

# Reinforcement Learning for Automated Systems: Review of Concepts and Implementations

Saba Mehmood<sup>1</sup>, Syaharuddin<sup>2</sup>

**Abstrak:** Studi ini bertujuan untuk melakukan kajian mendalam terhadap implementasi dan konsep Reinforcement Learning (RL) dalam sistem otomatis melalui pendekatan Systematic Literature Review. Penelitian ini menggunakan sumber literatur dari database seperti Scopus, DOAJ, dan Google Scholar dengan rentang tahun 2014-2024. Tinjauan ini menyoroti aplikasi RL dalam berbagai domain sistem otomatis seperti robotika, kendaraan otonom, manajemen lalu lintas, kedirgantaraan, manajemen energi, dan perawatan kesehatan. Hasil tinjauan menunjukkan bahwa RL memberikan kontribusi signifikan dalam meningkatkan efisiensi, adaptabilitas, dan kecerdasan sistem otomatis. Namun, implementasi RL juga dihadapkan pada tantangan seperti efisiensi data yang buruk, biaya komputasi yang tinggi, dan ketergantungan pada infrastruktur teknologi yang memadai. Berbagai solusi telah diusulkan, seperti pengoptimalan perangkat keras, metode hemat data, dan integrasi informasi struktural tambahan, untuk mengatasi tantangan ini. Meskipun demikian, masih diperlukan penelitian lanjutan untuk mengembangkan teknik-teknik yang lebih efisien dan adaptif dalam penggunaan data serta integrasi RL dengan infrastruktur otomatisasi yang lebih luas. Penelitian ini mengidentifikasi kesenjangan dalam literatur dan merumuskan topik riset mendesak untuk mengeksplorasi solusi-solusi inovatif guna memperluas aplikasi RL di masa mendatang.

**Kata Kunci :** *Pembelajaran Penguatan; Sistem Otomatis; Konsep dan Implementasi*

---

**Abstract:** This study aims to conduct an in-depth review of the implementation and concepts of Reinforcement Learning (RL) in automated systems through a Systematic Literature Review approach. The research utilizes literature sources from databases such as Scopus, DOAJ, and Google Scholar spanning the years 2014 to 2024. The review highlights RL applications in various domains of automated systems including robotics, autonomous vehicles, traffic management, aerospace, energy management, and healthcare. The findings reveal that RL significantly contributes to enhancing efficiency, adaptability, and intelligence in automated systems. However, RL implementation faces challenges such as poor data efficiency, high computational

---

<sup>1</sup> Department of Mathematics, School of Science, University of Management and Tehcnology, Pakistan, [saba.mehmood@umt.edu.pk](mailto:saba.mehmood@umt.edu.pk)

<sup>2</sup> Universitas Muhammadiyah Mataram, Mataram, Indonesia,

costs, and dependence on adequate technological infrastructure. Various solutions have been proposed, such as hardware optimization, data-efficient methods, and the integration of additional structural information, to address these challenges. Nevertheless, further research is needed to develop more efficient and adaptive techniques in data utilization and the integration of RL with broader automation infrastructure. This study identifies gaps in the literature and formulates urgent research topics to explore innovative solutions for expanding RL applications in the future.

**Keywords** : *Reinforcement Learning; Automated Systems; Concepts and Implementations*

## A. Pendahuluan

Perkembangan teknologi otomatisasi dalam berbagai industri telah mengalami kemajuan yang signifikan dalam beberapa dekade terakhir (Ramayani, 2023). Kemajuan ini mencakup berbagai sektor, mulai dari manufaktur, logistik, hingga sektor jasa. Di industri manufaktur, misalnya penggunaan robotika dan sistem kontrol otomatis telah meningkatkan efisiensi produksi dan mengurangi kesalahan manusia (Muna & Ismaya, 2023). Di sektor logistik, teknologi otomatisasi seperti sistem manajemen gudang dan kendaraan otonom telah memungkinkan pengiriman yang lebih cepat dan akurat. Selain itu, di sektor jasa, chatbot dan asisten virtual yang didukung oleh kecerdasan buatan telah meningkatkan kualitas layanan pelanggan (Sugiono, 2022). Seiring dengan kemajuan ini, kebutuhan akan sistem otomatis yang lebih cerdas dan adaptif juga meningkat. Sistem-sistem ini diharapkan mampu menyesuaikan diri dengan perubahan kondisi dan permintaan secara real-time, serta mempelajari pola-pola baru melalui teknik pembelajaran mesin.

Reinforcement Learning (RL) adalah salah satu metode pembelajaran mesin yang berfokus pada bagaimana agen harus mengambil tindakan dalam suatu lingkungan untuk memaksimalkan total hadiah yang diperolehnya (Andreas & Kurniawan, 2018). Berbeda dengan supervised learning yang membutuhkan data berlabel untuk pelatihan (Rani et al., 2023), RL tidak memerlukan pasangan input-output eksplisit. Sebaliknya, RL menggunakan mekanisme trial and error, di mana agen belajar dari konsekuensi tindakannya sendiri melalui umpan balik

berbentuk reward atau punishment. Di sisi lain, unsupervised learning tidak menggunakan label dan berfokus pada menemukan pola atau struktur tersembunyi dalam data, seperti clustering atau asosiasi. Sementara supervised learning bekerja dengan data yang terstruktur dengan baik dan berlabel, unsupervised learning mencoba memahami struktur internal data tanpa panduan eksplisit, dan RL berinteraksi dinamis dengan lingkungan untuk belajar secara progresif dari pengalaman. Dengan demikian, RL menawarkan pendekatan unik yang sangat berbeda dari supervised dan unsupervised learning, dengan aplikasi yang luas dalam bidang seperti robotika, permainan, dan sistem rekomendasi.

Penerapan Reinforcement Learning (RL) dalam berbagai sistem otomatis telah menunjukkan potensi besar dalam meningkatkan efisiensi dan efektivitas (Manzl et al., 2023) (Schindler et al., 2023). Misalnya, dalam kendaraan otonom, RL digunakan untuk mengajarkan kendaraan dalam mengambil keputusan secara real-time, seperti navigasi, penghindaran rintangan, dan pengoptimalan rute, yang pada gilirannya meningkatkan keselamatan dan keandalan operasional. Dalam bidang robotika, RL memungkinkan robot untuk belajar tugas-tugas kompleks seperti perakitan komponen, manipulasi objek, dan interaksi manusia-robot, dengan adaptasi yang lebih baik terhadap lingkungan yang dinamis. Pada manajemen jaringan, RL dapat digunakan untuk mengoptimalkan pengalokasian sumber daya, pengendalian lalu lintas data, dan penanganan gangguan, sehingga meningkatkan kinerja dan efisiensi jaringan. Manfaat utama RL dalam konteks ini adalah kemampuannya untuk belajar dan beradaptasi dari pengalaman tanpa memerlukan model lingkungan yang sempurna, memungkinkan sistem untuk beroperasi secara lebih cerdas dan responsif terhadap perubahan kondisi dan tantangan baru.

Menerapkan Reinforcement Learning (RL) menghadapi tantangan teknis seperti efisiensi data yang buruk, biaya komputasi yang tinggi, dan pertukaran eksplorasi-eksploitasi (Mohan et al. 2024). Untuk mengatasi masalah ini, para peneliti telah mengusulkan metode untuk memasukkan informasi struktural ke dalam proses pembelajaran RL, yang bertujuan untuk meningkatkan metrik kinerja dan mengatasi keterbatasan dalam skenario dunia nyata (Basu et al., 2023). Selain itu, kerangka generator data berbasis pembelajaran mesin telah diperkenalkan untuk membantu

peneliti dalam mengeksplorasi sistem fisik secara efisien tanpa memerlukan simulasi komputasi yang ekstensif, sehingga membantu dalam mendapatkan wawasan yang lebih dalam tentang proses yang kompleks (Ahamed, 2023). Selain itu, integrasi RL dengan sistem yang ada dan memastikan keandalan menimbulkan tantangan praktis yang perlu ditangani dengan hati-hati untuk memungkinkan penerapan dan pengoperasian algoritma RL yang mulus di berbagai aplikasi (Manzl et al., 2023).

Studi sebelumnya di bidang Pembelajaran Penguatan (RL) telah mencakup berbagai topik, termasuk formulasi dan pendekatan RL berkelanjutan (Khetarpal et al., 2022), aplikasi RL dalam kontrol sinyal lalu lintas (TSC) untuk peningkatan transportasi perkotaan (Noaen et al., 2022), RL terdistribusi (DRL) untuk menangani masalah skala besar dan kompleks (Useng & Avdulrahman, 2022), RL dalam proses keputusan Markov yang dapat diamati sebagian (POMDP) untuk pengambilan keputusan di lingkungan yang bising (Malekzadeh, 2022), dan aplikasi RL dalam kontrol proses dan pengoptimalan melalui pelatihan berbasis simulasi dan penerapan kebijakan dengan transfer pembelajaran (TL) (Faria et al., 2022). Namun, kesenjangan dalam literatur yang ada telah diidentifikasi, seperti kebutuhan akan peserta didik penguatan tambahan yang lebih baik untuk menangani non-stasionaritas dalam aplikasi realistis, kurangnya interaksi antara praktisi teknik lalu lintas dan peneliti dalam studi RL-NTSC, tantangan dalam skalabilitas dan efisiensi algoritma DRL, keterbatasan dalam menerapkan inferensi aktif ke ruang keadaan dan tindakan berkelanjutan, dan kebutuhan untuk mengintegrasikan RL dengan kontrol proses online secara efektif. Kesenjangan ini memotivasi penelitian lebih lanjut untuk mengatasi tantangan ini dan memajukan bidang RL di berbagai domain.

Pembelajaran Penguatan (RL) mencakup konsep-konsep kunci seperti penghargaan, kebijakan, fungsi nilai, dan model, penting untuk pengambilan keputusan dalam interaksi berurutan (Dhaval et al., 2023). RL telah berhasil diterapkan dalam berbagai sistem otomatis seperti robotika, perutean paket jaringan, dan distribusi energi, memanfaatkan metode seperti RL berbasis nilai, RL berbasis kebijakan, dan pembelajaran penguatan mendalam (Dhaval et al., 2023) (Dhaval et al., 2023). Contoh dunia nyata termasuk mengoptimalkan dosis eritropoietin pada pasien

hemodialisis dan mengotomatiskan rekomendasi pengobatan untuk komplikasi AKI atau CKD dalam nefrologi, menunjukkan potensi RL dalam pengaturan perawatan kesehatan (Dhaval et al., 2023). Algoritma seperti Deep Q Learning (DQN), Proses Keputusan Markov (MDP), dan algoritma aktor-kritik keunggulan asinkron (A3C) telah berperan penting dalam meningkatkan kinerja dan penerapan RL dalam skenario pengambilan keputusan yang kompleks (Zhang, 2023).

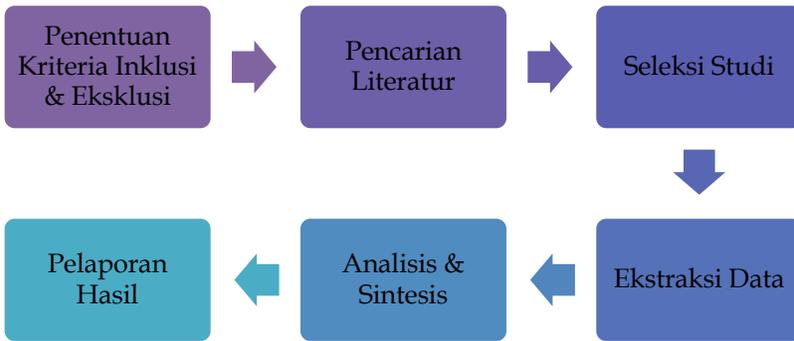
Penelitian sebelumnya tentang Reinforcement Learning (RL) telah mencakup berbagai topik dan aplikasi. Studi-studi ini menunjukkan keberhasilan RL dalam berbagai sistem otomatis yang didalamnya terdapat kesenjangan signifikan dalam literatur yang ada, seperti efisiensi data yang buruk dan biaya komputasi yang tinggi dalam RL yang belum sepenuhnya teratasi, serta kebutuhan akan peserta didik penguatan tambahan yang lebih baik untuk menangani non-stasionaritas dalam aplikasi realistik. Kesenjangan lainnya meliputi kurangnya interaksi antara praktisi teknik lalu lintas dan peneliti dalam studi RL untuk kontrol sinyal lalu lintas, tantangan dalam skalabilitas dan efisiensi algoritma RL terdistribusi, serta keterbatasan dalam menerapkan inferensi aktif ke ruang keadaan dan tindakan berkelanjutan. Penelitian ini bertujuan mengkaji dan menganalisis implementasi dan konsep RL dalam sistem otomatis melalui pendekatan *systematic literature review*, sehingga diharapkan dapat memberikan wawasan mendalam mengenai tantangan dan peluang dalam penerapan RL, serta mengidentifikasi metode dan kerangka kerja yang dapat meningkatkan efisiensi dan efektivitas RL di berbagai domain, dengan fokus pada integrasi RL dengan sistem yang ada dan memastikan keandalan serta kelancaran operasional algoritma RL dalam berbagai aplikasi praktis.

## **B. Metode Penelitian**

Metode penelitian ini menggunakan pendekatan kualitatif dengan pendekatan *systematic literature review* (SLR) untuk mengkaji dan menganalisis implementasi dan konsep Reinforcement Learning (RL) dalam sistem otomatis. Tahapan pelaksanaan penelitian ini dimulai dengan penentuan kriteria inklusi dan eksklusi. Kriteria inklusi meliputi penelitian yang membahas penerapan RL dalam sistem otomatis, studi

yang menjelaskan konsep dan teori dasar RL, serta artikel yang mengulas implementasi RL di berbagai domain seperti robotika, kendaraan otonom, manajemen jaringan, kontrol proses, dan aplikasi kesehatan. Artikel jurnal terkemuka, makalah konferensi terkemuka, laporan penelitian, dan ulasan literatur dari lembaga akademik atau industri yang diakui, serta publikasi dalam bahasa Inggris atau Indonesia dalam 10 tahun terakhir juga termasuk. Kriteria eksklusi mencakup studi yang tidak fokus pada penerapan RL dalam sistem otomatis, artikel teori tanpa aplikasi praktis, penelitian yang menekankan teknik pembelajaran mesin lain selain RL, artikel non-peer-reviewed, blog atau sumber informasi yang tidak divalidasi, penelitian dengan metodologi tidak jelas atau tidak memadai, studi dengan data tidak mencukupi atau hasil tidak meyakinkan, artikel dengan bias signifikan atau konflik kepentingan yang tidak dijelaskan, publikasi dalam bahasa selain Inggris atau Indonesia, dan penelitian lebih dari 10 tahun lalu kecuali referensi seminal.

Pencarian literatur dilakukan melalui Scopus, DOAJ, dan Google Scholar dengan kata kunci "Reinforcement Learning," "Automated Systems," dan "Concepts and Implementations," dengan rentang tahun publikasi antara 2014 dan 2024. Literatur yang dikumpulkan disaring berdasarkan judul dan abstrak, diikuti dengan evaluasi mendalam untuk memastikan relevansi dan kualitas. Dari studi yang terpilih, dilakukan ekstraksi data mencakup metode RL, domain aplikasi, hasil utama, serta tantangan dan solusi yang diidentifikasi. Data dianalisis untuk mengidentifikasi tren, kesenjangan, peluang, dan tantangan dalam penerapan RL di berbagai sistem otomatis. Hasil analisis disusun dalam laporan yang mencakup tinjauan mendalam tentang konsep dan implementasi RL, identifikasi tantangan dan peluang, serta rekomendasi untuk penelitian dan aplikasi di masa depan, seperti terlihat pada Gambar 1.



Gambar 1. Alur pelaksanaan Penelitian

### C. Temuan dan Pembahasan

Setelah melakukan pencarian, kami menemukan beberapa studi yang relevan yang memberikan wawasan penting yang mendukung fokus dan tujuan dari penelitian ini. Informasi yang kami dapatkan dari studi-studi ini memberikan tambahan berharga untuk memperdalam pemahaman tentang topik yang sedang diselidiki. Hasil dari penelitian ini telah kami susun dan disintesis dalam Tabel 1.

Tabel 1. Variabel Riset yang Dibahas dalam artikel

No	Bidang atau Fokus	Nama-nama Penulis	Insight atau Variabel Riset yang Dibahas
1	Robotika	Xu et al. (2023), Takiddin et al. (2021)	Navigasi robot otonom, keamanan, generalisasi, pembelajaran dari data terbatas.
2	Kendaraan Otonom	Sivamayil et al. (2023), Mushtaq et al. (2023), Yan et al. (2023)	Penggunaan Deep Q-Networks (DQN) untuk perencanaan jalur bebas tabrakan, interaksi dengan kendaraan lain di lingkungan dinamis.
3	Manajemen Lalu Lintas	Clemmons & Jin (2023)	Multi-Agent Reinforcement Learning (MARL) untuk mengoptimalkan aliran lalu lintas dan kontrol sinyal.
4	Kedirgantaraan	Manzl et al. (2023)	Optimasi hiperparameter dan arsitektur sistem kontrol kedirgantaraan.

5	Manajemen Energi	Robinette et al. (2022)	Adaptasi RL terhadap lingkungan yang berubah untuk mengoptimalkan penggunaan energi di gedung pintar dan kendaraan hibrida.
6	Perawatan Kesehatan	Sivamayil et al. (2023)	Tantangan dalam ketersediaan data dan adaptasi terhadap perubahan lingkungan dalam aplikasi dosis obat dan rekomendasi pengobatan.
7	Efisiensi dan BiayaKomputasi	Feng et al. (2022), Yang et al. (2023), Axelrod et al. (2022)	Tantangan data yang buruk dan biaya komputasi tinggi dalam implementasi RL, solusi seperti vektorisasi GPU, fusi kernel simulator, dan penggunaan data terbatas untuk pembelajaranprediktif.
8	Inovasi dalam Penggunaan Data	Mohan & Zhang (2024), Ball et al. (2023), Feng et al.(2022)	Penggunaan informasi struktural tambahan, data offline, metode pelatihan hemat data, dan arsitektur RL yang dipisahkan untuk meningkatkan efisiensi dan efektivitas RL.
9	RL dalam Sistem Otomatis yang LebihKompleks	Cipollone et al. (2023), Han & Yu (2023), Tamassia etal. (2017)	Penerapan RL hierarkis dan Deep RL (DRL) untuk mempelajari kebijakan optimal dengan sampel yang lebih sedikit dan meningkatkan kinerja dalam sistem kendaraan dan manajemen sumber daya.
10	Studi Kasus dan Peningkatan Kinerja	Mu et al. (2020), Han& Yu (2023), Tamassia et al. (2017)	Implementasi RL dalam kasus nyata seperti ConFRL untuk penyesuaian otomatis kinerja perangkat lunak dan RL-MRCONF untuk konfigurasi parameter MapReduce.
11	Inovasi Terbaru	Reda &	Penggunaan RL dalam sistem

	dalam RL	Vásárhelyi(2023), Song et al.(2020)	parkir otomatis, otomatisasi proses RL, dan penerapan DRL untuk strategi kontrol kendaraan, menawarkan solusi untuk pengambilan keputusan otomatis.
12	Interaksi antara Peneliti dan Praktisi	Hilger et al. (2018), Bi et al. (2022)	Pengaruh faktor-faktor seperti tekanan untuk aksi dunia nyata dan penggunaan teknik spesifik dalam meningkatkan kinerja algoritma RL dalam aplikasi praktis seperti navigasi kapal.

Tabel 1 di atas menyajikan hasil analisis terkait dengan aplikasi RL dalam berbagai domain atau fokus, mencakup nama-nama penulis yang relevan serta insight atau variabel riset yang dibahas dalam masing-masing studi. Analisis ini menggambarkan keragaman aplikasi RL dan berbagai tantangan serta solusi yang dibahas dalam literatur terkait, secara detail akan dibahas secara rinci pada pembahasan berikut ini.

### **Penerapan Reinforcement Learning dalam berbagai domain sistem otomatis**

Reinforcement Learning (RL) telah menemukan aplikasi yang sukses di berbagai domain utama seperti robotika, kendaraan otonom, dan manajemen lalu lintas. Di ranah robotika, RL telah berperan penting dalam meningkatkan navigasi robot otonom dengan mengatasi tantangan seperti keselamatan, generalisasi, dan pembelajaran dari data yang terbatas (Xu et al., 2023). Kendaraan otonom telah mendapat manfaat dari algoritma RL seperti Deep Q-Networks (DQN) untuk perencanaan jalur bebas tabrakan dan interaksi dengan beberapa kendaraan di lingkungan dinamis (Sivamayil et al., 2023) (Mushtaq et al., 2023). Selain itu, RL telah dimanfaatkan dalam sistem manajemen lalu lintas untuk mengoptimalkan aliran lalu lintas dan kontrol sinyal melalui teknik Multi-Agent Reinforcement Learning (MARL), meningkatkan efisiensi kendaraan otonom di jaringan jalan (Clemmons & Jin, 2023). Aplikasi ini menunjukkan keserbagunaan dan efektivitas RL dalam mengatasi masalah

kompleks di berbagai domain, mulai dari robotika hingga manajemen transportasi.

Aplikasi Reinforcement Learning (RL) bervariasi antar domain karena karakteristik unik yang mempengaruhi efektivitasnya. Dalam domain kedirgantaraan, optimasi hiperparameter dan arsitektur sangat penting untuk sistem kontrol kedirgantaraan, mengingat variabilitas dalam hasil pelatihan (Manzl et al., 2023). Sistem manajemen energi mendapat manfaat dari kemampuan beradaptasi RL terhadap lingkungan yang berubah, mengoptimalkan penggunaan energi di gedung pintar dan kendaraan hibrida (Robinette et al., 2022). Aplikasi perawatan kesehatan dari RL menghadapi tantangan terkait dengan ketersediaan kumpulan data dan adaptasi terhadap perubahan lingkungan, namun menunjukkan harapan dalam dosis obat dan rekomendasi pengobatan (Sivamayil et al., 2023). Algoritma RL secara tradisional mengandalkan fitur buatan tangan, membatasi ruang lingkup aplikasinya, tetapi kemajuan dalam Deep Learning, seperti Deep Q-network (DQN), telah meningkatkan kinerja di lingkungan yang kompleks seperti navigasi otonom dan kontrol produksi (Takiddin et al., 2021). Persyaratan dan tantangan spesifik setiap domain membentuk penerapan dan efektivitas metodologi RL.

Aplikasi Reinforcement Learning (RL) menunjukkan fleksibilitas dan efektivitas dalam mengatasi berbagai masalah kompleks di domain otomatis. Dalam robotika, RL meningkatkan navigasi dan keselamatan robot otonom, sementara pada kendaraan otonom, DQN membantu perencanaan jalur dan interaksi kendaraan dalam situasi lalu lintas dinamis. Manajemen lalu lintas dengan MARL meningkatkan efisiensi jaringan transportasi melalui pengaturan sistem multi-agen seperti sinyal lalu lintas. Di kedirgantaraan, fokus pada optimasi hiperparameter dan arsitektur memastikan sistem yang andal dan presisi tinggi. RL juga meningkatkan efisiensi energi dengan beradaptasi terhadap kondisi lingkungan yang berubah, dan dalam perawatan kesehatan, RL membantu membuat rekomendasi medis yang lebih baik meski menghadapi tantangan data. Namun, tantangan tetap ada: di robotika, masalah generalisasi dan pembelajaran dari data terbatas; pada kendaraan otonom, memastikan keselamatan dan reliabilitas dalam kondisi lalu lintas dinamis; manajemen lalu lintas dengan MARL memerlukan penelitian

lebih lanjut untuk masalah skala dan koordinasi antar agen; dalam kedirgantaraan, variabilitas hasil pelatihan memerlukan optimasi lebih baik; di manajemen energi, pengembangan diperlukan untuk integrasi dengan sistem energi kompleks; dan dalam perawatan kesehatan, kendala utama adalah akses ke data berkualitas serta adaptasi terhadap perubahan lingkungan medis yang cepat.

### **Tantangan utama dalam implementasi Reinforcement Learning dalam sistem otomatis**

Efisiensi data yang buruk dan biaya komputasi yang tinggi memang menimbulkan tantangan yang signifikan terhadap implementasi algoritma Reinforcement Learning (RL), terutama dalam skenario seperti tugas hadiah jarang cakrawala panjang (Feng et al., 2022). Pelatihan agen RL biasanya membutuhkan jutaan sampel data, yang mengarah ke waktu pelatihan yang panjang baik dalam simulasi maupun pengaturan dunia nyata. Untuk mengatasi masalah ini, para peneliti telah mengeksplorasi pengoptimalan seperti vektorisasi GPU dan fusi kernel simulator untuk meningkatkan efisiensi pengumpulan data dan mengurangi biaya komputasi (Yang et al., 2023). Pengoptimalan ini telah menunjukkan hasil yang menjanjikan, dengan vektorisasi GPU mencapai percepatan substansif atas simulator CPU dan fusi kernel simulator yang lebih meningkatkan kinerja, sehingga membuat RL lebih layak untuk aplikasi dunia nyata di mana pengumpulan data mahal dan memakan waktu.

Para peneliti telah mengusulkan berbagai solusi untuk mengatasi tantangan efisiensi data yang buruk dan biaya komputasi yang tinggi dalam menerapkan Reinforcement Learning (RL). Salah satu pendekatan melibatkan pelatihan model prediktif yang diawasi menggunakan kumpulan data terbatas untuk memprediksi hasil simulasi, diikuti dengan melatih agen pembelajaran penguatan untuk menghasilkan data seperti simulasi yang akurat, memungkinkan eksplorasi ruang parameter yang lebih efisien dan wawasan yang lebih dalam ke dalam sistem fisik (Axelrod et al., 2022). Strategi lain melibatkan memasukkan informasi struktural tambahan tentang masalah ke dalam proses pembelajaran RL untuk meningkatkan metrik kinerja seperti efisiensi data, kemampuan generalisasi, jaminan keamanan, dan interpretabilitas, sehingga

meningkatkan efektivitas algoritme RL dalam menangani skenario dunia nyata (Mohan & Zhang, 2024). Selain itu, memanfaatkan data offline dan membuat modifikasi minimal namun penting pada algoritma RL di luar kebijakan yang ada telah terbukti secara signifikan meningkatkan efisiensi sampel dan eksplorasi dalam RL online, yang mengarah pada peningkatan kinerja substansif di berbagai tolok ukur tanpa tambahan overhead komputasi (Ball et al., 2023). Selain itu, metode pelatihan hemat data telah diusulkan, memanfaatkan desain kurikulum untuk mempercepat proses pelatihan dalam skenario simulasi, menunjukkan berbagai tingkat efisiensi data dalam tahap pelatihan yang berbeda (Feng et al., 2022). Terakhir, arsitektur RL yang dipisahkan dinamika dan tugas telah diperkenalkan untuk mengatasi prosedur pembelajaran yang tidak efisien, dengan fokus pada pemodelan tugas tertentu tanpa melibatkan dinamika fisik, sehingga meningkatkan efisiensi dan kemanjuran dalam melatih UAV untuk tugas pencegahan target dinamis (Liu et al., 2023).

Tantangan utama dalam implementasi Reinforcement Learning (RL) dalam sistem otomatis adalah efisiensi data dan biaya komputasi yang tinggi. Agen RL membutuhkan banyak sampel untuk belajar, memakan waktu dan mahal, terutama dalam pengaturan dunia nyata. Biaya komputasi yang tinggi menghambat implementasi praktis karena memerlukan sumber daya komputasi yang signifikan. Pendekatan seperti vektorisasi GPU dan fusi kernel simulator meningkatkan efisiensi pengumpulan data dan mengurangi biaya komputasi dengan memanfaatkan hardware yang lebih efisien. Pelatihan model prediktif yang diawasi dan strategi untuk memasukkan informasi struktural tambahan ke dalam proses pembelajaran RL mengurangi kebutuhan data dan meningkatkan kinerja algoritma. Memanfaatkan data offline dan modifikasi minimal pada algoritma RL yang ada juga membantu meningkatkan efisiensi sampel dan eksplorasi, esensial untuk mengurangi overhead komputasi. Metode pelatihan hemat data dan arsitektur yang memisahkan dinamika dan tugas mempercepat pelatihan dan meningkatkan efisiensi secara keseluruhan. Meskipun solusi ini menjanjikan, mereka menghadapi keterbatasan seperti kebutuhan perangkat keras khusus, pemahaman mendalam tentang domain spesifik,

dan keterbatasan dalam skala dan kompleksitas masalah yang bisa ditangani.

### **Manfaat dan peningkatan yang dihasilkan dari penerapan Reinforcement Learning dalam sistem otomatis**

Reinforcement Learning (RL) secara signifikan meningkatkan efisiensi dan efektivitas sistem otomatis di berbagai domain. Dengan menggunakan RL hierarkis dengan model abstrak yang memandu pembelajaran dalam domain yang lebih kompleks, seperti yang diusulkan dalam makalah penelitian (Cipollone et al., 2023), kebijakan optimal dapat dipelajari dengan sampel yang lebih sedikit, mengatasi keterbatasan utama RL. Selain itu, penerapan pembelajaran penguatan mendalam (DRL) ke sistem kendaraan memungkinkan desain otomatis strategi kontrol, yang mengarah pada peningkatan kinerja dalam beragam skenario lalu lintas (Yan et al., 2023). Selanjutnya, metode pelatihan terdesentralisasi seperti IA2C laten telah terbukti meningkatkan efisiensi sampel dan kecepatan konvergensi dalam pengaturan pembelajaran penguatan multiagen, menjadikannya berharga untuk mengoptimalkan sistem otomatis di lingkungan yang kompetitif atau permusuhan (He, Doshi, 2023). Secara keseluruhan, teknik RL memainkan peran penting dalam meningkatkan efisiensi dan efektivitas sistem otomatis di berbagai domain.

Beberapa studi penelitian telah menunjukkan peningkatan yang signifikan dalam kinerja sistem otomatis melalui implementasi Reinforcement Learning (RL). Misalnya, sebuah studi oleh Han dan Yu memperkenalkan ConFRL, sebuah pendekatan yang memanfaatkan RL untuk secara otomatis menyesuaikan kinerja perangkat lunak, menampilkan kinerja jangka panjang yang lebih tinggi dalam program server dunia nyata (Tamassia et al., 2017). Selain itu, Mu dkk. mengembangkan RL-MRCONF, skema yang secara dinamis mengonfigurasi parameter MapReduce, menghasilkan peningkatan kinerja 50% dibandingkan dengan pengaturan default (Mu et al., 2020). Selanjutnya, Tamassia dkk. mempresentasikan algoritma yang memanfaatkan demonstrasi ahli untuk meningkatkan kinerja agen RL dalam video game seperti Pac-Man, yang mengarah ke peningkatan hasil

kinerja akhir. Studi kasus ini menyoroti efektivitas RL dalam mengoptimalkan kinerja sistem otomatis di berbagai domain.

Manfaat penerapan Reinforcement Learning (RL) dalam sistem otomatis meliputi pengurangan sampel data dengan Hierarchical RL, desain otomatis strategi kontrol oleh DRL pada kendaraan otonom, dan peningkatan efisiensi serta kecepatan konvergensi melalui metode seperti IA2C laten dalam pengaturan multiagen yang dinamis. RL juga mampu mengoptimalkan kinerja perangkat lunak dengan ConFRL dan meningkatkan efisiensi pengolahan data dengan RL-MRCONF. Penggunaan demonstrasi ahli dalam RL juga meningkatkan kinerja agen dalam aplikasi seperti video game. Namun, RL menghadapi tantangan dalam kompleksitas implementasi, kebutuhan akan sumber daya komputasi besar, dan ketergantungan pada kualitas data untuk demonstrasi ahli.

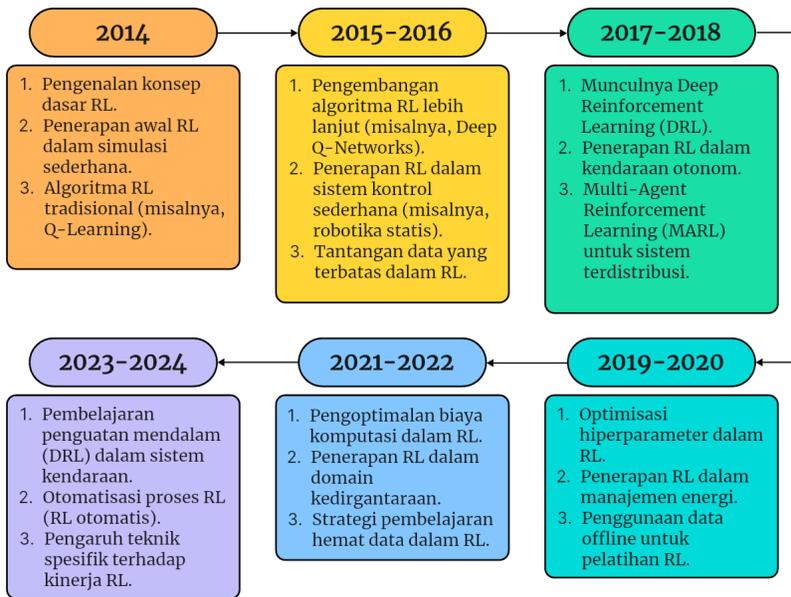
### **Tren dan perkembangan terbaru dalam penelitian dan aplikasi Reinforcement Learning untuk sistem otomatis**

Kemajuan terbaru dalam pembelajaran penguatan (RL) telah menunjukkan efektivitas yang signifikan dalam sistem otomatis. Salah satu inovasi penting adalah penerapan pembelajaran penguatan mendalam (DRL) dalam sistem kendaraan, di mana DRL digunakan untuk merancang strategi kontrol optimal untuk sistem lalu lintas dengan komponen otomatis, menghasilkan peningkatan efisiensi dan mitigasi kemacetan (Yan et al., 2023). Selain itu, metode RL hemat data telah dikembangkan untuk sistem parkir otomatis, menggabungkan teknik berbasis model dengan pencarian pohon Monte Carlo terpotong untuk meningkatkan pembelajaran dari data dan mencapai kinerja yang lebih baik dalam manuver parkir (Reda & Vásárhelyi, 2023). Selanjutnya, otomatisasi proses RL, yang dikenal sebagai RL otomatis, telah mendapatkan perhatian karena secara otomatis mendefinisikan komponen seperti pemodelan MDP, pemilihan algoritma, dan pengoptimalan hiperparameter, membuat RL lebih mudah diakses oleh non-ahli di berbagai bidang (Song et al., 2020). Inovasi-inovasi ini secara kolektif menampilkan lanskap RL yang berkembang dalam sistem otomatis, menawarkan solusi

yang menjanjikan untuk mengoptimalkan strategi kontrol dan proses pengambilan keputusan.

Interaksi antara peneliti dan praktisi memainkan peran penting dalam mempengaruhi pengembangan dan implementasi pembelajaran penguatan (RL) dalam aplikasi dunia nyata. Para peneliti telah mengidentifikasi bahwa peran peneliti di laboratorium dunia nyata (RWL) dipengaruhi oleh faktor-faktor seperti ditekankan untuk melakukan tindakan dunia nyata, memiliki mitra praktik dengan sumber daya yang lebih sedikit, dan bekerja tanpa kelompok proyek fungsional, mengarahkan mereka untuk terlibat dalam kegiatan di luar penelitian konvensional (Hilger et al., 2018). Selain itu, efektivitas RL dalam tugas-tugas seperti menavigasi probe ultrasound menuju tampilan standar kapal telah ditingkatkan melalui kerangka kerja berbasis simulasi, representasi keadaan multi-modalitas, dan pendekatan pengenalan baru, menunjukkan hasil navigasi yang berhasil (Bi et al., 2022). Selanjutnya, pengaruh teknik spesifik seperti inisialisasi, normalisasi input, dan pembelajaran adaptif pada kinerja algoritma RL telah diselidiki, menyoroti pentingnya solusi yang disesuaikan untuk aplikasi RL.

Perkembangan terbaru dalam Reinforcement Learning (RL) menekankan peningkatan efisiensi dan aksesibilitas di berbagai domain sistem otomatis. DRL pada kendaraan mengurangi kemacetan dan meningkatkan efisiensi lalu lintas. Metode RL hemat data meningkatkan kinerja sistem seperti parkir tanpa memerlukan data besar. Auto-RL memudahkan akses RL untuk praktisi, mengurangi kebutuhan akan pengetahuan mendalam. Di bidang medis, RL digunakan untuk meningkatkan akurasi diagnosis. Namun, inovasi RL menghadapi tantangan seperti biaya dan kompleksitas tinggi dalam DRL, keterbatasan data berkualitas dalam RL hemat data, dan kebutuhan akan infrastruktur otomatisasi yang memadai serta penyesuaian untuk aplikasi medis.



**Gambar 2.** Variabel-variabel penelitian yang terkandung dalam studi ini

Tabel 2 menggambarkan evolusi signifikan dalam domain Reinforcement Learning (RL) dari tahun 2013 hingga 2024. Pada awalnya, antara tahun 2013-2014, fokus utama adalah pada pengenalan konsep dasar RL seperti agen, lingkungan, reward, dan kebijakan, serta penerapan awal RL dalam simulasi sederhana dengan menggunakan algoritma tradisional seperti Q-Learning. Kemudian, pada periode 2015-2016, terjadi pengembangan lebih lanjut dengan diperkenalkannya Deep Q-Networks (DQN), yang memungkinkan pembelajaran RL dalam lingkungan yang lebih kompleks, sambil menghadapi tantangan terkait keterbatasan data untuk pelatihan. Lonjakan signifikan terjadi pada periode 2017-2018 dengan munculnya Deep Reinforcement Learning (DRL), di mana arsitektur deep neural network digunakan untuk meningkatkan kinerja RL dalam aplikasi seperti kendaraan otonom, sementara Multi-Agent Reinforcement Learning (MARL) mulai diterapkan untuk mengelola interaksi antara banyak agen dalam sistem terdistribusi. Pada periode 2019-2020, fokus bergeser ke optimisasi hiperparameter untuk meningkatkan efisiensi pelatihan RL dan penerapan RL dalam manajemen energi untuk mengoptimalkan penggunaan sumber daya, dengan penggunaan data

offline yang semakin luas. Penelitian terbaru dari tahun 2021 hingga 2024 menitikberatkan pada pengoptimalan biaya komputasi RL, aplikasi dalam domain kedirgantaraan untuk sistem kontrol penerbangan, dan strategi pembelajaran hemat data untuk mempercepat pelatihan agen RL. Fokus juga diperluas ke pembelajaran penguatan mendalam (DRL) dalam sistem kendaraan dan otomatisasi proses RL untuk memfasilitasi implementasi lebih mudah di berbagai aplikasi, sambil mengeksplorasi pengaruh teknik spesifik seperti inisialisasi dan normalisasi input terhadap kinerja algoritma RL secara keseluruhan.

#### **D. Simpulan**

Berdasarkan tinjauan atas aplikasi terkini Reinforcement Learning (RL) dalam sistem otomatis seperti robotika, kendaraan otonom, manajemen lalu lintas, kedirgantaraan, manajemen energi, dan perawatan kesehatan, dapat disimpulkan bahwa RL telah membawa kontribusi signifikan dalam meningkatkan efisiensi, adaptabilitas, dan kecerdasan sistem tersebut. Namun, implementasi RL juga menghadapi tantangan yang penting, termasuk efisiensi data yang buruk, biaya komputasi yang tinggi, dan ketergantungan pada infrastruktur teknologi yang memadai. Meskipun telah ditemukan berbagai solusi seperti pengoptimalan perangkat keras, metode hemat data, dan penggunaan informasi struktural tambahan, tantangan ini tetap menjadi fokus utama untuk penelitian lanjutan.

Salah satu kesenjangan utama yang dapat diidentifikasi adalah perlunya lebih banyak penelitian untuk mengatasi ketergantungan RL terhadap data yang besar dan kompleksitas komputasi yang tinggi. Meskipun penggunaan vektorisasi GPU dan fusi kernel simulator menjanjikan percepatan signifikan, masih ada ruang untuk peningkatan dalam efisiensi pengumpulan data dan pengolahan komputasi RL. Selain itu, aspek integrasi RL dengan infrastruktur otomatisasi yang lebih luas, seperti dalam Auto-RL, juga perlu diselidiki lebih lanjut untuk memfasilitasi penerapan yang lebih mudah dan skalabilitas di berbagai konteks aplikasi.

Topik riset yang mendesak untuk diteliti di masa mendatang adalah pengembangan teknik RL yang lebih adaptif terhadap sumber daya

terbatas, baik dari segi komputasi maupun data. Penelitian ini dapat mencakup pengembangan algoritma RL yang lebih efisien dalam penggunaan data, strategi baru untuk mengintegrasikan RL dengan infrastruktur komputasi yang ada, serta eksplorasi metode pembelajaran yang lebih adaptif dan responsif terhadap perubahan lingkungan dan kondisi operasional. Dengan demikian, inovasi ini diharapkan dapat mengurangi hambatan implementasi RL, meningkatkan kinerja sistem otomatis, dan memperluas cakupan aplikasi RL di masa depan.

### Daftar Pustaka

- Aditya Mohan, Amy Zhang, M. L. (2024). Structure in Deep Reinforcement Learning: A Survey and Open Problems. *Journal of Artificial Intelligence Research*, 78(2024), 1167–1236. <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://arxiv.org/pdf/2306.16021>
- Andreanus, J., & Kurniawan, A. (2018). Sejarah , Teori Dasar dan Penerapan Reinforcement Learning : Sebuah Tinjauan Pustaka. *Jurnal Telematika*.
- Axelrod, S., Schwalbe-Koda, D., Mohapatra, S., Damewood, J., Greenman, K. P., & Gómez-Bombarelli, R. (2022). Learning Matter: Materials Design with Machine Learning and Atomistic Simulations. *Accounts of Materials Research*. <https://doi.org/10.1021/accountsmr.1c00238>
- Ball, P. J., Smith, L., Kostrikov, I., & Levine, S. (2023). Efficient Online Reinforcement Learning with Offline Data. *Proceedings of Machine Learning Research*.
- Basu, S., Legault, M. A., Romero-Soriano, A., & Precup, D. (2023). On the Challenges of using Reinforcement Learning in Precision Drug Dosing: Delay and Prolongedness of Action Effects. *Proceedings of the 37th AAAI Conference on Artificial Intelligence, AAAI 2023*. <https://doi.org/10.1609/aaai.v37i12.26650>
- Bi, Y., Jiang, Z., Gao, Y., Wendler, T., Karlas, A., & Navab, N. (2022). VesNet-RL: Simulation-Based Reinforcement Learning for Real-World US Probe Navigation. *IEEE Robotics and Automation Letters*. <https://doi.org/10.1109/LRA.2022.3176112>
- Cipollone, R., De Giacomo, G., Favorito, M., Iocchi, L., & Patrizi, F. (2023). Exploiting Multiple Abstractions in Episodic RL via Reward Shaping. *Proceedings of the 37th AAAI Conference on Artificial Intelligence, AAAI 2023*. <https://doi.org/10.1609/aaai.v37i6.25881>
- Clemmons, J., & Jin, Y. F. (2023). Reinforcement Learning-Based Guidance

- of Autonomous Vehicles. *Proceedings - International Symposium on Quality Electronic Design, ISQED*.  
<https://doi.org/10.1109/ISQED57927.2023.10129362>
- Dhaval, S. S., Srihari, C., Vanishree, K., & Rashmi, R. (2023). An extensive review of applications, methods and recent advances in deep reinforcement learning. *HORA 2023 - 2023 5th International Congress on Human-Computer Interaction, Optimization and Robotic Applications, Proceedings*.  
<https://doi.org/10.1109/HORA58378.2023.10156687>
- Faria, R. de R., Capron, B. D. O., Secchi, A. R., & de Souza, M. B. (2022). Where Reinforcement Learning Meets Process Control: Review and Guidelines. In *Processes*. <https://doi.org/10.3390/pr10112311>
- Feng, W., Han, C., Lian, F., & Liu, X. (2022). A Data-Efficient Training Method for Deep Reinforcement Learning. *Electronics (Switzerland)*.  
<https://doi.org/10.3390/electronics11244205>
- Hilger, A., Rose, M., & Wanner, M. (2018). Changing faces-factors influencing the roles of researchers in real-world laboratories. *GAIA - Ecological Perspectives for Science and Society*.  
<https://doi.org/10.14512/gaia.27.1.9>
- Keyang He, Prashant Doshi, B. B. (2023). Latent Interactive A2C for Improved RL in Open Many-Agent Systems. *Cornell University*.  
chrome-extension://efaidnbmninnibpcjpcglclefindmkaj/<https://arxiv.org/pdf/2305.05159>
- Khanna Nailil Muna, & Malika Indah Nur Ismaya. (2023). Strategi Pengendalian Biaya Produksi Pada Operasional Manufaktur Yang Efektif. *Sanskara Manajemen Dan Bisnis*.  
<https://doi.org/10.58812/smb.v1i03.182>
- Khetarpal, K., Riemer, M., Rish, I., & Precup, D. (2022). Towards Continual Reinforcement Learning: A Review and Perspectives. *Journal of Artificial Intelligence Research*. <https://doi.org/10.1613/JAIR.1.13673>
- Liu, D. D., Hu, L., Zhang, Q., Ye, T., Naseem, U., & Lai, Z. Y. (2023). A Dynamics and Task Decoupled Reinforcement Learning Architecture for High-Efficiency Dynamic Target Intercept. *Proceedings of the 37th AAAI Conference on Artificial Intelligence, AAAI 2023*.  
<https://doi.org/10.1609/aaai.v37i10.26421>
- Manzl, P., Rogov, O., Gerstmayr, J., Mikkola, A., & Orzechowski, G. (2023). Reliability evaluation of reinforcement learning methods for mechanical systems with increasing complexity. *Multibody System Dynamics*. <https://doi.org/10.1007/s11044-023-09960-2>
- Mu, T. Y., Al-Fuqaha, A., & Salah, K. (2020). Automating the Configuration

- of MapReduce: A Reinforcement Learning Scheme. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*.  
<https://doi.org/10.1109/TSMC.2019.2951789>
- Mushtaq, A., Haq, I. U., Sarwar, M. A., Khan, A., Khalil, W., & Mughal, M. A. (2023). Multi-Agent Reinforcement Learning for Traffic Flow Management of Autonomous Vehicles. *Sensors*.  
<https://doi.org/10.3390/s23052373>
- Noaen, M., Naik, A., Goodman, L., Crebo, J., Abrar, T., Abad, Z. S. H., Bazzan, A. L. C., & Far, B. (2022). Reinforcement learning in urban network traffic signal control: A systematic literature review. In *Expert Systems with Applications*.  
<https://doi.org/10.1016/j.eswa.2022.116830>
- Parvin Malekzadeh, K. N. P. (2022). Active Inference and Reinforcement Learning: A unified inference on continuous state and action spaces under partial observability. *Cornell University*.  
<https://arxiv.org/abs/2212.07946>
- Ramayani, E. (2023). Robotika dan Automasi dalam Lingkup Teknik Mesin. *Writebox*.
- Rani, V., Nabi, S. T., Kumar, M., Mittal, A., & Kumar, K. (2023). Self-supervised Learning: A Succinct Review. In *Archives of Computational Methods in Engineering*. <https://doi.org/10.1007/s11831-023-09884-2>
- Reda, A., & Vásárhelyi, J. (2023). Design and Implementation of Reinforcement Learning for Automated Driving Compared to Classical MPC Control. *Designs*.  
<https://doi.org/10.3390/designs7010018>
- Robinette, P. K., Heiner, B. K., Ravaoli, U., Hamilton, N., Johnson, T. T., & Hobbs, K. L. (2022). Reinforcement Learning Heuristics for Aerospace Control Systems. *IEEE Aerospace Conference Proceedings*.  
<https://doi.org/10.1109/AERO53065.2022.9843224>
- Sabber Ahamed, M. M. U. (2023). Addressing computational challenges in physical system simulations with machine learning. *Cornell University*. <https://arxiv.org/abs/2305.09627>
- Schindler, S., Uray, M., & Huber, S. (2023). A Mini Review on the utilization of Reinforcement Learning with OPC UA. *IEEE International Conference on Industrial Informatics (INDIN)*.  
<https://doi.org/10.1109/INDIN51400.2023.10218289>
- Sivamayil, K., Rajasekar, E., Aljafari, B., Nikolovski, S., Vairavasundaram, S., & Vairavasundaram, I. (2023). A Systematic Study on Reinforcement Learning Based Applications. In *Energies*.

- <https://doi.org/10.3390/en16031512>
- Song, S., Chen, H., Sun, H., & Liu, M. (2020). Data efficient reinforcement learning for integrated lateral planning and control in automated parking system. *Sensors* (Switzerland). <https://doi.org/10.3390/s20247297>
- Sugiono, S. (2022). Peran Chatbot Dalam Mendukung Smart Service pada Smart Library. *VISI PUSTAKA: Buletin Jaringan Informasi Antar Perpustakaan*. <https://doi.org/10.37014/visipustaka.v23i3.1343>
- Takiddin, A., Elhissi, M., Abuhaliqa, S., & Yang, Y. (2021). Reinforcement Learning Applications in Health Informatics. In *Lecture Notes in Bioengineering*. [https://doi.org/10.1007/978-3-030-67303-1\\_12](https://doi.org/10.1007/978-3-030-67303-1_12)
- Tamassia, M., Zambetta, F., Raffe, W. L., Mueller, F., & Li, X. (2017). Learning Options From Demonstrations: A *Pac-Man* Case Study. *IEEE Transactions on Games*. <https://doi.org/10.1109/tciaig.2017.2658659>
- Useng, M., & Avdulrahman, S. (2022). A Survey on Distributed Reinforcement Learning. *Mesopotamian Journal of Big Data*. <https://doi.org/10.58496/mjbd/2022/006>
- Xu, Z., Liu, B., Xiao, X., Nair, A., & Stone, P. (2023). Benchmarking Reinforcement Learning Techniques for Autonomous Navigation. *Proceedings - IEEE International Conference on Robotics and Automation*. <https://doi.org/10.1109/ICRA48891.2023.10160583>
- Yan, Z., Kreidieh, A. R., Vinitsky, E., Bayen, A. M., & Wu, C. (2023). Unified Automatic Control of Vehicular Systems With Reinforcement Learning. *IEEE Transactions on Automation Science and Engineering*. <https://doi.org/10.1109/TASE.2022.3168621>
- Yang, D., Karimi, H. R., & Pawelczyk, M. (2023). A new intelligent fault diagnosis framework for rotating machinery based on deep transfer reinforcement learning. *Control Engineering Practice*. <https://doi.org/10.1016/j.conengprac.2023.105475>
- Zhang, Z. (2023). Basic things about reinforcement learning. *Applied and Computational Engineering*. <https://doi.org/10.54254/2755-2721/6/20230788>