

Penerapan Deep Reinforcement Learning untuk Optimasi Penggunaan Spektrum Adaptif pada Jaringan 5G di Area Kota Medan

Mutiara Widasari Sitopu¹, Lucky Trasya Simanjuntak², Samuel Natanael³

^{1,2,3} Politeknik Negeri Medan, Jl. Almamater No. 1 Kampus USU Medan,
Kota Medan Kode Pos (20155), Indonesia
e-mail: mutiarasitopu@polmed.ac.id

Abstrak— Peningkatan lalu lintas data secara signifikan di kota-kota besar seperti Medan telah menimbulkan tantangan baru dalam pengelolaan spektrum frekuensi jaringan 5G. Sistem alokasi spektrum tradisional yang statis tidak lagi mampu memenuhi kebutuhan dinamis dari lingkungan urban yang padat. Penelitian ini mengkaji penerapan algoritma Deep Reinforcement Learning (DRL) dalam mengoptimalkan penggunaan spektrum adaptif pada jaringan 5G di wilayah perkotaan. Dengan menggunakan simulasi berbasis Python dan TensorFlow, model pelatihan DRL diuji dalam kondisi padat pengguna untuk mengevaluasi efisiensi alokasi kanal, latensi, dan throughput. Hasil penelitian menunjukkan bahwa pendekatan ini mampu meningkatkan efisiensi penggunaan spektrum hingga 38% dibandingkan metode konvensional. Hal ini menunjukkan bahwa integrasi AI dalam pengelolaan spektrum merupakan solusi potensial dalam mendukung performa jaringan 5G di area seperti Kota Medan.

Kata kunci : Jaringan 5G, Reinforcement Learning, Spektrum Adaptif, Medan, Alokasi Kanal

Abstract— The significant increase in data traffic in major cities like Medan has created new challenges in spectrum management for 5G networks. Traditional static spectrum allocation systems are no longer sufficient to meet the dynamic demands of dense urban environments. This study explores the application of Deep Reinforcement Learning (DRL) algorithms to optimize adaptive spectrum usage in 5G networks in urban areas. Using Python- and TensorFlow-based simulations, the DRL model was tested in high-user-density scenarios to evaluate channel allocation efficiency, latency, and throughput. Results indicate that this approach improves spectrum utilization efficiency by up to 38% compared to conventional methods. This demonstrates that AI integration in spectrum management is a promising solution to support optimal 5G performance regions Medan.

Keywords : 5G network, reinforcement learning, adaptive spectrum, Medan, channel allocation

I. PENDAHULUAN

Perkembangan teknologi komunikasi nirkabel di Indonesia telah memasuki era transformasi besar dengan diperkenalkannya jaringan generasi kelima (5G). Teknologi ini menjanjikan kecepatan transmisi data yang tinggi, latensi rendah, dan kapasitas konektivitas yang lebih besar dibandingkan generasi sebelumnya. Kota Medan, sebagai salah satu kota metropolitan terbesar di Indonesia, mengalami pertumbuhan infrastruktur digital dan pengguna internet yang sangat pesat. Lonjakan lalu lintas data yang terjadi secara terus-menerus di kawasan urban padat seperti Medan menjadi

tantangan tersendiri bagi operator jaringan dalam menyediakan layanan berkualitas tinggi yang stabil dan efisien.

Salah satu kendala utama dalam pengembangan jaringan 5G di wilayah perkotaan adalah keterbatasan spektrum frekuensi. Spektrum merupakan sumber daya yang terbatas dan sangat vital dalam transmisi nirkabel. Sistem alokasi spektrum konvensional yang bersifat statis cenderung tidak mampu mengakomodasi dinamika lalu lintas data di lingkungan padat seperti pusat kota Medan. Ketika spektrum dialokasikan secara tetap tanpa mempertimbangkan beban trafik secara real-time, efisiensi penggunaan spektrum menjadi rendah dan potensi interferensi meningkat, yang pada akhirnya menurunkan kualitas layanan pengguna.

Berbagai pendekatan telah dikembangkan untuk mengatasi tantangan tersebut, salah satunya adalah melalui pemanfaatan kecerdasan buatan (*Artificial Intelligence/AI*) dalam sistem komunikasi. Salah satu teknik AI yang berkembang pesat dalam konteks jaringan adalah *Reinforcement Learning (RL)*, khususnya varian mendalamnya yaitu *Deep Reinforcement Learning (DRL)*. DRL menggabungkan kemampuan eksplorasi RL dengan pemrosesan data kompleks dari deep learning, sehingga mampu mengambil keputusan alokasi spektrum yang optimal berdasarkan kondisi lingkungan jaringan secara langsung dan berkesinambungan.

Penelitian-penelitian terdahulu menunjukkan bahwa penggunaan algoritma RL dalam pengelolaan spektrum memberikan hasil yang menjanjikan, terutama dalam hal efisiensi kanal dan pengurangan konflik frekuensi. Namun, penerapannya pada konteks lokal seperti Kota Medan masih sangat terbatas. Karakteristik lalu lintas data yang khas, seperti fluktuasi jumlah pengguna harian, kepadatan sinyal di pusat bisnis, dan variasi kebutuhan layanan, menjadikan Kota Medan sebagai studi kasus menarik untuk menguji model DRL dalam kondisi nyata.

Penelitian ini bertujuan untuk mengembangkan dan menguji model DRL yang dapat mengoptimalkan penggunaan spektrum secara adaptif pada jaringan 5G di area urban padat Kota Medan. Dengan pendekatan simulasi berbasis Python dan TensorFlow, studi ini akan mengevaluasi performa sistem dalam hal efisiensi alokasi spektrum, penurunan latency, serta peningkatan throughput jaringan. Penelitian ini diharapkan dapat menjadi pijakan awal dalam pengembangan teknologi jaringan cerdas berbasis AI di wilayah perkotaan Indonesia.

Melalui penelitian ini, diharapkan solusi pengelolaan spektrum berbasis AI tidak hanya menjadi wacana global, tetapi juga dapat diadaptasi secara lokal dengan memperhatikan kebutuhan dan tantangan spesifik dari kota-kota besar seperti Medan. Dengan demikian, teknologi 5G dapat dimaksimalkan untuk mendukung transformasi digital yang merata, inklusif, dan berkelanjutan di Indonesia.

II. STUDI PUSTAKA

Pengelolaan spektrum frekuensi dalam jaringan komunikasi nirkabel telah menjadi isu strategis dalam pengembangan teknologi 5G. Spektrum merupakan sumber daya terbatas yang sangat vital untuk mendukung kualitas layanan komunikasi, terutama di wilayah padat pengguna seperti perkotaan. Alokasi spektrum secara statis, seperti yang diterapkan dalam sistem *Fixed Spectrum Allocation (FSA)*, dinilai tidak lagi memadai dalam memenuhi kebutuhan dinamis masyarakat urban modern. Efisiensi alokasi spektrum menjadi semakin penting, mengingat banyaknya perangkat yang saling terhubung secara simultan di area metropolitan seperti Kota Medan.

Salah satu pendekatan yang berkembang dalam menjawab tantangan tersebut adalah konsep *Dynamic Spectrum Access (DSA)*, yaitu mekanisme di mana pengguna jaringan dapat mengakses kanal secara fleksibel berdasarkan kondisi ketersediaan spektrum. Teknologi ini awalnya banyak diterapkan

pada jaringan kognitif (Cognitive Radio), di mana perangkat dapat secara otomatis mendeteksi spektrum yang tidak digunakan dan memanfaatkannya tanpa mengganggu pengguna utama. Penelitian Zhang et al. (2019) menunjukkan bahwa DSA dapat meningkatkan efisiensi spektrum hingga 25% dibandingkan FSA. Namun, kelemahan DSA terletak pada keterbatasannya dalam membuat keputusan secara kompleks dan cepat di lingkungan padat.

Untuk mengatasi hal tersebut, pendekatan berbasis kecerdasan buatan (Artificial Intelligence) mulai digunakan dalam manajemen spektrum. Salah satu cabang AI yang menonjol dalam konteks ini adalah *Reinforcement Learning* (RL), yang mampu belajar dari interaksi dengan lingkungan tanpa perlu pemrograman eksplisit. RL bekerja berdasarkan prinsip reward dan penalty, sehingga agen dapat membentuk strategi optimal berdasarkan pengalaman. Studi oleh Li et al. (2020) membuktikan bahwa algoritma Deep Q-Learning mampu meningkatkan efisiensi kanal dan mengurangi interferensi pada jaringan padat pengguna.

Penelitian lokal juga mulai mengadopsi konsep ini. Rachmawati dan Darmawan (2021) menerapkan machine learning untuk pengalokasian spektrum di jaringan 5G, dan hasilnya menunjukkan peningkatan throughput serta penurunan latency pada lingkungan padat. Selain itu, Surya dan Hidayatullah (2022) melakukan simulasi Q-Learning dalam jaringan 5G dan menemukan bahwa agen mampu mengadaptasi pola penggunaan spektrum yang efisien dalam skenario padat pengguna, khususnya di wilayah perkotaan seperti Jakarta dan Surabaya, yang memiliki pola lalu lintas data serupa dengan Kota Medan.

Pendekatan Deep Reinforcement Learning (DRL) adalah pengembangan dari RL yang menggabungkan algoritma pembelajaran mendalam (deep learning) untuk menangani dimensi masalah yang lebih besar. DRL memungkinkan agen untuk mengelola keputusan spektrum dengan mempertimbangkan banyak variabel sekaligus, seperti kepadatan pengguna, kualitas sinyal, gangguan kanal, dan prioritas layanan. DRL juga mendukung adaptasi real-time yang sangat penting dalam lingkungan 5G yang dinamis. Dalam simulasi oleh Yu dan He (2021), DRL mampu mempertahankan efisiensi spektrum lebih dari 90% bahkan dalam kondisi jaringan yang sangat padat.

Selain pendekatan algoritmik, studi pustaka juga menunjukkan pentingnya adaptasi sistem terhadap karakteristik lokal. Kota Medan sebagai kota besar dengan kombinasi antara area bisnis, perumahan, dan fasilitas publik memerlukan strategi pengelolaan spektrum yang fleksibel dan responsif terhadap variasi beban trafik harian. Oleh karena itu, penelitian berbasis konteks lokal menjadi sangat penting agar sistem cerdas seperti DRL dapat benar-benar menyatu dengan kondisi nyata di lapangan.

Dengan merujuk pada literatur internasional dan lokal, dapat disimpulkan bahwa penggunaan DRL dalam manajemen spektrum 5G memberikan peluang signifikan dalam menghadapi tantangan keterbatasan spektrum di area urban. Studi pustaka ini menjadi fondasi yang kuat dalam mengembangkan sistem alokasi spektrum adaptif berbasis AI yang siap diimplementasikan secara nyata di kota-kota besar Indonesia seperti Medan.

III. METODE

Penelitian ini menggunakan pendekatan eksperimental berbasis simulasi untuk mengkaji efektivitas algoritma Deep Reinforcement Learning (DRL) dalam pengelolaan spektrum adaptif pada jaringan 5G di lingkungan urban padat, khususnya di Kota Medan. Model simulasi dirancang untuk merepresentasikan kondisi nyata jaringan dengan trafik tinggi, kepadatan pengguna yang beragam, serta fluktuasi kebutuhan layanan yang kompleks.

Simulasi dilakukan menggunakan bahasa pemrograman Python dan pustaka *machine learning* TensorFlow, dengan integrasi dari pustaka OpenAI Gym sebagai lingkungan pengujian. Lingkungan simulasi mencerminkan topologi jaringan 5G sederhana dengan sejumlah node pengguna (user equipment/UE) yang tersebar dalam area urban, serta node base station (gNodeB) sebagai pusat akses. Setiap node pengguna secara berkala meminta akses kanal untuk mentransmisikan data, dan agen DRL bertugas mengalokasikan kanal yang tersedia secara optimal.

Model DRL yang digunakan adalah algoritma *Deep Q-Network* (DQN), yang menggabungkan *Q-learning* tradisional dengan jaringan saraf tiruan (neural network). Dalam konteks penelitian ini, agen DRL berfungsi sebagai sistem pengambil keputusan untuk menentukan kanal mana yang akan diberikan kepada pengguna berdasarkan kondisi jaringan saat itu (misalnya: jumlah kanal tersedia, kualitas kanal, jumlah pengguna aktif, dan tingkat interferensi).

Proses pelatihan dimulai dengan inialisasi lingkungan dan parameter-parameter pelatihan, seperti:

- Jumlah kanal: 10 unit
- Jumlah pengguna: 50-100 (simulasi bertingkat)
- Epsilon awal (exploration rate): 1.0 (turun secara bertahap)
- Learning rate: 0.001
- Discount factor (gamma): 0.95
- Ukuran batch: 32
- Jumlah episode pelatihan: 10.000

Reward diberikan kepada agen berdasarkan efektivitas alokasi kanal. Jika alokasi menghasilkan throughput tinggi dan latensi rendah tanpa konflik kanal, agen menerima reward positif. Sebaliknya, jika terjadi penumpukan trafik, konflik kanal, atau idle spektrum yang tinggi, agen menerima reward negatif. Model pelatihan menggunakan strategi *epsilon-greedy* untuk menyeimbangkan eksplorasi dan eksploitasi selama pembelajaran berlangsung.

Setelah pelatihan selesai, agen DRL diuji dalam berbagai skenario kepadatan pengguna dan kondisi spektrum. Kinerja agen dibandingkan dengan dua pendekatan lainnya, yaitu:

1. Fixed Spectrum Allocation (FSA) - di mana kanal dialokasikan secara tetap tanpa mempertimbangkan beban.
2. Heuristic-Based Allocation - pendekatan berbasis aturan prioritas pengguna.

Evaluasi dilakukan dengan mengukur empat metrik utama:

1. Efisiensi spektrum (% kanal yang dimanfaatkan optimal)
2. Latency rata-rata (ms)
3. Jumlah konflik kanal
4. Total throughput (Mbps)

Analisis hasil dilakukan secara kuantitatif menggunakan statistik deskriptif dan visualisasi grafik performa. Hasil simulasi digunakan untuk membuktikan hipotesis bahwa DRL lebih unggul dalam merespons dinamika trafik jaringan urban seperti yang terjadi di Kota Medan.

Penelitian ini menggunakan pendekatan eksperimental berbasis simulasi untuk mengkaji efektivitas algoritma Deep Reinforcement Learning (DRL) dalam pengelolaan spektrum adaptif pada jaringan 5G di lingkungan urban padat, khususnya di Kota Medan. Simulasi dilakukan menggunakan bahasa pemrograman Python dan pustaka TensorFlow, dengan integrasi pustaka OpenAI Gym

sebagai lingkungan pengujian. Model simulasi mencerminkan topologi jaringan 5G sederhana dengan sejumlah node pengguna (user equipment/UE) dan node base station (gNodeB).

Model DRL yang digunakan adalah algoritma Deep Q-Network (DQN). Agen DRL bertugas sebagai sistem pengambil keputusan yang menentukan alokasi kanal berdasarkan kondisi lingkungan. Sistem pelatihan mengikuti skenario dengan variasi jumlah pengguna dan kondisi trafik dinamis.

Berikut merupakan pseudocode algoritma DQN yang digunakan:

Algoritma Deep Q-Learning untuk Alokasi Spektrum

1. Inisialisasi memori pengalaman D dengan kapasitas N
2. Inisialisasi jaringan Q dengan bobot acak
3. Untuk setiap episode:
 - a. Inisialisasi status awal s
 - b. Untuk setiap langkah waktu t:
 - i. Dengan probabilitas ϵ , pilih aksi a secara acak
Jika tidak, pilih $a = \operatorname{argmax} Q(s, a)$
 - ii. Lakukan aksi a, amati reward r dan status berikutnya s'
 - iii. Simpan transisi (s, a, r, s') ke dalam D
 - iv. Sampling mini-batch dari D
 - v. Untuk setiap transisi:
$$\text{target} = r + \gamma * \max_{a'} Q(s', a')$$
$$\text{loss} = (Q(s, a) - \text{target})^2$$
 - vi. Lakukan backpropagation untuk memperbarui bobot jaringan
 - vii. Update status: $s = s'$
 - c. Kurangi nilai ϵ secara bertahap

Evaluasi kinerja dilakukan berdasarkan empat metrik utama: efisiensi spektrum, latency rata-rata, jumlah konflik kanal, dan total throughput. Hasil dibandingkan dengan metode Fixed Spectrum Allocation (FSA) dan pendekatan heuristik. Analisis dilakukan secara kuantitatif dengan grafik visual dan statistik deskriptif.

IV. HASIL DAN PEMBAHASAN

Hasil simulasi menunjukkan bahwa penerapan algoritma *Deep Reinforcement Learning* (DRL) pada skenario jaringan 5G di Kota Medan menghasilkan peningkatan efisiensi spektrum secara signifikan. Dalam pengujian terhadap berbagai tingkat kepadatan pengguna (dari 50 hingga 100 pengguna aktif), sistem DRL mampu mempertahankan efisiensi alokasi spektrum di atas 90%, sementara metode Fixed Spectrum Allocation (FSA) hanya mencapai kisaran 55–60%, dan pendekatan heuristik berkisar di angka 72–78%. Rata-rata efisiensi spektrum yang dicapai oleh DRL berada di angka 38% lebih tinggi dibandingkan FSA, yang menjadi bukti kuat akan keunggulan pendekatan ini dalam kondisi urban padat seperti Medan.

Dari aspek latency, sistem DRL juga menunjukkan performa yang konsisten dan rendah. Rata-rata latency tercatat sebesar 18–22 milidetik, lebih rendah dibandingkan pendekatan heuristik yang mencatat latency 30 ms, dan FSA yang bahkan bisa mencapai 45 ms pada saat trafik tinggi. Penurunan latency ini sangat krusial bagi layanan real-time seperti video call, game online, dan aplikasi transportasi yang banyak digunakan di lingkungan kota besar.

Dalam pengukuran throughput, DRL kembali menunjukkan keunggulannya dengan peningkatan throughput hingga 18–20% lebih tinggi dibandingkan pendekatan lainnya. Ini berarti kapasitas jaringan meningkat secara keseluruhan, yang berdampak langsung terhadap jumlah data yang berhasil dikirimkan dalam satuan waktu. Kondisi ini menggambarkan bahwa sistem mampu memaksimalkan penggunaan kanal tanpa menghasilkan interferensi yang berlebihan.

Secara adaptif, agen DRL memperlihatkan respons yang cepat terhadap perubahan pola lalu lintas pengguna. Dalam simulasi skenario jam sibuk (pagi dan sore hari), sistem tetap mampu mengalokasikan spektrum dengan efisien tanpa lonjakan konflik kanal. Hal ini membuktikan kemampuan sistem DRL untuk beradaptasi secara real-time terhadap kondisi jaringan yang berubah-ubah, menjadikannya cocok diterapkan di wilayah seperti pusat kota Medan, pusat perbelanjaan, atau kawasan pendidikan yang memiliki pola trafik yang tidak menentu.

Diskusi juga mencakup tantangan yang dihadapi. Salah satunya adalah waktu pelatihan yang cukup lama, karena model perlu menjalani ribuan episode untuk mencapai performa optimal. Selain itu, kebutuhan daya **komputasi** yang tinggi masih menjadi hambatan utama jika sistem ini hendak diterapkan langsung pada edge device atau perangkat base station dengan spesifikasi terbatas.

Namun demikian, hasil yang diperoleh menunjukkan bahwa integrasi DRL dalam manajemen spektrum dapat memberikan solusi nyata terhadap permasalahan keterbatasan spektrum di kota-kota besar Indonesia. Kota Medan sebagai representasi wilayah urban padat memiliki potensi besar untuk menjadi lokasi uji coba nyata (pilot project) penerapan manajemen spektrum berbasis AI ini. Dengan dukungan dari infrastruktur digital yang semakin berkembang di Sumatera Utara, penerapan sistem ini akan menjadi tonggak penting dalam revolusi jaringan cerdas di Indonesia.

V. KESIMPULAN

Penelitian ini membuktikan bahwa penerapan algoritma Deep Reinforcement Learning (DRL) dalam manajemen spektrum adaptif pada jaringan 5G memberikan peningkatan kinerja yang signifikan, khususnya dalam lingkungan urban padat seperti Kota Medan. Sistem yang dikembangkan melalui pendekatan DRL mampu meningkatkan efisiensi penggunaan spektrum

hingga 38% dibandingkan metode konvensional, sekaligus menurunkan latency serta meningkatkan throughput jaringan. Hal ini menunjukkan bahwa pendekatan berbasis kecerdasan buatan tidak hanya mampu menyesuaikan diri dengan dinamika trafik secara real-time, tetapi juga dapat mengoptimalkan kinerja sistem komunikasi nirkabel secara menyeluruh.

Keunggulan lain dari pendekatan ini adalah kemampuannya untuk belajar dan beradaptasi dari pengalaman sebelumnya, sehingga agen sistem mampu membuat keputusan alokasi kanal yang lebih efisien dalam situasi yang tidak terduga. Kemampuan ini sangat relevan untuk diterapkan di kawasan urban seperti Medan, di mana pola lalu lintas data sangat fluktuatif dan penggunaan spektrum sangat padat. Integrasi AI seperti DRL memberikan fleksibilitas yang tidak dimiliki oleh sistem manajemen spektrum konvensional yang bersifat statis.

Meskipun hasil yang diperoleh sangat menjanjikan, penerapan model ini di dunia nyata masih menghadapi beberapa tantangan. Salah satunya adalah kebutuhan komputasi yang tinggi untuk pelatihan awal, serta integrasi teknis dengan perangkat keras jaringan yang ada. Oleh karena itu, perlu dilakukan pendekatan bertahap dalam penerapan teknologi ini, dimulai dari simulasi berskala kecil hingga pengujian lapangan yang lebih luas.

Sebagai pengembangan masa depan, penelitian ini dapat diperluas dengan menguji sistem dalam lingkungan nyata menggunakan data langsung dari operator jaringan di Kota Medan. Selain itu, integrasi dengan teknologi lain seperti *federated learning* dan *edge AI* dapat ditelusuri untuk mengurangi beban komputasi pusat dan mempercepat proses adaptasi. Penelitian lintas sektor juga dapat dilakukan, termasuk mengaitkan sistem spektrum adaptif ini dengan manajemen energi dan pemantauan jaringan otomatis.

Dengan semakin berkembangnya infrastruktur digital dan kebutuhan layanan data di wilayah perkotaan Indonesia, integrasi DRL dalam manajemen spektrum dapat menjadi salah satu solusi strategis dalam mendukung konektivitas yang cepat, stabil, dan cerdas. Hasil penelitian ini diharapkan dapat menjadi kontribusi nyata dalam mendorong pengembangan sistem komunikasi masa depan yang adaptif dan berkelanjutan.

DAFTAR PUSTAKA

- [1] Eason, G., Noble, B., & Sneddon, I. N. (1955). On certain integrals of Lipschitz-Hankel type involving products of Bessel functions. *Phil. Trans. Roy. Soc. London*, A247, 529–551.
- [2] Hidayat, T., & Purnomo, F. (2024). Adaptive Network Intelligence dalam Optimalisasi Spektrum untuk Jaringan Masa Depan. *Jurnal Sains dan Teknologi Telekomunikasi*, 11(1), 1–9.
- [3] Jacobs, I. S., & Bean, C. P. (1963). Fine particles, thin films and exchange anisotropy. In *Magnetism* (Vol. III, pp. 271–350). Academic Press.
- [4] Lestari, D. P., & Wibowo, S. (2019). Analisis Kinerja Dynamic Spectrum Access pada Lingkungan Perkotaan. *Jurnal Teknik ITS*, 8(2), B107–B111.
- [5] Li, Z., Chen, L., & Yu, F. R. (2020). Deep reinforcement learning for dynamic spectrum access in wireless networks. *IEEE Wireless Communications*, 27(3), 110–117.
- [6] Maxwell, J. C. (1892). *A Treatise on Electricity and Magnetism* (3rd ed., Vol. 2). Oxford: Clarendon Press.

- [7] Nugroho, H. A., & Setiawan, A. (2020). Evaluasi Efisiensi Spektrum pada Jaringan Seluler Menggunakan Metode Adaptive Spectrum Sharing. *Jurnal Telekomunikasi dan Komputer*, 14(1), 33–41.
- [8] Pramono, A., & Santoso, E. (2021). Reinforcement Learning untuk Manajemen Sumber Daya Spektrum di Jaringan Mobile. *Jurnal Teknologi dan Sistem Komputer*, 9(4), 333–341.
- [9] Rachmawati, Y., & Darmawan, R. (2021). Penerapan Machine Learning untuk Optimalisasi Alokasi Spektrum Frekuensi pada Jaringan 5G. *Jurnal Teknologi Informasi dan Komputer*, 7(2), 145–152.
- [10] Rahmawati, N., & Mulyadi, R. (2023). Studi Penerapan Kecerdasan Buatan dalam Sistem Komunikasi Bergerak Generasi Kelima. *Jurnal Informatika dan Sistem Informasi*, 12(1), 22–29.
- [11] Ramadhan, A., & Yusuf, M. (2018). Efisiensi Kanal dengan Teknik Dynamic Allocation di Jaringan LTE dan Implementasi Menuju 5G. *Jurnal Teknologi Informasi dan Komunikasi*, 6(1), 58–64.
- [12] Surya, D., & Hidayatullah, A. (2022). Implementasi Algoritma Q-Learning untuk Dinamika Alokasi Kanal di Jaringan 5G. *Jurnal Elektro dan Telekomunikasi Terapan*, 10(3), 201–210.
- [13] Wulandari, S., & Saputra, D. (2020). Simulasi Alokasi Spektrum Menggunakan Deep Reinforcement Learning pada Jaringan Berbasis IoT. *Jurnal Ilmiah Elektro dan Komputer*, 15(2), 75–82.
- [14] Yu, J., & He, H. (2021). Multi-armed bandit-based spectrum access in cognitive radio networks. *IEEE Transactions on Cognitive Communications and Networking*, 7(2), 256–268.
- [15] Zhang, Y., Wang, Y., & Liu, J. (2019). Dynamic Spectrum Allocation in Cognitive Radio Networks: A Survey. *IEEE Communications Surveys & Tutorials*, 21(1), 123–140.