



Efisiensi Algoritma Pencarian Dalam Permainan Dan Navigasi Robot

Nabiel Syarof Azzaky¹, Achmad Varis Abdussalam², Ahmad Nur Ihsan Purwanto³

¹Computer Science Departement , Universitas Ary Ginanjar, Jakarta, Idnonesia

^{2,31} Computer Science Departement , Universitas Ary Ginanjar, Jakarta, Idnonesia

Email: ¹nabiel.syarof.azzaky@students.esqbs.ac.id,

²achmad.varis.abdussalam@students.esqbs.ac.id,³ahmadnur.ihsan@esqbs.ac.id

Abstract

This article reviews the literature on the efficiency of algorithmic search and navigation in the domain of computer games and robot navigation. This study focuses on heuristic optimization methods such as bidirectional A*, sampling-based techniques, and Reinforcement-based algorithms. Statistics show that bidirectional A* routes reduce the long-distance time by 40% compared to conventional A* routes. Overall, although extreme parameter optimization is required, sampling-based algorithms definitely show the probability level up to a given value point. Reinforcement algorithm styles such as Deep Deterministic Policy Gradient and Proximal Policy Optimization have also been successful. By combining CNN, RNN, and LSTM, Reinforcement algorithms that work in dense environments enable robots to adapt to the environment, responding to human movement. Improved sample-based algorithms with boundary-based exploration have also proven to be effective and can be transferred from simulation to real environments.

Keywords: Search Algorithms, Robot Navigation, Deep Reinforcement Learning, Bidirectional A*, RRT*, MCTS, Path Efficiency, Motion Planning

1. PENDAHULUAN

Dengan semakin berkembangnya permainan otonom modern dan robotika, masalah penyusunan jalur optimal cenderung menjadi topik utama. Algoritma heuristik seperti A* maupun sampling-based algoritma seperti RRT*, PRM, masih menjadi rujukan yang umum, mengingat sejarah penggunaannya yang nyaman dan jaminan sudut tetap optimal. Walau demikian, solusi konvensional sebagian kecil dalam mendeteksi pola grup yang kompleks, situasi, dan tantangan real time.



DRL menawarkan solusi fleksibel untuk lingkungan yang berlawanan dengan intuisi dan berinteraksi seperti menavigasi robot manusia. Dalam permainan, DRL memungkinkan robot atau agen untuk belajar dari kesalahannya, mengatasi rintangan, dan secara otomatis beradaptasi dengan rezim pembelajaran jalur. Kinerja DRL juga dapat ditingkatkan dengan arsitektur jaringan saraf seperti CNN, LSTM, dan Transformer. Dalam pengembangan permainan, algoritma seperti MCTS telah dikembangkan, yang menghasilkan solusi strategis secara andal saat dikombinasikan dengan jaringan saraf. Di antara mereka, dalam permainan, parameter seperti kemampuan agen untuk mengidentifikasi rintangan dan kemampuan mereka untuk memperbarui secara real-time menentukan keberhasilan sistem karena keduanya penting. Karena efisiensi menjadi semakin penting dalam jalur dan pilihan pelatihan, evaluasi kinerja berbagai algoritma bahkan lebih lazim dalam robot digital.

2. METHODS

Sumber utama dalam kajian literatur ini berasal dari artikel-artikel ilmiah yang dipublikasikan dalam jurnal bereputasi internasional dan prosiding konferensi bergengsi yang dikelola oleh penerbit ternama seperti MDPI, Springer, dan Elsevier. Proses pengumpulan data dilakukan secara sistematis dengan memanfaatkan mesin pencari akademik dan database terbuka, menggunakan kombinasi kata kunci yang disesuaikan dengan topik inti, seperti “bidirectional A”, “robot navigasi berbasis DRL”, “RRT (Rapidly-exploring Random Tree Star)”, “MCTS (Monte Carlo Tree Search) untuk kecerdasan buatan dalam game”, serta “eksplorasi berbasis frontier dalam DRL”. Setiap publikasi yang terpilih melalui proses penyaringan tersebut kemudian dianalisis secara kualitatif dan kuantitatif menggunakan berbagai metrik evaluasi, seperti efisiensi waktu perencanaan jalur, panjang lintasan yang dihasilkan, efektivitas dalam menghindari tabrakan, serta kapabilitas generalisasi dalam skenario transfer learning dari lingkungan simulasi ke dunia nyata (sim-to-real transfer). Pendekatan analitis ini memungkinkan identifikasi secara menyeluruh terhadap kekuatan, keterbatasan, serta potensi integrasi lintas algoritma, sehingga memberikan landasan yang kuat bagi perumusan strategi navigasi robot otonom dan agen game cerdas di masa mendatang.

2.1. Research Methods

Metode penelitian dapat mencakup teori-teori yang digunakan dalam kajian pustaka, yang diperoleh dari berbagai sumber literatur dan harus disertai dengan referensi. Uraikan secara singkat metode penelitian yang digunakan serta jelaskan tahapan-tahapan pelaksanaannya.

2.2. Persamaan Matematis

Persamaan matematis diberi nomor menggunakan angka Arab yang ditulis di dalam tanda kurung dan ditempatkan rata kanan.

$$y(n) = \sum_{k=-\infty}^{\infty} x(k)x(n-k) \quad (1)$$

Persamaan ditulis dengan sedikit menjorok (indentasi) dan diberi nomor urut yang sesuai.

$$net = \sum x_i w_i + b \quad (2)$$

2.3. Penulisan Sitasi dan Referensi

Reference in the discussion is marked by literature number which is referenced in square brackets. Examples: [1], [2, 5-7], or [2-5, 12-13].

3. RESULTS AND DISCUSSION

3.1 Heuristik dan Sampling-Based

Algoritma Bidirectional A* secara bersamaan menginisiasi proses pencarian dari kedua arah, yaitu titik awal dan titik akhir. Secara teori, pendekatan ini mengubah $O(b^d)$ menjadi $O(2^{b(d/2)})$, yang dalam praktiknya dapat meningkatkan waktu perencanaan hingga 40% jika dibandingkan dengan algoritma A* konvensional. Selain itu, algoritma berbasis sampling seperti Probabilistic Roadmap (PRM) dan Rapidly-exploring Random Tree (RRT*) memberikan informasi statistik tentang kemungkinan jalur di area berukuran besar. Efektivitas algoritma ini sangat bergantung pada parameter seperti kepadatan sampling dan radius konektivitas node-to-node.

3.2 Deep Reinforcement Learning

Dalam simulasi berbasis Gazebo, algoritma Proximal Policy Optimization (PPO) yang telah disempurnakan memberikan hasil yang lebih baik dalam hal keamanan dan efisiensi, sedangkan algoritma Deep Deterministic Policy Gradient (DDPG) lebih cocok untuk lingkungan dengan kontrol berkelanjutan, seperti tipe Ackermann. Menurut survei baru yang dilakukan pada tahun 2024 tentang navigasi di lingkungan yang padat, integrasi Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), dan Long Short-Term Memory (LSTM) dapat memprediksi dan mengantisipasi pergerakan manusia secara proaktif dengan akurasi dan efisiensi yang lebih tinggi daripada pendekatan berbasis model tradisional. Antara lain, kolaborasi antara pembelajaran kurikulum, pembelajaran penguatan di luar kebijakan, dan logika fuzzy (SCF) telah berhasil meningkatkan efisiensi pengembangan sampel dan kemudahan navigasi dalam kondisi saat ini.




Gambar 1. Alur Deep Reinforcement Learning

3.3 Deep Reinforcement Learning

Dalam hal permainan strategi, Monte Carlo Tree Search (MCTS) tidak diragukan lagi merupakan alat yang ampuh. Menggabungkan MCTS dengan jaringan saraf tiruan, seperti pendekatan AlphaZero, menghasilkan strategi permainan yang lebih fleksibel dan efektif. Proses eksplorasi acak awal dari MCTS memungkinkan agen permainan untuk

menilai dan menentukan tindakan terbaik berdasarkan hasil simulasi yang potensial.



Gambar 2. Ilustrasi Proses Backpropagation

4. CONCLUSION

Berdasarkan hasil penelitian, dapat disimpulkan bahwa banyak algoritma pencarian yang memiliki karakteristik dan keunggulan unik yang membuatnya cocok untuk konteks aplikasi, baik itu permainan komputer maupun navigasi robot. Algoritma heuristik seperti Bidirectional A* memberikan efisiensi yang sangat baik dalam pengaturan statistik dan struktur grafik yang besar karena dapat mengurangi kompleksitas waktu pencarian dari $O(b^d)$ menjadi $O(2b^{(d/2)})$. Hal ini menjadikannya pilihan yang tepat untuk skenario dengan topologi yang telah dikenali sebelumnya yang tidak mengalami banyak perubahan.

Teknik pengambilan sampel seperti Probabilistic Roadmap (PRM) dan Rapidly-exploring Random Tree (RRT*) memberikan solusi yang melihat berbagai macam data. Meskipun sifatnya probabilistik, efektivitas metode ini sangat bergantung pada parameter seperti kepadatan sampel dan radius koneksi. Karena itu, parameter penyetelan merupakan faktor

penting dalam mencapai hasil terbaik.

Deep Reinforcement Learning (DRL) merupakan solusi utama untuk permasalahan navigasi di lingkungan yang tidak terstruktur dengan baik, dinamis, atau terkelola dengan baik. Kelebihannya terletak pada tingkat adaptasi yang tinggi terhadap perubahan kondisi lingkungan. Ketika DRL dikombinasikan dengan pendekatan klasik seperti logika fuzzy dan pembelajaran kurikulum, sistem menjadi lebih efektif dalam pengajaran dan lebih andal ketika dioperasikan di dunia nyata. Sebaliknya, Monte Carlo Tree Search (MCTS) tetap menjadi algoritma terpenting dalam industri game, bahkan ketika digunakan dengan pembelajaran berbasis jaringan saraf, seperti pada AlphaZero, yang menghasilkan strategi permainan yang lebih kompetitif dan adaptif.

Oleh karena itu, pemilihan dan pengembangan algoritma pencarian harus sesuai dengan karakteristik lingkungan aplikasi dan kinerja sistem yang diharapkan.

REFERENSI

- [1] S. Mehmood and S. Syaharuddin, "Reinforcement Learning for Automated Systems: Review of Concepts and Implementations," *Jurnal Pemikiran dan Penelitian Pendidikan Matematika (JP3M)*, vol. 7, no. 2, pp. 146–166, 2024.
- [2] Y. Hu, Y. Zhao, C. Zhao, and A. Cohan, "MCTS-RAG: Enhancing Retrieval-Augmented Generation with Monte Carlo Tree Search," *arXiv preprint arXiv:2503.20757*, 2025.
- [3] C. Tang, B. Abbatematteo, J. Hu, R. Chandra, R. Martín-Martín, and P. Stone, "Deep Reinforcement Learning for Robotics: A Survey of Real-World Successes," in *Proc. AAAI Conf. Artif. Intell.*, vol. 39, no. 27, pp. 28694–28698, Apr. 2025.

- [4] S. Sudirwo *et al.*, *Artificial Intelligence: Teori, Konsep, dan Implementasi di Berbagai Bidang*. PT. Sonpedia Publishing Indonesia, 2025.
- [5] Y. Zhu *et al.*, "Deep Reinforcement Learning of Mobile Robot Navigation in Dynamic Environment: A Review," *Sensors*, vol. 25, no. 11, p. 3394, 2025.
- [6] Han *et al.*, "Memory-driven DRL for Partially Observable Robot Navigation," *Eng. Sci. & Technol.*, vol. 62, p. 101942, 2024.
- [7] Springer, "Comprehensive Review DRL in Crowded Environments," *J. Intell. & Robot. Syst.*, vol. 110, p. 158, 2024.
- [8] H. Taheri, S. R. Hosseini, and M. A. Nekoui, "Deep Reinforcement Learning with Enhanced PPO for Safe Mobile Robot Navigation," *arXiv preprint arXiv:2405.16266*, 2024.
- [9] Y. Zhu, W. Z. W. Hasan, H. R. H. Ramli, N. M. H. Norsahperi, M. S. M. Kassim, and Y. Yao, "Deep Reinforcement Learning of Mobile Robot Navigation in Dynamic Environment: A Review," *Sensors (Basel)*, vol. 25, no. 11, p. 3394, 2025.
- [10] F. Ramadhan, *Integrasi Data Multisensor untuk Peningkatan Lokalisasi pada Navigasi Mobile Robot Menggunakan Extended Kalman Filter*, Doctoral dissertation, Institut Teknologi Sepuluh Nopember, 2025.