

IMPLEMENTASI DEEP REINFORCEMENT LEARNING UNTUK PENGEMBANGAN AGEN GAME DODGEBALL MENGGUNAKAN UNITY ML- AGENTS

Dzaky Fiantino¹, T. Yudi Hadiwandra²

^{1,2}Program Studi Teknik Informatika Universitas Riau

¹dzaky.fiantino3404@student.unri.ac.id, ²tyudihw@lecturer.unri.ac.id

ABSTRACT

The gaming industry has grown rapidly, and one of the key elements in a game is the non-playable character (NPC). Easily predictable NPC behavior often reduces player engagement and satisfaction. Static or unresponsive NPCs tend to create monotonous and less challenging gameplay experiences, ultimately lowering game quality and player interest. This study applies Deep Reinforcement Learning (DRL) using Unity ML-Agents to train agents in a Dodgeball game, enabling them to make adaptive decisions through self-play. A reward system was designed to provide positive feedback for strategic actions, such as picking up and throwing the ball, and penalties for mistakes, such as hitting walls or being hit by the ball. The training results showed a gradual improvement in agent performance, reflected in the increasing and stable cumulative rewards and ELO scores at the end of training. In performance testing, the DRL agent achieved a 66% win rate against the rule-based agent over 50 matches. A user preference test also revealed that 80% of players preferred competing against the DRL agent, with 60% of them considering it more challenging than the rule-based one. These results demonstrate that the DRL agent not only outperforms the rule-based agent but also provides a more dynamic and realistic gameplay experience.

Keywords: Deep Reinforcement Learning, Dodgeball, Game, Unity ML-Agents, Self-play

ABSTRAK

Industri game berkembang dengan pesat. Salah satu elemen penting dalam sebuah game adalah non playable character (NPC). Perilaku NPC yang dapat diprediksi dengan mudah sering kali mengurangi tingkat keterlibatan dan kepuasan pemain. NPC yang berperilaku secara statis atau tidak responsif terhadap perubahan situasi dalam permainan cenderung menciptakan pengalaman bermain yang monoton dan kurang menantang. Hal tersebut dapat menurunkan kualitas permainan dan mengurangi minat pemain. Penelitian ini menggunakan Deep Reinforcement Learning (DRL) dengan Unity ML-Agents untuk melatih agen dalam bermain Dodgeball agar mampu mengambil keputusan secara adaptif berdasarkan pengalaman melalui mekanisme self-play. Sistem reward dirancang untuk memberikan umpan balik positif pada tindakan strategis seperti mengambil dan

melempar bola, serta penalti pada kesalahan seperti menabrak dinding atau terkena bola. Hasil pelatihan menunjukkan peningkatan performa agen secara bertahap yang tercermin dari nilai cumulative reward dan ELO score yang meningkat dan stabil pada akhir pelatihan. Pada pengujian performa, agen DRL memperoleh tingkat kemenangan sebesar 66% terhadap agen rule-based dari total 50 pertandingan. Uji preferensi pengguna juga menunjukkan bahwa 80% pemain lebih menyukai bertanding dengan agen DRL, dan 60% di antaranya menilai agen DRL lebih menantang dibanding agen rule-based. Hasil ini menunjukkan bahwa agen DRL tidak hanya unggul secara performa, tetapi juga memberikan pengalaman bermain yang lebih dinamis dan realistis.

Kata Kunci: *Deep Reinforcement Learning, Dodgeball, Game, Unity ML-Agents, Self-play*

A. Pendahuluan

Perkembangan industri game mendorong kebutuhan akan karakter non-playable character (NPC) yang mampu berperilaku adaptif dan responsif. Metode pengendalian tradisional seperti rule-based system dan finite state machine masih banyak digunakan karena implementasinya sederhana, namun pendekatan tersebut menghasilkan perilaku NPC yang statis, mudah diprediksi, dan kurang menantang bagi pemain (Silva & Ribeiro, 2021). Keterbatasan ini berdampak pada menurunnya imersi serta kualitas pengalaman bermain.

Kecerdasan buatan, khususnya Reinforcement Learning (RL), menawarkan solusi untuk menghasilkan agen yang mampu belajar dari interaksi dengan lingkungan melalui mekanisme reward

dan punishment (Sutton & Barto, 2018). Pengembangan RL menjadi Deep Reinforcement Learning (DRL) memungkinkan agen menangani lingkungan kompleks dan mempelajari strategi secara mandiri tanpa pemrograman eksplisit (Mnih et al., 2015). Dalam konteks game, DRL dinilai efektif untuk menciptakan perilaku agen yang adaptif, dinamis, dan sulit diprediksi.

Unity ML-Agents merupakan platform pembelajaran yang banyak digunakan untuk integrasi algoritma DRL ke dalam lingkungan game karena menyediakan mekanisme observasi, aksi, reward, serta simulasi pelatihan yang fleksibel (Juliani et al., 2018). Game dodgeball, yang memiliki dinamika aksi-reaksi cepat dan kebutuhan pengambilan keputusan real-time, menjadi lingkungan yang

relevan untuk eksperimen agen berbasis DRL (Wijaya & Lestari, 2022).


Pelatihan berbasis self-play semakin meningkatkan kemampuan agen dalam mengembangkan strategi kompetitif karena agen belajar dengan menghadapi lawan yang berkembang seiring waktu. Pendekatan ini terbukti efektif dalam penelitian sebelumnya, seperti AlphaStar pada permainan StarCraft II (Vinyals et al., 2019).

Penelitian ini bertujuan mengembangkan agen game dodgeball menggunakan Deep Reinforcement Learning pada Unity ML-Agents dan menganalisis performanya dalam simulasi kompetitif. Hasil penelitian diharapkan memberikan kontribusi pada pengembangan NPC adaptif serta menjadi referensi implementasi DRL dalam pengembangan game interaktif.

B. Metode Penelitian

Penelitian ini menggunakan metode penelitian eksperimen. Dalam konteks penelitian ini, eksperimen dilakukan untuk mengevaluasi efektivitas agen dalam game dodgeball yang dikembangkan menggunakan Deep Reinforcement

Learning (DRL) saat dibandingkan dengan agen yang dikendalikan menggunakan metode rule-based. Alur penelitian tampak pada gambar 1.



Gambar 1. Alur Penelitian

1. Observasi

Tahap observasi dilakukan dengan mengamati karakteristik non-playable character (NPC) pada berbagai game yang masih menggunakan pendekatan berbasis aturan (rule-based system). Hasil pengamatan menunjukkan bahwa pendekatan tersebut menghasilkan perilaku yang mudah diprediksi dan kurang adaptif terhadap situasi permainan yang dinamis. Keterbatasan ini mendorong perlunya penerapan metode yang memungkinkan agen belajar secara

mandiri dari interaksi dalam lingkungan permainan.

2. Identifikasi Masalah

Berdasarkan hasil observasi, masalah utama yang ditemukan adalah kurangnya kemampuan adaptasi agen terhadap perubahan situasi permainan. Agen berbasis aturan memiliki logika perilaku yang statis dan tidak dapat mengembangkan strategi baru saat menghadapi kondisi yang berbeda [2]. Oleh karena itu, diperlukan pendekatan berbasis pembelajaran yang dapat meningkatkan fleksibilitas agen dan membuatnya mampu beradaptasi, seperti deep reinforcement learning (DRL).

3. Studi Literatur

Studi literatur dalam penelitian ini dilakukan dengan menganalisis berbagai sumber terkait pengembangan agen menggunakan Deep Reinforcement Learning (DRL) pada lingkungan permainan. Kegiatan ini bertujuan untuk memperoleh landasan teori dan pemahaman yang relevan dalam merancang serta melatih agen yang adaptif menggunakan Unity ML-Agents. Sumber literatur yang digunakan meliputi jurnal ilmiah, prosiding, buku, serta penelitian terdahulu yang

membahas hal terkait. Referensi tersebut menjadi dasar dalam menentukan metode pelatihan, perancangan lingkungan permainan dodgeball, serta konfigurasi sistem reward yang digunakan dalam penelitian ini..

4. Perancangan Lingkungan Game

Lingkungan permainan dirancang menggunakan Unity dengan integrasi Unity ML-Agents sebagai kerangka pembelajaran. Arena permainan berbentuk area terbagi dua untuk dua agen yang saling berhadapan dalam game dodgeball. Setiap agen memiliki kemampuan dasar seperti bergerak, mengambil, dan melempar bola. Desain lingkungan dibuat agar agen menghadapi situasi kompetitif yang menuntut pengambilan keputusan cepat dan adaptif.

5. Implementasi Unity ML-Agents

Implementasi dilakukan dengan mendefinisikan parameter pelatihan seperti kecepatan gerak, area permainan, serta kondisi yang memengaruhi performa agen. Unity ML-Agents digunakan sebagai penghubung antara lingkungan Unity dan model pembelajaran DRL. Proses pelatihan berlangsung secara self-play, di mana agen berkompetisi

melawan dirinya sendiri untuk mengasah strategi yang lebih efektif.

6. Konfigurasi Sistem Reward

Sistem reward dirancang untuk mendorong perilaku optimal selama pelatihan. Agen menerima reward positif saat berhasil mengenai lawan atau menghindari serangan, dan reward negatif saat terkena bola atau melakukan tindakan tidak produktif. Pengaturan nilai reward dilakukan secara bertahap berdasarkan hasil pengamatan performa agen selama pelatihan agar diperoleh perilaku yang stabil dan efisien.

7. Pelatihan Agen

Proses pelatihan dilakukan dengan metode deep reinforcement learning berbasis algoritma Proximal Policy Optimization (PPO). Agen berlatih dalam skenario self-play, di mana tingkat kesulitan meningkat seiring peningkatan kemampuan lawan. Evaluasi dilakukan dengan memantau metrik seperti rata-rata cumulative reward dan tingkat kemenangan untuk memastikan konvergensi pelatihan.


8. Pengujian Agen

Setelah pelatihan, agen diuji melalui dua skenario: melawan agen berbasis aturan dan melawan pemain manusia. Tujuan pengujian adalah mengevaluasi tingkat adaptasi dan

variasi strategi agen DRL dibandingkan agen rule-based. Data hasil pengujian digunakan untuk menilai efektivitas metode DRL dalam menghasilkan perilaku yang lebih realistis dan dinamis.

C. Hasil Penelitian dan Pembahasan

Game dodgeball dikembangkan menggunakan Unity dengan dua agen yang saling berhadapan di satu arena. Masing-masing agen hanya dapat bergerak di area sendiri dan akan menang jika berhasil mengenai lawan dengan bola. Lingkungan permainan ini juga dirancang agar mudah dikontrol dan diamati selama proses pelatihan menggunakan Unity ML-Agents Toolkit, dengan fokus pada pembelajaran strategi menyerang dan bertahan. Gambar 2 memperlihatkan tampilan dalam game.



Gambar 2. Tampilan Game Dodgeball

1. Sistem Reward dan Observasi

Sistem reward berperan penting dalam pembelajaran agen. Agen

memperoleh reward ketika melakukan aksi yang sesuai tujuan permainan, seperti berhasil menghindar atau mengenai lawan, dan mendapatkan penalti jika gagal mempertahankan diri atau terkena bola.

Tabel 1. Sistem Reward pada Agen Dodgeball


No	Kondisi	Reward
1	Mengambil bola	+0.1
2	Melempar bola sejajar dengan posisi lawan	+0.15
3	M mengenai lawan dengan bola	+0.1
4	Menabrak tembok	-0.1
5	Terkena bola	-1

Tabel 1 merupakan sistem reward yang diterapkan pada proses pelatihan. Agen juga menerima observation yang mencakup posisi bola, posisi lawan, dan posisi dirinya sendiri di arena. Informasi ini membantu agen membentuk representasi keadaan permainan untuk menentukan tindakan yang optimal.

2. Hasil Pelatihan Agen


Proses pelatihan dilakukan dengan pendekatan self-play, di mana agen berlatih melawan dirinya sendiri untuk mengembangkan kemampuan menyerang dan bertahan secara adaptif. Hasil pelatihan menunjukkan

peningkatan performa agen yang konsisten seiring bertambahnya jumlah episode seperti yang terlihat pada gambar 3.



Gambar 3. Grafik Cumulative Reward dan Episode Length

Grafik cumulative reward menunjukkan tren kenaikan yang stabil, yang menandakan bahwa model telah mencapai stabilitas pembelajaran. Hal ini juga didukung dengan skor ELO yang sudah mencapai kestabilan seperti yang terlihat pada gambar 4.



Gambar 4. Grafik Skor ELO

3. Perbandingan dengan Agen Rule-Based

Agen hasil pelatihan diuji melawan agen rule-based untuk mengukur performa dan adaptivitasnya. Hasilnya menunjukkan bahwa agen berbasis deep reinforcement learning (DRL)

memiliki tingkat kemenangan yang lebih tinggi karena mampu menyesuaikan strategi terhadap perilaku lawan seperti yang terlihat pada tabel 2.

Tabel 2. Hasil Pertandingan Agen DRL vs Agen Rule-Based

Jumlah Pertandingan	Jumlah Kemenangan Agen DRL	Jumlah Kemenangan Agen Rule-based
10	7	3
20	13	7
30	20	10
40	26	14
50	33	17

Agen DRL memperlihatkan perilaku yang lebih dinamis, seperti memilih waktu lempar yang optimal dan bergerak secara efisien untuk menghindari. Sebaliknya, agen rule-based cenderung kaku dan mudah diprediksi karena mengikuti pola tetap.


4. Evaluasi Melawan Pemain Manusia

Untuk menguji sejauh mana performa agen jika melawan manusia, dilakukan uji coba dengan pemain manusia. Hasilnya menunjukkan bahwa agen DRL memberikan tantangan yang seimbang dan dianggap lebih menarik oleh sebagian besar pemain.

Tabel 3. Hasil Pertandingan Pemain Melawan Agen DRL dan Rule-based

Pemain	Kemenangan Melawan Agen DRL	Kemenangan Melawan Agen Rule- based
1	5	6
2	6	7
3	5	5
4	7	6
5	5	5
Rata- Rata	5.6	5.8


Tabel 3 menampilkan hasil pertandingan pemain melawan agen DRL dan juga rule-based. Pemain memperoleh kemenangan yang lebih besar saat melawan agen rule-based dibanding saat melawan agen DRL.



Gambar 5. Agen yang Lebih Sulit Menurut Pemain

Gambar 5 menunjukkan 60% dari pemain yang disurvei merasa agen DRL lebih sulit dibanding agen rule-based. Gambar 6 menampilkan diagram yang menunjukkan preferensi agen yang lebih menyenangkan untuk dihadapi oleh pemain.

Agen mana yang lebih menyenangkan untuk dihadapi?
5 jawaban



Gambar 6. Agen yang Lebih Menyenangkan Menurut Pemain

Gambar 6 menunjukkan 80% dari pemain yang disurvei merasa agen DRL lebih menyenangkan untuk dihadapi dibanding agen rule-based. Sebagian besar pemain menilai agen DRL lebih “cerdas” dalam mengambil keputusan dan menghadirkan pengalaman bermain yang lebih realistis dibandingkan agen rule-based. Hal ini menunjukkan keberhasilan metode DRL dalam menghasilkan perilaku agen yang adaptif.

5. Analisa Hasil Pengujian

Dari hasil eksperimen, metode deep reinforcement learning dengan pendekatan self-play terbukti efektif dalam meningkatkan kemampuan agen dalam game dodgeball. Agen mampu mempelajari strategi kompleks secara mandiri tanpa aturan eksplisit. Agen DRL menunjukkan kinerja yang lebih stabil, adaptif, dan kompetitif dibandingkan agen rule-based.

E. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan Deep Reinforcement Learning pada game Dodgeball berhasil menghasilkan agen yang mampu beradaptasi terhadap lingkungan permainan dodgeball. Penelitian menunjukkan agen DRL bisa bersaing dengan agen rule-based dalam permainan dodgeball sederhana. Agen DRL memperoleh tingkat kemenangan yang lebih tinggi dibanding agen rule-based. Uji preferensi pengguna juga menunjukkan bahwa mayoritas pemain menganggap agen DRL memiliki perilaku yang lebih alami dan dinamis dibanding agen rule-based sehingga lebih menyenangkan untuk dimainkan..

DAFTAR PUSTAKA

- Arsyad, R., & Rachmawati, D. (2022). Penerapan Deep Reinforcement Learning untuk Pengembangan Agen Cerdas pada Game RPG Berbasis Unity. *Jurnal Ilmu Komputer dan Aplikasi*, 10(1), 50–59.
- Christiano, P. F., Leike, J., Brown, T., Martic, M., Legg, S., & Amodei, D. (2017). Deep reinforcement learning from human preferences.

- Advances in Neural Information Processing Systems, 30.
- Han, S., Lee, J., & Kim, Y. (2020). Multi-Agent Reinforcement Learning in Unity-based Environments. *Journal of Simulation and Gaming*, 15(3), 211–225.
- Indrawan, R., & Fajri, A. (2021). Perancangan Agen Game Berbasis AI Menggunakan Unity ML-Agents. *Jurnal Ilmu Komputer Terapan*, 4(2), 45–52.
- Isnain, A. A., Febrian, R., & Pramudito, S. (2021). Implementasi Deep Reinforcement Learning dengan Unity ML-Agents pada Game 3D Sederhana. *Jurnal Teknologi dan Sistem Komputer*, 9(3), 239–246.
- Juliani, A., Berges, V. P., Vckay, E., Gao, Y., Henry, H., Mattar, M., & Lange, D. (2018). Unity: A general platform for intelligent agents.
- Lample, G., & Chaplot, D. S. (2016). Playing FPS games with deep reinforcement learning. <https://doi.org/10.1609/aaai.v31i1.10827>
- Lee, H., Kim, Y., & Cho, K. (2021). Learning Dodgeball Strategies via Multi-Agent Reinforcement Learning.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533.
- Nugroho, F. H., & Ramadhan, T. M. (2020). Implementasi Reinforcement Learning pada Game Snake Menggunakan Unity. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 7(4), 861–869.
- Prasetyo, M. D., & Irawan, A. (2023). Pemanfaatan Unity ML-Agents untuk Melatih Agen dalam Game Strategi. *Jurnal Sains dan Teknologi Komputer*, 6(2), 101–108.
- Silva, D., & Ribeiro, A. (2021). Enhancing NPC behavior for better player experience in video games. *Journal of Game Design*, 15(2), 45–58.
- Siu, H. C., Pena, J. D., Chen, E., Zhou, Y., Lopez, V. J., Palko, K., Chang, K. C., & Allen, R. E. (2021). Evaluation of human–AI teams for learned and rule-based agents in Hanabi. <https://doi.org/10.48550/arXiv.2107.07630>
- Tan, M., Wang, L., Liu, Q., Zhao, D., & Zhang, J. (2018). Self-play for reinforcement learning.
- Troy, M., Ferreira, J. C., & Figueiredo, R. (2024). Using provenance data and imitation learning to train human-like bots. *Entertainment Computing*, 47, 100539. <https://doi.org/10.1016/j.entcom.2023.100539>
- Vinyals, O., Babuschkin, I., Czarnecki, W. M., Mathieu, M., Dudzik, A., Chung, J., Silver, D. (2019). Grandmaster level in StarCraft II using multi-agent reinforcement learning. *Nature*, 575(7782), 350–354.
- Wang, S., Luo, Y., & Lin, H. (2021). Self-Play Reinforcement Learning for Multi-Agent Combat Games. *IEEE Transactions on Games*, 13(4), 211–220.

- Wijaya, R., & Lestari, S. D. (2022). Pengembangan Agen AI dalam Permainan Dodgeball Menggunakan Deep Reinforcement Learning dan Unity ML-Agents. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(2), 157–166.
- Wiratama, A., Sutanto, G., & Sari, M. (2023). The impact of NPC behavior on player engagement in interactive games. *International Journal of Game Studies*, 9(1), 112-126.
- Zhang, Y., Chen, H., & Zhou, F. (2020). Multi-Agent Reinforcement Learning in a Competitive Dodgeball Environment. *International Conference on Autonomous Agents and Multiagent Systems*.
- Zhang, Y., Chen, X., & Wang, H. (2021). Dodgeball AI: Training Competitive Agents using DRL. *International Journal of Game-Based Learning*, 11(2), 34-45.