

Penerapan Reinforcement Learning untuk Penentuan Lokasi Optimal Usaha Minimarket

Nur Idil Fitri Idris^{1,*}, Mashud², Maysaro³, Rosmini⁴

¹ Sistem informasi, Universitas Teknologi Akba Makassar, Makassar, Indonesia

^{2,4} Bisnis Digital, Universitas Teknologi Akba Makassar, Makassar, Indonesia

³ Teknik Informatika, Universitas Teknologi Akba Makassar, Makassar, Indonesia

Email: ^{1,*}nuridilfitriidris@gmail.com, ²mashud@akba.ac.id, ³rosmini.barinong04@gmail.com

Email Penulis Korespondensi: nuridilfitriidris@gmail.com

Abstrak—Penentuan lokasi usaha minimarket merupakan keputusan strategis dalam sektor ritel modern karena dipengaruhi oleh kepadatan penduduk, aksesibilitas, intensitas lalu lintas, jarak terhadap cabang lain, tingkat persaingan, dan potensi pasar. Beberapa penelitian sebelumnya telah menerapkan metode sistem pendukung keputusan seperti *Analytical Hierarchy Process* (AHP), *Geographic Information System* (GIS), *fuzzy logic*, dan *machine learning* untuk membantu pemilihan lokasi usaha. Namun, sebagian besar pendekatan tersebut masih bersifat statis, bergantung pada bobot manual, belum mempertimbangkan mekanisme pembelajaran berbasis *reward*, serta belum secara khusus diterapkan pada kasus penentuan lokasi minimarket yang memiliki karakteristik persaingan ritel, risiko kanibalisasi cabang, dan perubahan kondisi lingkungan bisnis secara dinamis. Berdasarkan kesenjangan tersebut, penelitian ini bertujuan mengembangkan sistem adaptif berbasis *Reinforcement Learning* dengan pendekatan Q-Learning untuk menentukan lokasi optimal usaha minimarket di Kecamatan Tamalanrea. Metode penelitian meliputi pengumpulan data lokasi, pembersihan data, normalisasi data, penentuan bobot kriteria, pembentukan fungsi *reward*, proses pembelajaran Q-Learning, pemeringkatan lokasi, serta validasi hasil terhadap kondisi lapangan. Kontribusi utama penelitian ini adalah merancang model penilaian lokasi minimarket yang adaptif melalui integrasi empat kriteria utama, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor ke dalam fungsi *reward*. Hasil pengujian menunjukkan bahwa lokasi dengan nilai *reward* tertinggi adalah Indomaret Poros BTP sebesar 0,9981, kategori sedang pada Indomaret KM 12 No.16 sebesar 0,9278, dan kategori terendah pada Indomaret Poros Kapassa Raya sebesar 0,1457. Hasil ini menunjukkan bahwa sistem yang dikembangkan mampu memberikan rekomendasi lokasi usaha secara lebih objektif, terukur, adaptif, dan berbasis data untuk mendukung pengambilan keputusan strategis dalam pengembangan minimarket.

Kata Kunci: *Reinforcement Learning*; Q-Learning; Penentuan Lokasi; Minimarket.

Abstract—Determining the location of a minimarket is a strategic decision in the modern retail sector because it is influenced by population density, accessibility, traffic intensity, distance to other branches, level of competition, and market potential. Several previous studies have applied decision support system methods such as Analytical Hierarchy Process (AHP), Geographic Information System (GIS), fuzzy logic, and machine learning to assist in business location selection. However, most of these approaches are still static, rely on manual weighting, do not consider reward-based learning mechanisms, and have not been specifically applied to the case of minimarket location determination which has the characteristics of retail competition, the risk of branch cannibalization, and dynamically changing business environment conditions. Based on these gaps, this study aims to develop an adaptive system based on Reinforcement Learning with a Q-Learning approach to determine the optimal location of a minimarket business in Tamalanrea District. The research methods include location data collection, data cleaning, data normalization, determination of criteria weights, formation of reward functions, the Q-Learning learning process, location ranking, and validation of results against field conditions. The main contribution of this research is to design an adaptive minimarket location assessment model through the integration of four main criteria, namely population density, traffic intensity, distance to other branches, and distance to competitors into the reward function. The test results show that the location with the highest reward value is Indomaret Poros BTP at 0.9981, the medium category is at Indomaret KM 12 No.16 at 0.9278, and the lowest category is at Indomaret Poros Kapassa Raya at 0.1457. These results indicate that the developed system is able to provide business location recommendations that are more objective, measurable, adaptive, and data-based to support strategic decision making in minimarket development.

Keywords: *Reinforcement Learning*; Q-Learning; Location Determination; Minimarket

1. PENDAHULUAN

Perkembangan sektor ritel modern semakin kompetitif, terutama pada wilayah perkotaan yang memiliki mobilitas masyarakat tinggi. Salah satu bentuk usaha ritel yang berkembang pesat adalah minimarket karena mampu menyediakan kebutuhan harian masyarakat secara cepat, mudah dijangkau, dan dekat dengan kawasan permukiman. Dalam konteks bisnis ritel, pemilihan lokasi merupakan keputusan strategis karena berpengaruh terhadap jumlah pelanggan, tingkat penjualan, visibilitas usaha, biaya operasional, serta potensi keuntungan jangka panjang. Lokasi yang berada pada kawasan padat penduduk, memiliki akses jalan yang baik, intensitas lalu lintas tinggi, dan tidak terlalu dekat dengan kompetitor umumnya memiliki peluang bisnis yang lebih besar. Sebaliknya, lokasi yang kurang strategis dapat menyebabkan rendahnya kunjungan pelanggan, tingginya biaya promosi, dan menurunnya daya saing usaha.

Kecamatan Tamalanrea merupakan salah satu wilayah di Kota Makassar yang memiliki karakteristik kawasan berkembang, baik dari sisi pertumbuhan permukiman, aktivitas pendidikan, perdagangan, maupun mobilitas masyarakat. Dinamika kepadatan penduduk, keberadaan jalan utama, pusat aktivitas masyarakat, serta meningkatnya jumlah pelaku usaha ritel menjadikan wilayah ini menarik untuk dikaji dalam konteks penentuan lokasi minimarket. Namun, penentuan lokasi usaha masih sering dilakukan berdasarkan pengalaman pribadi, intuisi, pengamatan lapangan terbatas, atau pertimbangan subjektif. Pendekatan tersebut memiliki kelemahan karena tidak selalu mampu membaca perubahan kondisi

lingkungan secara dinamis. Di sisi lain, pendekatan konvensional seperti analisis statistik sederhana atau pembobotan manual cenderung bersifat statis karena nilai kriteria ditentukan sejak awal dan tidak otomatis menyesuaikan perubahan data lapangan, seperti perubahan arus lalu lintas, pertumbuhan penduduk, pembangunan kawasan baru, dan bertambahnya kompetitor.

Seiring berkembangnya teknologi digital, pemanfaatan data dan kecerdasan buatan atau *Artificial Intelligence* menjadi salah satu pendekatan yang banyak digunakan untuk mendukung pengambilan keputusan secara lebih akurat. Dalam konteks ritel, AI dan *machine learning* digunakan untuk mengolah data, memberikan panduan prediksi, meningkatkan akurasi peramalan, dan membantu sistem merespons kondisi pasar yang berubah [1]. Pendekatan berbasis AI memungkinkan sistem menganalisis berbagai parameter, mengenali pola, serta menghasilkan rekomendasi berdasarkan data yang tersedia. Salah satu metode AI yang relevan untuk masalah penentuan lokasi usaha adalah *Reinforcement Learning* (RL). RL memungkinkan sistem belajar melalui interaksi antara *agent* dan *environment* dengan mekanisme *state*, *action*, *reward*, dan *policy* [2]. RL dapat digunakan untuk meningkatkan akurasi peramalan dan optimasi keputusan dalam rantai pasok ritel, sedangkan RL mampu mengakomodasi variabel yang lebih kompleks dibandingkan pendekatan analitik konvensional [3].

Penelitian terkait pemilihan lokasi ritel dalam lima tahun terakhir menunjukkan adanya pergeseran dari metode konvensional menuju pendekatan berbasis data. *Location Profiling for Retail-Site Recommendation* menggunakan pendekatan *machine learning*. Penelitian tersebut menggunakan beberapa model klasifikasi untuk membangun rekomendasi lokasi ritel berdasarkan profil lokasi. Hasil penelitian menunjukkan bahwa pendekatan *machine learning* mampu mendukung proses rekomendasi lokasi secara lebih terukur. Namun, penelitian tersebut masih berfokus pada klasifikasi dan prediksi berdasarkan data pelatihan, sehingga belum menggunakan mekanisme *reward* untuk memperbarui keputusan secara adaptif [4].

Pemilihan lokasi toko optimal dengan memanfaatkan *check-in data* dan profil pengguna dari *Location-Based Social Network* (LBSN). Penelitian tersebut menghitung pengaruh lokasi toko dalam jaringan jalan dan mengembangkan algoritma percepatan untuk menemukan lokasi toko yang optimal. Hasil penelitian menunjukkan bahwa data LBSN dapat membantu mengidentifikasi lokasi toko yang sesuai dengan perilaku pengguna. Namun, pendekatan tersebut masih memiliki keterbatasan karena bergantung pada data pengguna LBSN dan belum mempertimbangkan mekanisme *state-action-reward* sebagaimana konsep *Reinforcement Learning* [5].

Pendekatan *machine learning* untuk mencari lokasi bisnis yang menguntungkan. Penelitian tersebut menunjukkan bahwa analisis data mampu membantu mengidentifikasi lokasi dengan potensi keuntungan yang lebih baik. Akan tetapi, fokus penelitian tersebut masih berada pada pencarian lokasi bisnis yang menguntungkan secara umum, bukan pada penentuan lokasi minimarket yang memiliki karakteristik khusus seperti risiko kanibalisasi cabang, kedekatan dengan kompetitor, kepadatan penduduk, dan intensitas lalu lintas [6].

Dengan demikian, penelitian tersebut belum sepenuhnya menjawab kebutuhan model pemilihan lokasi minimarket yang adaptif dan spesifik terhadap dinamika ritel harian. Mengembangkan rekomendasi ritel menggunakan *similarity measures* dan pendekatan *machine learning*. Penelitian tersebut bertujuan membantu menemukan lokasi atau bisnis ritel yang sesuai melalui pemanfaatan data geografis, demografis, dan ukuran kemiripan. Hasil penelitian menunjukkan bahwa pendekatan berbasis kemiripan dapat membantu proses rekomendasi ritel. Namun, model tersebut masih berorientasi pada pencocokan karakteristik dan klasifikasi, bukan pada proses pembelajaran keputusan yang memperbarui strategi melalui *reward* [7]. Dengan demikian, pendekatan tersebut belum secara khusus menjawab kebutuhan penentuan lokasi minimarket yang harus mempertimbangkan kepadatan penduduk, arus lalu lintas, jarak ke cabang lain, serta kedekatan dengan kompetitor dalam satu fungsi evaluasi adaptif [8], analisis dan prediksi lokasi toko ritel baru pada kasus Luckin Coffee dan Starbucks di Shanghai dengan menggunakan model *Random Forest*. Penelitian tersebut membagi wilayah studi ke dalam grid $100\text{ m} \times 100\text{ m}$ dan menggunakan model interpretabilitas untuk menganalisis faktor yang memengaruhi pemilihan lokasi. Hasil penelitian menunjukkan bahwa model tersebut mampu memprediksi lokasi toko baru dengan pendekatan berbasis data spasial dan urban commercial space [9]. Namun, penelitian tersebut tetap berorientasi pada prediksi lokasi berdasarkan pola historis dan belum menggunakan mekanisme *state-action-reward* untuk mengevaluasi alternatif lokasi secara adaptif. Selain itu, objek penelitian tersebut adalah kedai kopi, sehingga karakteristiknya berbeda dengan minimarket yang memiliki risiko kanibalisasi cabang dan persaingan ritel harian yang lebih padat. Pengembangan model *Massive Retail Location Choice as a Human Flow-Covering Problem*. Penelitian tersebut memformulasikan pemilihan lokasi ritel sebagai masalah cakupan aliran manusia dengan memanfaatkan data pergerakan individu dalam skala besar. Hasil penelitian menunjukkan bahwa pendekatan berbasis *human flow* dapat meningkatkan kualitas pemilihan lokasi dibandingkan pendekatan tradisional yang sering menyederhanakan pola perjalanan konsumen. Namun, pendekatan tersebut lebih berfokus pada optimasi cakupan aliran manusia dan belum secara khusus mengintegrasikan variabel minimarket seperti jarak ke cabang lain, jarak ke kompetitor, dan fungsi *reward* berbasis Q-Learning [10].

Kajian semi-sistematis mengenai penerapan *Reinforcement Learning* dalam *supply chain management*. Kajian tersebut menunjukkan bahwa RL semakin berkembang untuk menyelesaikan masalah keputusan dinamis dalam rantai pasok, seperti inventori, distribusi, dan perencanaan operasional [11]. Namun, fokus kajian tersebut masih pada rantai pasok secara umum, bukan pada pemilihan lokasi usaha ritel. Dengan demikian, masih terdapat ruang penelitian untuk membawa kemampuan adaptif RL ke dalam sistem pendukung keputusan lokasi minimarket. Penelitian tersebut menunjukkan bahwa RL dapat meningkatkan kinerja pengambilan keputusan pada permasalahan operasional yang

kompleks. Namun, fokus penelitian tersebut masih berada pada manajemen inventori, bukan pada penentuan lokasi ritel. Kesenjangan ini memperkuat kebutuhan untuk menerapkan RL pada konteks lain dalam bisnis ritel, khususnya pemilihan lokasi minimarket yang membutuhkan evaluasi dinamis terhadap potensi pasar dan tekanan persaingan. [10], [12]

Berdasarkan sepuluh penelitian tersebut, dapat disimpulkan bahwa penelitian terbaru dalam rentang 2021–2026 telah memanfaatkan *machine learning*, data spasial, LBSN, *similarity measures*, *Random Forest*, *human flow analysis*, dan *Reinforcement Learning* untuk berbagai masalah ritel dan rantai pasok. Namun, penelitian-penelitian tersebut masih memiliki tiga keterbatasan utama. Pertama, sebagian besar pendekatan pemilihan lokasi masih berfokus pada prediksi, klasifikasi, kemiripan lokasi, atau pemetaan spasial, bukan pada evaluasi keputusan berbasis *reward*. Kedua, penerapan RL dalam ritel masih lebih banyak diarahkan pada rantai pasok, inventori, dan peramalan, bukan pada penentuan lokasi usaha minimarket. Ketiga, belum banyak penelitian yang secara khusus mengintegrasikan kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor dalam fungsi *reward* untuk menentukan lokasi minimarket secara adaptif.

Berdasarkan kesenjangan tersebut, penelitian ini menawarkan pendekatan *Reinforcement Learning* berbasis Q-Learning untuk menentukan lokasi optimal usaha minimarket di Kecamatan Tamalanrea. Model yang dikembangkan menilai setiap alternatif lokasi melalui fungsi *reward* yang mengintegrasikan empat kriteria utama, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Kontribusi penelitian ini adalah menyediakan model penilaian lokasi minimarket yang lebih objektif, terukur, dan adaptif dibandingkan pendekatan konvensional maupun prediktif murni. Dengan demikian, penelitian ini diharapkan dapat mendukung pengambilan keputusan strategis dalam pengembangan usaha minimarket berbasis data.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Metodologi penelitian ini dirancang untuk membangun sistem adaptif dalam menentukan lokasi optimal usaha minimarket di Kecamatan Tamalanrea menggunakan metode *Reinforcement Learning*. Penelitian ini dilakukan melalui beberapa tahapan utama, yaitu pengumpulan data, normalisasi data, penentuan bobot kriteria, pembentukan fungsi *reward*, proses evaluasi dan pembelajaran, penentuan kebijakan optimal, serta validasi hasil terhadap kondisi lapangan. Tahapan tersebut disusun secara sistematis agar model yang dikembangkan mampu menghasilkan rekomendasi lokasi usaha yang objektif, adaptif, dan relevan dengan dinamika lingkungan ritel modern. Data penelitian diperoleh melalui observasi lapangan dan sumber daring yang relevan, seperti data kepadatan penduduk, kondisi lalu lintas, jarak terhadap cabang minimarket lain, serta jarak terhadap kompetitor. Data tersebut digunakan sebagai dasar dalam membangun lingkungan sistem atau *environment* pada model *Reinforcement Learning*. Setiap alternatif lokasi diperlakukan sebagai kandidat tindakan atau *action* yang akan dievaluasi oleh sistem berdasarkan nilai *reward* tertentu. Dengan demikian, sistem tidak hanya menilai lokasi berdasarkan satu aspek, tetapi mempertimbangkan beberapa faktor penting secara terintegrasi.

Secara umum, alur penelitian dimulai dari tahap pengumpulan data. Pada tahap ini, data diperoleh dari pengamatan langsung di Kecamatan Tamalanrea dan sumber digital pendukung. Data yang dikumpulkan meliputi kepadatan penduduk, intensitas lalu lintas, jarak ke cabang minimarket lain, dan jarak ke kompetitor. Keempat kriteria ini dipilih karena memiliki pengaruh langsung terhadap potensi keberhasilan usaha minimarket. Kepadatan penduduk menunjukkan potensi jumlah konsumen, intensitas lalu lintas menggambarkan tingkat keramaian dan aksesibilitas lokasi, jarak ke cabang lain digunakan untuk menghindari kanibalisasi pasar, sedangkan jarak ke kompetitor menunjukkan tingkat persaingan usaha. Setelah data terkumpul, tahap berikutnya adalah normalisasi data. Normalisasi dilakukan karena setiap variabel memiliki satuan dan skala nilai yang berbeda. Misalnya, kepadatan penduduk dapat dinyatakan dalam jumlah jiwa per wilayah, intensitas lalu lintas dapat dinilai berdasarkan tingkat keramaian, sedangkan jarak lokasi dinyatakan dalam satuan meter atau kilometer. Apabila data dengan skala berbeda langsung digunakan dalam perhitungan, maka hasil analisis dapat menjadi tidak seimbang. Oleh karena itu, normalisasi diperlukan agar semua data berada pada rentang nilai yang seragam dan dapat dibandingkan secara proporsional.

Tahap selanjutnya adalah penentuan bobot kriteria. Bobot diberikan untuk menunjukkan tingkat kepentingan masing-masing faktor dalam menentukan kelayakan lokasi usaha minimarket. Faktor yang memiliki pengaruh lebih besar terhadap keberhasilan usaha diberikan bobot yang lebih tinggi, sedangkan faktor pendukung diberikan bobot yang lebih rendah. Bobot total dari seluruh kriteria disusun agar bernilai satu sehingga dapat digunakan dalam perhitungan fungsi *reward*. Proses ini penting karena kualitas rekomendasi sistem sangat dipengaruhi oleh ketepatan pemilihan kriteria dan bobot yang digunakan. Setelah bobot kriteria ditentukan, sistem melakukan evaluasi menggunakan metode *Reinforcement Learning*. Pada tahap ini, agen atau *agent* mengevaluasi setiap alternatif lokasi sebagai tindakan yang mungkin dipilih. Setiap tindakan menghasilkan nilai *reward* berdasarkan kesesuaian lokasi terhadap kriteria yang telah ditentukan. Lokasi dengan kombinasi nilai terbaik akan memperoleh *reward* lebih tinggi, sedangkan lokasi dengan kondisi kurang sesuai akan memperoleh *reward* lebih rendah. Proses evaluasi dilakukan secara berulang sehingga sistem dapat belajar dari setiap hasil penilaian dan memperbaiki strategi pemilihan lokasi.

Tahapan akhir dari proses ini adalah penentuan kebijakan optimal atau *optimal policy*. *Optimal policy* merupakan keputusan terbaik yang dihasilkan oleh sistem berdasarkan nilai *reward* tertinggi. Dalam konteks penelitian ini, lokasi

dengan nilai *reward* tertinggi direkomendasikan sebagai lokasi yang paling potensial untuk pengembangan usaha minimarket. Hasil rekomendasi tersebut kemudian dibandingkan dengan kondisi lapangan untuk memastikan bahwa keluaran sistem sesuai dengan situasi nyata. Alur tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Metode *Reinforcement Learning* dalam Penentuan Lokasi Usaha Minimarket

Gambar 1 menunjukkan bahwa proses penelitian terdiri atas beberapa tahapan yang saling berhubungan, mulai dari pengumpulan data hingga penentuan kebijakan optimal. Faktor pemilihan lokasi yang digunakan dalam penelitian meliputi kepadatan penduduk, keramaian lalu lintas, jarak dengan cabang lain, dan jarak dengan kompetitor. Keempat faktor tersebut menjadi dasar dalam proses pembentukan nilai *reward* pada model *Reinforcement Learning*. Dengan alur tersebut, sistem diharapkan mampu menghasilkan rekomendasi lokasi usaha yang lebih terukur dibandingkan pendekatan konvensional.

2.2 Kriteria Penentuan Lokasi

Kriteria penentuan lokasi dalam penelitian ini ditetapkan berdasarkan faktor-faktor yang berpengaruh terhadap keberhasilan usaha minimarket. Kriteria tersebut digunakan sebagai variabel utama dalam membentuk *state* pada model *Reinforcement Learning*. Setiap kriteria memiliki karakteristik dan arah penilaian yang berbeda. Kriteria kepadatan penduduk dan intensitas lalu lintas bersifat positif, artinya semakin tinggi nilainya maka semakin baik potensi lokasi tersebut. Sebaliknya, jarak ke cabang lain dan jarak ke kompetitor perlu dianalisis secara lebih hati-hati karena lokasi yang terlalu dekat dengan cabang sendiri dapat menimbulkan kanibalisasi pasar, sedangkan lokasi yang terlalu dekat dengan kompetitor dapat meningkatkan tekanan persaingan. Kriteria yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Kriteria Penentuan Lokasi Usaha Minimarket

No	Kriteria	Indikator Penilaian	Arah Penilaian
1	Kepadatan penduduk	Jumlah penduduk di sekitar lokasi potensial	Semakin tinggi semakin baik
2	Intensitas lalu lintas	Tingkat keramaian kendaraan dan aktivitas masyarakat	Semakin ramai semakin baik
3	Jarak ke cabang lain	Kedekatan lokasi dengan cabang minimarket yang sudah ada	Terlalu dekat berisiko kanibalisasi pasar
4	Jarak ke kompetitor	Kedekatan lokasi dengan usaha ritel sejenis	Terlalu dekat meningkatkan persaingan

Berdasarkan Tabel 1, setiap kriteria memiliki peran penting dalam proses penentuan lokasi. Kepadatan penduduk digunakan untuk mengukur potensi pasar, sedangkan intensitas lalu lintas digunakan untuk melihat tingkat aksesibilitas dan visibilitas lokasi. Jarak ke cabang lain digunakan untuk memastikan agar lokasi baru tidak mengganggu pasar cabang yang sudah ada. Sementara itu, jarak ke kompetitor digunakan untuk menilai tingkat persaingan pada wilayah tertentu. Kombinasi seluruh kriteria tersebut menjadi dasar dalam pembentukan fungsi *reward* pada model *Reinforcement Learning*.

2.3 Pembentukan Model *Reinforcement Learning*

Pembentukan model *Reinforcement Learning* pada penelitian ini dilakukan untuk menghasilkan sistem yang mampu belajar dari kondisi lingkungan dan memberikan rekomendasi lokasi secara adaptif. Model ini dirancang berdasarkan interaksi antara *agent* dan *environment*. *Agent* berperan sebagai sistem pengambil keputusan, sedangkan *environment* merepresentasikan kondisi lokasi usaha di Kecamatan Tamalanrea. Setiap alternatif lokasi diperlakukan sebagai tindakan

atau *action* yang dapat dipilih oleh *agent*. Setelah tindakan dipilih, sistem akan memberikan nilai *reward* berdasarkan kualitas lokasi tersebut. Secara konseptual, model *Reinforcement Learning* dalam penelitian ini terdiri atas empat komponen utama, yaitu *state*, *action*, *reward*, dan *policy*. *State* menggambarkan kondisi lingkungan berdasarkan nilai kriteria lokasi. *Action* merupakan keputusan untuk memilih salah satu lokasi potensial. *Reward* adalah nilai umpan balik yang diberikan kepada sistem setelah memilih suatu lokasi. Sementara itu, *policy* merupakan strategi yang digunakan oleh sistem untuk memilih tindakan terbaik berdasarkan nilai *reward* yang diperoleh. Hubungan antara komponen tersebut membentuk proses pembelajaran yang berulang hingga sistem menemukan keputusan yang paling optimal.

Model *Reinforcement Learning* yang digunakan dalam penelitian ini mengacu pada pendekatan *Q-Learning*. *Q-Learning* merupakan salah satu algoritma *model-free Reinforcement Learning* yang tidak memerlukan pemodelan lingkungan secara eksplisit. Algoritma ini mempelajari nilai kualitas dari pasangan *state* dan *action* melalui proses pembaruan nilai secara iteratif. Nilai tersebut kemudian digunakan untuk menentukan tindakan terbaik pada kondisi tertentu. Persamaan pembaruan nilai *Q* dapat dituliskan sebagai berikut:

$$Q(s, a) = Q(s, a) + \alpha [r + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (1)$$

Persamaan tersebut digunakan untuk memperbarui nilai keputusan pada setiap pasangan kondisi dan tindakan dalam proses pembelajaran *Reinforcement Learning*. Simbol $Q(s, a)$ menunjukkan nilai kualitas keputusan ketika sistem berada pada suatu kondisi atau *state* tertentu, yaitu s , dan memilih suatu tindakan atau *action*, yaitu a . Nilai α merupakan *learning rate* yang berfungsi untuk menentukan seberapa besar pengaruh informasi baru terhadap nilai Q sebelumnya. Nilai r menunjukkan *reward* atau imbalan yang diterima sistem setelah memilih suatu tindakan, sedangkan γ merupakan *discount factor* yang digunakan untuk mempertimbangkan nilai keuntungan pada kondisi berikutnya. Selanjutnya, s' menunjukkan kondisi baru setelah suatu tindakan dilakukan, dan a' menunjukkan tindakan berikutnya yang mungkin dipilih pada kondisi tersebut. Melalui persamaan ini, sistem dapat memperbarui nilai keputusan secara bertahap berdasarkan pengalaman sebelumnya, sehingga lokasi yang menghasilkan nilai *reward* lebih tinggi akan cenderung diprioritaskan sebagai rekomendasi lokasi usaha minimarket yang lebih optimal.

2.4 Fungsi *Reward* dan Proses Pembelajaran

Fungsi *reward* merupakan bagian penting dalam model *Reinforcement Learning* karena menjadi dasar bagi sistem untuk menilai kualitas setiap lokasi. Dalam penelitian ini, nilai *reward* dihitung berdasarkan hasil normalisasi dan pembobotan dari seluruh kriteria lokasi. Setiap kriteria diberikan nilai sesuai tingkat kontribusinya terhadap kelayakan lokasi. Lokasi dengan kepadatan penduduk tinggi, intensitas lalu lintas tinggi, jarak ideal dari cabang lain, dan tingkat persaingan yang terkendali akan memperoleh nilai *reward* yang lebih tinggi. Secara sederhana, fungsi *reward* dapat dirumuskan sebagai berikut:

$$[R = (w_1x_1) + (w_2x_2) + (w_3x_3) + (w_4x_4)]. \quad (2)$$

Persamaan tersebut digunakan untuk menghitung nilai kelayakan setiap alternatif lokasi minimarket berdasarkan kombinasi beberapa kriteria yang telah ditentukan. Simbol R menunjukkan nilai *reward* atau skor akhir kelayakan lokasi. Simbol w_1 , w_2 , w_3 , dan w_4 menunjukkan bobot dari masing-masing kriteria, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Sementara itu, simbol x_1 , x_2 , x_3 , dan x_4 menunjukkan nilai hasil normalisasi dari setiap kriteria tersebut. Nilai *reward* diperoleh dengan mengalikan setiap bobot kriteria dengan nilai normalisasinya, kemudian menjumlahkan seluruh hasil perkalian tersebut. Semakin tinggi nilai *reward* yang diperoleh suatu lokasi, maka semakin besar tingkat kelayakan lokasi tersebut untuk direkomendasikan sebagai lokasi usaha minimarket. Sebaliknya, nilai *reward* yang rendah menunjukkan bahwa lokasi tersebut memiliki kelemahan pada satu atau beberapa kriteria, sehingga kurang direkomendasikan oleh sistem.

2.5 Arsitektur Sistem *Reinforcement Learning*

Berikut pada Gambar 2 menunjukkan mekanisme pembelajaran pada model *Reinforcement Learning*. Sistem bekerja dengan cara mengevaluasi setiap kandidat lokasi melalui proses interaksi antara *agent* dan *environment*. *Agent* memilih tindakan berdasarkan kondisi yang tersedia, kemudian memperoleh nilai *reward* dari lingkungan. Nilai *reward* tersebut digunakan untuk memperbaiki kebijakan atau *policy* sehingga keputusan yang dihasilkan menjadi semakin optimal. Dalam konteks penelitian ini, kebijakan optimal merupakan rekomendasi lokasi minimarket dengan nilai *reward* tertinggi.

	Lokasi	Skor_RL
0	Indomaret POROS BTP	0.998119
1	Indomaret BTP BLOK A24-A25	0.991582
2	Indomaret Poros BTP 2	0.990685
3	Indomaret BTP BLOK C	0.988717
4	Indomaret Bumi Tamalanrea Permai 4	0.951651
5	Indomaret Bumi Tamalanrea Permai	0.951542
6	Indomaret Perintis Kemerdekaan 11	0.947448
7	Indomaret SPBU Perintis Kemerdekaan	0.947339
8	Indomaret KM 12 NO. 16	0.927879
9	Indomaret SPBU Perintis Kemerdekaan K.9	0.799082
10	Indomaret Perintis Kemerdekaan K.7	0.774069
11	Indomaret Perintis Kemerdekaan 8	0.773958
12	Indomaret Bung NO.13	0.764806
13	Indomaret Kemerdekaan 4	0.755820
14	Indomaret IDF BTN Wesabbe	0.729795
15	Indomaret Biring romang	0.695626
16	Indomaret Perintis Kemerdekaan 9	0.692958
17	Indomaret BTN Hamzi	0.691875
18	Indomaret Nusa Tamalanrea Indah	0.551433
19	Indomaret IDF IR Sutami	0.464015
20	Indomaret Kapasa Baru NO 51B	0.432251
21	Indomaret Akasia 26-27	0.365088
22	Indomaret Exit Tol Bira	0.312255
23	Indomaret Talassa City	0.234914
24	Indomaret Poros Kapassa Raya	0.145744

Gambar 2. Arsitektur *Reinforcement Learning*

Arsitektur sistem dalam penelitian ini menggambarkan hubungan antara *agent*, *environment*, *action*, *reward*, dan *policy*. *Agent* menerima informasi dari lingkungan berupa data lokasi, kemudian memilih tindakan dalam bentuk pemilihan alternatif lokasi. Setelah tindakan dilakukan, lingkungan memberikan nilai *reward* sebagai umpan balik. Nilai tersebut digunakan oleh *agent* untuk memperbarui strategi pemilihan lokasi. Proses ini berlangsung secara berulang hingga diperoleh kebijakan terbaik. Arsitektur konseptual model dapat dilihat pada Gambar 2.

2.6 Evaluasi dan Validasi Model

Evaluasi model dilakukan dengan membandingkan nilai *reward* dari setiap lokasi yang menjadi kandidat. Lokasi dengan nilai *reward* tertinggi dinyatakan sebagai lokasi yang paling direkomendasikan oleh sistem. Namun, hasil perhitungan sistem tetap perlu divalidasi dengan kondisi lapangan agar rekomendasi yang dihasilkan tidak hanya unggul secara matematis, tetapi juga sesuai dengan keadaan nyata. Validasi dilakukan dengan memperhatikan kondisi akses jalan, tingkat keramaian, keberadaan permukiman, dan konsentrasi kompetitor di sekitar lokasi. Evaluasi juga dilakukan untuk melihat kemampuan sistem dalam menghasilkan rekomendasi yang adaptif. Sistem dianggap baik apabila mampu memberikan nilai lokasi secara objektif berdasarkan data yang tersedia. Selain itu, sistem juga harus mampu menyesuaikan hasil rekomendasi apabila terjadi perubahan data, misalnya peningkatan jumlah penduduk, perubahan arus lalu lintas, munculnya cabang baru, atau bertambahnya kompetitor. Dengan demikian, metode *Reinforcement Learning* tidak hanya digunakan sebagai alat perhitungan, tetapi juga sebagai pendekatan pembelajaran yang dapat meningkatkan kualitas rekomendasi secara berkelanjutan.

Melalui tahapan metodologi ini, penelitian diharapkan mampu menghasilkan sistem pendukung keputusan yang lebih cerdas dalam menentukan lokasi usaha minimarket. Sistem yang dikembangkan tidak hanya bergantung pada intuisi atau penilaian subjektif, tetapi memanfaatkan data, kriteria terukur, dan mekanisme pembelajaran adaptif. Dengan penerapan metode *Reinforcement Learning*, rekomendasi lokasi usaha dapat dibuat lebih akurat, responsif, dan sesuai dengan kebutuhan pengambilan keputusan pada sektor ritel modern.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Implementasi Sistem

Hasil implementasi penelitian ini menunjukkan bahwa metode *Reinforcement Learning* dapat digunakan untuk membangun sistem adaptif dalam menentukan lokasi usaha minimarket di Kecamatan Tamalanrea. Sistem yang dikembangkan bekerja dengan cara mengolah data lokasi berdasarkan empat kriteria utama, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Keempat kriteria tersebut digunakan sebagai dasar dalam proses normalisasi, pembobotan, perhitungan nilai *reward*, serta penentuan rekomendasi lokasi terbaik. Implementasi dilakukan menggunakan Google Colab karena platform ini mendukung pemrosesan data berbasis *cloud*, integrasi dengan Google Drive, serta penggunaan pustaka Python yang relevan untuk analisis data dan pembelajaran mesin. Data dan alur hasil implementasi yang digunakan dalam bagian ini berasal dari tahapan sistem yang telah disiapkan pada naskah penelitian.

Tahap awal implementasi dilakukan dengan menghubungkan Google Drive ke lingkungan kerja Google Colab. Proses ini diperlukan agar dataset yang tersimpan di Google Drive dapat diakses secara langsung tanpa harus mengunggah file secara manual setiap kali proses komputasi dijalankan. Perintah yang digunakan adalah `drive.mount('/content/drive', force_remount=True)`. Parameter `force_remount=True` berfungsi untuk memastikan Google Drive dipasang ulang apabila sebelumnya sudah pernah terhubung. Tahapan ini penting karena dataset menjadi komponen utama dalam proses pembentukan *environment* pada model *Reinforcement Learning*.

```
# 1. Mount Google Drive (jika sudah terpasang sebelumnya, bisa abaikan)
from google.colab import drive
drive.mount('/content/drive', force_remount=True)
```

Gambar 3. Mount Google Drive

Gambar 3 menunjukkan proses pemasangan Google Drive pada Google Colab. Setelah proses ini berhasil dilakukan, sistem dapat membaca dataset dari folder penyimpanan yang telah ditentukan. Dengan cara ini, proses pengolahan data menjadi lebih efisien dan terstruktur. Selain itu, penyimpanan hasil analisis juga dapat dilakukan kembali ke Google Drive sehingga hasil penelitian terdokumentasi dengan baik dan dapat digunakan untuk proses evaluasi lanjutan.

Tahap berikutnya adalah melakukan impor pustaka atau *library* yang dibutuhkan dalam proses pengolahan data. Pustaka yang digunakan meliputi *pandas*, *numpy*, *random*, *re*, dan *MinMaxScaler* dari *sklearn.preprocessing*. Pustaka *pandas* digunakan untuk membaca dan mengelola dataset dalam bentuk *DataFrame*. Pustaka *numpy* digunakan untuk mendukung komputasi numerik. Pustaka *random* digunakan untuk mendukung proses simulasi yang membutuhkan pemilihan nilai secara acak. Pustaka *re* digunakan untuk membersihkan data berbasis ekspresi reguler, sedangkan *MinMaxScaler* digunakan untuk melakukan normalisasi nilai data ke dalam rentang 0 sampai 1.

```
# 2. Import library
import pandas as pd
import numpy as np
import random
import re
from sklearn.preprocessing import MinMaxScaler
```

Gambar 4. Import Library

Gambar 4 memperlihatkan pustaka utama yang digunakan dalam implementasi sistem. Keberadaan pustaka tersebut menunjukkan bahwa proses penelitian tidak hanya berfokus pada perhitungan manual, tetapi juga memanfaatkan komputasi berbasis Python. Penggunaan pustaka Python menjadi penting karena data lokasi memiliki karakteristik yang beragam, baik dalam bentuk angka, teks, maupun nilai yang perlu dibersihkan sebelum digunakan dalam proses pembelajaran. Oleh karena itu, tahapan impor pustaka menjadi bagian awal yang menentukan kelancaran proses implementasi berikutnya.

Setelah pustaka berhasil diimpor, tahap selanjutnya adalah membaca dataset menggunakan fungsi *pd.read_csv()*. Dataset yang digunakan berisi daftar lokasi minimarket beserta atribut atau parameter yang berkaitan dengan kriteria penentuan lokasi. Setiap baris data merepresentasikan satu alternatif lokasi, sedangkan setiap kolom merepresentasikan variabel yang digunakan dalam proses penilaian. Dalam konteks *Reinforcement Learning*, dataset ini berfungsi sebagai *environment*, yaitu lingkungan yang menyediakan informasi bagi sistem untuk mengevaluasi setiap alternatif lokasi.

```
# 3. Load dataset (lewati 1 baris atas, gunakan delimiter ; )
path = '/content/drive/MyDrive/Dataset/datasettes.csv'
df = pd.read_csv(path, delimiter=';', skiprows=1)
```

Gambar 5. Load Dataset

Gambar 5 menunjukkan proses pembacaan dataset ke dalam sistem. Setelah dataset berhasil dimuat, sistem dapat melakukan pemeriksaan awal terhadap struktur data, jumlah kolom, jumlah baris, serta tipe data pada setiap variabel. Tahap ini penting untuk memastikan bahwa dataset yang digunakan sudah sesuai dengan kebutuhan analisis. Apabila ditemukan data yang tidak konsisten, seperti karakter non-numerik pada kolom angka, maka data perlu dibersihkan sebelum masuk ke tahap normalisasi dan perhitungan *reward*.

Keberhasilan impor pustaka menunjukkan bahwa sistem telah memiliki komponen perangkat lunak yang diperlukan untuk menjalankan tahapan penelitian. Dengan adanya pustaka tersebut, data lokasi minimarket dapat dibaca, dibersihkan, dinormalisasi, dihitung nilai *reward*-nya, dan diurutkan berdasarkan tingkat kelayakan lokasi. Tahap ini juga memperlihatkan bahwa penelitian tidak dilakukan secara manual, tetapi menggunakan pendekatan komputasi berbasis Python sehingga hasil yang diperoleh lebih konsisten, terukur, dan dapat direplikasi. Hal ini penting dalam penelitian berbasis kecerdasan buatan karena seluruh proses penilaian lokasi harus memiliki alur yang jelas, mulai dari pembacaan data hingga keluaran rekomendasi.

Berdasarkan hasil implementasi awal tersebut, sistem telah berhasil melewati dua tahap penting, yaitu akses dataset dan persiapan lingkungan komputasi. Kedua tahap ini menjadi fondasi dalam penerapan metode *Reinforcement Learning*. Setelah dataset dapat dibaca dan pustaka berhasil diimpor, sistem dapat dilanjutkan ke tahap pembersihan data, normalisasi kriteria, pembentukan fungsi *reward*, serta pemeringkatan lokasi minimarket. Dengan demikian, hasil yang

terlihat pada tahap implementasi awal menunjukkan bahwa sistem telah siap digunakan untuk melakukan analisis kelayakan lokasi secara adaptif berdasarkan data yang tersedia.

3.1.1 Hasil Pengolahan Data dan Normalisasi

Setelah dataset berhasil diakses melalui Google Drive dan pustaka pendukung berhasil diimpor, tahap selanjutnya adalah membaca dataset lokasi minimarket menggunakan fungsi `pd.read_csv()`. Hasil dari proses ini adalah data lokasi minimarket dapat ditampilkan dalam bentuk *DataFrame*, sehingga setiap baris mewakili satu alternatif lokasi dan setiap kolom mewakili atribut yang digunakan dalam penilaian. Atribut yang dianalisis meliputi kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Dengan terbentuknya *DataFrame*, sistem dapat memeriksa struktur data, tipe data, jumlah lokasi, serta kelengkapan nilai pada setiap kriteria.

Tahap pembersihan data dilakukan untuk memastikan bahwa seluruh nilai yang digunakan dalam perhitungan dapat diproses secara numerik. Pada dataset lokasi minimarket, beberapa nilai dapat mengandung karakter tambahan, seperti satuan jarak, simbol, tanda baca, atau teks lain yang tidak dapat langsung digunakan dalam perhitungan matematis. Oleh karena itu, fungsi `clean_angka()` digunakan untuk menghapus karakter non-numerik dan mengubah data menjadi format angka. Proses ini penting karena kesalahan format data dapat memengaruhi hasil normalisasi, pembobotan, dan perhitungan nilai *reward*.

```
# 5. Bersihkan dan ubah data ke numerik
def clean_angka(val):
    if isinstance(val, str):
        val = val.lower().replace('jiwa', '').replace('m', '').replace(',', '').replace('km', '')
        val = re.sub(r'^\d.', '', val) # hapus karakter selain angka dan titik
    try:
        return float(val)
    except:
        return np.nan

df['Kepadatan_Penduduk'] = df['Kepadatan_Penduduk'].apply(clean_angka)
df['Keramaian_LaluLintas'] = df['Keramaian_LaluLintas'].apply(clean_angka)
df['Jarak_Cabang'] = df['Jarak_Cabang'].apply(clean_angka)
df['Jarak_Kompetitor'] = df['Jarak_Kompetitor'].apply(clean_angka)
```

Gambar 6. Data ke Numerik

Gambar 6 menunjukkan proses konversi data ke bentuk numerik. Tahapan ini memastikan bahwa seluruh kriteria, seperti kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor, dapat digunakan dalam proses analisis. Tanpa proses konversi ini, sistem tidak dapat menghitung nilai *reward* secara konsisten. Selain itu, pembersihan data juga membantu mengurangi risiko kesalahan akibat perbedaan format penulisan pada dataset.

Setelah data dibersihkan, proses berikutnya adalah normalisasi menggunakan `MinMaxScaler()`. Normalisasi dilakukan untuk menyamakan skala nilai dari setiap kriteria. Hal ini diperlukan karena masing-masing variabel memiliki satuan dan rentang nilai yang berbeda. Misalnya, kepadatan penduduk dapat memiliki nilai yang jauh lebih besar dibandingkan jarak ke kompetitor. Apabila data tidak dinormalisasi, variabel dengan nilai besar dapat mendominasi hasil perhitungan, meskipun belum tentu menjadi faktor yang paling penting dalam penentuan lokasi.

```
# 6. Normalisasi data
scaler = MinMaxScaler()
fit_cols = ['Kepadatan_Penduduk', 'Keramaian_LaluLintas', 'Jarak_Cabang', 'Jarak_Kompetitor']
df_norm = df.copy()
df_norm[fit_cols] = scaler.fit_transform(df[fit_cols])
```

Gambar 7. Normalisasi Data

Gambar 7 menunjukkan proses normalisasi data ke dalam rentang 0 sampai 1. Dengan normalisasi ini, setiap kriteria memiliki peluang kontribusi yang seimbang sesuai bobot yang telah ditentukan. Normalisasi juga membantu model *Reinforcement Learning* dalam membaca pola data secara lebih stabil. Nilai yang telah dinormalisasi kemudian digunakan sebagai input dalam fungsi *reward*. Dengan demikian, sistem dapat membandingkan setiap alternatif lokasi secara lebih objektif dan proporsional.

Setelah data dibersihkan, sistem melakukan normalisasi menggunakan metode Min-Max. Hasil normalisasi menunjukkan bahwa seluruh nilai kriteria telah berada pada rentang 0 sampai 1. Normalisasi ini membuat setiap kriteria memiliki skala yang sebanding, sehingga kriteria dengan nilai asli yang besar tidak mendominasi proses perhitungan. Sebagai contoh, kepadatan penduduk dapat memiliki nilai angka yang jauh lebih besar dibandingkan jarak ke kompetitor. Tanpa normalisasi, nilai kepadatan penduduk dapat terlalu memengaruhi hasil akhir. Melalui normalisasi, seluruh kriteria dapat dihitung secara lebih proporsional dalam fungsi *reward*.

3.1.2 Hasil Perhitungan Nilai Reward

Berdasarkan hasil pengujian, lokasi dengan nilai *reward* tertinggi adalah Indomaret Poros BTP dengan nilai 0,9981. Nilai ini menunjukkan bahwa lokasi tersebut memiliki tingkat kelayakan yang sangat tinggi berdasarkan kriteria yang digunakan. Lokasi ini dinilai memiliki potensi pasar yang kuat karena didukung oleh kondisi lingkungan yang lebih sesuai dengan karakteristik usaha minimarket. Nilai *reward* yang mendekati 1 menunjukkan bahwa lokasi tersebut sangat dekat dengan kondisi ideal yang diharapkan oleh sistem. Lokasi dengan kategori sedang adalah Indomaret KM 12 No.16 dengan nilai *reward* sebesar 0,9278. Nilai ini masih tergolong tinggi, tetapi lebih rendah dibandingkan Indomaret Poros BTP. Hal ini menunjukkan bahwa lokasi tersebut tetap potensial, namun terdapat beberapa faktor yang belum sepenuhnya optimal. Faktor tersebut dapat berupa intensitas lalu lintas, jarak terhadap cabang lain, atau kedekatan dengan kompetitor. Dengan demikian, lokasi ini masih dapat dipertimbangkan sebagai alternatif, tetapi bukan sebagai prioritas utama.

Sementara itu, lokasi dengan nilai *reward* terendah adalah Indomaret Poros Kapassa Raya dengan nilai 0,1457. Nilai ini menunjukkan bahwa lokasi tersebut kurang direkomendasikan oleh sistem. Rendahnya nilai *reward* dapat disebabkan oleh kombinasi beberapa faktor, seperti kepadatan penduduk yang rendah, intensitas lalu lintas yang kurang mendukung, jarak yang kurang ideal terhadap cabang lain, atau tingkat persaingan yang tinggi. Hasil ini membuktikan bahwa sistem mampu membedakan tingkat kelayakan lokasi berdasarkan data dan kriteria yang telah ditentukan.

3.2 Hasil Pengujian Lokasi Minimarket

Hasil pengujian menunjukkan bahwa sistem mampu memberikan nilai *reward* yang berbeda pada setiap lokasi berdasarkan kriteria yang digunakan. Perbedaan nilai ini menunjukkan bahwa setiap lokasi memiliki tingkat kelayakan yang berbeda. Lokasi dengan nilai *reward* tinggi dianggap lebih potensial untuk dijadikan lokasi usaha minimarket, sedangkan lokasi dengan nilai *reward* rendah dinilai kurang optimal. Berdasarkan hasil pengujian, lokasi dengan kategori tertinggi adalah Indomaret Poros BTP dengan nilai *reward* sebesar 0,9981. Nilai ini menunjukkan bahwa lokasi tersebut memiliki karakteristik yang sangat baik berdasarkan kriteria yang digunakan. Lokasi ini dinilai memiliki potensi pasar yang besar karena didukung oleh kepadatan penduduk, tingkat lalu lintas yang cukup tinggi, serta posisi yang relatif strategis. Nilai *reward* yang mendekati 1 menunjukkan bahwa lokasi tersebut sangat sesuai dengan kondisi ideal yang diharapkan oleh sistem.

Lokasi dengan kategori sedang adalah Indomaret KM 12 No.16 dengan nilai *reward* sebesar 0,9278. Nilai ini masih tergolong tinggi, tetapi lebih rendah dibandingkan lokasi Poros BTP. Hal ini menunjukkan bahwa lokasi tersebut tetap potensial, namun terdapat beberapa faktor yang mungkin sedikit menurunkan tingkat kelayakannya. Faktor tersebut dapat berupa jarak ke cabang lain, jarak ke kompetitor, atau intensitas lalu lintas yang tidak seoptimal lokasi dengan nilai tertinggi. Sementara itu, lokasi dengan kategori terendah adalah Indomaret Poros Kapassa Raya dengan nilai *reward* sebesar 0,1457. Nilai ini menunjukkan bahwa lokasi tersebut kurang direkomendasikan oleh sistem. Rendahnya nilai *reward* dapat disebabkan oleh kombinasi beberapa faktor, seperti rendahnya kepadatan penduduk, kurangnya intensitas lalu lintas, jarak yang kurang ideal terhadap cabang lain, atau tingkat persaingan yang tinggi dengan kompetitor. Hasil ini menunjukkan bahwa sistem mampu membedakan lokasi berdasarkan tingkat kelayakan secara objektif.

Tabel 1. Hasil Pengujian Nilai Reward Lokasi Minimarket

No	Lokasi Minimarket	Nilai Reward	Kategori
1	Indomaret Poros BTP	0,9981	Tinggi
2	Indomaret KM 12 No.16	0,9278	Sedang
3	Indomaret Poros Kapassa Raya	0,1457	Rendah

Tabel 1, dapat diketahui bahwa sistem memberikan rekomendasi paling kuat pada lokasi Indomaret Poros BTP. Nilai *reward* yang tinggi menunjukkan bahwa lokasi tersebut memenuhi sebagian besar kriteria yang dianggap penting dalam penentuan lokasi usaha minimarket. Sementara itu, Indomaret KM 12 No.16 tetap dapat dipertimbangkan sebagai lokasi alternatif karena memiliki nilai *reward* yang cukup tinggi. Adapun Indomaret Poros Kapassa Raya kurang direkomendasikan karena nilai *reward* yang diperoleh relatif rendah.

Berdasarkan seluruh tahapan implementasi, penelitian ini menghasilkan sistem yang mampu mengolah data lokasi minimarket, melakukan normalisasi kriteria, menghitung nilai *reward*, dan menyusun rekomendasi lokasi berdasarkan tingkat kelayakan. Hasil penelitian menunjukkan bahwa metode *Reinforcement Learning* berbasis Q-Learning dapat digunakan sebagai pendekatan adaptif dalam mendukung pengambilan keputusan lokasi usaha minimarket. Sistem tidak hanya menghasilkan skor akhir, tetapi juga memberikan dasar penilaian yang lebih objektif karena setiap lokasi dievaluasi berdasarkan kombinasi beberapa kriteria penting. Secara umum, hasil penelitian memperlihatkan bahwa Indomaret Poros BTP menjadi lokasi paling direkomendasikan, Indomaret KM 12 No.16 menjadi lokasi alternatif dengan kategori sedang, dan Indomaret Poros Kapassa Raya menjadi lokasi yang kurang direkomendasikan. Temuan ini menunjukkan bahwa sistem yang dikembangkan mampu memberikan rekomendasi lokasi secara lebih terukur dibandingkan pendekatan manual atau subjektif. Dengan demikian, hasil penelitian ini dapat menjadi dasar bagi pelaku usaha ritel dalam menentukan lokasi ekspansi minimarket secara lebih rasional, adaptif, dan berbasis data.

3.3 Perbandingan Hasil Penelitian dengan Penelitian Terdahulu

Hasil penelitian ini menunjukkan bahwa penerapan *Reinforcement Learning* berbasis Q-Learning mampu menghasilkan rekomendasi lokasi minimarket secara lebih adaptif dibandingkan beberapa pendekatan yang telah digunakan pada penelitian terdahulu. Dalam penelitian ini, sistem menghasilkan nilai *reward* tertinggi sebesar 0,9981 pada lokasi Indomaret Poros BTP, nilai 0,9278 pada Indomaret KM 12 No.16, dan nilai terendah sebesar 0,1457 pada Indomaret Poros Kapassa Raya. Hasil tersebut menunjukkan bahwa sistem mampu membedakan tingkat kelayakan lokasi berdasarkan kombinasi empat kriteria utama, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Perbedaan nilai *reward* antar lokasi memperlihatkan bahwa model tidak hanya memberikan hasil berupa peringkat lokasi, tetapi juga menunjukkan seberapa kuat tingkat kelayakan masing-masing lokasi berdasarkan kondisi data yang dianalisis. Jika dibandingkan dengan penelitian yang menggunakan kombinasi *Geographic Information System* dan *Analytical Hierarchy Process* dalam pemilihan lokasi ritel, penelitian ini memiliki perbedaan utama pada mekanisme pengambilan keputusan. Penelitian tersebut unggul dalam memetakan kondisi spasial dan membantu pengambil keputusan melihat hubungan lokasi dengan lingkungan sekitarnya. Namun, pendekatan GIS-AHP masih cenderung bersifat statis karena bobot kriteria ditentukan di awal dan tidak diperbarui secara otomatis ketika terjadi perubahan kondisi lingkungan. Sementara itu, penelitian ini menggunakan nilai *reward* sebagai mekanisme evaluasi sehingga setiap lokasi dapat dinilai berdasarkan kombinasi kriteria yang telah dinormalisasi. Dengan demikian, hasil penelitian ini lebih menekankan kemampuan sistem dalam memberikan rekomendasi yang adaptif, bukan hanya pemetaan dan pembobotan lokasi.[13]

Dibandingkan dengan penelitian yang menerapkan AHP untuk mengevaluasi elemen pemilihan lokasi toko ritel, hasil penelitian ini juga menunjukkan keunggulan pada aspek objektivitas penilaian. AHP memang mampu menyusun prioritas kriteria secara sistematis, tetapi hasil akhirnya sangat bergantung pada pendapat pakar atau responden dalam memberikan bobot. Apabila bobot diberikan oleh penilai yang berbeda, maka hasil rekomendasi lokasi juga dapat berubah. Berbeda dengan hal tersebut, penelitian ini menggunakan pendekatan Q-Learning yang menempatkan nilai *reward* sebagai dasar penilaian lokasi. Dengan cara ini, sistem dapat mengevaluasi lokasi berdasarkan data yang tersedia, bukan semata-mata berdasarkan penilaian subjektif. Hasil berupa nilai *reward* pada setiap lokasi menunjukkan bahwa sistem mampu memberikan ukuran kelayakan yang lebih terukur dan konsisten. [14]

Penelitian yang menggunakan strategi kompetisi spasial dan *double-channel convolutional neural network* menunjukkan bahwa pendekatan *deep learning* dapat membantu meningkatkan proses seleksi lokasi ritel. Penelitian tersebut kuat dalam mengenali pola spasial dan pola kompetisi berdasarkan data yang kompleks. Namun, model *deep learning* pada umumnya lebih berorientasi pada prediksi berdasarkan pola data, bukan pada pembelajaran keputusan melalui interaksi dengan lingkungan. Penelitian ini berbeda karena menggunakan *Reinforcement Learning*, yaitu sistem belajar melalui hubungan antara *state*, *action*, *reward*, dan *policy*. Oleh karena itu, hasil penelitian ini tidak hanya menunjukkan lokasi mana yang potensial, tetapi juga memberikan dasar mengapa lokasi tersebut memperoleh nilai kelayakan tertentu melalui perhitungan *reward*. [15] [16]

Penelitian pendekatan *machine learning* untuk rekomendasi lokasi ritel, penelitian ini memiliki keunggulan pada aspek pembelajaran adaptif. Penelitian berbasis *machine learning* umumnya mengandalkan data pelatihan untuk membentuk model prediksi atau klasifikasi. Pendekatan tersebut dapat menghasilkan rekomendasi yang baik apabila pola data pelatihan masih relevan dengan kondisi terbaru. Namun, dalam konteks penentuan lokasi minimarket, kondisi lingkungan dapat berubah akibat pertumbuhan penduduk, perubahan intensitas lalu lintas, munculnya kompetitor baru, atau pembukaan cabang baru. Penelitian ini menjawab keterbatasan tersebut dengan membangun fungsi *reward* yang dapat digunakan untuk menilai ulang setiap alternatif lokasi ketika data diperbarui. Dengan demikian, hasil penelitian ini lebih sesuai untuk lingkungan ritel yang dinamis.[3]

Selanjutnya, jika dibandingkan dengan penelitian yang menggunakan *machine learning* untuk mencari lokasi bisnis yang menguntungkan, penelitian ini memiliki fokus yang lebih spesifik pada karakteristik minimarket. Penelitian Han et al. lebih menekankan pada pencarian lokasi yang berpotensi menguntungkan secara umum, sedangkan penelitian ini secara khusus mempertimbangkan faktor yang sangat relevan dengan usaha minimarket, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Hasil penelitian ini menunjukkan bahwa lokasi dengan nilai *reward* tinggi bukan hanya lokasi yang ramai, tetapi juga lokasi yang memiliki keseimbangan antara potensi pasar, aksesibilitas, risiko kanibalasi cabang, dan tekanan kompetitor. Hal ini menjadi pembeda penting karena pemilihan lokasi minimarket tidak cukup hanya melihat potensi keuntungan, tetapi juga harus memperhatikan distribusi cabang dan tingkat persaingan di sekitar lokasi.[17], [18]

Berdasarkan perbandingan tersebut, dapat dijelaskan bahwa hasil penelitian ini memberikan kontribusi yang berbeda dari penelitian terdahulu. Penelitian sebelumnya banyak menggunakan pendekatan GIS, AHP, *deep learning*, dan *machine learning* untuk memetakan, membobotkan, atau memprediksi lokasi potensial. Namun, sebagian besar pendekatan tersebut belum secara eksplisit menggunakan mekanisme *reward* untuk mengevaluasi kualitas keputusan secara adaptif. Hasil penelitian ini menunjukkan bahwa *Reinforcement Learning* berbasis Q-Learning mampu menghasilkan rekomendasi lokasi yang lebih terukur melalui nilai *reward*. Nilai *reward* tertinggi pada Indomaret Poros BTP sebesar 0,9981 menunjukkan bahwa lokasi tersebut paling sesuai dengan kriteria yang digunakan, sedangkan nilai *reward* rendah pada Indomaret Poros Kapassa Raya sebesar 0,1457 menunjukkan bahwa lokasi tersebut kurang layak untuk diprioritaskan. Dengan demikian, penelitian ini memperkuat bahwa pendekatan berbasis *reward* dapat menjadi

alternatif yang lebih adaptif dalam sistem pendukung keputusan lokasi usaha minimarket dibandingkan metode konvensional maupun prediktif murni.

3.4 Pembahasan

Hasil penelitian ini menunjukkan bahwa metode *Reinforcement Learning* berbasis Q-Learning mampu memberikan rekomendasi lokasi minimarket secara lebih adaptif dan terukur dibandingkan beberapa pendekatan yang digunakan dalam penelitian terdahulu. Hasil pengujian menunjukkan bahwa Indomaret Poros BTP memperoleh nilai *reward* tertinggi sebesar 0,9981, Indomaret KM 12 No.16 memperoleh nilai *reward* sebesar 0,9278, sedangkan Indomaret Poros Kapassa Raya memperoleh nilai *reward* terendah sebesar 0,1457. Perbedaan nilai tersebut menunjukkan bahwa sistem mampu membedakan tingkat kelayakan setiap lokasi berdasarkan kombinasi kriteria kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Temuan ini memperlihatkan bahwa model yang dikembangkan tidak hanya menghasilkan urutan rekomendasi lokasi, tetapi juga memberikan ukuran kuantitatif mengenai seberapa layak suatu lokasi untuk diprioritaskan sebagai lokasi usaha minimarket. Penggunaan kombinasi *Geographic Information System* dan *Analytical Hierarchy Process* dalam pemilihan lokasi ritel, hasil penelitian ini memiliki keunggulan pada aspek adaptasi keputusan. Pendekatan GIS-AHP mampu memetakan lokasi dan menyusun prioritas kriteria secara spasial, tetapi proses penilaiannya masih bergantung pada bobot yang ditentukan sejak awal. Dalam kondisi lingkungan ritel yang dinamis, seperti perubahan kepadatan penduduk, perubahan arus lalu lintas, dan bertambahnya kompetitor, pendekatan statis tersebut memiliki keterbatasan. Berbeda dengan penelitian tersebut, penelitian ini menggunakan nilai *reward* sebagai dasar evaluasi, sehingga setiap lokasi dapat dinilai berdasarkan kombinasi data yang telah dinormalisasi dan dapat dikembangkan untuk diperbarui ketika data lingkungan berubah. [19][20]

Menerapkan AHP dalam evaluasi pemilihan lokasi toko ritel, penelitian ini memberikan hasil yang lebih objektif karena tidak sepenuhnya bergantung pada penilaian subjektif pakar. AHP memang mampu menyusun prioritas kriteria secara sistematis, tetapi perubahan bobot dari responden atau pengambil keputusan dapat menghasilkan rekomendasi yang berbeda. Pada penelitian ini, penentuan lokasi dilakukan melalui perhitungan *reward* berbasis data, sehingga hasil rekomendasi lebih konsisten dan terukur. Nilai *reward* yang diperoleh setiap lokasi menunjukkan bahwa sistem mampu memberikan dasar penilaian yang lebih jelas dibandingkan sekadar hasil prioritas berbasis bobot manual. [13] Penggunaan *double-channel convolutional neural network* untuk meningkatkan seleksi lokasi ritel berdasarkan strategi kompetisi spasial, penelitian ini memiliki perbedaan pada mekanisme pengambilan keputusan. Pendekatan *deep learning* dapat mengenali pola spasial yang kompleks, tetapi umumnya berfokus pada prediksi berdasarkan pola data. Penelitian ini tidak hanya memprediksi lokasi potensial, tetapi juga mengevaluasi setiap alternatif melalui konsep *state*, *action*, *reward*, dan *policy*. [21]

Dengan demikian, hasil penelitian ini lebih menekankan pada proses pembelajaran keputusan yang dapat diarahkan untuk menyesuaikan rekomendasi berdasarkan umpan balik nilai *reward*. [22] yang Jika dibandingkan menggunakan pendekatan *machine learning* untuk rekomendasi lokasi ritel dan pencarian lokasi bisnis yang menguntungkan, hasil penelitian ini memiliki fokus yang lebih spesifik pada karakteristik minimarket. Penelitian berbasis *machine learning* umumnya membentuk model prediksi berdasarkan data pelatihan, tetapi belum secara eksplisit menggunakan mekanisme *reward* untuk memperbarui kualitas keputusan. Dalam penelitian ini, lokasi dinilai dengan mempertimbangkan tidak hanya potensi pasar, tetapi juga risiko kanibalisasi cabang dan tekanan persaingan dari kompetitor. Oleh karena itu, hasil penelitian ini lebih sesuai untuk kasus minimarket yang memiliki persaingan lokasi sangat ketat dan membutuhkan keputusan ekspansi yang lebih hati-hati. [5], [17]

Berdasarkan perbandingan tersebut, dapat ditegaskan bahwa hasil penelitian ini memperkuat keunggulan *Reinforcement Learning* sebagai pendekatan adaptif dalam sistem pendukung keputusan lokasi usaha. Penelitian terdahulu umumnya masih menekankan pemetaan spasial, pembobotan kriteria, klasifikasi, atau prediksi lokasi potensial. Sementara itu, penelitian ini menghasilkan model yang menilai kelayakan lokasi melalui nilai *reward*, sehingga setiap alternatif lokasi dapat dibandingkan secara kuantitatif dan lebih objektif. Dengan nilai *reward* tertinggi sebesar 0,9981 pada Indomaret Poros BTP, penelitian ini menunjukkan bahwa sistem mampu mengidentifikasi lokasi yang paling mendekati kondisi ideal. Sebaliknya, nilai *reward* terendah sebesar 0,1457 pada Indomaret Poros Kapassa Raya menunjukkan bahwa sistem juga mampu mengidentifikasi lokasi yang kurang layak untuk diprioritaskan. Dengan demikian, penelitian ini memberikan kontribusi yang lebih kuat dibandingkan pendekatan terdahulu karena mampu menggabungkan evaluasi berbasis data, pembelajaran adaptif, dan konteks khusus usaha minimarket dalam satu model keputusan.

4. KESIMPULAN

Berdasarkan hasil perancangan, implementasi, dan pengujian yang telah dilakukan, penelitian ini menyimpulkan bahwa metode *Reinforcement Learning* berbasis Q-Learning dapat digunakan sebagai pendekatan adaptif dalam menentukan lokasi optimal usaha minimarket. Sistem yang dikembangkan mampu menilai setiap alternatif lokasi berdasarkan empat kriteria utama, yaitu kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor. Keempat kriteria tersebut diolah melalui proses normalisasi dan perhitungan nilai *reward*, sehingga setiap lokasi memperoleh skor kelayakan yang dapat digunakan sebagai dasar pemeringkatan. Hasil pengujian menunjukkan bahwa Indomaret Poros BTP memperoleh nilai *reward* tertinggi sebesar 0,9981 dan menjadi lokasi yang paling direkomendasikan, Indomaret

KM 12 No.16 memperoleh nilai 0,9278 sebagai lokasi alternatif, sedangkan Indomaret Poros Kapassa Raya memperoleh nilai terendah sebesar 0,1457 sehingga kurang direkomendasikan. Kontribusi utama penelitian ini terletak pada pengembangan model penentuan lokasi minimarket yang lebih adaptif dibandingkan pendekatan konvensional seperti AHP, GIS, *fuzzy logic*, maupun *machine learning* klasifikasi. Penelitian terdahulu umumnya masih bersifat statis, bergantung pada bobot manual, atau hanya berfokus pada prediksi berdasarkan data historis. Berbeda dengan pendekatan tersebut, penelitian ini menerapkan mekanisme *reward* pada *Reinforcement Learning* berbasis Q-Learning untuk mengevaluasi setiap alternatif lokasi secara lebih objektif dan terukur. Dengan mekanisme ini, sistem tidak hanya menghasilkan urutan lokasi terbaik, tetapi juga memberikan ukuran kuantitatif mengenai tingkat kelayakan setiap lokasi berdasarkan kondisi lingkungan yang dianalisis. Secara teoretis, penelitian ini memberikan kontribusi pada pengembangan sistem pendukung keputusan berbasis kecerdasan buatan, khususnya penerapan *Reinforcement Learning* dalam konteks pemilihan lokasi usaha ritel. Penelitian ini menunjukkan bahwa konsep *state*, *action*, *reward*, dan *policy* dapat diterapkan pada permasalahan bisnis, bukan hanya pada bidang permainan, robotika, atau sistem kontrol. Dengan mengintegrasikan kriteria kepadatan penduduk, intensitas lalu lintas, jarak ke cabang lain, dan jarak ke kompetitor, penelitian ini memperluas pemanfaatan Q-Learning untuk menghasilkan rekomendasi lokasi minimarket yang lebih sesuai dengan dinamika lingkungan bisnis. Secara praktis, kontribusi penelitian ini adalah menyediakan model rekomendasi yang dapat membantu pelaku usaha ritel dalam menentukan lokasi ekspansi minimarket secara lebih rasional, objektif, dan berbasis data. Sistem ini dapat digunakan untuk mengurangi ketergantungan pada intuisi atau pengalaman subjektif dalam pemilihan lokasi. Selain itu, model yang dikembangkan dapat dijadikan dasar untuk pengembangan aplikasi berbasis dashboard, integrasi dengan *Geographic Information System*, serta pemanfaatan data lalu lintas dan kepadatan penduduk secara berkala. Dengan demikian, penelitian ini tidak hanya menghasilkan rekomendasi lokasi terbaik di Kecamatan Tamalanrea, tetapi juga memberikan dasar pengembangan sistem pendukung keputusan ritel yang adaptif, terukur, dan berkelanjutan.

REFERENCES

- [1] C.-Y. Ting and M. Y. Jie, "Location Profiling for Retail-Site Recommendation Using Machine Learning Approach," in *Proceedings of the International Conference on Computer, Information Technology and Intelligent Computing (CITIC 2022)*, Dordrecht: Atlantis Press International BV, 2022, pp. 48–67. doi: 10.2991/978-94-6463-094-7_5.
- [2] A. Bhattacharjee *et al.*, "Optimizing Retail Recommendation via Similarity Measures and Machine Learning Approach," *JOIV : International Journal on Informatics Visualization*, vol. 8, no. 3, p. 1192, Sep. 2024, doi: 10.62527/joiv.8.3.2360.
- [3] Z. Zare, M. Ashrafzadeh, and M. Karatas, "A Hybrid Fuzzy AHP and TOPSIS Approach for Warehouse Location Selection," *Computer and Decision Making: An International Journal*, vol. 2, pp. 613–632, May 2025, doi: 10.59543/comdem.v2i.14239.
- [4] C.-Y. Ting and M. Y. Jie, "Location Profiling for Retail-Site Recommendation Using Machine Learning Approach," in *Proceedings of the International Conference on Computer, Information Technology and Intelligent Computing (CITIC 2022)*, Dordrecht: Atlantis Press International BV, 2022, pp. 48–67. doi: 10.2991/978-94-6463-094-7_5.
- [5] L. Morallista and A. Rueda, "Deep learning for retail market segmentation," *Comput. Ind. Eng.*, vol. 183, pp. 109–125, 2023, doi: 10.1016/j.cie.2023.109125.
- [6] L. Ezquerro, R. Coimbra, B. Bauluz, C. Núñez-Lahuerta, T. Román-Berdiel, and M. Moreno-Azanza, "Large dinosaur egg accumulations and their significance for understanding nesting behaviour," *Geoscience Frontiers*, vol. 15, no. 5, Sep. 2024, doi: 10.1016/j.gsf.2024.101872.
- [7] Z. Zhao, G. Chen, J. Duan, and Y. Xu, "Site Selection Analysis and Prediction of New Retail Stores from an Urban Commercial Space Perspective: A Case Study of Luckin Coffee and Starbucks in Shanghai," *ISPRS Int. J. Geoinf.*, vol. 14, no. 6, p. 217, May 2025, doi: 10.3390/ijgi14060217.
- [8] Y.-H. Lin, Y.-C. Chen, S.-M. Chiu, C. Lee, and F.-C. Wang, "Applying Check-in Data and User Profiles to Identify Optimal Store Locations in a Road Network," *ISPRS Int. J. Geoinf.*, vol. 11, no. 5, p. 314, May 2022, doi: 10.3390/ijgi11050314.
- [9] H. N. Saputra and A. Fajriani, "Development of augmented reality-assisted health education posters on Covid-19," *Qanun Medika - Medical Journal Faculty of Medicine Muhammadiyah Surabaya*, vol. 5, no. 2, pp. 239–250, Jul. 2021, doi: 10.30651/jqm.v5i2.7378.
- [10] A. Basuki and F. Hidayat, "Analisis faktor penentu lokasi bisnis menggunakan metode AHP," *Jurnal Ilmiah Informatika*, vol. 7, no. 2, pp. 120–130, 2020.
- [11] S. Han, X. Jia, X. Chen, S. Gupta, A. Kumar, and Z. Lin, "Search well and be wise: A machine learning approach to search for a profitable location," *J. Bus. Res.*, vol. 144, pp. 416–427, May 2022, doi: 10.1016/j.jbusres.2022.01.049.



- [12] M. R. A. C. E. P. First Wanita, “Rancang Bangun Sistem Informasi Pengendalian Persediaan (Control Buffer Stock) Untuk Efisiensi Kewirausahaan Penjualan Kopi Pada Soft Coffee,” 2021. Accessed: Jun. 08, 2026. [Online]. Available: tiulm.ti.ft.ulm.ac.id/index.php/jtiulm/article/view/70
- [13] M. Z. Iskandar, “Machine learning-based decision support for retail business,” *Indonesian Journal of Information Systems*, vol. 5, no. 2, pp. 78–86, 2020.
- [14] B. Rolf, I. Jackson, M. Müller, S. Lang, T. Reggelin, and D. Ivanov, “A review on reinforcement learning algorithms and applications in supply chain management,” *Int. J. Prod. Res.*, vol. 61, no. 20, pp. 7151–7179, Oct. 2023, doi: 10.1080/00207543.2022.2140221.
- [15] M. Akalin, G. Turhan, and A. Sahin, “The Application of AHP Approach for Evaluating Location Selection Elements for Retail Store,” *International Journal of Research in Business and Social Science (2147- 4478)*, vol. 2, no. 4, pp. 01–20, Oct. 2013, doi: 10.20525/ijrbs.v2i4.77.
- [16] A. Bhattacharjee, “Optimizing Retail Recommendation via Similarity Measures and Machine Learning Approach,” *JOIV: International Journal on Informatics Visualization*, vol. 8, no. 3, pp. 1192–1202, doi: 10.62527/joiv.8.3.2360.
- [17] H. Zhang, H. Jiang, Y. Li, Q. Lu, Y. Liu, and L. Xu, “Massive Retail Location Choice as a Human Flow-Covering Problem.” doi: 10.48550/arXiv.2410.20378.
- [18] P. Kusuma, “AI-driven decision systems for retail optimization,” *Journal of Computer Applications and Technology*, vol. 8, no. 4, pp. 245–259, 2021.