PADD-QL (Q-Learning) Menggunakan Mesin Learning dan tidak menggunakan GAN. Fokus pada Data dissemination routing.	Lifetime meningkat 66%

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
	Wireless Sensor Networks		
2024, Nazeer Shaik, Ahmed Asif Shaik, International Journal of Advanced Research in Science, Communication and Technology.	Reinforcement Learning for Adaptive Cognitive Sensor Networks	Q-Learning RL Adaptive. Menggunakan Mesin Learning dan tidak menggunakan GAN. Fokus pada Adaptive parameter tuning.	Spektrum & efisiensi energi meningkat
2024, Et al. Balasaheb Balkhande, Deleted Journal.	Artificial Intelligence Driven Power Optimization in IoT-Enabled Wireless Sensor Networks	Deep Q-Network + DVFS. Menggunakan Mesin Learning dan AI tidak menggunakan GAN. Fokus pada Power optimization	QoS meningkat, efisiensi runtime tinggi
2024, Efi Dvir, Mark Shifrin, Omer Gurewitz, Mathematics.	Cooperative Multi-Agent Reinforcement Learning for Data Gathering in Energy-Harvesting Wireless Sensor Networks	Multi-Agent Q-Learning. Menggunakan Mesin Learning dan Tidak Menggunakan GAN. Fokus pada Data gathering EH-WSN.	Adaptif terhadap perubahan topologi
2024, Deden Ardiansyah, Mustafid Mustafid, Teddy Mantoro, SIML2024.	Q-Learning Energy Management System (Q-EMS) in Wireless Sensor Network	Q-Learning EMS. Mesin Learning dan Tidak Menggunakan GAN. Fokus pada Manajemen energi harvesting.	Keseimbangan suplai-permintaan energi
Deden Ardiansyah	GAN + Q-Learning Routing	GAN + Q-Learning Routing. Fokus pada Routing adaptif berbasis reward & lingkungan dan energi manajemen.	Prediksi kondisi + routing adaptif

Berdasarkan critical matrix tabel 5 terhadap studi terkini mengenai penerapan Q-Learning dalam manajemen energi pada Wireless Sensor Network (WSN), terlihat bahwa sebagian besar penelitian telah mengadopsi pendekatan pembelajaran adaptif untuk meningkatkan efisiensi routing, optimasi transmisi energi, dan pengumpulan data. Beragam teknik seperti Deep Q-Network, Fuzzy Q-

Learning, dan Multi-Agent Q-Learning telah diterapkan untuk merespons dinamika jaringan dan memperpanjang masa hidup sensor (Sampoorna Bhimshetty, 2024), (Shaik & Shaik, 2024), (Wang, N. C. dkk., 2024a), (Wang, Zhen & Duan, 2025). Namun, seluruh studi tersebut masih mengandalkan data lingkungan aktual sebagai input pembelajaran tanpa menggunakan model prediktif atau generatif untuk mensimulasikan kondisi lingkungan yang lebih luas dan tidak terduga. Selain itu, semua studi yang dianalisis masih terbatas pada simulasi, tanpa pendekatan prediksi proaktif berbasis data sintetis untuk mengantisipasi perubahan kontekstual di lingkungan WSN.

Penelitian ini hadir dengan pendekatan yang berbeda, yaitu dengan menggabungkan *Generative Adversarial Network (GAN)* dan *Q-Learning* untuk membangun strategi *smart adaptive routing* yang tidak hanya adaptif terhadap reward energi dan kualitas jaringan, tetapi juga dapat memperkirakan kondisi lingkungan melalui data sintetis hasil generasi GAN. Dengan cara ini, sistem dapat belajar dari kombinasi data nyata dan prediksi lingkungan, memungkinkan pembentukan kebijakan routing yang lebih tahan terhadap dinamika cuaca, ketersediaan energi surya, dan variabel lingkungan lainnya. Pendekatan ini merupakan kontribusi baru dalam bidang manajemen energi WSN, karena membuka jalur pengembangan sistem yang mampu mengoptimalkan pengambilan keputusan berbasis *future state*—yang selama ini belum disentuh dalam studi-studi Q-Learning sebelumnya.

2.1.6 Peran Generative Adversarial Networks (GAN) dalam Simulasi Data.

GAN terdiri dari dua jaringan saraf generator dan discriminator yang bekerja bersama untuk menghasilkan data sintetis yang mirip dengan data nyata. Dalam penelitian ini, GAN digunakan untuk menghasilkan skenario konsumsi energi, kondisi lingkungan, dan pola komunikasi untuk pelatihan Q-learning tanpa membebani node fisik (N. Alsalmi, K. Navaie, 2024). Penggunaan GAN menjawab masalah kurangnya data realistis untuk pelatihan reinforcement learning. GAN diterapkan dalam menghasilkan data spektral sintetis, mengatasi kelangkaan data dalam konteks ilmiah. Modifikasi seperti *Wasserstein GANs (WGANs)* membantu menghindari *mode collapse* dan meningkatkan akurasi pelabelan data,

meningkatkan kinerja model dalam kondisi data terbatas (García-Esteban dkk., 2023). Dalam pemodelan geologi, GAN digunakan untuk simulasi *fasies* kondisional, mengintegrasikan pola geologi dengan data yang diamati untuk memprediksi sumber daya bawah permukaan. Ini melibatkan pelatihan GAN agar konsisten dengan data pengkondisian input, meningkatkan kualitas dan penerapan model yang dihasilkan (Song dkk., 2021).

GAN beroperasi dengan melatih dua jaringan saraf, *generator* dan *discriminator*, untuk menghasilkan instance baru yang menyerupai distribusi data pelatihan. Pendekatan ini berlaku luas di bidang-bidang seperti visi komputer, segmentasi semantik, dan pemrosesan bahasa alami (Cros, 2023), (Torre, 2023). Arsitektur dan metode pelatihan GAN, termasuk fungsi kerugian dan teknik optimasi, sangat penting untuk keberhasilannya dalam menghasilkan data yang realistis. Tantangan seperti *mode collapse* dan ketidakstabilan pelatihan adalah area penelitian yang berkelanjutan (Krichen, 2023). Meskipun GAN menawarkan keuntungan signifikan dalam simulasi data, mereka juga menghadirkan tantangan dan pertimbangan etis. Masalah seperti bias kumpulan data, tuntutan komputasi, dan ketidakstabilan pelatihan dapat membatasi generalisasi keluaran GAN (Krichen, 2023), (Pradhan, 2025). Pengembangan GAN yang dilakukan dalam penelitian ini GAN membantu menghasilkan data transisi yang realistis untuk memperkaya replay buffer agen RL. Selain itu, GAN dapat digunakan untuk simulasi data lingkungan dan perilaku konsumsi energi, seperti variasi suhu, kelembaban, dan intensitas trafik, yang kemudian digunakan untuk melatih sistem pengambilan keputusan berbasis pembelajaran mesin secara lebih efisien. Dengan demikian, GAN tidak hanya mempercepat proses pembelajaran, tetapi juga meningkatkan efisiensi energi dengan mengurangi kebutuhan eksperimen fisik dan memperluas cakupan skenario pelatihan.

Tabel 2. 6 GAP Penelitian Peran Generative Adversarial Networks (GAN) dalam Simulasi Data

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2025, Balachandrar Jeganathan, International	Exploring the Power of Generative	Digit Image Generation. Basic GAN.	Image synthesis (MNIST). Visual similarity.

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Journal of Advances in Engineering and Management (IAEM).	Adversarial Networks (GANs) for Image Generation: A Case Study on the MNIST Dataset		Cocok untuk studi awal dan benchmark
2024, Swati Goyal, Lovely Kaushal, Deleted Journal.	Harnessing generative AI: Transformative applications in medical imaging and beyond	Healthcare, Education. Standard GAN	Synthetic data for AI training. Praktikalitas & resolusi gambar. Transformasi besar di pendidikan dan medis
2024, Sanskruti Patel, Unnati Patel, Jay Nanavati, International Conference on Computing for Sustainable Global Development.	Analyzing Generative Models for Realistic Data Augmentation across Modalities and Applications	Augmentasi Data Umum. GAN, VAE	Data diversity & overfitting prevention. IS, FID, F1-score, IoU. Meningkatkan performa klasifikasi & deteksi.
2024, E. V, Jenefa A, Thiyagu T.M, Lincy A, Antony Taurshia, International Journal of Knowledge-based and Intelligent Engineering Systems.	DeepGAN: Utilizing generative adversarial networks for improved deep learning	Multi-domain data. GAN-VAE	Cross-domain augmentation. Akurasi klasifikasi (97%). Efektif untuk augmentasi gambar & teks.
2024, Bilgi Yilmaz, Christian Laudagé, Ralf Korn, Sascha Desmettre, Commodities	Electricity GANs: Generative Adversarial Networks for Electricity Price Scenario Generation	Electricity Forecasting. Electricity GAN.	Synthetic electricity price data. Statistik kesesuaian distribusi. Mendukung strategi & validasi model risiko.
Deden Ardiansyah'(2025)		WSN & Environmental Sensing. Custom GAN + Q-Learning	Prediksi kondisi lingkungan. Reward routing, SoH, and energy consumption. Data sintetis untuk optimasi routing & manajemen energi

Berdasarkan critical matrix dari berbagai studi terkait penerapan Generative Adversarial Networks (GAN), dapat disimpulkan bahwa mayoritas pemanfaatan

GAN sejauh ini berfokus pada augmentasi data dalam domain citra, seperti rekonstruksi medis, pembuatan gambar digit, dan klasifikasi gambar multi-domain. Studi-studi tersebut menonjol dalam aspek peningkatan resolusi visual, pelatihan model klasifikasi, dan pencegahan overfitting, dengan evaluasi berbasis visual realism, akurasi klasifikasi, hingga metrik statistik seperti FID dan Inception Score. Namun, seluruh pendekatan ini belum menjangkau pemanfaatan GAN dalam bentuk data numerik bersifat waktu nyata (real-time), khususnya dalam sistem siber-fisik seperti Wireless Sensor Network (WSN) atau lingkungan yang memerlukan perutean dan pengambilan keputusan secara adaptif.

Penelitian ini bertujuan mengatasi kekurangan tersebut dengan menggunakan GAN untuk mensintesis data lingkungan yang dinamis seperti suhu, kelembapan, dan radiasi matahari. Data ini kemudian digunakan sebagai input untuk algoritma Q-Learning dalam sistem routing WSN. Berbeda dari studi sebelumnya yang hanya berfokus pada visual atau teks, pendekatan ini menggabungkan kekuatan GAN dan reinforcement learning guna menciptakan strategi routing yang adaptif berbasis reward dan prediksi kontekstual. Dengan demikian, penelitian ini tidak hanya memperluas penerapan GAN ke bidang energi dan IoT, tetapi juga memberikan kontribusi unik dalam pengembangan sistem sensor cerdas yang mampu belajar dan merespons secara proaktif terhadap kondisi lingkungan.

2.1.7 Integrasi GAN-Q-Learning untuk Optimasi Energi WSN

Integrasi GAN dengan Q-learning membentuk kerangka kerja GAN-Q-Learning yang memungkinkan pelatihan kebijakan manajemen energi dalam berbagai skenario lingkungan sintesis. Kerangka ini menghasilkan keputusan operasional seperti perutean, penempatan node, dan penjadwalan tidur yang efisien secara energi, adaptif terhadap perubahan jaringan, dan skalabel untuk implementasi WSN berskala besar (Anusuya dkk., 2024; Zhang, S. dkk., 2023).

Integrasi *Generative Adversarial Networks* (GAN) dengan Q-Learning untuk optimasi energi dalam Jaringan Sensor Nirkabel (WSN) adalah pendekatan yang menjanjikan untuk meningkatkan efisiensi dan umur panjang jaringan ini. Q-Learning, sejenis *reinforcement learning*, telah banyak digunakan untuk

mengoptimalkan konsumsi energi di WSN dengan secara dinamis menyesuaikan jalur perutean, mengelola aktivitas *node*, dan menyeimbangkan beban energi. Potensi integrasi dengan GAN dapat lebih meningkatkan kemampuan ini dengan menghasilkan data sintetik untuk mensimulasikan berbagai kondisi jaringan, sehingga meningkatkan proses pembelajaran algoritma Q-Learning. Integrasi ini bertujuan untuk mengatasi tantangan kelangkaan energi dan distribusi energi yang tidak merata di WSN, yang pada akhirnya mengarah pada operasi jaringan yang lebih berkelanjutan dan efisien.

Q-Learning telah berhasil digunakan untuk mengelola energi di WSN dengan mengoptimalkan konsumsi energi dan keseimbangan pasokan. *Q-Learning Energy Management System* (Q-EMS) berfokus pada pengurangan konsumsi energi melalui tindakan optimal berdasarkan *reward* dan hukuman, mengatasi kebutuhan energi, pemanenan, dan strategi transfer (Ardiansyah dkk., 2024). Q-Learning meningkatkan protokol perutean dengan mempelajari jalur optimal yang menyeimbangkan konsumsi energi di seluruh *node*, secara signifikan memperpanjang masa pakai jaringan dan mengurangi *packet delay* (Areibi, 2016; Kumar & Asbe, 2023). Protokol seperti PADD-QL menggunakan Q-Learning untuk memilih jalur transmisi data yang optimal, meningkatkan masa pakai jaringan hingga 66% dibandingkan dengan metode tradisional (Wang, N. C. dkk., 2024a).

GAN dapat menghasilkan data sintetik untuk mensimulasikan berbagai kondisi jaringan, menyediakan kumpulan data yang lebih kaya untuk dilatih oleh algoritma Q-Learning. Hal ini dapat meningkatkan ketahanan dan adaptasi model Q-Learning dalam skenario dunia nyata. Dengan mensimulasikan skenario konsumsi dan pemanenan energi yang berbeda, GAN dapat membantu dalam menyempurnakan strategi Q-Learning, memastikan bahwa model siap untuk kondisi operasional yang beragam. Q-Learning telah diterapkan untuk mengoptimalkan strategi pemanenan energi, meminimalkan transisi status sensor yang tidak perlu dan meningkatkan konservasi energi.

Integrasi Q-Learning dengan metode seperti *Kullback Sparse Encoder* membantu dalam mengelola lalu lintas dan kemacetan, mengurangi *overhead* perutean, dan meningkatkan rasio pengiriman paket.

Pendekatan Q-Learning yang ringan seperti SEES-QL secara dinamis menyesuaikan siklus transmisi, secara signifikan meningkatkan penghematan energi dan masa pakai sistem (Abdul-Qawy dkk., 2024b).

Meskipun integrasi GAN dengan Q-Learning menawarkan potensi besar, terdapat tantangan kompleksitas komputasi yang perlu dipertimbangkan secara serius, terutama karena *node* WSN memiliki sumber daya yang sangat terbatas. Berdasarkan identifikasi masalah pada Bab I, tantangan utama meliputi:

Tabel 2.6.a.Sumber Daya Terbatas Node WSN

Sumber Daya	Karakteristik Node WSN	Kebutuhan GAN	Implikasi
Memori	32-256 KB (mikrokontroler)	2-4 GB (training), 50-100 MB (inference)	GAN tidak dapat dijalankan di node
CPU	8-16 MHz, low-power	GPU (minimal NVIDIA GTX 1060 untuk training)	Diperlukan akselerator eksternal
Energi	Terbatas (baterai/harvesting)	Training: 100-300 Watt	Akan menguras baterai dalam hitungan jam
Komunikasi	Low-bandwidth (ZigBee, LoRa)	Transfer data besar (MB-GB)	Tidak efisien untuk komunikasi node

Untuk mengatasi tantangan tersebut, penelitian ini mengimplementasikan arsitektur hybrid yang memisahkan komputasi berat dari node sensor:

1. Offline Training (Edge/Cloud Server)

- Pelatihan GAN dilakukan secara *offline* pada edge server atau GPU server (bukan di node sensor)
- Kebutuhan: Memori ~2-4 GB, GPU NVIDIA GTX 1060 atau lebih tinggi
- Waktu training: 5000 epoch (sekitar 2-4 jam untuk dataset 5 tahun)
- Hasil training: Model GAN yang telah konvergen (D Loss ≈ 1.3 , G Loss ≈ 0.7)

2. Inference GAN pada Gateway

- Inference* GAN (menghasilkan data sintetik) hanya memerlukan CPU
- Dapat dijalankan di **gateway** atau **edge device** (Raspberry Pi 4 ke atas)

- c. Memori yang dibutuhkan: ~100-200 MB
- d. Data sintetik yang dihasilkan kemudian dikirim ke node dalam bentuk *policy update*

3. Node Sensor Hanya Menjalankan Q-Learning Inference

- a. Node tidak perlu menjalankan GAN sama sekali
- b. Node hanya menyimpan **Q-table** (2,8 MB) atau **Q-network** (small MLP)
- c. *Inference* Q-Learning: kompleksitas $O(|S| \times |A|)$ dengan $|S| = 5-10$ state, $|A| = 5$ aksi
- d. Konsumsi energi untuk inferensi: < 10 mW

4. Strategi Update Berkala

- a. Node menerima *policy update* dari gateway setiap beberapa jam/hari
- b. Komunikasi dilakukan saat energi mencukupi (siang hari)
- c. Update bersifat inkremental (hanya perubahan Q-value)

Tabel 2. 7 GAP Penelitian Integrasi GAN-Q-Learning untuk Optimasi Energi WSN.

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
2024 ,S. Anslam Sibi, L. Sherly Puspha Annabel ,	Optimizing Energy Resources in WSNs: ARIMA Feature Selection Meets Adaptive Reinforcement Learning	ARIMA + Actor-Critic RL. Fokus pada Feature selection + adaptive RL	Konsumsi energi rendah, lifetime tinggi
2024 ,Qiao Gang, Wazir Ur Rahman, Feng Zhou, Muhammad Bilal, Wasiq Ali, Sajid Ullah Khan, Muhammad Ilyas Khattak ,	A Q-Learning-Based Approach to Design an Energy-Efficient MAC Protocol for UWSNs Through Collision Avoidance	Q-Learning MAC Protocol. Fokus pada MAC dan collision avoidance	Throughput +23%, tabrakan - 38%
2024 ,Neng Chung Wang, Chao-Yang Lee, Ming-Fong Tsai,	A Q-Learning Based Power-Aware Data Dissemination Protocol for	PADD-QL (Q-Learning). Fokus pada Data dissemination	Peningkatan 66% lifetime


Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
H. Y. Fu, Wei-Jung Hsu ,	Wireless Sensor Networks		
2024 ,Jishan Li, Yong Feng ,	Deep-Reinforcement-Learning-Based Joint Energy Replenishment and Data Collection Scheme for WRSN	K-means + Deep RL. Fokus pada UAV energy replenishment	Optimasi multiobjektif efektif
2024 ,Jinyu Yuan, Jingyi Peng, Qing Yan, Gang He, Honglin Xiang, Zili Liu ,	Deep Reinforcement Learning-Based Energy Consumption Optimization for Peer-to-Peer (P2P) Communication in Wireless Sensor Networks	Double Deep Q Network (DDQN). Fokus pada P2P communication	Konsumsi energi rendah
2023 ,S. Soundararajan, B. R. Tapas Bapu, S. Sargunavathi, I. Poonguzhali ,	Self-attention based generative adversarial network with Aquila optimization algorithm espoused energy aware cluster head selection in WSN	Self-attention GAN + AqOA. Fokus pada CH selection berbasis GAN	Alive node +59%, delay -85%
2023 ,N.S. Murthy, G Venkata Subbaiah ,	Network life time augmentation of WSN through efficient energy using GAN algorithm	GAN for CH selection. Fokus pada Routing & energy at base station	Energi rendah, lifetime meningkat
2024 ,Amit Kumar Jain, Sushil Kumar	Optimizing wireless sensor network routing with Q-learning:	Q-Learning + K-means.	Efisiensi tinggi, node mortality rendah

Tahun, Penulis, Jurnal	Topik / Judul	Metode/Algoritma dan Sumber Energi	Hasil
Jain, Garima Mathur ,	enhancing energy efficiency and network longevity	Fokus pada Routing & CH election.	
Penelitian Ini (2025)		GAN + Q-Learning. Fokus pada Prediksi lingkungan + routing adaptif	Routing kontekstual & efisiensi energi

Sebagian besar studi terbaru telah mengadopsi Q-Learning atau *reinforcement learning* dalam bentuk lain untuk mengoptimalkan protokol komunikasi dan efisiensi energi dalam WSN. Studi seperti milik Qiao Gang et al. (2024) dan N.C. Wang et al. (2024) membuktikan efektivitas Q-Learning dalam meningkatkan throughput, mengurangi tabrakan data, dan memperpanjang umur jaringan. Namun, seluruh studi tersebut masih bergantung pada data lingkungan nyata sebagai dasar pengambilan keputusan, tanpa memanfaatkan pendekatan generatif yang bisa memprediksi kondisi yang tak teramati. Di sisi lain, studi yang menggunakan GAN seperti oleh Soundararajan dan Murthy hanya memfokuskan GAN untuk pemilihan cluster head dan augmentasi struktur topologi, tanpa integrasi langsung ke dalam kerangka routing berbasis pembelajaran.

Penelitian ini menjadi satu-satunya pendekatan yang mengintegrasikan GAN dan Q-Learning secara langsung dalam membentuk kebijakan routing adaptif berbasis reward dan prediksi lingkungan. Dengan menggunakan GAN untuk menyintesis data kondisi lingkungan seperti suhu, kelembaban, atau intensitas cahaya, Q-Learning dapat belajar dari state yang lebih kaya dan kontekstual, memungkinkan strategi perutean yang lebih efisien dan dinamis. Posisi ini tidak hanya menjembatani dua jalur riset besar (generatif dan pembelajaran adaptif), tetapi juga mengarah pada pengembangan sistem sensor cerdas yang lebih siap menghadapi ketidakpastian dan dinamika lingkungan.

2.2 Keaslian Penelitian



Gambar 2. 2.1. Clusterisasi Penelitian Sebelumnya menggunakan VOSviewer

2.2.1 Posisi Riset dalam Peta (Mapping State-of-the-Art)

Pada Peta ini menampilkan tiga cluster penelitian utama dalam bidang Wireless Sensor Networks (WSN) yang seluruhnya relevan dengan integrasi GAN (Generative Adversarial Networks) dan Q-Learning.

1. Cluster Pink (Arsitektur & Manajemen Node)


- a. Kata kunci seperti node, sensor node, residual energy, scheme, dan data adalah inti dari pengelolaan WSN.
- b. Dalam konteks riset: Q-Learning berperan mengatur jadwal pengaktifan node, pengaturan beban, dan pengalihan rute data agar residual energy optimal.
- c. GAN berkontribusi dengan mensintesis data lingkungan (misalnya variasi suhu, kelembaban, trafik data) untuk melatih Q-agent tanpa perlu data lapangan yang mahal atau sulit diperoleh.

2. Cluster Hijau (Protokol & Efisiensi Energi)

- a. Kata kunci protocol, energy efficiency, network lifetime, dan technique menandakan fokus penelitian pada mekanisme komunikasi hemat energi.

- b. Pada riset yang dilakukan posisi Q-Learning sebagai mekanisme adaptif untuk memilih protokol komunikasi terbaik sesuai kondisi lingkungan sintetis dari GAN.
 - c. GAN menghasilkan skenario lingkungan yang bervariasi Q-Learning mempelajari protokol optimal untuk memaksimalkan network lifetime.
3. Cluster Biru (Pendekatan & Aplikasi)
- a. Kata kunci approach, application, sensor, dan wireless sensor menunjukkan dimensi metodologi dan implementasi praktis.
 - b. Integrasi GAN–Q-Learning di sini dapat diposisikan sebagai approach baru untuk adaptive energy management.
 - c. Fokusnya adalah pada real-time decision-making yang mampu beradaptasi pada lingkungan dinamis (misalnya fluktuasi cuaca atau beban data).

2.2.2 Keterhubungan Antar-Cluster dalam Konteks GAN–Q-Learning



Gambar 2. 2 Bagan keterhubungan antar-klaster

Peta ini secara visual menunjukkan alur logis riset:


1. Node & Data (Pink): menyediakan sumber daya terbatas (energi, jalur komunikasi).
2. Protocol & Energy Efficiency (Hijau): Membutuhkan metode optimasi yang adaptif.
3. Approach & Application (Biru): Membawa solusi berbasis AI seperti GAN–Q-Learning.

Integrasi ini dapat dijelaskan sebagai berikut:

- a. GAN: Menghasilkan data sintetis berdasarkan pola historis, memungkinkan pengembangan skenario pelatihan tanpa keterbatasan dataset nyata.
- b. Q-Learning: Menggunakan data tersebut untuk belajar menentukan aksi terbaik, seperti mode operasi node, rute data, atau protokol switching.
- c. Hasil: Memperpanjang umur jaringan dan meningkatkan efisiensi energi.

2.2.3 State-of-the-Art Mapping

Dari peta, terlihat bahwa topik efisiensi energi dan protokol sudah cukup kuat, tetapi integrasi metode generatif (GAN) dengan reinforcement learning pengambilan keputusan (Q-Learning) masih jarang ditemukan dalam kata kunci. Sehingga terdapat novelty riset untuk Mendukung Kontribusi Ilmiah yang menghasilkan Metodologi baru, manfaat praktis dan dampak teknis.



Gambar 2.3. Integrasi Peta Vosviewer dengan Arsitektur GAN-Q-Learning untuk WSN

Berdasarkan analisis komprehensif terhadap state-of-the-art dan identifikasi gap penelitian, penelitian ini memiliki kontribusi orisinal yang dapat dibuktikan melalui empat dimensi kebaruan berikut:

1. Paradigma Baru: Dynamic Node Deployment dengan Generative-Adversarial Reinforcement Learning. Penelitian ini memperkenalkan paradigma penempatan node dinamis berbasis integrasi GAN-Q-Learning yang mampu mengatasi keterbatasan pendekatan statis konvensional. Keaslian terletak pada:
 - a. Generative Environment Simulation: GAN tidak hanya berfungsi sebagai generator data statis, tetapi sebagai dynamic environment simulator yang memodelkan transisi state lingkungan berdasarkan pola Markovian
 - b. Reinforcement Learning dengan Synthetic Experience: Q-Learning memanfaatkan lingkungan sintesis GAN untuk experience replay yang diperkaya dengan skenario ekstrem dan langka
 - c. Closed-Loop Adaptation: Terbentuknya sistem umpan balik tertutup di mana kebijakan penempatan node terus diperbarui berdasarkan kondisi lingkungan yang disimulasikan
2. Integrasi Pengetahuan Domain dalam Architecture AI Hybrid. Penelitian ini mengusulkan *domain-knowledge-infused* AI framework yang terintegrasi secara struktural:
 - a. *Physics-Based Reward Engineering*: Perancangan fungsi reward Q-Learning yang mengincorporasi model degradasi baterai, karakteristik panel surya, dan pola trafik data.
 - b. *Constraint-Aware Optimization*: Formulasi masalah penempatan node sebagai optimasi multi-objek dengan constraint fisik perangkat keras.
 - c. *Energy Harvesting-Aware Decision Making*: Mekanisme pengambilan keputusan yang mempertimbangkan prediksi ketersediaan energi terbarukan.
3. *Architecture Dual-Time Scale untuk Sustainable Energy Management*. Keaslian terletak pada pengembangan multi-timescale adaptive framework:
 - a. Short-Term Adaptation (detik-menit): Respons cepat terhadap fluktuasi lingkungan melalui Q-Learning

- b. Long-Term Optimization (jam-hari): Strategi penempatan node untuk optimalisasi masa pakai jaringan melalui integrasi prediksi GAN
 - c. Cross-Timescale Coordination: Mekanisme koordinasi antara adaptasi jangka pendek dan optimasi jangka panjang dalam satu arsitektur terpadu
4. *Holistic Framework untuk Coverage Hole Prevention dan Energy Balancing.* Penelitian ini mengusulkan integrated coverage-energy optimization framework yang:
- a. *Dynamic Coverage Maintenance:* Mekanisme deteksi dan perbaikan coverage holes secara otonom melalui adaptasi penempatan node
 - b. *Load-Balancing melalui Role Rotation:* Strategi rotasi peran node (cluster head, relay) berbasis Q-Learning untuk penyebaran beban energi
 - c. *Predictive Node Failure Anticipation:* Kemampuan prediktif untuk mengantisipasi kegagalan node melalui analisis pola degradasi energi

2.2.4 Bukti Keaslian Penelitian dan Keterkaitannya dengan Research GAP serta Body of Knowledge

1. Hubungan antara GAP, Novelty, dan Keaslian Penelitian

Studi literatur bibliometrik mengungkap empat research gap utama di bidang (Energy-Aware Wireless Sensor Networks) EWSN:

- (1) data lingkungan yang tidak realistis,
- (2) tidak terintegrasinya model generatif dan pembelajaran adaptif,
- (3) absennya physics-informed optimization, dan
- (4) kurangnya framework adaptif yang otonom.

Sebagai solusi, penelitian ini menawarkan novelty berupa arsitektur MEMA, yang mengintegrasikan GAN dan Q-Learning. Keaslian MEMA terletak pada kemampuannya menciptakan paradigma manajemen energi baru yang sepenuhnya adaptif dan otonom, dengan karakteristik self-learning, self-adapting, self-optimizing, dan self-healing.

2. Bukti Keaslian Penelitian Berdasarkan Perspektif Akademik

Tabel 2. 8 Keaslian Penelitian berdasarkan Perspektif Akademik

Perspektif	Bukti Keaslian	Keterkaitan dengan Research GAP	Kontribusi terhadap Body of Knowledge
Metodologis	a. Integrasi GAN-Q-Learning yang belum memiliki preseden pada konteks penempatan node WSN. b. Physics-Informed AI Framework yang menyatukan model fisik panel surya dan baterai dengan algoritma pembelajaran. c. Multi-Objective Optimization dengan Dynamic Priority Adjustment berdasarkan konteks operasional.	Menjawab GAP (1) dan (2): kurangnya integrasi AI adaptif serta tidak adanya reward fisik yang relevan dengan sistem energi.	Memperluas BoK dalam AI-based adaptive control systems dan physics-aware reinforcement learning pada domain energi terdistribusi.
Teknis	a. Generative Predictive Modeling untuk mensintesis kondisi lingkungan ekstrem yang tidak terwakili pada data nyata. b. Dual-Time Scale Adaptation Mechanism yang menyeimbangkan antara responsiveness jangka pendek dan	Menjawab GAP (1) dan (3): keterbatasan data cuaca realistik dan ketiadaan mekanisme adaptasi berlapis waktu.	Menambah BoK dalam data-driven environmental modeling dan multi-temporal optimization for WSN.

Perspektif	Bukti Keaslian	Keterkaitan dengan Research GAP	Kontribusi terhadap Body of Knowledge
	sustainability jangka panjang. c. Autonomous Coverage Management melalui virtual node repositioning untuk menjaga jangkauan jaringan.		
Implementatif / Praktis	a. End-to-End Adaptive Energy Management dari level node hingga level jaringan. b. Practical Framework untuk WSN berkelanjutan yang siap diimplementasikan pada perangkat komersial. c. Scalable Architecture untuk aplikasi IoT berskala besar.	Menjawab GAP (4): kurangnya validasi sistemik dan transferabilitas hasil penelitian ke konteks nyata.	Memberikan kontribusi langsung pada BoK bidang IoT energy architecture dan sustainable autonomous systems.

3. Paradigma Baru dalam Desain Sistem WSN Otonom.


Penelitian ini tidak hanya mengusulkan integrasi dua algoritma (GAN dan Q-Learning), tetapi membangun paradigma baru dalam desain sistem WSN otonom dengan empat karakteristik adaptif:

Tabel 2. 9 Sistem WSN otonom dengan Empat Karakteristik Adaptif

Karakteristik	Deskripsi	Implikasi Akademik
Self-Learning	Sistem mampu belajar secara terus-menerus dari	Memperluas konsep continuous learning

Karakteristik	Deskripsi	Implikasi Akademik
	perubahan lingkungan dan data sintetis yang dihasilkan GAN.	dalam lingkungan dinamis.
Self-Adapting	Node dan protokol beradaptasi terhadap fluktuasi energi, cuaca, dan trafik jaringan.	Menambah literatur pada real-time adaptive reinforcement systems.
Self-Optimizing	Agen Q-Learning menyesuaikan strategi energi berdasarkan reward dinamis dan prediksi jangka panjang.	Memperkuat BoK dalam multi-objective adaptive optimization.
Self-Healing	Sistem dapat memulihkan konektivitas atau distribusi energi setelah gangguan node.	Menjadi kontribusi baru dalam fault-tolerant adaptive WSN architectures.

4. Integrasi dengan Kontribusi terhadap Body of Knowledge



Gambar 2. 4. Integrasi dengan Kontribusi terhadap Body of Knowledge

Berdasarkan analisis, penelitian ini diinisiasi untuk menjawab tiga kesenjangan penelitian (*research gap*) utama yang teridentifikasi di dalam literatur. Kesenjangan tersebut mencakup:

- (1) Keterbatasan atau tidak realistisnya data lingkungan yang digunakan,
- (2) Belum terintegrasinya model generatif dengan metode pembelajaran adaptif,
- (3) Absennya pendekatan *physics-informed optimization*.

Untuk mengatasi ketiga tantangan tersebut, penelitian ini mengajukan sebuah kebaruan (*novelty*) berupa arsitektur baru yang secara inovatif mengintegrasikan *Generative Adversarial Network* (GAN) dan *Q-Learning*. Kontribusi dari *novelty* ini memposisikan penelitian secara unik di dalam *body of knowledge*, menempatkannya tepat pada irisan antara tiga domain utama:

1. *Artificial Intelligence for Energy Systems*,
2. *Wireless Sensor Network Optimization*, dan
3. *Sustainable IoT Architectures*.

Secara spesifik, seperti yang ditunjukkan dalam alur, integrasi GAN-Q-Learning ini berkontribusi langsung pada pengembangan tiga bidang:

1. Kecerdasan Buatan Adaptif dalam Jaringan Terbatas Energi (*Adaptive Artificial Intelligence in Energy-Constrained Networks*),
2. Kerangka Kerja Pembelajaran Penguatan Generatif (*Generative Reinforcement Learning Frameworks*), dan
3. Sistem IoT yang Otonom dan Berkelanjutan (*Sustainable, Autonomous IoT Systems*).


Penelitian ini tidak hanya mengisi irisan tersebut, tetapi juga menambahkan satu *knowledge domain* baru yang dinamakan “Generative–Adaptive Learning Framework for Energy-Aware WSN”. Domain baru inilah yang berfungsi sebagai jembatan fundamental, menghubungkan model fisik dari sebuah sistem energi dengan mekanisme pembelajaran adaptif yang berbasis data.

2.3 Landasan Teori

2.3.1 Wireless Sensor Network (WSN) dan Permasalahan Energi

Wireless Sensor Network (WSN) merupakan jaringan sensor nirkabel yang terdiri dari node-node mandiri untuk mengumpulkan dan mengirimkan data dari lingkungan sekitar. Node ini biasanya ditempatkan di lokasi terpencil dan dijalankan menggunakan sumber daya terbatas seperti baterai atau panel surya. Komponen utama dalam WSN meliputi sensing unit, processing unit, dan

communication unit. Permasalahan utama dalam WSN adalah keterbatasan energi yang cepat habis akibat konsumsi daya tinggi dari aktivitas komunikasi, degradasi baterai akibat kondisi lingkungan ekstrem seperti suhu tinggi, kelembaban, dan fluktuasi lalu lintas data (Sharma dkk., 2019).



Gambar 2. 5. Blok sistem suplai energi untuk Wireless Sensor Network (WSN)

Setiap node WSN umumnya terdiri dari empat komponen utama Sensing Unit, Processing Unit, Communication Unit, dan Power Unit. Gambar 1 merupakan diagram blok sistem suplai energi untuk Wireless Sensor Network (WSN) berbasis panel surya dan baterai isi ulang (Sharma dkk., 2019), (Zhao, Q., 2020). Gambar tersebut menunjukkan arsitektur sistem energi hybrid untuk WSN dengan jalur utama sebagai berikut:

1. Power Unit yang terdiri dari,
 - a. Solar Panel yang berfungsi sebagai sumber energi utama. Solar panel mengubah energi cahaya matahari menjadi listrik DC.
 - b. DC-DC Converter yang berfungsi Menyesuaikan tegangan keluaran panel surya agar sesuai dengan kebutuhan sistem dan proses charging. Pengaturan dilakukan oleh kontrol:
 - i. PWM (Pulse Width Modulation) atau
 - ii. MPPT (Maximum Power Point Tracking) untuk memastikan efisiensi maksimum dalam konversi energi dari panel surya.

- iii. Rechargeable Battery yang berfungsi untuk Menyimpan energi dari panel surya melalui konversi DC-DC. Dalam gambar, terdapat dua baterai (Battery A dan Battery B) yang bekerja secara bergantian atau paralel untuk menyediakan kontinuitas suplai.
2. WSN Node Load Merupakan beban dari sistem sensor yang terdiri dari tiga unit utama:
- a. Sensing Unit, Berisi sensor dan ADC (Analog to Digital Converter), untuk mengakuisisi data lingkungan seperti suhu, kelembaban, tekanan, getaran, dsb.
 - b. Processing Unit, Prosesor dan memori yang mengolah data sensor. Melakukan pengolahan data awal dan pengambilan keputusan sederhana menggunakan mikrokontroler
 - c. Communication Unit: Transceiver dan receiver yang mentransmisikan data ke node lain atau ke gateway. Menyediakan kemampuan komunikasi antar node dan dengan sink node menggunakan protokol komunikasi nirkabel seperti ZigBee, LoRa, atau WiFi.

Blok sistem pada gambar 1, memiliki prinsip kerja sebagai berikut:

1. Pada siang hari, panel surya menghasilkan energi yang langsung disuplai ke node WSN dan digunakan juga untuk mengisi baterai isi ulang.
2. Konverter DC-DC memastikan bahwa tegangan tetap stabil meskipun kondisi cahaya berubah-ubah.
3. MPPT controller sangat penting dalam kondisi pencahayaan yang fluktuatif agar tetap mendapatkan output daya maksimum.
4. Energi dari baterai digunakan saat malam hari atau ketika intensitas cahaya tidak cukup.

Penggunaan dua baterai (Battery A dan B) mengindikasikan sistem load balancing atau rotational charging-discharging, yang dapat mencegah degradasi dini dan memperpanjang umur baterai. Dalam sistem cerdas, ini bisa dikontrol

dengan algoritma manajemen energi berbasis GAN-QL untuk Memutuskan kapan node masuk mode sleep, Mengatur prioritas transmisi data, Menyeimbangkan distribusi beban antar node (Nguyen dkk., 2023), (Sreekala, 2024), (Swati & Arora, 2022). Lebih jelasnya seperti pada formula berikut:

$$E_i^t = I_{iA}^t \left(R_{iA}^t + \left\lceil \frac{R_{iB}^t + \Delta_i^t}{B_{max}} \right\rceil B_{max} \right) + (1 - I_{iA}^t) \left(R_{iB}^t + \frac{R_{iA}^t + \Delta_i^t}{B_{max}} \right) B_{max} \quad (1)$$

Dimana,

E_i^t : Energi yang digunakan oleh node ke-i pada waktu ke-t.

I_{iA}^t : Indikator biner (0 atau 1): apakah node menggunakan Baterai A.

R_{iA}^t : Sisa energi baterai A pada node-i di waktu ke-t.

R_{iB}^t : Sisa energi baterai B pada node-i di waktu ke-t.

Δ_i^t : Tambahan beban energi (misalnya akibat fluktuasi suhu, data dan kelembaban)

B_{max} : Kapasitas maksimum baterai

Formula 1 Formula ini mengakomodasi dua skenario, tergantung apakah node sedang menggunakan baterai A (jika $I_{iA}^t=1$) atau baterai B (jika $I_{iA}^t=0$).

1. Ketika menggunakan baterai A ($I_{iA}^t=1$)

$$E_i^t = R_{iA}^t + \left\lceil \frac{R_{iB}^t + \Delta_i^t}{B_{max}} \right\rceil B_{max} \Rightarrow E_i^t = R_{iA}^t + R_{iB}^t + \Delta_i^t \quad (2)$$

2. Ketika menggunakan baterai B ($I_{iA}^t=0$)

$$E_i^t = R_{iB}^t + \left\lceil \frac{R_{iA}^t + \Delta_i^t}{B_{max}} \right\rceil B_{max} \Rightarrow E_i^t = R_{iB}^t + R_{iA}^t + \Delta_i^t \quad (3)$$

Secara matematis, nilai akhirnya akan tetap:

$$E_i^t = R_{iA}^t + R_{iB}^t + \Delta_i^t \quad (4)$$

Namun penggunaan indikator I_{iA}^t Menunjukkan bahwa sistem tetap mencatat baterai mana yang sedang aktif, yang penting untuk analisis strategi switching, pemodelan manajemen beban energi secara cerdas, penjadwalan charging dan discharging.

Kebutuhan energi (*Energy Demand*) merupakan faktor kunci dalam merancang dan mengoperasikan Wireless Sensor Network (WSN) yang efisien, andal, dan berumur panjang. Total energi yang dibutuhkan oleh sebuah node sensor dapat dihitung dengan menjumlahkan energi yang dikonsumsi untuk berbagai aktivitasnya. Dalam sistem Wireless Sensor Network (WSN), permintaan energi (*Energy Demand*) merujuk pada jumlah energi yang dibutuhkan oleh setiap node sensor untuk menjalankan fungsinya, seperti sensing, komputasi lokal, komunikasi, dan kadang penyimpanan data. Permintaan energi ini sangat bergantung pada mode operasi node (idle, transmit, receive, sleep), frekuensi aktivitas sensor, intensitas komunikasi data antar node, lingkungan fisik yang mempengaruhi efisiensi kerja perangkat keras (Jinyuan Tang, H. W. Lin, 2024), (Vázquez-Canteli & Nagy, 2019). Permintaan energi total untuk satu periode operasi dapat dihitung dengan:

$$E_{demand} = E_{mc} + E_{s1} + E_{s2} + E_{tx} + E_{rx} + E_{idle} + E_{storage} \quad (5)$$

E_{mc} : Energi yang dikonsumsi oleh microcontroller.

E_{s1}, E_{s2} : Energi yang dikonsumsi oleh Sensor 1 dan 2.

E_{tx} : Energi untuk transmisi data.

E_{rx} : Energi untuk menerima data.

E_{idle} : Energi dalam mode idle.

$E_{storage}$: Energi untuk akses Eprom atau penyimpanan.

Alternatif bentuk umum dengan waktu operasi adalah sebagai berikut:

$$E_{demand} = \sum_{i=1}^n I_i \cdot V \cdot t_i \quad (6)$$

I_i : Arus yang dikonsumsi pada mode ke-i (dalam ampere).

V : Tegangan Operasi (Volt).

t_i : Durasi waktu dalam mode ke-i (detik).

n : Jumlah mode aktif (misalnya ; active, sleep, tx,rx).

Permintaan energi pada node sensor tidak hanya dipengaruhi oleh konfigurasi internal (waktu operasi, arus, tegangan), tetapi juga oleh kondisi lingkungan yang menyebabkan fluktuasi konsumsi daya (Leelakrishnan &

Chakrapani, 2024). Untuk mengakomodasi pengaruh lingkungan, formula umum Energy Demand dimodifikasi sebagai berikut:

$$E_{demand}(T, H, \tau) = E_{base} \cdot \exp(\alpha T + \beta H + \gamma \tau) \quad (7)$$

$E_{demand}(T, H, \tau)$: Total Permintaan Energi yang dipengaruhi oleh lingkungan
(Joule)

E_{base} : Energi dasar (ideal) tanpa pengaruh lingkungan.

α : Koefisien sensitivitas terhadap suhu ($^{\circ}C^{-1}$).

β : Koefisien sensitivitas terhadap kelembaban ($\%^{-1}$).

γ : Koefisien sensitivitas terhadap intensitas data movement ($unit^{-1}$).

T : Suhu lingkungan ($^{\circ}C$).

H : Kelembaban lingkungan (%).

τ : Indeks Intensitas data movement (jumlah event atau paket perwaktu).

Bentuk eksponensial menggambarkan bahwa pengaruh lingkungan terhadap konsumsi energi bersifat tidak linear. Nilai Ebase bisa dihitung dari konfigurasi statis node (misalnya dari datasheet). Parameter α, β, γ ditentukan berdasarkan pengamatan eksperimen atau kalibrasi terhadap kondisi operasional nyata. Wireless Sensor Network (WSN) merupakan sistem terdistribusi yang terdiri dari banyak node sensor. Agar dapat beroperasi dalam jangka waktu lama tanpa intervensi manusia, sistem WSN mengandalkan teknik energy harvesting, terutama dari sumber energi terbarukan seperti panel surya (PV), energi panas, dan getaran mekanik (Ezhilarasi & Krishnaveni, 2019), (Fraternali dkk., 2021).

$$E_{harvest} = A \cdot \eta \cdot G_t \cdot t \quad (8)$$

$E_{harvest}$: Energi yang dihasilkan per hari (Joule).

A : Luas permukaan panel (m^2).

η : Efisiensi konversi panel (% biasanya 10–20%).

G_t : Intensitas cahaya matahari rata-rata (W/m^2).

t : Waktu penyinaran efektif per hari (jam).

Pengaruh Suhu dan Kelembaban terhadap Harvesting Energi

$$E_{harvest} = A \cdot \eta(T, H) \cdot G_t \cdot t \quad (9)$$

$\eta(T, H)$: Efisiensi panel yang dipengaruhi suhu dan kelembaban.

- Efek Suhu (T) terhadap Efisiensi (η), Meningkatnya suhu akan menurunkan efisiensi panel surya karena tegangan sel menurun.

Hubungan tipikal:

$$\eta(T) = \eta_{ref} \cdot (1 - \alpha \cdot (T - T_{ref})) \quad (10)$$

α : Koefisien Suhu (0.004-0.006/ $^{\circ}\text{C}$)

T_{ref} : Suhu Referensi (25°C)

- Efek kelembaban terhadap efisiensi (η). Kelembaban tinggi dapat mengurangi cahaya ke permukaan karena kondensasi atau kabut dan dapat meningkatkan resistansi internal karena kontaminasi uap air, sehingga menurunkan efisiensi. Model (η) dapat diperluas menjadi:

$$\eta(T, H) = \eta_{ref} \cdot (1 - \alpha_T \cdot (T - T_{ref}) - \beta_H \cdot (H - H_{ref})) \quad (11)$$


Kawasan beriklim tropis seperti Indonesia, yang cenderung memiliki suhu dan kelembaban tinggi sepanjang tahun, pemodelan efisiensi energi menjadi sangat penting untuk memperkirakan secara akurat jumlah energi yang dapat dihasilkan dan digunakan oleh node sensor dalam sistem Wireless Sensor Network (WSN). Kondisi lingkungan yang dinamis ini dapat menyebabkan penurunan efisiensi konversi energi, sehingga sistem WSN perlu dirancang secara adaptif. Adaptasi tersebut dapat dilakukan dengan menerapkan algoritma manajemen daya yang mampu merespons perubahan lingkungan secara real-time, menjadwalkan aktivitas node secara efisien melalui teknik seperti duty cycling, serta memilih lokasi pemasangan panel surya yang optimal untuk memaksimalkan penerimaan radiasi matahari (Deden Ardiansyah, Teddy Mantoro, 2022).

2.3.2 Model Markov Multivariabel untuk Prediksi Energi

Model prediktif berbasis Markov digunakan untuk memperkirakan pengurangan energi dan masa pakai baterai dalam WSN secara dinamis. Model ini mempertimbangkan variabel lingkungan seperti suhu (T), kelembaban (H), dan


pergerakan data (τ). Setiap variabel dimodelkan sebagai rantai Markov yang menghasilkan kemungkinan transisi antar status lingkungan. Diagram ini menggambarkan sebuah pendekatan prediktif untuk memperkirakan masa pakai (lifetime) baterai pada sistem Wireless Sensor Network (WSN) berdasarkan data sekuensial dari kondisi lingkungan dan perilaku jaringan. Proses dimulai dengan input berupa urutan informasi okupansi (input sequence of occupancy information), yang mencerminkan kondisi lingkungan yang berubah terhadap waktu, seperti suhu (T), kelembaban (H), dan intensitas data (DM – data movement atau traffic load).

Model 1 merepresentasikan kondisi suhu dan kelembaban rendah dengan beban data ringan. Model 2 mencerminkan suhu sedang dengan kelembaban tinggi dan beban data sedang. Model n mencerminkan kombinasi ekstrem atau unik lainnya. Setiap model kemudian digunakan untuk menghitung nilai probabilitas bahwa urutan input tersebut dihasilkan oleh model tersebut, ditandai seperti gambar 3. Informasi input tersebut kemudian dievaluasi terhadap sejumlah model prediktif yang telah dilatih sebelumnya, masing-masing didefinisikan sebagai di mana tiap model mencerminkan skenario lingkungan yang berbeda.



Gambar 2. 6. Markov Model Prediction

SEKOLAH PASCASARJANA



Gambar 2. 7. A two-dimensional Markov chain model of a node's backoff stage and backoff counter

Suhu (T):

- Initial Status, Transition from T, k to $T, k + 1$:

$$P(T, k \rightarrow T, k + 1 = 1 \text{ for } 0 \leq k \leq W_T - 2 \quad (12)$$

- Transition between statuses, Transition from $T, W_T - 1$ to $T, W_T - 1$:

$$P(T, W_T - 1) \rightarrow T, W_T - 1) = \frac{P}{W_T}$$

- Absorption Status, Transition from $T, 0$ to $T, W_T - 1$:

$$P(T, 0 \rightarrow T, W_T - 1) = \frac{1 - p}{T_0}$$

Humidity (H):

- Initial Status, Transition from H, k to $H, k + 1$: (13)

$$P(H, k \rightarrow H, k + 1 = 1 \text{ for } 0 \leq k \leq W_H - 2$$

- Transition between statuses, Transition from $T, W_T - 1$ to $T, W_T - 1$:

$$P(H, W_H - 1) \rightarrow H, W_H - 1) = \frac{P}{W_H}$$

- Absorption Status, from $T, 0$ to $T, W_T - 1$:

$$P(H, 0 \rightarrow H, W_H - 1) = \frac{1 - p}{H_0}$$

Data Movement (τ_n):

- Initial Status, Transition from τ_n, k to $\tau_n, k + 1$: (14)

$$P(\tau_n, k \rightarrow \tau_n, k + 1) = 1 \text{ for } 0 \leq k \leq W_{\tau_n} - 2$$

- Transition between statuses, Transition from $\tau_n, W_{\tau_n} - 1$ to $\tau_n, W_{\tau_n} - 1$:

$$P(\tau_n, W_{\tau_n} - 1 \rightarrow T, W_{\tau_n} - 1) = \frac{P}{W_{\tau_n}}$$

- Absorption Status, Transition from $\tau_n, 0$ to $\tau_n, W_{\tau_n} - 1$:

$$P(\tau_n, 0 \rightarrow \tau_n, W_{\tau_n} - 1) = \frac{1 - p}{\tau_{n0}}$$

Untuk setiap parameter (Suhu, Kelembaban, Pergerakan Data), nilai harapan atau durasi keadaan rata-rata dapat diturunkan dari probabilitas transisi dan keadaan. Nilai Harapan untuk pergerakan data (τ_n) dapat dihitung seperti pada formula 6.

$$\tau_n(p) = \frac{1}{1 + W_i + \frac{p}{1-p} W_i \sum_{i=0}^{m-1} (2p)^i} \quad (15)$$

W_i = Bobot atau parameter yang sesuai dengan setiap keadaan.

P = Kemungkinan transisi dari satu keadaan ke keadaan lain.

Gambar 3 menampilkan visualisasi model Rantai Markov dua dimensi yang menggambarkan perilaku *node* dalam konteks efisiensi energi, khususnya terkait tahap *backoff* dan penghitung *backoff* pada sebuah *node*. Model ini menguraikan tiga Rantai Markov terpisah, masing-masing merepresentasikan dinamika dari

parameter lingkungan dan operasional krusial: suhu (T), kelembapan (H), dan pergerakan data (τ_n). Setiap rantai dirancang untuk menangkap perubahan status dari waktu ke waktu, dengan mempertimbangkan status awal, mekanisme transisi antarstatus, dan adanya status penyerapan terminal yang menandakan kondisi kritis atau non-operasional.

Parameter Kunci dalam Model P Mewakili probabilitas transisi dari satu keadaan ke keadaan lain., T Mengacu pada parameter Suhu, H Mengacu pada parameter Kelembaban dan τ_n Mengacu pada parameter Pergerakan Data. Detail Rantai Markov untuk Setiap Parameter:

1. Suhu (T), Rantai Markov untuk Suhu memodelkan fluktuasi suhu lingkungan yang memengaruhi operasional *node*.
 - a. Status Awal: Rantai ini dimulai dari $T,0$, yang mewakili kondisi suhu awal atau normal bagi *node*. Transisi dari status $T,0$ (seperti yang ditunjukkan oleh panah yang kembali ke $T,0$ atau panah keluar ke status lain) menandakan probabilitas perubahan suhu dari kondisi awal ini, seperti yang mungkin dijelaskan dalam persamaan (12).
 - b. Transisi Antar Status: *Node* dapat bertransisi antara status suhu yang berbeda, seperti dari $T,0$ ke $T,1$, lalu ke $T,2$, dan seterusnya hingga $T,WT-3$, $T,WT-4$, atau status suhu lainnya yang relevan. Setiap panah berlabel '1' menunjukkan transisi deterministik ke status berikutnya, sementara panah lain dengan probabilitas $(1-P)/T_n$ atau P/WT menunjukkan mekanisme transisi yang lebih kompleks antar status atau kembali ke status $T,0$.
 - c. Status Penyerapan: Model ini mengindikasikan adanya status penyerapan, meskipun tidak dilabeli secara eksplisit di diagram ini, namun tersirat dari panah yang mengarah keluar dari rantai utama (misalnya, panah dari $T,0$ yang mengarah ke beberapa jalur lain). Dalam konteks ini, status penyerapan mungkin merepresentasikan kondisi suhu ekstrem yang menyebabkan *node* berhenti berfungsi atau tidak dapat kembali ke operasi normal.

2. Kelembaban (H), Rantai Markov untuk Kelembaban menangkap dinamika tingkat kelembaban di sekitar *node*.

- a. Status Awal: Rantai kelembaban dimulai dari $H,0$, yang mewakili kondisi kelembaban awal atau ideal. Transisi dari $H,0$ (seperti yang ditunjukkan oleh panah yang kembali ke $H,0$ atau panah keluar ke status lain) mencerminkan probabilitas perubahan kelembaban dari kondisi awal ini, sebagaimana mungkin dijelaskan dalam persamaan (13).
- b. Transisi Antar Status: Mirip dengan suhu, *node* dapat berpindah antar status kelembaban ($H,0$, $H,1$, $H,2$, hingga $H,WH-3$, $H,WH-4$). Label '1' pada panah menunjukkan transisi sekuensial yang pasti, sementara probabilitas $(1-P)/H_n$ atau P/WH mengatur transisi yang lebih acak atau kembali ke status $H,0$.
- c. Status Penyerapan: Terdapat indikasi status penyerapan di luar jalur utama rantai (misalnya, panah dari $H,0$ yang mengarah ke beberapa jalur lain). Status ini akan mewakili kondisi kelembaban kritis (misalnya, sangat tinggi atau sangat rendah) yang mengakibatkan kegagalan permanen atau non-operasional *node*.

3. Pergerakan Data (τ_n), Rantai Markov untuk Pergerakan Data menggambarkan intensitas aliran data dalam jaringan, yang secara langsung berkaitan dengan konsumsi energi.

- a. Status Awal: Rantai pergerakan data dimulai dari $\tau_n,0$, mewakili tingkat pergerakan data awal atau normal. Transisi dari status $\tau_n,0$ (seperti yang ditunjukkan oleh panah yang kembali ke $\tau_n,0$ atau panah keluar ke status lain) menunjukkan probabilitas perubahan volume atau frekuensi pergerakan data dari kondisi awal ini, seperti yang mungkin dijelaskan dalam persamaan (14).
- b. Transisi Antar Status: *Node* bertransisi antar status pergerakan data ($\tau_n,0$, $\tau_n,1$, $\tau_n,2$, hingga τ_n,W_n-3 , τ_n,W_n-4). Panah berlabel '1' menandakan progresi yang pasti, sementara probabilitas $(1-P)/\tau_n$ atau P/W_{τ_n} mengatur transisi lain atau kembali ke status $\tau_n,0$.

- c. Status Penyerapan: Terdapat juga status penyerapan yang tersirat dari panah yang mengarah keluar dari rantai utama (misalnya, panah dari τ_n , 0 yang mengarah ke beberapa jalur lain). Ini bisa merepresentasikan kondisi jaringan yang stagnan, seperti kemacetan total, kegagalan transmisi data yang berkelanjutan, atau *node* yang mati, di mana tidak ada pergerakan data yang berarti.

Setiap parameter (Suhu, Kelembaban, Pergerakan Data), nilai harapan atau durasi keadaan rata-rata dapat diturunkan dari probabilitas transisi dan keadaan. Konsep ini dilakukan untuk memahami perilaku jangka panjang dari *node*. Nilai Harapan untuk pergerakan data (τ_n) dapat dihitung seperti yang direferensikan dalam formula 15 (yang tidak disertakan di sini, namun secara umum akan melibatkan penjumlahan produk probabilitas status dan nilai yang diasosiasikan dengan status tersebut). Secara umum, dalam konteks model Rantai Markov ini, utamanya merujuk pada probabilitas transisi (P) yang mengatur perpindahan dari satu keadaan ke keadaan lain. Probabilitas P ini menjadi kunci untuk menganalisis dan mengoptimalkan efisiensi energi *node*, karena memungkinkan estimasi waktu yang dihabiskan di setiap status dan, secara tidak langsung, konsumsi energi terkait.

2.3.3 Reinforcement Learning dan Q-Learning

Reinforcement Learning (RL) adalah metode pembelajaran yang melibatkan agen untuk belajar melalui interaksi dengan lingkungan guna memaksimalkan reward jangka panjang. Q-Learning adalah algoritma RL model-free yang banyak digunakan dalam skenario diskrit. Dalam konteks WSN, Q-Learning digunakan untuk menentukan strategi manajemen energi seperti perutean data, waktu aktif node, dan penjadwalan tidur. Namun, Q-Learning memiliki keterbatasan dalam lingkungan yang berubah secara dinamis (non-stasioner) dan cenderung lambat karena ketergantungan pada eksplorasi acak seperti epsilon-greedy.

Q-learning (disebut sebagai model free algorithm) merupakan algoritma RL tanpa model untuk mempelajari *policy* yang memberi tahu agen tindakan apa yang harus diambil dalam keadaan apa. *Q-learning* tidak memerlukan model dari environment, dan dapat menangani masalah dengan transisi stokastik dan *reward*,

tanpa memerlukan adaptasi. Q-learning sering disebut juga value-based off-policy temporal difference (TD) RL. *Off-Policy* berarti agent mengikuti perilaku *policy* dalam memilih *action* untuk mencapai *state* berikutnya s_{t+1} from state s_t . From s_{t+1} . *Off-Policy* digunakan untuk *policy* π yang berbeda dari perilaku *policy*. Tujuan utama algoritma Q-learning adalah untuk memaksimalkan nilai Q. Nilai Q Learning dapat diturunkan dari persamaan bellman yaitu

$$V(s) = \max_a [R(s, a) + \gamma \sum_{s'} P(s, a, s') V(s')] \quad (16)$$

Dalam persamaan (16), terlihat berbagai komponen, termasuk *reward*, *discount factor* (γ), *probability*, dan end states s' . Q- menunjukkan kualitas *action* pada setiap *state*. Dengan menggunakan *value* pada setiap *state*, nilai Q dapat dipasangkan dengan *state* dan *action* menjadi $Q(s, a)$. Nilai Q menentukan action mana yang lebih baik dari yang lain, jika menurut Q-value menunjukkan yang terbaik maka *agent* akan mengambil langkah selanjutnya. Persamaan bellman dapat digunakan untuk menentukan Q-value.

Untuk melakukan action apapun, agent akan mendapatkan reward $R(s, a)$, dan action akan berakhir pada pada state tertentu , sehingga persamaan Q-Value akan menjadi seperti pada persamaan 17.

$$Q(s, a) = R(s, a) + \gamma \sum_{s'} P(s, a, s') V(s') \quad (17)$$

Oleh karena itu, kita dapat mengatakan bahwa, $V(s) = \max_a [Q(s, a)]$

$$Q(s, a) = R(s, a) + \gamma \sum_{s'} (P(s, a, s') \max_{a'} Q(s', a')) \quad (18)$$

Persamaan 18 digunakan untuk memperkirakan nilai-Q dalam Q-Learning.

Q-table atau matriks dibuat saat melakukan Q-learning. Tabel mengikuti pasangan state dan action, yaitu $[s, a]$, dan menginisialisasi nilai menjadi nol. Setelah setiap action, tabel diperbarui, dan nilai-q disimpan di dalam tabel. Agen RL menggunakan tabel-Q ini sebagai tabel referensi untuk memilih tindakan terbaik berdasarkan nilai-q. pada Tabel 7 dijelaskan Diagram Q-Learning menggunakan Q-Table.

Tabel 2.1. Konsep Dasar Q-Learning


Flowchart	Pseudo Code
<pre> graph TD A[Inisialisasi Q-Table] --> B[Memilih Action untuk Melakukan] B --> C[Lakukan Action yang sudah di pilih] C --> D[Mengukur Reward] D --> E[Update Q-Table] E --> B </pre>	1. Inisialisasi Q-Table dengan Zero value. 2. Memilih Action untuk memulai/melakukan. 3. Lakukan Action yang di pilih. a_t dari state s_t and amati selanjutnya state s_{t+1} and reward r hitung nilai Q value menggunakan persamaan and update the Q-table 4. s_{t+1} is the new state s_t and repeat steps 3 to 4 until the s_{t+1} reaches the terminal state 5. Episode ends 6. Ulangi steps 2 to 5 sampai optimal Q value is reacheds

Q-Learning merupakan algoritma *reinforcement learning model-free* yang mempelajari kebijakan optimal melalui coba-coba. Di WSN, agen Q-Learning (*node* sensor) belajar membuat keputusan berdasarkan status (misalnya, tingkat energi, riwayat transmisi) dan *reward* (misalnya, penghematan energi, transmisi yang berhasil). Representasi Status dan Aksi Dalam Q-Learning, ruang status mewakili status *node* saat ini (misalnya, tingkat energi, status *buffer*), sedangkan ruang aksi mencakup keputusan yang mungkin (misalnya, transmisi, tidur, menyesuaikan daya). Fungsi *reward* dirancang untuk memandu proses pembelajaran menuju efisiensi energi.

2.3.4 Generative Adversarial Networks (GAN)

Jaringan adversarial generatif (GAN) merupakan arsitektur deep learning. Arsitektur ini melatih dua jaringan neural untuk saling bersaing agar dapat menghasilkan data baru yang lebih autentik dari set data pelatihan yang diberikan.. GAN disebut adversarial karena melatih dua jaringan yang berbeda dan mengadu keduanya. Jaringan pertama menghasilkan data baru dengan mengambil sampel data input dan memodifikasinya semaksimal mungkin. Di sisi lain, jaringan kedua mencoba memprediksi apakah output data yang dihasilkan termasuk dalam set data

asli. Dengan kata lain, jaringan prediksi menentukan keaslian data yang dihasilkan. Sistem menghasilkan versi nilai data palsu yang lebih baru dan lebih baik hingga jaringan prediksi tidak lagi dapat membedakan antara yang palsu dan asli.



Gambar 2. 8 Arsitektur GAN


$$\min_G \max_D V(D, G) \quad V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (19)$$

- G : Generator (1)
- D : Discriminator
- Pdata(x) : distribution of real data
- P(z) : distribution of generator
- x : sample from Pdata(x)
- z : sample from P(z)
- D(x) : Discriminator network
- G(z) : Generator network

Generator menghasilkan data sintetik seperti transisi state-action-reward-next_state, sementara discriminator mengevaluasi keaslian data tersebut. Dalam konteks WSN dan RL, GAN memungkinkan pembuatan skenario lingkungan yang kompleks tanpa interaksi langsung, sehingga mengurangi biaya eksplorasi dan risiko terhadap node fisik. GAN membantu menghasilkan data transisi yang realistis untuk memperkaya replay buffer agen RL.

2.3.5 Integrasi GAN-Q-Learning

Integrasi GAN dengan Q-Learning menciptakan kerangka GAN-Q-Learning, yang memanfaatkan data sintetik dari GAN untuk mempercepat pelatihan Q-table. Kerangka ini efektif dalam meningkatkan adaptabilitas dan konvergensi algoritma Q-Learning di lingkungan yang dinamis. Hasil dari integrasi ini mencakup Akselerasi eksplorasi awal, Adaptasi kebijakan terhadap perubahan reward dan transisi state, Reduksi eksplorasi acak yang mahal dan lambat.



Gambar 2. 9 Integrasi GAN dan Q-Learning

Gambar integrasi *Generative Adversarial Networks* (GAN) dan Q-Learning dalam *Reinforcement Learning* (RL), berdasarkan tiga bagian utama yang digambarkan:

1. Komponen GAN (*Generative Adversarial Network*)

- Generator menghasilkan data sintetik berupa *state* (keadaan) dan *reward* (imbalan) yang menyerupai pengalaman dari lingkungan nyata (*fake samples*).

- b. Diskriminator menerima dua jenis masukan: *real samples* (sampel nyata) dari data asli dan *fake samples* (sampel palsu) dari Generator. Tugas Diskriminator adalah membedakan antara data nyata dan data palsu.
- c. Kedua komponen ini dilatih secara *adversarial* (berlawanan):
 - 1) Generator Loss diperoleh ketika data palsu berhasil menipu Diskriminator.
 - 2) Discriminator Loss dihasilkan dari kemampuannya untuk mengklasifikasikan data dengan benar.
- d. Keluaran dari GAN adalah data sintesis yang digunakan untuk augmentasi pengalaman bagi agen RL atau sebagai masukan tambahan untuk pembaruan *Q-table*.

Generative Adversarial Networks (GAN) menggunakan dua fungsi *loss* yang berbeda: *Loss Discriminator* dan *Loss Generator*. *Loss Discriminator* dirancang secara spesifik untuk membedakan antara data aktual dan data sintesis yang dihasilkan oleh Generator. Fungsi *loss* yang terkait dengan Diskriminator bertujuan untuk meningkatkan kemampuan Diskriminator dalam mengklasifikasikan data asli secara akurat sebagai "nyata" dengan probabilitas tinggi, sambil secara bersamaan mengidentifikasi data sintesis ($G(z)$) sebagai "palsu" dengan probabilitas rendah ($D(G(z)) \approx 0$) (Krichen, 2023).

$$L_D = -E_{x \sim p_{data}(x)} [\log D(x)] - E_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (20)$$

dengan:

- $x \sim p_{data}(x)$: Kumpulan data asli yang berasal dari distribusi data empiris.
- $z \sim p_z(z)$: *Noise* stokastik diekstraksi dari distribusi probabilitas tertentu (misalnya, distribusi Gaussian).
- $D(x)$: Probabilitas bahwa Diskriminator menilai data x sebagai otentik
- $D(G(z))$: Probabilitas yang diberikan oleh Diskriminator bahwa data yang dihasilkan oleh Generator adalah sah (asli)..

Generator dikembangkan secara cermat untuk menghasilkan data sintesis ($G(z)$) yang memiliki kapasitas untuk secara efektif "menyesatkan" Diskriminator.

Dengan kata lain, Generator berusaha menciptakan data yang tidak dapat dibedakan dari data otentik yang dipersepsikan oleh Diskriminator. Tujuan dari fungsi *loss* Generator adalah untuk mengoptimalkan nilai $D(G(z))$, yang berarti membujuk diskriminator untuk menganggap data sintetis yang dihasilkan oleh Generator sebagai "nyata" ($D(G(z)) \rightarrow 1$).

$$L_G = -E_{z \sim p_z(z)} [\log D(G(z))] \quad (21)$$

dengan:

$z \sim p_z(z)$: Gangguan acak dimasukkan ke Generator untuk menghasilkan data artifisial.

$D(G(z))$: Probabilitas bahwa Diskriminator mengevaluasi data sintetis sebagai otentik.

2. Komponen *Reinforcement Learning* (RL)

- a. Agen menerima masukan dari lingkungan dalam bentuk:
 - 1) *State* St : keadaan saat ini.
 - 2) *Reward* Rt : imbalan yang dihasilkan dari aksi sebelumnya.
- b. Agen menggunakan suatu *policy* (kebijakan) untuk memilih dan melakukan aksi At , yang dikirimkan ke Lingkungan.
- c. Lingkungan merespons aksi tersebut dengan menyediakan:
 - 1) *Next state* $St+1$: keadaan berikutnya.
 - 2) *Next reward* $Rt+1$: imbalan berikutnya.
- d. Data interaksi ini digunakan sebagai masukan untuk pelatihan GAN dan pembaruan *Q-table*.

3. Komponen Q-Learning

Proses pembelajaran Q-Learning terdiri dari lima langkah utama:

- a. Inisialisasi Q-Table: *Q-table* diinisialisasi dengan nilai acak atau nol.
- b. Pilih Aksi yang Akan Dilakukan: Aksi dipilih berdasarkan *Q-table*, mungkin menggunakan strategi eksplorasi (seperti ϵ -greedy).
- c. Lakukan Aksi yang Dipilih: Aksi dieksekusi oleh agen di lingkungan.
- d. Ukur *Reward*: Agen menerima imbalan dari lingkungan.

- e. Perbarui Q-Table: *Q-table* diperbarui menggunakan persamaan 18.

4. Integrasi GAN–Q-Learning

- a. Data sintetis dari GAN dapat digunakan sebagai augmentasi pengalaman, membantu Q-Learning untuk memperbarui *Q-table* secara lebih adaptif, terutama ketika lingkungan berubah.
- b. GAN juga dapat menyediakan transisi yang dibayangkan (*imagined transitions*) yang memperkaya eksplorasi tanpa interaksi langsung dengan lingkungan.
- c. *Q-table* dapat dilatih dari kombinasi pengalaman nyata dan hasil GAN untuk mempercepat konvergensi dan mengurangi eksplorasi acak.

2.2.5.1 Mendorong Eksplorasi yang Lebih Terinformasi

Dalam Q-Learning tradisional, eksplorasi sering kali bergantung pada strategi acak seperti ϵ -greedy, di mana agen memilih aksi secara acak (eksplorasi) atau mengeksploitasi aksi-aksi bernilai tinggi yang sudah diketahui. Namun, pendekatan ini bisa tidak efisien dalam ruang *state-action* yang besar atau lingkungan dengan *reward* yang jarang. GAN mengatasi tantangan ini dengan menghasilkan pengalaman sintetis yang memandu eksplorasi secara terstruktur dan efisien. GAN menghasilkan pasangan *state-action-reward* sintetis untuk memperkaya pembelajaran agen. Fungsi *loss* dari Generator dan Diskriminator memainkan peran penting dalam meningkatkan kualitas dan relevansi pengalaman yang dihasilkan ini.

1. Generator Loss (LG), dengan menggunakan Persamaan 21, Generator menghasilkan transisi sintetis $G(z)=(s,a,r,s')$ yang sangat menyerupai pengalaman otentik dalam lingkungan. Tujuannya adalah untuk meminimalkan LG sedemikian rupa sehingga Diskriminator mengaitkan probabilitas tinggi ($D(G(z)) \rightarrow 1$) pada transisi yang dihasilkan. Sangat penting bahwa pengalaman yang dihasilkan secara akurat mencerminkan distribusi *state-action-reward* otentik, dengan penekanan khusus pada area yang menjanjikan dan kurang dieksplorasi dalam ruang *state-action*.

Implikasinya terhadap eksplorasi sangat signifikan; dengan menghasilkan transisi yang realistis dan beragam, Generator memfasilitasi eksplorasi *state* dan *action* yang jarang ditemui namun memiliki potensi *reward* yang besar. Pendekatan ini mengurangi ketergantungan pada eksplorasi acak dan mendorong agen untuk menyelidiki area yang memiliki nilai lebih tinggi.

2. Diskriminator Loss (LD), dengan memanfaatkan Persamaan 21, Diskriminator menilai apakah sampel *state-action-reward* tertentu otentik atau disintesis. Tujuannya adalah untuk mengoptimalkan LD, untuk menjamin bahwa Diskriminator secara akurat membedakan pengalaman asli sebagai otentik ($D(G(x)) \rightarrow 1$) dan pengalaman sintetis sebagai tidak otentik ($D(G(z)) \rightarrow 0$). Hal ini memaksa Generator untuk menghasilkan pengalaman sintetis dengan kualitas yang lebih unggul. Akibatnya, dampak pada eksplorasi adalah bahwa Diskriminator menjamin pengalaman yang dihasilkan bermakna dan sesuai dengan lingkungan sebenarnya, sehingga menghindari transisi yang tidak relevan atau tidak masuk akal. Ini berfungsi sebagai mekanisme "kontrol kualitas", menghalangi agen untuk mendalami area yang tidak informatif atau tidak valid dalam ruang *state-action*.


Berdasarkan penjelasan Diskriminator Loss dan Generator Loss, dimungkinkan untuk mengintegrasikan Q-Learning dengan GAN untuk generasi data. Agen Q-Learning menggunakan data otentik dan data yang dihasilkan GAN untuk merevisi nilai-Q-nya. Fungsi *loss* agen terus mengikuti *Bellman error* konvensional:

$$L_Q = E_{(s,a,r,s') \sim D} \left[\left(Q(s,a) - \left(r + \gamma \max_{a'} Q(s',a') \right) \right)^2 \right] \quad (22)$$

Di sini, D merepresentasikan *replay buffer* gabungan dari pengalaman nyata dan sintetis. Transisi yang dihasilkan GAN (s,a,r,s') memungkinkan agen untuk belajar dari *state* dan *action* yang kurang dieksplorasi di lingkungan nyata.

Mengikuti persamaan (8) dari *Bellman error*, representasi skematis yang menggambarkan integrasi *Generative Adversarial Networks* (GAN) dalam

kerangka Q-Learning, untuk Mendorong Eksplorasi yang Lebih Terinformasi, dapat diformulasikan seperti yang digambarkan pada Gambar 6.



Gambar 2. 10. Integration Diagram of GAN and Q-Learning for Adaptive Exploration.

2.2.5.2 Integrasi GAN dan Q-Learning untuk Eksplorasi Adaptif yang Melengkapi Eksploitasi

Mengintegrasikan *Generative Adversarial Networks* (GAN) ke dalam Q-Learning meningkatkan proses eksploitasi dengan menghasilkan sampel yang realistis dan berkualitas tinggi yang melengkapi pengetahuan agen yang sudah ada. Proses ini memanfaatkan pengalaman yang dihasilkan GAN untuk menyempurnakan kebijakan agen dan meningkatkan efisiensi pembelajaran.


Berikut adalah bagaimana fungsi *loss* dalam GAN dan Q-Learning memfasilitasi proses ini:

1. Generator Loss (LG): Generator (G) menciptakan sampel *state-action-reward* sintetis ($G(z) \rightarrow (s, a, r, s')$) yang meniru lingkungan nyata. Sampel-sampel ini ditambahkan ke *dataset* pelatihan agen untuk meningkatkan eksploitasi berdasarkan formula 7. Realisme Sampel Sintetis mencirikan fungsi *Loss Generator* dalam konteks eksploitasi, yang berarti bahwa Generator secara efektif meminimalkan *loss*-nya dengan menghasilkan sampel yang tidak dapat dibedakan oleh Diskriminator dari data aktual ($D(G(z)) \rightarrow 1$). Lebih lanjut, sampel otentik ini membantu agen meningkatkan kebijakan mereka dengan menyediakan data berkualitas tinggi yang selaras dengan dinamika lingkungan. Selain itu, generator berfokus pada wilayah bernilai tinggi, menunjukkan bahwa mereka dapat dilatih secara sistematis untuk memprioritaskan pengambilan sampel dari segmen ruang *action-state* yang sesuai dengan *reward* yang ditingkatkan. Metodologi yang ditargetkan secara strategis ini meningkatkan eksploitasi dengan memperkuat pemahaman agen tentang tindakan yang menghasilkan nilai tinggi.
2. Diskriminator Loss (LD): Diskriminator (D) mengevaluasi kualitas sampel sintetis yang dihasilkan oleh G dan memastikan bahwa sampel tersebut sedekat mungkin dengan pengalaman nyata menggunakan formula 21. Fungsi *Loss Discriminator* dalam Eksploitasi awal melibatkan pelaksanaan Validasi Sampel. Diskriminator memainkan peran penting dalam memastikan bahwa sampel yang dihasilkan oleh G menunjukkan realisme dan bermanfaat untuk penyempurnaan kebijakan. Mekanisme "kontrol kualitas" ini secara efektif menghalangi agen untuk menggunakan sampel yang tidak relevan atau di bawah standar, yang berpotensi menyesatkan eksploitasi. Selain itu, ia melakukan Umpan Balik Pelatihan untuk Generator; dengan secara tepat menunjukkan kekurangan pada $G(z)$, Diskriminator memberikan umpan balik yang memfasilitasi peningkatan

keluaran Generator. Akibatnya, ini menghasilkan sampel sintetis yang secara progresif lebih realistis dan menguntungkan untuk optimasi kebijakan.

Agen Q-Learning menggunakan sampel aktual dan yang dihasilkan GAN untuk menyempurnakan nilai-Q-nya, mengoptimalkan kebijakannya sambil mempertahankan kemampuan untuk eksplorasi strategis. Persamaan mengenai Melengkapi Eksploitasi mencerminkan persamaan Mendorong Eksplorasi yang Lebih Terinformasi yang disajikan dalam persamaan 8; namun, perbedaannya terletak pada nilai D , yang merupakan *replay buffer* gabungan yang mencakup sampel otentik dan yang dihasilkan oleh GAN dan adalah formula Target Q-value yang didasarkan pada *reward* (r) dan *discounted future rewards* (γ). Gambar 7 mengilustrasikan alur proses integrasi GAN dalam Q-Learning, yang didasarkan pada prinsip melengkapi eksploitasi. Kontribusi *Q Learning Loss* (LQ) dalam konteks Eksploitasi dijelaskan sebagai berikut:

1. Penyempurnaan Kebijakan: Sampel yang dihasilkan oleh GAN memberikan transisi tambahan untuk meningkatkan nilai-Q, sehingga membantu agen dalam menyempurnakan kebijakannya secara cermat terlepas dari ketergantungan eksklusif pada interaksi dunia nyata. Sampel tersebut memungkinkan agen untuk mengeksploitasi kebijakan yang ada dengan efikasi yang lebih besar dengan memperkaya pemahamannya tentang aksi yang menghasilkan *reward* tinggi.
2. Pemeliharaan Eksplorasi Strategis: Meskipun penekanannya tetap pada eksploitasi, data sintetis mencakup beragam pasangan *state-action*, yang mencegah agen menyerah pada *overfitting* atau stagnasi. Data yang dihasilkan oleh GAN memfasilitasi eksplorasi strategis yang berkelanjutan untuk agen, bahkan saat mereka mengeksploitasi kebijakan bernilai tinggi yang sudah mapan.



Gambar 2. 11. Model Eksplorasi–Eksplorasi Hibrida Menggunakan Replay yang Diperkaya GAN

2.3.6 Integrasi GAN-Q-Learning dan Model Markov dalam WSN


Wireless Sensor Network (WSN) yang bergantung pada sumber energi terbarukan seperti panel surya menghadapi berbagai tantangan teknis dan operasional yang kompleks. Salah satu tantangan utama adalah ketergantungan terhadap intensitas sinar matahari, yang menyebabkan sistem menjadi rentan terhadap kondisi cuaca mendung atau lokasi dengan pencahayaan rendah. Dalam kondisi tersebut, proses pengisian daya baterai menjadi tidak optimal dan dapat

mengakibatkan gangguan pada fungsi node sensor. Selain itu, komponen komunikasi dalam WSN merupakan penyumbang konsumsi energi terbesar, jauh melebihi komponen sensing dan pemrosesan. Oleh karena itu, diperlukan strategi efisiensi energi seperti perutean adaptif, agregasi data, dan penjadwalan mode tidur (sleep scheduling) untuk meminimalkan pemborosan daya. Tantangan lainnya mencakup sinkronisasi antar komponen node, degradasi baterai akibat siklus pengisian yang berulang, serta penempatan node yang tidak strategis yang dapat menyebabkan ketidakseimbangan beban dan penurunan cakupan jaringan secara keseluruhan.

Menghadapi kondisi tersebut, pendekatan berbasis Q-Learning menawarkan solusi yang adaptif dan dinamis. Q-Learning memungkinkan sistem WSN untuk belajar dari kondisi lingkungan dan secara mandiri menentukan kebijakan optimal dalam mengatur aktivitas node, memilih jalur komunikasi, serta menyesuaikan perilaku energi. Namun, kelemahan utama dari metode ini terletak pada kebutuhan akan data pelatihan yang mencerminkan kondisi ekstrem dan realistis, yang seringkali sulit diperoleh dari data lingkungan nyata. Untuk mengatasi keterbatasan tersebut, integrasi dengan Generative Adversarial Networks (GAN) menjadi kunci. GAN memungkinkan sistem menghasilkan data sintetis berkualitas tinggi yang merepresentasikan kondisi lingkungan non-stasioner, seperti fluktuasi suhu, kelembaban, dan trafik data. Data ini sangat berguna dalam melatih agen Q-Learning agar mampu beradaptasi dengan skenario dunia nyata yang beragam dan tidak terduga.

Di sisi lain, penggabungan dengan Model Markov memberikan dasar probabilistik untuk memetakan perubahan kondisi lingkungan secara temporal. Dengan memodelkan transisi status energi berdasarkan suhu, kelembaban, dan beban data dalam kerangka Markov, sistem dapat memperkirakan pola perubahan dan menyesuaikan kebijakan energi secara lebih presisi. Melalui kerangka kerja terintegrasi GAN-Q-Learning berbasis Markov, sistem WSN dapat menyesuaikan strategi aktif/sleep berdasarkan prediksi kondisi lingkungan, mengoptimalkan proses energy harvesting dan perutean data secara kontekstual, memperpanjang lifetime baterai node melalui manajemen daya berbasis pembelajaran adaptif,

Melakukan penempatan node yang strategis berdasarkan evaluasi reward jangka panjang.



Gambar 2. 12 Skema AEMGQ (*Adaptive Energy Model Based on GAN-Q-Learning*).

Dengan demikian, pendekatan ini mampu menyelesaikan rumusan masalah WSN berbasis panel surya, terutama dalam hal ketidakpastian energi, konsumsi daya tinggi, dan kebutuhan akan keputusan adaptif dalam skenario jaringan yang dinamis. Penelitian ini tidak hanya mengelola konsumsi energi secara efisien, tetapi juga meningkatkan daya tahan, skalabilitas, dan keandalan sistem WSN secara menyeluruh.

Gambar 2.12. menunjukkan arsitektur sistem cerdas yang menggabungkan Generative Adversarial Network (GAN), Q-Learning, dan Model Markov dalam rangka memaksimalkan efisiensi energi dalam jaringan sensor nirkabel (WSN). Pendekatan ini bertujuan memperpanjang umur baterai dan meningkatkan keandalan sistem dalam menghadapi kondisi lingkungan yang dinamis. Dalam arsitektur tersebut terdapat tiga komponen utama yaitu environment, Q-Learning Agent dan Integrasi dengan Markov multivariable model.

1. Lingkungan (Environment), sistem WSN dimodelkan dengan kondisi lingkungan yang dinamis. Komponen utamanya adalah:

- a. Wireless Sensor Node (WSN): sebagai titik awal pengambilan data dan konsumsi energi.

- b. Generative Adversarial Network (GAN): digunakan untuk *mensintesis data lingkungan* seperti suhu, kelembaban, dan pola pergerakan data berdasarkan kondisi historis dan fluktuasi Markovian.

- 1) Generator mensimulasikan kondisi lingkungan, dengan formula

$$\hat{x}_t = G(z_t, \hat{x}_{t-1}, c) = G(|z_t| |\hat{x}_{t-1}| |c|) \rightarrow [\hat{T}_t, \hat{H}_t, \hat{t}_t] \quad (24)$$

$\hat{x}_t$: Data Lingkungan sintetis pada waktu ke-t

$\hat{x}_{t-1}$: Output waktu sebelumnya – menggambarkan dependensi Markov orde-1.

z_t : Noise vector pada waktu t.

c : Kondisi tetap (konteks), bisa berupa ID lokasi, tipe node, musim, atau waktu hari.

Output adalah vektor: suhu, kelembaban, pergerakan data.

Untuk menyesuaikan karakteristik lingkungan lokal, vektor distribusi lokal d_l yang diturunkan dari data historis di lokasi tertentu.

$$\hat{x}_t = G(|z_t|, |\hat{x}_{t-1}|, |d_l| |c|) \quad (25)$$

$$d_l = |\mu_T, \sigma_T, \mu_H, \sigma_H, \mu_T, \sigma_T|$$

μ, σ : rata-rata dan deviasi suhu, kelembaban, dan trafik data.

Generator tidak hanya mengikuti pola temporal, tapi juga menyesuaikan karakter distribusi tiap node berdasarkan lokasinya.

Dalam konteks Markov, dengan menyertakan $\hat{x}_{t-1}$ sebagai input, Generator memperhitungkan transisi dari waktu sebelumnya. Probabilitas kondisi saat ini bergantung pada masa lalu sesuai dengan asumsi proses Markov orde-1:

$$P(\hat{x}_t | \hat{x}_{t-1}) \text{ bukan } P(\hat{x}_t)$$

- 2) Discriminator memvalidasi realisme data sintetis untuk menjamin kesesuaian dengan distribusi nyata. Formula Discriminator seperti pada formula 18 dalam Generative Adversarial Network (GAN) yang digunakan untuk memvalidasi realisme data sintetis dan memastikan bahwa data tersebut sesuai dengan distribusi nyata lingkungan (misalnya suhu, kelembaban, trafik data pada WSN).

Data WSN bergantung pada konteks (mis. lokasi, waktu, status energi), kita gunakan Conditional GAN:

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x|c)] + E_{z \sim p_z(z)} [\log(1 - D(G(z|c)))] \quad (26)$$


c : Konteks lingkungan, misalnya waktu, node ID, atau distribusi lokal.

Diskriminator mengevaluasi apakah x sesuai dengan distribusi nyata yang relevan dengan konteks c .

Diskriminator dilatih untuk memberikan skor tinggi untuk data lingkungan nyata: $D(x) \rightarrow 1$, Memberikan skor rendah untuk data sintetis palsu: $D(G(z)) \rightarrow 0$.

Jika Generator berhasil menipu Discriminator (nilai output $D(G(z)) \approx 0.5$), maka data sintetis tersebut dianggap realistis dan konsisten dengan distribusi lingkungan sebenarnya.

c. Data hasil GAN dimasukkan ke dalam modul-modul seperti gambar 6



Gambar 2. 13. Data hasil GAN dimasukkan ke dalam modul-modul energi

- 1) Energy Demand
- 2) Energy Harvesting
- 3) Energy Transfer

Masing-masing modul berkontribusi membentuk fungsi objektif yang mewakili beban energi total dan potensi daya yang tersedia.

2. Q-Learning Agent, sebagai sistem pengambilan keputusan adaptif. Komponen utamanya seperti pada gambar 9.

- a. Expert Knowledge Integrasi pengetahuan pakar (expert knowledge) ke dalam proses pembelajaran Q-learning. Salah satu keunggulan utama sistem ini terletak pada integrasi pengetahuan pakar (expert knowledge) ke dalam proses pembelajaran *Q-learning*. Informasi ini tidak didapatkan dari data lingkungan sintetis *GAN*, melainkan bersumber dari model fisik dan empiris yang sudah dikenal secara spesifik domain. Sebagai contoh, karakteristik baterai seperti kapasitas maksimum (dalam Wh atau mAh), efisiensi siklus pengisian/pengosongan, serta laju degradasi (*State of Health*, SoH) terhadap suhu dan beban, menjadi data penting yang diintegrasikan. Selain itu, produksi energi panel surya (PV) juga diperhitungkan, termasuk efisiensi panel dalam kondisi suhu atau kelembaban tertentu, perilaku *output* daya terhadap waktu, awan, atau posisi matahari, serta nilai referensi efisiensi (η_{ref}), koefisien suhu (β_T), dan kelembaban (β_H). Pengetahuan ini kemudian dimanfaatkan sebagai faktor pembobotan dalam penilaian nilai *reward* maupun fungsi Q. Dengan demikian, keputusan agen tidak hanya didasarkan pada data observasi, melainkan juga dipandu oleh prinsip fisis yang telah diketahui.

b. Data dari lingkungan digunakan untuk membentuk:

- 1) STATE: kombinasi dari status energi node, prediksi cuaca, dan beban trafik.

"State" dalam konteks ini adalah kombinasi dari beberapa parameter lingkungan yang relevan. Parameter-parameter tersebut meliputi status energi *node*, yang mencakup level *State of Charge* (SoC) dan *State of Health* (SoH). Kemudian, ada prediksi cuaca, baik itu suhu maupun kelembaban, yang bisa berasal dari hasil simulasi *GAN* atau observasi langsung. Terakhir, tingkat trafik data, yaitu beban komunikasi yang harus diproses atau dikirim, juga menjadi bagian dari *state* ini. Keseluruhan *state* ini kemudian diubah menjadi vektor numerik yang digunakan agen untuk mengevaluasi nilai potensi dari setiap aksi yang mungkin dilakukan.

- 2) REWARD: dihitung dari efisiensi energi (misalnya energi yang dipanen vs yang digunakan).

Reward dihitung berdasarkan **efisiensi energi *node*** dalam situasi tertentu, dengan formula umumnya memperhatikan rasio antara energi yang dipanen dan energi yang dibutuhkan, dikurangi penalti dari konsumsi transfer dan degradasi baterai. Secara matematis, rumusnya adalah sebagai berikut:

$$Reward = \left(\frac{E_{harvest}}{E_{demand}} \right) - (Penalti konsumsi transfer + degradasi baterai) \quad (27)$$

Nilai *reward* akan tinggi jika beberapa kondisi terpenuhi, yaitu:

- 1) Energi yang dipanen ($E_{harvest}$) lebih besar daripada energi yang dikonsumsi (E_{demand}).
- 2) Aksi yang diambil tidak menyebabkan degradasi *State of Health* (SoH) yang signifikan pada baterai.

- 3) Trafik dapat ditangani dengan efisiensi optimal.

- c. Agen Q-Learning menggunakan *state* dan *reward* untuk menentukan aksi terbaik. Berdasarkan nilai Q dari kombinasi *state* dan *reward*, agen

kemudian memilih **aksi terbaik** yang dapat diambil. Aksi-aksi ini mencakup beberapa keputusan krusial:

- 1) *Active/Sleep Switching*, Agen akan menentukan apakah node sebaiknya tidur untuk menghemat energi, atau tetap aktif untuk melakukan *sensing* atau *relay* data. Keputusan ini vital untuk menjaga efisiensi energi secara keseluruhan.
- 2) Pengaturan Pengiriman Data, Agen akan memutuskan apakah data harus dikirim langsung ke *sink node*, atau ditunda hingga energi mencukupi. Penundaan bisa menjadi strategi cerdas jika kondisi energi sedang tidak optimal.
- 3) *Routing Adaptif*, di mana agen perlu memutuskan apakah *node* perlu beralih jalur untuk menghindari *node* lain yang sedang kelebihan beban atau kehabisan daya. Ini memastikan aliran data tetap lancar dan efisien, menghindari kemacetan atau kegagalan transmisi.

Agen *Q-Learning* bertindak sebagai otak adaptif dari sistem Jaringan Sensor Nirkabel (WSN). Dengan menggabungkan pengetahuan pakar (*expert knowledge*) dan data lingkungan, agen ini memiliki kemampuan untuk:

- 1) Merespons kondisi secara kontekstual: Agen dapat menyesuaikan perilakunya secara dinamis berdasarkan perubahan kondisi lingkungan dan internal *node*.
- 2) Mengambil keputusan berbasis *reward* jangka panjang: Fokusnya tidak hanya pada keuntungan instan, tetapi juga pada optimalisasi kinerja dan efisiensi dalam jangka waktu yang lebih panjang.
- 3) Memperpanjang *lifetime node* dan menjaga stabilitas jaringan secara efisien: Dengan pengambilan keputusan yang cerdas, agen ini berkontribusi pada penggunaan energi yang efisien, sehingga memperpanjang usia operasional setiap *node* dan menjaga stabilitas keseluruhan jaringan.

3. Integrasi dengan Model Markov, Kondisi lingkungan yang dihasilkan oleh GAN tidak acak, melainkan mengikuti *model probabilistik dua dimensi* berbasis Markov Chain, yang memperhitungkan evolusi suhu, kelembaban, dan trafik data secara temporal. Dengan ini, Q-Learning dapat:
- a. Memprediksi fluktuasi energi secara lebih realistis. Model Markov memungkinkan GAN menghasilkan urutan suhu, kelembaban, dan beban data yang memiliki korelasi waktu, bukan hanya snapshot acak. Hal ini memungkinkan Q-Learning untuk memperkirakan fluktuasi energi berdasarkan tren historis dan tidak bergantung pada pengamatan satu waktu saja.
 - b. Menyesuaikan strategi aktif/sleep secara kontekstual. Agen *Q-Learning* memiliki kemampuan untuk menyesuaikan strategi aktif/tidur (*active/sleep*) secara kontekstual. Ini dilakukan dengan memahami kemungkinan transisi lingkungan, contohnya dari cuaca cerah menjadi mendung. Dengan pengetahuan ini, agen *Q-Learning* dapat:
 - 1) Mengantisipasi penurunan energi yang akan datang: Agen bisa memperkirakan kapan ketersediaan energi dari sumber seperti panel surya akan berkurang.
 - 2) Mengatur jadwal tidur *node* untuk menghindari kehabisan energi: Dengan antisipasi tersebut, agen dapat menjadwalkan *node* untuk "tidur" atau memasuki mode hemat daya pada waktu yang tepat, mencegah kehabisan energi di saat-saat krusial.
 - 3) Menghemat energi tanpa mengorbankan akurasi data: Pengaturan ini memastikan bahwa penghematan energi tidak mengganggu fungsi utama *node* dalam mengumpulkan atau mengirimkan data secara akurat.
 - c. Menghindari beban puncak (*peak energy load*) dengan redistribusi beban. Model Markov memungkinkan deteksi kondisi yang mengarah pada beban puncak (*peak load*), seperti lonjakan trafik data atau kebutuhan daya tinggi secara simultan. Dengan informasi ini, agen *Q*-

Learning dapat menyesuaikan strateginya untuk menjaga stabilitas dan efisiensi jaringan. Agen *Q-Learning* memiliki kemampuan untuk:

- 1) Mengalihkan beban ke *node* dengan energi lebih tinggi: Jika ada *node* yang mendekati beban puncak atau kehabisan daya, agen dapat mengalihkan sebagian beban tugas ke *node* lain yang memiliki kapasitas energi lebih besar.
- 2) Menunda pengiriman data yang tidak mendesak: Data yang tidak membutuhkan transmisi instan dapat ditunda pengirimannya untuk mengurangi beban jaringan saat terjadi puncak.
- 3) Memprioritaskan aktivitas penting secara adaptif: Agen akan mengidentifikasi dan memprioritaskan aktivitas yang paling krusial, memastikan bahwa fungsi inti jaringan tetap berjalan optimal meskipun dalam kondisi beban tinggi.

2.4 Hipotesis

Penelitian ini mengajukan hipotesis bahwa penerapan AEMGQ (Adaptive Energy Model Based on GAN-Q-Learning) mampu meningkatkan efisiensi energi, memperbaiki kinerja jaringan, dan memperpanjang umur jaringan pada WSN secara signifikan dibandingkan dengan pendekatan konvensional. Secara khusus, penggunaan data sintetis berbasis GAN diduga meningkatkan robustness agen pembelajaran, sedangkan integrasi SoC, SoH, efisiensi panel surya, dan pola trafik data ke dalam proses Q-Learning diduga menghasilkan kebijakan pengelolaan energi yang lebih optimal, kontekstual, dan berkelanjutan.

1. Hipotesis Operasional

- a. Hipotesis Sintesis Data Lingkungan. Pemanfaatan GAN untuk menghasilkan data lingkungan sintetis (variasi suhu, kelembaban, pola trafik data, dan ketersediaan energi) dapat menciptakan dataset pelatihan yang lebih beragam, realistis, dan mencakup skenario ekstrem, sehingga meningkatkan ketahanan model Q-Learning dibandingkan dengan penggunaan data historis yang terbatas.

- b. Hipotesis Kebijakan Penempatan Node Adaptif. Agen Q-Learning yang dilatih di lingkungan sintetis GAN dapat mengembangkan kebijakan penempatan node yang dinamis dan lebih efisien, dalam hal menyeimbangkan konsumsi energi, mencegah coverage holes, dan merotasi peran node secara optimal, dibandingkan metode penempatan statis konvensional.
 - c. Hipotesis ini menyatakan bahwa mengintegrasikan pengetahuan domain, seperti karakteristik baterai dan model panel surya, ke dalam fungsi reward Q-Learning dapat menghasilkan kebijakan yang lebih baik. Kebijakan ini mampu menyeimbangkan trade-off antara efisiensi energi, kualitas cakupan, dan umur jaringan secara lebih optimal dibandingkan dengan pendekatan reinforcement learning konvensional.
 - d. Hipotesis Adaptasi Skala Waktu Ganda. Arsitektur adaptasi skala waktu ganda mampu memberikan respons cepat terhadap perubahan lingkungan jangka pendek sekaligus menjaga keberlanjutan jaringan jangka panjang, yang diukur melalui peningkatan 30% dalam umur jaringan dan penurunan 25% dalam lubang cakupan.
 - e. Hipotesis Predictive Maintenance. Sistem yang mengintegrasikan kemampuan prediktif GAN dengan kemampuan pengambilan keputusan Q-Learning mampu mengantisipasi 80% kasus kegagalan node dan kondisi coverage holes sebelum terjadi, melalui mekanisme penempatan node preventif dan alokasi energi secara proaktif.
2. Hipotesis Kinerja Sistem
- a. Hipotesis Efisiensi Energi. Implementasi MEMA menghasilkan peningkatan efisiensi energi sebesar 35-50% dibandingkan strategi penempatan node statis, yang diukur melalui pengurangan konsumsi energi per transmisi data dan peningkatan umur jaringan.
 - b. Hipotesis Kualitas Layanan. Penerapan adaptive node placement berbasis GAN-Q-Learning mempertahankan Packet Delivery Ratio di atas 95% dan mengurangi end-to-end delay hingga di bawah 100 ms dalam kondisi lingkungan yang dinamis.

- c. Hipotesis Robustness. Sistem menunjukkan ketahanan yang superior terhadap kondisi lingkungan ekstrem dan 104ystem104, dengan degradasi performa tidak lebih dari 15% di bawah 104ystem104o ekstrem, dibandingkan degradasi 40-60% pada 104ystem konvensional.
3. Variabel Penelitian
- a. Variabel Bebas:
- 1) Penggunaan arsitektur GAN-Q-Learning terintegrasi
 - 2) Penerapan domain knowledge dalam reward function
 - 3) Implementasi dual-time scale adaptation
 - 4) Utilisasi synthetic data training
- b. **Variabel Terikat:**
- 1) Efisiensi energi jaringan (energy consumption per node)
 - 2) Masa pakai jaringan (network lifetime)
 - 3) Kualitas cakupan (coverage ratio)
 - 4) Stabilitas jaringan (packet delivery ratio, delay)
 - 5) Robustness terhadap kondisi ekstrem
- c. **Variabel Kontrol:**
- 1) Jumlah dan tipe node sensor
 - 2) Topologi jaringan awal
 - 3) Model konsumsi energi
 - 4) Pattern energy harvesting
 - 5) Scenario lingkungan testing

Hipotesis-hipotesis ini akan divalidasi melalui:

1. Simulasi komprehensif menggunakan platform NS-3 dengan berbagai skenario lingkungan.
2. Comparative analysis terhadap pendekatan konvensional (LEACH, GEAR, static placement).
3. Statistical testing menggunakan ANOVA dan paired t-test untuk signifikansi performa.
4. Sensitivity analysis terhadap parameter kritis model.
5. Field testing pada prototype WSK skala terbatas.