

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Dalam era transisi energi yang semakin mendesak, keberadaan Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) menjadi krusial untuk mendukung penggunaan kendaraan listrik. Kendaraan listrik, yang dianggap sebagai solusi untuk mengurangi emisi karbon dan ketergantungan pada bahan bakar fosil, memerlukan infrastruktur pengisian yang memadai agar dapat beroperasi secara optimal. Penelitian mengenai alokasi SPKLU menggunakan Geographic Information System (GIS) dan machine learning telah menunjukkan potensi yang besar dalam meningkatkan efisiensi dan efektivitas penempatan infrastruktur ini. Menurut laporan dari International Energy Agency (IEA, 2021), jumlah kendaraan listrik di seluruh dunia diperkirakan akan mencapai 145 juta unit pada tahun 2030, yang tentunya memerlukan jaringan SPKLU yang memadai untuk mendukung pertumbuhan tersebut.

Dalam konteks ini, penting untuk mengeksplorasi lebih dalam mengenai bagaimana alokasi SPKLU dapat dilakukan secara optimal. Sejumlah penelitian telah dilakukan untuk mengeksplorasi metode alokasi SPKLU. Salah satu studi oleh Zhang et al. (2020) mengusulkan penggunaan model berbasis GIS untuk menganalisis lokasi strategis SPKLU di kota-kota besar di Tiongkok. Penelitian ini menunjukkan bahwa dengan memanfaatkan data demografis dan pola perjalanan, model yang dihasilkan mampu menentukan lokasi yang optimal untuk SPKLU, sehingga dapat meningkatkan aksesibilitas bagi pengguna kendaraan listrik. Misalnya, dengan menganalisis data jumlah penduduk, frekuensi perjalanan, dan lokasi tempat tinggal, model tersebut dapat merekomendasikan lokasi yang tidak hanya strategis tetapi juga mudah diakses oleh pengguna. Selain itu, penelitian ini juga menemukan bahwa lokasi yang dipilih berdasarkan analisis GIS dapat meningkatkan penggunaan SPKLU hingga 30% dibandingkan dengan lokasi yang ditentukan secara acak. Hal ini menunjukkan bahwa pendekatan berbasis data dapat menghasilkan keputusan yang lebih baik dalam pengembangan infrastruktur.

Dalam konteks di Indonesia, alokasi SPKLU di Jakarta perlu mempertimbangkan faktor-faktor seperti kepadatan penduduk, lokasi pusat perbelanjaan, dan aksesibilitas transportasi umum. Penelitian ini menggunakan analisis spasial untuk mengidentifikasi area dengan potensi tinggi untuk pengembangan SPKLU. Hasilnya menunjukkan bahwa pengembangan SPKLU di dekat pusat-pusat aktivitas ekonomi, seperti mal dan kantor, dapat meningkatkan tingkat adopsi kendaraan listrik, sejalan dengan kebijakan pemerintah yang

mendukung transisi energi bersih. Misalnya, penempatan SPKLU di lokasi strategis seperti pusat perbelanjaan yang ramai dapat mendorong pengguna kendaraan listrik untuk mengisi daya sambil berbelanja, sehingga meningkatkan efisiensi penggunaan waktu dan sumber daya.

Penggunaan machine learning dalam alokasi SPKLU juga semakin banyak diteliti. Sebuah penelitian oleh Wang et al. (2021) menerapkan algoritma pembelajaran mesin untuk memprediksi permintaan pengisian daya di berbagai lokasi. Dengan memanfaatkan data historis penggunaan SPKLU dan variabel lingkungan seperti cuaca dan jam sibuk, model yang dihasilkan mampu memberikan rekomendasi lokasi yang tidak hanya optimal tetapi juga adaptif terhadap perubahan pola penggunaan. Misalnya, pada hari-hari tertentu atau saat cuaca buruk, permintaan pengisian daya mungkin meningkat, dan model machine learning dapat memprediksi tren ini dengan akurasi yang tinggi. Penelitian ini menekankan pentingnya integrasi data real-time dalam pengambilan keputusan untuk pengembangan infrastruktur SPKLU. Dengan demikian, pengelola SPKLU dapat menyesuaikan kapasitas dan lokasi pengisian daya berdasarkan pola permintaan yang berubah-ubah, sehingga meningkatkan efisiensi operasional.

Selain itu, relevansi penelitian ini semakin meningkat seiring dengan komitmen pemerintah dan sektor swasta dalam mengembangkan infrastruktur kendaraan listrik. Dalam Rencana Umum Energi Nasional (RUEN), pemerintah Indonesia menargetkan 2,1 juta kendaraan listrik pada tahun 2025, yang tentunya memerlukan dukungan infrastruktur yang memadai (Kementerian Energi dan Sumber Daya Mineral, 2020). Target ini menunjukkan bahwa ada kebutuhan mendesak untuk mempercepat pengembangan SPKLU agar dapat mendukung pertumbuhan kendaraan listrik yang diproyeksikan. Oleh karena itu, penelitian mengenai model alokasi SPKLU menggunakan GIS dan machine learning tidak hanya relevan tetapi juga sangat dibutuhkan untuk mencapai target-target tersebut secara efektif. Misalnya, jika alokasi SPKLU dilakukan secara optimal, diharapkan dapat meningkatkan kepercayaan masyarakat terhadap kendaraan listrik, yang pada gilirannya akan mendorong lebih banyak orang untuk beralih dari kendaraan berbahan bakar fosil.

Dengan demikian, penelitian ini diharapkan dapat berkontribusi pada pengembangan model alokasi SPKLU yang lebih baik dan efisien, serta mendukung upaya pemerintah dalam mewujudkan visi transportasi berkelanjutan di Indonesia. Melalui penggunaan teknologi modern seperti GIS dan machine learning, diharapkan alokasi SPKLU dapat dilakukan secara cerdas dan berbasis data, sehingga mendukung transisi energi yang lebih ramah lingkungan. Dalam kesimpulannya, penting untuk menyadari bahwa pengembangan infrastruktur SPKLU tidak hanya sekadar soal teknologi, tetapi juga melibatkan pertimbangan sosial, ekonomi, dan

lingkungan yang lebih luas. Penelitian yang mendalam dan terintegrasi akan menjadi kunci untuk mencapai tujuan transisi energi yang berkelanjutan dan inklusif di Indonesia..

2.2 Landasan Teori

2.2.1 Geographic Information System (GIS)

Geographic Information System (GIS) adalah teknologi yang sangat penting dalam pengelolaan dan analisis data geografis. Dengan kemampuannya untuk mengumpulkan, menyimpan, menganalisis, dan memvisualisasikan data yang berkaitan dengan lokasi di permukaan bumi, GIS memberikan wawasan yang mendalam tentang pola, hubungan, dan tren yang ada dalam data tersebut. Menurut Longley et al. (2005), GIS mengintegrasikan berbagai elemen, termasuk perangkat keras, perangkat lunak, data, dan manusia, dalam proses analisis spasial yang kompleks. Hal ini menjadikan GIS sebagai alat yang sangat fleksibel dan kuat dalam mendukung pengambilan keputusan yang berbasis lokasi, yang dapat diterapkan di berbagai sektor, mulai dari perencanaan kota hingga manajemen sumber daya alam dan transportasi.

Salah satu contoh aplikasi GIS yang sangat signifikan adalah dalam perencanaan infrastruktur, terutama dalam pengembangan Stasiun Pengisian Kendaraan Listrik Umum (SPKLU). Dengan memanfaatkan GIS, perencana infrastruktur dapat melakukan analisis mendalam terhadap berbagai data, seperti data demografis, pola lalu lintas, dan lokasi infrastruktur yang sudah ada. Melalui analisis ini, mereka dapat menentukan lokasi optimal untuk SPKLU, yang sangat penting untuk meningkatkan aksesibilitas dan efisiensi penggunaan kendaraan listrik. Misalnya, penelitian oleh Kwan et al. (2020) menunjukkan bahwa analisis spasial dapat membantu dalam mengidentifikasi area dengan permintaan tinggi untuk pengisian kendaraan listrik. Dengan demikian, GIS tidak hanya membantu dalam perencanaan, tetapi juga dalam implementasi yang lebih efisien dari infrastruktur yang diperlukan.

Dalam konteks data yang digunakan dalam GIS, sangat beragam jenis data yang dapat diolah. Data ini mencakup data vektor yang terdiri dari titik, garis, dan poligon, serta data raster yang mencakup citra satelit dan peta topografi. Pengolahan data ini memungkinkan pengguna untuk membuat peta tematik yang menggambarkan berbagai aspek, seperti kepadatan penduduk, aksesibilitas transportasi, dan sebaran infrastruktur. Sebagai contoh, proyek di kota Amsterdam menunjukkan bagaimana analisis GIS digunakan untuk menentukan lokasi pengisian yang strategis berdasarkan pola perjalanan pengguna kendaraan listrik (Hajialiasghari, 2019). Dengan menggunakan data yang tepat dan analisis yang cermat,

perencana dapat mengidentifikasi lokasi SPKLU yang tidak hanya memenuhi kebutuhan pengguna, tetapi juga meminimalkan dampak lingkungan.

Namun, meskipun GIS menawarkan banyak keuntungan, terdapat tantangan yang tidak dapat diabaikan dalam penerapannya. Salah satu tantangan utama adalah kualitas dan ketersediaan data yang digunakan dalam analisis. Data yang tidak akurat atau usang dapat mengarah pada kesalahan dalam pengambilan keputusan yang berpotensi merugikan. Sebagai contoh, penelitian oleh Hwang et al. (2018) menunjukkan bahwa data yang tidak representatif dari populasi lokal dapat menghasilkan lokasi SPKLU yang tidak efisien. Hal ini pada akhirnya dapat mengurangi adopsi kendaraan listrik, yang bertentangan dengan tujuan keberlanjutan lingkungan. Oleh karena itu, sangat penting untuk memastikan bahwa data yang digunakan dalam analisis GIS adalah terkini, relevan, dan akurat.

Secara keseluruhan, GIS merupakan alat yang sangat berharga dalam perencanaan dan pengembangan infrastruktur, termasuk SPKLU. Dengan kemampuannya untuk menganalisis dan memvisualisasikan data spasial, GIS mendukung pengambilan keputusan yang lebih baik dan lebih informasional. Dalam konteks pengembangan SPKLU, penggunaan GIS dapat membantu dalam mengidentifikasi lokasi yang optimal, sehingga mendukung pertumbuhan kendaraan listrik dan berkontribusi pada keberlanjutan lingkungan. Dengan demikian, penting bagi pemangku kepentingan untuk memahami dan memanfaatkan teknologi GIS secara maksimal, agar dapat merencanakan dan mengembangkan infrastruktur yang tidak hanya efisien tetapi juga berkelanjutan dalam jangka panjang.

Dalam era digital saat ini, di mana informasi dan data menjadi salah satu aset terpenting, pemanfaatan GIS dalam berbagai sektor semakin mendesak. Hal ini tidak hanya terbatas pada perencanaan infrastruktur, tetapi juga mencakup bidang seperti manajemen bencana, pengelolaan sumber daya alam, dan perencanaan tata ruang. Dengan kemampuan untuk menganalisis data dalam konteks geografis, GIS memberikan perspektif yang lebih komprehensif dan mendalam tentang isu-isu yang dihadapi oleh masyarakat saat ini. Oleh karena itu, investasi dalam teknologi GIS dan pelatihan bagi penggunaannya sangat penting untuk memastikan bahwa potensi penuh dari teknologi ini dapat dimanfaatkan.

Dengan demikian, GIS tidak hanya berfungsi sebagai alat analisis, tetapi juga sebagai jembatan yang menghubungkan berbagai disiplin ilmu dan sektor. Melalui kolaborasi antara peneliti, perencana, dan pembuat kebijakan, teknologi ini dapat digunakan untuk menciptakan solusi yang inovatif dan berkelanjutan untuk tantangan yang dihadapi oleh masyarakat modern. Dalam konteks ini, penting untuk terus mengembangkan dan memperbaharui sistem GIS agar tetap relevan dengan kebutuhan dan perkembangan zaman. Dengan pendekatan yang tepat,

GIS dapat menjadi pendorong utama dalam menciptakan lingkungan yang lebih baik dan lebih berkelanjutan bagi generasi mendatang.

Kesimpulannya, Geographic Information System (GIS) adalah alat yang sangat berharga dalam pengelolaan dan analisis data geografis. Dengan kemampuannya untuk mengumpulkan, menyimpan, menganalisis, dan memvisualisasikan data yang berkaitan dengan lokasi, GIS memberikan wawasan yang mendalam dan mendukung pengambilan keputusan yang berbasis lokasi. Meskipun terdapat tantangan dalam penerapannya, seperti kualitas dan ketersediaan data, manfaat yang ditawarkan oleh GIS dalam perencanaan infrastruktur, termasuk pengembangan SPKLU, sangat signifikan. Dengan memanfaatkan teknologi ini secara maksimal, kita dapat menciptakan solusi yang lebih efisien dan berkelanjutan untuk tantangan yang dihadapi oleh masyarakat saat ini, serta mendukung pertumbuhan kendaraan listrik dan keberlanjutan lingkungan.

2.2.2 SPKLU

Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) merupakan infrastruktur yang sangat vital dalam mendukung transisi menuju penggunaan kendaraan listrik (EV) di Indonesia. Dalam konteks global, pergeseran menuju kendaraan listrik adalah langkah krusial untuk mengurangi dampak negatif terhadap lingkungan akibat emisi gas rumah kaca. SPKLU berfungsi sebagai penyedia energi listrik yang diperlukan oleh kendaraan listrik agar dapat beroperasi dengan optimal. Menurut Kementerian Energi dan Sumber Daya Mineral (ESDM) Republik Indonesia, penggunaan kendaraan listrik diharapkan dapat mengurangi emisi gas rumah kaca dan ketergantungan pada bahan bakar fosil (Kementerian ESDM, 2020). Hal ini sejalan dengan data dari International Energy Agency (IEA), yang menunjukkan bahwa jumlah kendaraan listrik di seluruh dunia terus meningkat, dengan proyeksi mencapai 145 juta unit pada tahun 2030 (IEA, 2021). Dengan pertumbuhan yang pesat ini, penempatan SPKLU yang strategis menjadi sangat penting untuk mendukung pertumbuhan ekosistem kendaraan listrik.

Dalam konteks alokasi SPKLU, terdapat beberapa faktor penting yang perlu dipertimbangkan, seperti kepadatan penduduk, pola perjalanan, dan keberadaan infrastruktur lainnya. Penelitian yang dilakukan oleh Zhang (2020) menunjukkan bahwa lokasi SPKLU yang tepat dapat meningkatkan penggunaan kendaraan listrik secara signifikan. Misalnya, penempatan SPKLU di area perbelanjaan dan pusat bisnis dapat menarik lebih banyak pengguna karena kemudahan akses dan waktu pengisian yang efisien. Dengan demikian, model alokasi SPKLU harus didasarkan pada analisis yang mendalam terhadap data geografis dan demografis.

Salah satu aspek yang tidak dapat diabaikan adalah kepadatan penduduk. Di daerah dengan kepadatan penduduk yang tinggi, seperti Jakarta, keberadaan SPKLU akan sangat berpengaruh terhadap adopsi kendaraan listrik. Dalam konteks ini, penting untuk melakukan analisis mendalam mengenai pola perjalanan masyarakat. Misalnya, banyak orang yang melakukan perjalanan harian dari tempat tinggal ke tempat kerja. Jika SPKLU diletakkan di sepanjang rute perjalanan tersebut, maka pengguna kendaraan listrik akan lebih cenderung untuk mengisi daya kendaraan mereka. Contoh konkret dapat dilihat di beberapa negara maju yang telah sukses dalam mengimplementasikan SPKLU di lokasi strategis, seperti di dekat stasiun kereta api atau pusat transportasi umum lainnya.

Selanjutnya, keberadaan infrastruktur lain juga memainkan peran penting dalam penempatan SPKLU. Misalnya, jika sebuah lokasi memiliki akses yang baik ke fasilitas umum, seperti restoran, pusat perbelanjaan, atau tempat rekreasi, maka pengguna kendaraan listrik akan lebih tertarik untuk mengisi daya kendaraan mereka sambil melakukan aktivitas lain. Transisi yang mulus antara pengisian daya dan kegiatan sehari-hari ini dapat meningkatkan kenyamanan pengguna, yang pada gilirannya akan mendorong lebih banyak orang untuk beralih ke kendaraan listrik. Oleh karena itu, perlu dilakukan kajian yang komprehensif mengenai infrastruktur yang ada dan bagaimana SPKLU dapat terintegrasi dengan baik di dalamnya.

Analisis mendalam juga perlu dilakukan terkait dengan aspek teknis dari SPKLU itu sendiri. Terdapat berbagai jenis SPKLU, mulai dari pengisian daya cepat hingga pengisian daya lambat. Pemilihan jenis SPKLU yang tepat harus disesuaikan dengan kebutuhan pengguna di lokasi tertentu. Misalnya, di area yang banyak dikunjungi orang dalam waktu singkat, seperti pusat perbelanjaan, pengisian daya cepat akan lebih sesuai. Sebaliknya, di area perumahan di mana kendaraan mungkin terparkir untuk waktu yang lebih lama, pengisian daya lambat dapat menjadi pilihan yang lebih efisien. Dengan memahami kebutuhan pengguna dan karakteristik lokasi, pengelola SPKLU dapat merancang solusi yang lebih efektif untuk meningkatkan adopsi kendaraan listrik.

Terakhir, penting untuk mempertimbangkan aspek keberlanjutan dan dampak lingkungan dari pengembangan SPKLU. Penempatan SPKLU harus dilakukan dengan mempertimbangkan dampak terhadap lingkungan, seperti penggunaan lahan dan sumber daya alam. Misalnya, pengembangan SPKLU di area yang sebelumnya tidak terjamah dapat menimbulkan dampak negatif terhadap ekosistem lokal. Oleh karena itu, perlu dilakukan studi dampak lingkungan (AMDAL) sebelum pengembangan SPKLU untuk memastikan bahwa proyek tersebut tidak merugikan lingkungan.

Kesimpulannya, Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) merupakan komponen yang sangat penting dalam mendukung transisi menuju kendaraan listrik di Indonesia. Penempatan SPKLU yang strategis dapat meningkatkan penggunaan kendaraan listrik dan berkontribusi pada pengurangan emisi gas rumah kaca. Dengan mempertimbangkan faktor-faktor seperti kepadatan penduduk, pola perjalanan, dan keberadaan infrastruktur lainnya, serta aspek teknis dan keberlanjutan, kita dapat merancang model alokasi SPKLU yang efektif dan efisien. Dengan demikian, upaya untuk memperluas jaringan SPKLU akan mendukung pertumbuhan ekosistem kendaraan listrik dan membantu Indonesia mencapai target pengurangan emisi yang telah ditetapkan.

2.2.3 Demografis

Demografi merupakan cabang ilmu yang mengkaji kondisi dan dinamika penduduk dalam suatu wilayah secara komprehensif, meliputi jumlah dan kepadatan penduduk, distribusi spasial, struktur usia dan jenis kelamin, tingkat pendidikan, kondisi sosial ekonomi, tingkat kemiskinan, pengangguran, serta karakteristik rumah tangga. Data demografi juga mencerminkan pola aktivitas masyarakat, daya beli, mobilitas, dan kebutuhan layanan publik yang berbeda antarwilayah, sehingga dapat digunakan untuk menggambarkan intensitas interaksi manusia dengan infrastruktur perkotaan. Dalam konteks perencanaan dan pemodelan Stasiun Pengisian Kendaraan Listrik Umum (SPKLU), informasi demografis menjadi komponen penting karena wilayah dengan kepadatan penduduk tinggi, dominasi usia produktif, tingkat pendidikan dan pendapatan yang relatif baik, serta aktivitas ekonomi yang intensif cenderung memiliki potensi adopsi kendaraan listrik yang lebih besar. Oleh karena itu, variabel demografi digunakan sebagai dasar untuk merepresentasikan tingkat permintaan, intensitas penggunaan, dan prioritas pengembangan SPKLU, sehingga model yang dibangun mampu menghasilkan rekomendasi lokasi yang lebih akurat, efektif, dan sesuai dengan karakteristik masyarakat setempat serta mendukung pengembangan infrastruktur kendaraan listrik yang berkelanjutan (Chen & Chen, 2023).

Demografi merupakan salah satu aspek penting dalam perencanaan dan pengembangan infrastruktur, termasuk dalam konteks penyediaan Stasiun Pengisian Kendaraan Listrik Umum (SPKLU). Dalam kajian ini, demografi merujuk pada karakteristik populasi yang berpengaruh terhadap permintaan dan penggunaan SPKLU. Menurut Badan Pusat Statistik (BPS) 2021, jumlah kendaraan listrik di Indonesia diproyeksikan akan meningkat pesat seiring dengan kebijakan pemerintah yang mendukung transisi energi dan pengurangan emisi karbon. Data ini

menunjukkan bahwa pemahaman terhadap demografi pengguna kendaraan listrik sangat penting untuk menentukan lokasi yang strategis bagi SPKLU.

Berdasarkan data BPS, populasi Indonesia pada tahun 2022 mencapai sekitar 273 juta jiwa, dengan pertumbuhan populasi yang terus meningkat. Dalam konteks ini, distribusi penduduk di wilayah perkotaan dan pedesaan memiliki implikasi yang signifikan terhadap aksesibilitas SPKLU. Wilayah perkotaan, yang memiliki kepadatan penduduk yang lebih tinggi, cenderung memiliki permintaan yang lebih besar terhadap kendaraan listrik dan, oleh karena itu, SPKLU. Sebagai contoh, Jakarta sebagai ibu kota, dengan populasi lebih dari 10 juta jiwa, menunjukkan tren peningkatan penggunaan kendaraan listrik yang signifikan, sehingga memerlukan penempatan SPKLU yang strategis untuk memenuhi kebutuhan pengguna.

Statistik menunjukkan bahwa kelompok usia produktif, khususnya antara 20 hingga 40 tahun, merupakan pengguna utama kendaraan listrik. Menurut survei yang dilakukan oleh Kementerian Perhubungan pada tahun 2021, sekitar 60% pengguna kendaraan listrik berada dalam rentang usia ini. Hal ini menunjukkan bahwa demografi pengguna kendaraan listrik tidak hanya dipengaruhi oleh faktor usia, tetapi juga oleh tingkat pendidikan dan kesadaran lingkungan. Masyarakat yang lebih terdidik cenderung lebih sadar akan isu lingkungan dan lebih terbuka terhadap teknologi baru, termasuk kendaraan listrik.

Selain itu, faktor ekonomi juga memainkan peran penting dalam demografi pengguna kendaraan listrik. Menurut laporan dari International Energy Agency (IEA) 2021, pendapatan per kapita yang lebih tinggi berhubungan dengan adopsi kendaraan listrik yang lebih besar. Di Indonesia, dengan pertumbuhan ekonomi yang stabil, semakin banyak individu yang mampu berinvestasi dalam kendaraan listrik. Oleh karena itu, pemetaan demografis yang mencakup aspek ekonomi sangat krusial dalam menentukan lokasi SPKLU yang optimal. Misalnya, daerah dengan pendapatan tinggi seperti kawasan bisnis di Jakarta Selatan menunjukkan potensi yang lebih besar untuk pengembangan SPKLU.

Akhirnya, penting untuk mempertimbangkan faktor-faktor sosial dan budaya yang dapat mempengaruhi penggunaan kendaraan listrik dan SPKLU. Dalam konteks Indonesia, budaya penggunaan kendaraan pribadi yang tinggi dan ketergantungan pada kendaraan bermotor konvensional menjadi tantangan tersendiri. Namun, dengan semakin banyaknya kampanye untuk mengurangi emisi karbon dan meningkatkan kesadaran akan pentingnya kendaraan ramah lingkungan, diharapkan akan ada perubahan perilaku di kalangan masyarakat. Oleh karena itu, pemahaman yang mendalam tentang demografi, termasuk faktor sosial dan budaya, sangat penting dalam merancang model alokasi SPKLU yang efektif dan berkelanjutan.

Menggali lebih dalam, kita perlu memahami bahwa demografi tidak hanya sekadar angka dan statistik, tetapi juga mencerminkan dinamika sosial yang kompleks. Dalam konteks kendaraan listrik, kita dapat melihat bagaimana perubahan dalam struktur demografis, seperti migrasi dari desa ke kota, mempengaruhi pola penggunaan kendaraan. Misalnya, banyak generasi muda yang pindah ke kota besar untuk mencari pekerjaan, yang pada gilirannya meningkatkan permintaan akan kendaraan listrik sebagai solusi transportasi yang lebih efisien dan ramah lingkungan. Dengan demikian, analisis demografis yang cermat dapat membantu dalam merencanakan lokasi SPKLU yang tidak hanya berdasarkan jumlah pengguna, tetapi juga mempertimbangkan tren migrasi dan mobilitas penduduk.

Selain itu, penting untuk menganalisis bagaimana faktor pendidikan dan kesadaran lingkungan berinteraksi dengan demografi. Misalnya, individu dengan pendidikan tinggi cenderung lebih terpapar pada informasi tentang perubahan iklim dan teknologi hijau, sehingga mereka lebih mungkin untuk mengadopsi kendaraan listrik. Hal ini dapat dilihat dalam survei yang menunjukkan bahwa daerah dengan tingkat pendidikan yang lebih tinggi, seperti di beberapa universitas di Jakarta, memiliki proporsi pengguna kendaraan listrik yang lebih besar. Oleh karena itu, penyuluhan dan pendidikan tentang manfaat kendaraan listrik perlu ditargetkan kepada kelompok demografis yang lebih luas untuk meningkatkan adopsi.

Dalam hal ekonomi, kita dapat menyelami lebih dalam bagaimana pendapatan per kapita yang lebih tinggi tidak hanya berhubungan dengan kemampuan membeli kendaraan listrik, tetapi juga dengan akses terhadap infrastruktur pendukung, seperti SPKLU. Misalnya, di kawasan elit seperti SCBD (Sudirman Central Business District), di mana banyak perusahaan teknologi dan start-up beroperasi, terdapat permintaan yang lebih tinggi untuk kendaraan listrik dan infrastruktur pengisian yang memadai. Hal ini menunjukkan bahwa pemetaan demografis yang mempertimbangkan aspek ekonomi harus mencakup analisis tentang lokasi-lokasi yang memiliki potensi pertumbuhan ekonomi dan teknologi yang tinggi.

Faktor sosial dan budaya juga tidak bisa diabaikan dalam analisis demografis. Indonesia memiliki budaya yang kuat dalam penggunaan kendaraan bermotor konvensional, dan pergeseran menuju kendaraan listrik memerlukan perubahan perilaku yang signifikan. Kampanye yang efektif harus mempertimbangkan nilai-nilai budaya lokal dan cara-cara untuk mengintegrasikan kendaraan listrik ke dalam kehidupan sehari-hari masyarakat. Misalnya, mengadakan acara komunitas yang mengedukasi masyarakat tentang manfaat kendaraan listrik dan memberikan kesempatan untuk mencoba kendaraan listrik secara langsung dapat menjadi strategi yang efektif untuk meningkatkan kesadaran dan adopsi.

Dalam kesimpulan, pemahaman mendalam tentang demografi pengguna kendaraan listrik sangat penting untuk perencanaan dan pengembangan SPKLU yang efektif. Dengan mempertimbangkan faktor-faktor seperti distribusi populasi, kelompok usia, pendidikan, ekonomi, serta aspek sosial dan budaya, kita dapat merancang solusi yang lebih tepat sasaran dan berkelanjutan. Hal ini tidak hanya akan memenuhi kebutuhan pengguna, tetapi juga berkontribusi pada upaya nasional dalam mengurangi emisi karbon dan mempromosikan penggunaan energi terbarukan. Dengan demikian, kajian demografis yang komprehensif akan menjadi landasan yang kuat dalam merancang infrastruktur yang mendukung transisi menuju kendaraan listrik di Indonesia.

2.2.4 Socio-Economic

1. **Jumlah_Miskin (Populasi Miskin)**, yang merepresentasikan dimensi sosial dan kondisi spasial dalam perencanaan infrastruktur SPKLU. Meskipun populasi miskin tidak secara langsung mencerminkan tingkat kepemilikan kendaraan listrik, distribusinya memiliki keterkaitan spasial dengan kepadatan penduduk, pola permukiman, dan aksesibilitas jaringan jalan yang merupakan variabel demografi yang memengaruhi hasil prediksi SPKLU.
2. **Kendaraan (Jumlah Kendaraan Bermotor)**, variabel jumlah kendaraan bermotor menjadi salah satu variabel prediktor dalam prediksi lokasi SPKLU karena merepresentasikan tingkat aktivitas dan intensitas mobilitas suatu wilayah yang berkorelasi langsung dengan potensi permintaan infrastruktur pengisian kendaraan listrik. Secara spasial, wilayah dengan konsentrasi kendaraan bermotor yang tinggi cenderung memiliki kebutuhan pengisian energi yang lebih besar dan berkelanjutan. Dengan demikian, integrasi variabel jumlah kendaraan bermotor dalam model prediktif meningkatkan kemampuan analisis dalam mengidentifikasi lokasi SPKLU.
3. **Kepadatan (Kepadatan Penduduk)**, variabel kepadatan penduduk juga sebagai variabel prediktor dalam prediksi lokasi SPKLU karena merepresentasikan intensitas aktivitas manusia dan konsentrasi potensi pengguna kendaraan listrik dalam suatu wilayah. Secara spasial, wilayah dengan kepadatan penduduk yang tinggi cenderung memiliki tingkat mobilitas harian yang lebih besar, kebutuhan energi transportasi yang lebih intensif, serta aksesibilitas yang lebih baik terhadap jaringan jalan dan fasilitas publik. Kondisi tersebut meningkatkan peluang pemanfaatan SPKLU secara berkelanjutan dan efisien. Oleh karena itu, integrasi variabel kepadatan penduduk dalam model prediktif berperan penting dalam

meningkatkan akurasi identifikasi lokasi SPKLU yang strategis dan relevan terhadap dinamika spasial wilayah.

4. **KK (Jumlah Rumah Tangga)**, Secara spasial, tingginya jumlah rumah tangga menunjukkan konsentrasi permukiman yang berpotensi memiliki kebutuhan pengisian energi transportasi, baik melalui kepemilikan kendaraan pribadi maupun penggunaan fasilitas pengisian publik. Selain itu, jumlah rumah tangga mencerminkan pola penggunaan ruang dan ketersediaan area parkir yang berperan penting dalam penentuan lokasi SPKLU yang mudah diakses. Sebagai indikator demografis yang lebih stabil dibandingkan jumlah penduduk, variabel ini membantu menangkap distribusi permintaan potensial secara lebih akurat. Oleh karena itu, integrasi variabel jumlah rumah tangga dalam model prediktif meningkatkan kemampuan analisis dalam mengidentifikasi lokasi SPKLU yang relevan.
5. **Minoritas (Populasi Minoritas)**, secara spasial, kelompok minoritas sering terkonsentrasi pada kawasan tertentu yang memiliki karakteristik sosial-ekonomi dan aksesibilitas yang berbeda dibandingkan wilayah mayoritas, sehingga berisiko terpinggirkan dalam perencanaan infrastruktur. Meskipun tidak mencerminkan permintaan langsung terhadap kendaraan listrik, variabel ini berfungsi sebagai indikator keadilan sosial dan spasial yang penting untuk memastikan distribusi SPKLU yang lebih merata. Dengan memasukkan populasi minoritas ke dalam model prediktif, analisis mampu mengidentifikasi lokasi SPKLU yang tidak hanya optimal secara teknis, tetapi juga selaras dengan prinsip pemerataan layanan dan keadilan energi dalam transisi transportasi berkelanjutan.
6. **Pendidikan (Indeks Pendidikan)**, mencerminkan tingkat literasi, kapasitas adopsi teknologi, dan kesadaran masyarakat terhadap inovasi transportasi berkelanjutan. Selain itu, indeks pendidikan berkorelasi dengan karakteristik sosial-ekonomi, pola mobilitas, dan preferensi penggunaan kendaraan yang memengaruhi permintaan infrastruktur pengisian kendaraan listrik. Dengan demikian, integrasi variabel indeks pendidikan dalam model prediktif berperan sebagai indikator terhadap kesiapan sosial wilayah dalam mendukung pemanfaatan SPKLU secara optimal dan berkelanjutan.
7. **Penduduk (Total Populasi)**, merepresentasikan besarnya potensi permintaan energi transportasi dalam suatu wilayah. Secara spasial, wilayah dengan jumlah penduduk yang besar cenderung memiliki tingkat aktivitas ekonomi dan mobilitas yang lebih tinggi, sehingga meningkatkan kebutuhan terhadap infrastruktur pengisian kendaraan listrik. Total populasi juga berfungsi sebagai indikator kapasitas pasar dan intensitas penggunaan ruang, yang memengaruhi efisiensi operasional SPKLU. Sehingga membantu model prediktif

dalam mengidentifikasi lokasi SPKLU yang strategis dan mampu melayani jumlah pengguna yang lebih besar secara berkelanjutan

8. **Pengangguran (Populasi Pengangguran)**, menggambarkan kondisi sosial-ekonomi dan dinamika pasar tenaga kerja yang memengaruhi pola mobilitas serta distribusi kebutuhan infrastruktur publik. Secara spasial, tingkat pengangguran yang tinggi sering beririsan dengan kawasan permukiman padat dan wilayah dengan keterbatasan akses layanan, sehingga berpotensi mengalami ketimpangan penyediaan infrastruktur transportasi berkelanjutan. Dengan memasukkan populasi pengangguran ke dalam model prediktif, analisis menjadi lebih sensitif terhadap aspek keadilan spasial dan mampu menghasilkan rekomendasi lokasi SPKLU yang tidak hanya efisien secara teknis, tetapi juga inklusif secara sosial.
9. **Pengeluaran (Pengeluaran Per Kapita)**, mencerminkan tingkat kemampuan ekonomi dan pola konsumsi masyarakat yang berkaitan dengan adopsi teknologi transportasi berbasis kendaraan listrik. Secara empiris, wilayah dengan pengeluaran per kapita yang lebih tinggi cenderung memiliki daya beli yang lebih besar, tingkat kepemilikan kendaraan pribadi yang lebih tinggi, serta kesiapan finansial untuk beralih ke kendaraan listrik. Oleh karena itu, integrasi variabel pengeluaran per kapita dalam model prediktif berperan sebagai indikator terhadap potensi permintaan SPKLU, sehingga meningkatkan relevansi dan akurasi identifikasi lokasi pengisian kendaraan listrik yang strategis.
10. **Persentase_Miskin (Persentase Kemiskinan)**, secara spasial, wilayah dengan persentase kemiskinan yang tinggi sering kali memiliki keterbatasan akses terhadap fasilitas transportasi modern, sehingga berpotensi terpinggirkan dalam proses transisi menuju kendaraan listrik. Meskipun tidak merepresentasikan permintaan langsung terhadap SPKLU, variabel ini berfungsi sebagai indikator keadilan spasial yang penting untuk mencegah bias perencanaan yang hanya berorientasi pada wilayah berpendapatan tinggi. Dengan memasukkan persentase kemiskinan ke dalam model prediktif, analisis mampu menghasilkan rekomendasi lokasi SPKLU yang lebih inklusif dan seimbang, selaras dengan prinsip pemerataan layanan dan keadilan energi.
11. **Produ (Jumlah Individu Usia Produktif)**, kelompok usia ini merupakan segmen populasi yang paling aktif secara ekonomi dan memiliki tingkat mobilitas harian yang tinggi. Secara empiris, individu usia produktif cenderung menjadi pengguna utama kendaraan pribadi untuk aktivitas kerja, pendidikan, dan kegiatan sosial, sehingga berkontribusi signifikan terhadap kebutuhan energi transportasi. Oleh karena itu, distribusi spasial populasi usia produktif menjadi indikator penting dalam mengidentifikasi wilayah dengan potensi

permintaan SPKLU yang tinggi dan berkelanjutan, sehingga meningkatkan akurasi model prediktif dalam menentukan lokasi pengisian kendaraan listrik yang strategis.

2.2.5 Machine Learning

Machine Learning (ML) merupakan salah satu bagian dari Artificial Intelligence (AI) yang berfokus pada penciptaan algoritma serta model yang dapat membuat sistem komputer belajar secara otomatis dari data dan melakukan prediksi berdasarkan pola yang ditemukan. Menurut Mitchell (1997), machine learning didefinisikan sebagai “sebuah bidang studi yang memungkinkan komputer memperoleh kemampuan belajar tanpa harus diprogram secara langsung.” Dalam konteks ini, machine learning bukan hanya sekedar alat, tetapi juga sebuah paradigma yang memungkinkan komputer untuk beradaptasi dan meningkatkan kinerjanya seiring dengan bertambahnya data. Hal ini menjadi sangat relevan dalam berbagai sektor, termasuk dalam sistem penempatan Stasiun Pengisian Kendaraan Listrik Umum (SPKLU), yang membutuhkan kemampuan analisis data berskala besar dan pengambilan keputusan otomatis secara efisien.

Dalam penerapan pada sistem SPKLU, teknologi machine learning memiliki peran penting dalam mengenali pola konsumsi energi, memproyeksikan kebutuhan pengisian daya kendaraan listrik, serta menentukan lokasi dan jumlah SPKLU secara optimal. Misalnya, studi yang dilakukan oleh Zhang (2020) membuktikan bahwa penggunaan algoritma machine learning mampu memprediksi permintaan listrik di kawasan perkotaan dengan tingkat akurasi mencapai 90%. Angka ini menunjukkan seberapa besar potensi machine learning dalam meningkatkan efisiensi serta ketepatan dalam distribusi infrastruktur SPKLU. Dengan demikian, machine learning tidak hanya berfungsi sebagai alat analisis, tetapi juga sebagai pendorong inovasi dalam perencanaan dan pengembangan infrastruktur yang lebih berkelanjutan.

Terdapat beberapa jenis algoritma machine learning yang umum digunakan, termasuk unsupervised learning, supervised learning, dan reinforcement learning. Supervised learning, misalnya, melibatkan pelatihan model dengan data yang telah diberi label, sehingga model dapat belajar untuk memprediksi hasil yang diinginkan. Dalam konteks SPKLU, hal ini dapat diterapkan untuk memprediksi jumlah pengguna yang akan menggunakan fasilitas pengisian berdasarkan data historis. Di sisi lain, unsupervised learning digunakan untuk menemukan pola dalam data yang tidak terlabel. Ini sangat berguna dalam konteks SPKLU, di mana data pengguna mungkin tidak selalu terstruktur. Sebagai contoh, algoritma clustering dalam unsupervised learning dapat digunakan untuk mengelompokkan area dengan pola penggunaan

kendaraan listrik yang serupa, sehingga membantu dalam menentukan lokasi SPKLU yang paling strategis.

Penerapan machine learning dalam alokasi SPKLU juga dapat didukung oleh Geographic Information System (GIS), yang memungkinkan analisis data spasial. GIS memberikan alat untuk memvisualisasikan dan menganalisis data geospasial, yang sangat penting dalam konteks perencanaan infrastruktur. Kombinasi antara ML dan GIS dapat memberikan wawasan yang lebih mendalam mengenai lokasi strategis untuk pembangunan SPKLU berdasarkan pola penggunaan kendaraan listrik di suatu daerah. Sebagai contoh, penelitian oleh Yang et al. (2021) menunjukkan bahwa integrasi GIS dengan machine learning dapat meningkatkan akurasi prediksi kebutuhan SPKLU hingga 15% dibandingkan dengan metode tradisional. Ini menunjukkan bahwa dengan memanfaatkan data geospasial, kita dapat membuat keputusan yang lebih tepat dan berbasis data dalam penempatan SPKLU.

Secara keseluruhan, machine learning menawarkan berbagai metode dan teknik yang dapat membantu dalam pengambilan keputusan yang lebih baik dalam alokasi SPKLU. Dengan menggunakan data yang ada, algoritma machine learning mampu menghasilkan rekomendasi yang lebih akurat dan efisien, serta berperan dalam perencanaan infrastruktur untuk mendukung peralihan menuju kendaraan listrik yang lebih ramah lingkungan. Dalam konteks ini, penting untuk terus melakukan penelitian dan pengembangan dalam bidang machine learning agar dapat mengoptimalkan penggunaannya dalam infrastruktur pengisian kendaraan listrik, serta mendukung transisi menuju sistem transportasi yang lebih berkelanjutan dan efisien.

Dengan demikian, dapat disimpulkan bahwa machine learning memiliki potensi yang sangat besar dalam meningkatkan efisiensi dan efektivitas sistem penempatan SPKLU. Melalui pemanfaatan algoritma yang tepat dan integrasi dengan teknologi GIS, kita dapat mengatasi tantangan yang ada dalam perencanaan dan pengembangan infrastruktur pengisian kendaraan listrik. Hal ini bukan hanya akan berkontribusi pada pengembangan infrastruktur yang lebih baik, tetapi juga mendukung tujuan global untuk mengurangi emisi karbon dan mempromosikan penggunaan energi terbarukan. Ke depan, kolaborasi antara peneliti, praktisi industri, dan pembuat kebijakan akan sangat penting dalam memastikan bahwa teknologi machine learning dapat dimanfaatkan secara optimal untuk mencapai tujuan ini.

1. Algoritma Machine Learning yang Relevan

Dalam era digital saat ini, perkembangan teknologi informasi dan komunikasi telah membawa dampak yang signifikan dalam berbagai aspek kehidupan, termasuk dalam

pengelolaan energi dan infrastruktur kendaraan listrik. Salah satu inovasi yang sangat penting dalam konteks ini adalah penggunaan algoritma machine learning untuk model alokasi Stasiun Pengisian Kendaraan Listrik Umum (SPKLU). Penggunaan algoritma machine learning tidak hanya meningkatkan efisiensi, tetapi juga memberikan prediksi yang lebih akurat mengenai kebutuhan dan pola penggunaan energi. Dalam pembahasan ini, kita akan mengkaji beberapa algoritma machine learning yang relevan, termasuk regresi linier, decision tree, dan neural networks, serta bagaimana masing-masing algoritma ini dapat diimplementasikan dalam konteks alokasi SPKLU.

Regresi linier merupakan salah satu algoritma yang paling sederhana namun sangat efektif dalam memprediksi nilai kontinu. Metode ini didasarkan pada asumsi bahwa terdapat hubungan linear antara variabel independen dan dependen. Dalam konteks alokasi SPKLU, regresi linier dapat digunakan untuk memprediksi jumlah pengisian yang dibutuhkan berdasarkan variabel seperti jumlah kendaraan listrik yang terdaftar di suatu area, kepadatan penduduk, dan jumlah SPKLU yang tersedia. Misalnya, jika kita memiliki data historis mengenai jumlah kendaraan listrik dan frekuensi pengisian di suatu wilayah, kita dapat menggunakan regresi linier untuk memproyeksikan kebutuhan pengisian di masa depan. Analisis ini tidak hanya memberikan gambaran yang jelas mengenai kebutuhan energi, tetapi juga membantu dalam perencanaan infrastruktur yang lebih baik.

Namun, meskipun regresi linier memiliki keunggulan dalam kesederhanaan dan interpretabilitas, ia juga memiliki keterbatasan, terutama dalam menangkap hubungan yang lebih kompleks antara variabel. Di sinilah decision tree menjadi relevan. Algoritma ini membagi data menjadi subset yang lebih kecil berdasarkan nilai atribut tertentu, sehingga memungkinkan untuk membuat keputusan yang lebih terperinci. Decision tree sangat berguna ketika kita ingin mempertimbangkan berbagai faktor yang mempengaruhi kebutuhan pengisian, seperti waktu, lokasi, dan jenis kendaraan. Sebagai contoh, sebuah studi oleh Breiman et al. (1986) menunjukkan bahwa decision tree dapat mencapai akurasi yang tinggi dalam klasifikasi dan regresi. Dalam konteks SPKLU, decision tree dapat digunakan untuk mengidentifikasi pola penggunaan berdasarkan karakteristik pengguna dan lingkungan, yang pada gilirannya dapat membantu dalam penempatan stasiun pengisian yang lebih strategis.

Neural networks, yang terinspirasi oleh cara kerja otak manusia, menawarkan pendekatan yang lebih canggih dan fleksibel dalam analisis data. Algoritma ini mampu menangani data yang sangat besar dan kompleks serta dapat menangkap hubungan non-linear antara variabel. Penelitian oleh LeCun et al. (2015) menunjukkan bahwa neural networks telah berhasil diterapkan dalam berbagai bidang, termasuk pengenalan pola dan prediksi. Dalam

konteks alokasi SPKLU, neural networks dapat digunakan untuk memprediksi pola penggunaan energi yang lebih rumit berdasarkan data historis yang beragam. Misalnya, jika kita memiliki data mengenai waktu penggunaan, lokasi, dan jenis kendaraan, neural networks dapat membantu dalam memahami bagaimana berbagai faktor tersebut saling berinteraksi dan mempengaruhi kebutuhan pengisian. Dengan demikian, neural networks tidak hanya memberikan prediksi yang lebih akurat, tetapi juga memungkinkan untuk pengembangan model yang lebih adaptif terhadap perubahan pola penggunaan energi.

Satu contoh penerapan algoritma machine learning dalam alokasi SPKLU dapat dilihat pada penelitian oleh Yang et al. (2021), yang menggunakan kombinasi dari beberapa algoritma untuk meningkatkan akurasi prediksi kebutuhan SPKLU. Dalam studi tersebut, mereka menemukan bahwa model ensemble, yang menggabungkan beberapa algoritma, dapat memberikan hasil yang lebih baik dibandingkan dengan model tunggal. Hal ini menunjukkan pentingnya eksplorasi berbagai algoritma untuk menemukan pendekatan yang paling efektif dalam konteks alokasi SPKLU. Penggunaan model ensemble tidak hanya meningkatkan akurasi, tetapi juga memberikan ketahanan terhadap overfitting, yang sering kali menjadi masalah dalam model yang terlalu kompleks.

Dengan demikian, pemilihan algoritma machine learning yang tepat sangat penting dalam model alokasi SPKLU. Setiap algoritma memiliki kelebihan dan kekurangan masing-masing, dan kombinasi dari beberapa metode dapat menghasilkan hasil yang lebih baik. Oleh karena itu, penelitian lebih lanjut diperlukan untuk mengeksplorasi dan menguji berbagai algoritma dalam konteks alokasi SPKLU. Dalam rangka mencapai efisiensi energi yang lebih baik dan pengelolaan infrastruktur yang lebih efektif, penting untuk terus mengembangkan dan menerapkan teknik-teknik machine learning yang inovatif.

Kesimpulannya, algoritma machine learning seperti regresi linier, decision tree, dan neural networks memainkan peran yang krusial dalam model alokasi SPKLU. Masing-masing algoritma menawarkan pendekatan yang berbeda dalam memecahkan masalah alokasi energi dan pengisian kendaraan listrik. Dengan memahami dan menerapkan algoritma ini secara efektif, kita dapat meningkatkan efisiensi pengisian, merencanakan infrastruktur yang lebih baik, dan akhirnya mendukung transisi menuju penggunaan energi yang lebih berkelanjutan. Penelitian lebih lanjut dalam bidang ini sangat penting untuk mengeksplorasi potensi algoritma machine learning lainnya dan untuk mengembangkan solusi yang lebih inovatif dalam menghadapi tantangan energi di masa depan.

2. Penerapan Machine Learning dalam Sistem Alokasi SPKLU

Penerapan machine learning dalam sistem alokasi Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) telah menjadi topik yang semakin relevan dan penting dalam konteks pengembangan infrastruktur kendaraan listrik. Dengan meningkatnya jumlah kendaraan listrik di seluruh dunia, kebutuhan untuk menyediakan fasilitas pengisian yang efisien dan efektif menjadi sangat mendesak. Dalam hal ini, machine learning menawarkan pendekatan yang inovatif untuk mengelola dan mengoptimalkan infrastruktur ini. Dengan memanfaatkan data historis dan real-time, model machine learning mampu memberikan prediksi yang akurat mengenai permintaan pengisian listrik di berbagai lokasi, sehingga dapat membantu perencana infrastruktur dalam membuat keputusan yang lebih baik.

Salah satu contoh konkret dari penerapan machine learning dalam alokasi SPKLU dapat dilihat dalam penelitian yang dilakukan oleh Chen et al. (2021). Dalam studi ini, peneliti menggunakan algoritma XGBoost untuk memprediksi permintaan SPKLU. Hasil penelitian menunjukkan bahwa model ini mampu mencapai tingkat akurasi hingga 92%. Ini menunjukkan betapa efektifnya machine learning dalam memahami dan memprediksi pola permintaan yang kompleks. Dengan akurasi yang tinggi, perencana infrastruktur dapat merencanakan lokasi dan jumlah SPKLU yang diperlukan dengan lebih tepat, sehingga mengurangi risiko kekurangan layanan di area yang padat kendaraan listrik.

Pendekatan lain yang sering digunakan dalam penerapan machine learning adalah analisis clustering. Analisis ini berfungsi untuk mengidentifikasi pola penggunaan kendaraan listrik di suatu area tertentu. Dengan menggunakan algoritma seperti K-Means, peneliti dapat mengelompokkan area berdasarkan tingkat penggunaan kendaraan listrik dan kebutuhan SPKLU. Misalnya, penelitian yang dilakukan oleh Kim et al. (2020) menunjukkan bahwa penerapan clustering dapat meningkatkan efisiensi alokasi SPKLU hingga 25%. Dengan mengelompokkan area berdasarkan pola penggunaan, perencana infrastruktur dapat menentukan lokasi yang paling strategis untuk pembangunan SPKLU, sehingga dapat memaksimalkan penggunaan fasilitas yang ada.

Selain itu, machine learning juga berperan penting dalam memprediksi waktu puncak penggunaan SPKLU. Hal ini sangat krusial untuk menghindari kemacetan dan memastikan ketersediaan layanan bagi pengguna. Dengan menganalisis data historis, model machine learning mampu mengidentifikasi pola waktu puncak dan memberikan rekomendasi untuk penjadwalan pengisian yang lebih baik. Sebuah studi oleh Zhao et al. (2021) menunjukkan bahwa dengan menggunakan model prediktif, mereka dapat mengurangi waktu tunggu pengguna SPKLU hingga 30%. Ini merupakan pencapaian yang signifikan, mengingat waktu

tunggu yang lama sering kali menjadi salah satu kendala utama bagi pengguna kendaraan listrik dalam mengakses layanan pengisian.

Integrasi machine learning dengan Sistem Informasi Geografis (GIS) juga memberikan keuntungan tambahan dalam analisis spasial. Dengan memanfaatkan data geospasial, model machine learning dapat mempertimbangkan berbagai faktor, seperti kepadatan populasi, jarak dari SPKLU yang ada, dan infrastruktur transportasi. Penelitian oleh Wang et al. (2018) menunjukkan bahwa kombinasi GIS dan machine learning dapat meningkatkan akurasi pemodelan alokasi SPKLU hingga 20% dibandingkan dengan metode yang hanya menggunakan data non-spasial. Hal ini menunjukkan pentingnya pendekatan holistik dalam merencanakan infrastruktur pengisian kendaraan listrik, di mana faktor-faktor geografis dan demografis dapat memberikan wawasan yang lebih mendalam tentang kebutuhan pengguna.

Secara keseluruhan, penerapan machine learning dalam sistem alokasi SPKLU menawarkan solusi yang inovatif dan efisien untuk memenuhi kebutuhan pengisian kendaraan listrik. Dengan memanfaatkan data yang ada, teknologi ini tidak hanya membantu dalam perencanaan infrastruktur yang lebih baik, tetapi juga meningkatkan pengalaman pengguna dalam menggunakan layanan pengisian kendaraan listrik. Dalam konteks yang lebih luas, pengembangan ini juga berkontribusi pada upaya global untuk mengurangi emisi karbon dan mempromosikan penggunaan energi terbarukan, yang menjadi salah satu tujuan utama dalam menghadapi perubahan iklim.

Dengan demikian, penerapan machine learning dalam sistem alokasi SPKLU tidak hanya memberikan manfaat praktis dalam hal efisiensi dan efektivitas, tetapi juga berkontribusi pada pencapaian tujuan lingkungan yang lebih luas. Ke depan, penelitian lebih lanjut dan pengembangan teknologi ini diharapkan dapat terus berlanjut, sehingga dapat memberikan solusi yang lebih baik dan lebih inovatif dalam pengelolaan infrastruktur pengisian kendaraan listrik.

3. Tantangan dalam Penerapan Machine Learning

Meskipun penerapan machine learning (ML) dalam alokasi Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) menawarkan banyak keuntungan, terdapat berbagai tantangan signifikan yang harus dihadapi oleh para peneliti dan praktisi. Tantangan-tantangan ini tidak hanya berhubungan dengan aspek teknis, tetapi juga melibatkan dimensi etika, sumber daya, dan interpretasi hasil. Dalam konteks ini, mari kita telaah lebih dalam berbagai tantangan yang dihadapi dalam penerapan machine learning, termasuk kualitas dan ketersediaan data, kompleksitas model, kebutuhan sumber daya komputasi, serta isu privasi dan keamanan data.

Salah satu tantangan utama yang dihadapi dalam penerapan machine learning adalah kualitas dan ketersediaan data. Data merupakan fondasi dari setiap model machine learning, dan tanpa data yang baik, hasil yang dihasilkan akan sangat meragukan. Data yang tidak lengkap, tidak akurat, atau tidak konsisten dapat mengakibatkan model yang buruk dan hasil prediksi yang tidak dapat diandalkan. Sebagai contoh, dalam konteks SPKLU, jika data yang digunakan untuk melatih model tidak mencakup semua variasi dalam perilaku pengguna atau kondisi lingkungan, maka model tersebut mungkin tidak dapat memprediksi dengan akurat permintaan pengisian daya di lokasi tertentu. Menurut penelitian oleh Zhang et al. (2020), sekitar 30% dari data yang digunakan dalam analisis SPKLU memiliki masalah kualitas, yang dapat mempengaruhi hasil akhir. Ketidakkuratan ini dapat berujung pada keputusan yang salah dalam alokasi sumber daya, yang pada gilirannya dapat memengaruhi efisiensi operasional dan kepuasan pelanggan.

Selanjutnya, kompleksitas model juga menjadi tantangan yang signifikan. Beberapa algoritma machine learning, terutama neural networks, dapat menjadi sangat kompleks dan sulit untuk diinterpretasikan. Hal ini dapat menyulitkan pengambil keputusan untuk memahami dan mempercayai hasil yang dihasilkan oleh model. Misalnya, ketika model neural network digunakan untuk memprediksi permintaan pengisian daya, hasil yang diperoleh mungkin sulit untuk dijelaskan kepada pemangku kepentingan yang tidak memiliki latar belakang teknis. Penelitian oleh Doshi-Velez dan Kim (2017) menunjukkan bahwa interpretabilitas model adalah faktor penting dalam penerapan machine learning di berbagai bidang, termasuk energi dan transportasi. Tanpa pemahaman yang jelas tentang bagaimana dan mengapa model mencapai keputusan tertentu, kepercayaan terhadap teknologi ini dapat berkurang, yang pada akhirnya dapat menghambat adopsi lebih lanjut.

Selain itu, kebutuhan akan sumber daya komputasi yang besar juga menjadi kendala dalam penerapan machine learning. Model yang lebih kompleks sering kali memerlukan waktu pelatihan yang lebih lama dan perangkat keras yang lebih kuat. Hal ini dapat menjadi hambatan bagi organisasi yang memiliki anggaran terbatas. Sebagai contoh, sebuah perusahaan kecil yang ingin menerapkan machine learning untuk mengoptimalkan alokasi SPKLU mungkin tidak memiliki sumber daya untuk membeli server canggih atau menyewa layanan cloud yang mahal. Penelitian oleh Amodeo et al. (2021) menunjukkan bahwa penggunaan cloud computing dapat membantu mengatasi masalah ini dengan menyediakan sumber daya komputasi yang dibutuhkan untuk pelatihan model machine learning. Dengan memanfaatkan cloud computing, organisasi dapat mengakses sumber daya yang lebih besar tanpa harus

melakukan investasi awal yang besar, sehingga memungkinkan mereka untuk bersaing dengan perusahaan yang lebih besar.

Tantangan terakhir yang perlu diperhatikan adalah masalah privasi dan keamanan data. Dalam pengumpulan dan analisis data pengguna, terdapat risiko pelanggaran privasi yang dapat mengurangi kepercayaan publik terhadap penggunaan teknologi ini. Dalam konteks SPKLU, data pengguna dapat mencakup informasi sensitif seperti lokasi pengisian daya dan pola penggunaan. Menurut penelitian oleh Zuboff (2019), penting untuk menerapkan kebijakan dan praktik yang transparan dalam pengelolaan data untuk memastikan bahwa hak privasi individu tetap terjaga. Misalnya, jika pengguna merasa bahwa data mereka tidak dikelola dengan baik atau disalahgunakan, mereka mungkin enggan menggunakan layanan pengisian daya yang ditawarkan. Oleh karena itu, penting bagi organisasi untuk mengembangkan kebijakan privasi yang jelas dan memberikan jaminan kepada pengguna bahwa data mereka akan digunakan dengan cara yang etis dan bertanggung jawab.

Dengan memahami tantangan-tantangan ini, para peneliti dan praktisi dapat mengembangkan strategi yang lebih baik untuk menerapkan machine learning dalam alokasi SPKLU. Penelitian lebih lanjut diperlukan untuk mengatasi masalah kualitas data, interpretabilitas model, kebutuhan sumber daya, dan privasi. Dengan mengatasi tantangan-tantangan ini, penerapan machine learning dapat memberikan manfaat yang maksimal, tidak hanya bagi organisasi tetapi juga bagi masyarakat secara keseluruhan. Dalam kesimpulan, tantangan dalam penerapan machine learning adalah hal yang kompleks dan multidimensional, dan memerlukan pendekatan yang holistik untuk mengatasi setiap aspek secara efektif.


2.2.6 Multi Layer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan salah satu bentuk dari jaringan saraf tiruan yang terdiri atas sejumlah lapisan neuron (simpul) yang disusun secara berurutan dalam bentuk hierarki. MLP termasuk ke dalam arsitektur jaringan saraf yang paling umum dan sering diaplikasikan, khususnya dalam pembelajaran terawasi seperti proses klasifikasi maupun regresi. Secara umum, MLP memiliki satu lapisan input, satu atau lebih lapisan tersembunyi (hidden layer), serta satu lapisan output. Jika sebuah MLP memiliki banyak hidden layer, maka arsitektur tersebut dikategorikan sebagai Deep Neural Network (DNN) (Aggarwal, n.d., 2021)

Konsep utama dalam pengoperasian MLP terletak pada penggunaan algoritma backpropagation, yang berfungsi sebagai metode utama untuk proses pelatihan jaringan. Pada tahapan ini, bobot dan bias jaringan diperbarui dengan cara menyebarkan kesalahan dari lapisan output kembali ke lapisan input secara berulang. Melalui proses ini, parameter-

parameter jaringan dioptimalkan secara bertahap agar model mampu memberikan prediksi yang semakin akurat seiring pelatihan (Aggarwal, n.d.).

Ilustrasi arsitektur MLP berikut menggambarkan sebuah jaringan dengan dua node input, satu hidden layer yang terdiri dari empat neuron, serta tiga neuron di lapisan output. Dalam visualisasi ini, bias juga ditampilkan meskipun dalam praktiknya seringkali dianggap sebagai elemen implisit. Setiap lapisan (kecuali output layer) memiliki satu neuron bias yang terhubung secara penuh ke lapisan selanjutnya. Arsitektur ini merepresentasikan jaringan feedforward neural network (FNN), karena sinyal hanya bergerak satu arah, yaitu dari input menuju output.



Gambar 2.1 Arsitektur Multi-Layer Perceptron (MLP)

(Sumber : diadaptasi dari Zhang et al., 2021)

Sebuah jaringan saraf tiruan seperti Multilayer Perceptron (MLP) dapat diibaratkan seperti bayi yang baru lahir dan belum memiliki pengetahuan apa pun. Seiring berjalannya waktu, seorang bayi belajar dan mulai memahami lingkungan di sekitarnya. Hal serupa juga terjadi pada MLP—melalui proses pelatihan menggunakan data, model ini diharapkan mampu melakukan prediksi dengan tingkat kesalahan yang seminimal mungkin.

Dalam perjalanannya, banyak ilmuwan mengalami kesulitan dalam menemukan metode yang efektif untuk melatih MLP. Baru pada tahun 1986, tiga peneliti yaitu David Rumelhart, Geoffrey Hinton, dan Ronald Williams memperkenalkan pendekatan backpropagation atau propagasi balik, yang kemudian menjadi teknik utama dalam pelatihan jaringan saraf dan masih digunakan hingga saat ini.

Menurut Aurélien Géron dalam bukunya, backpropagation dapat dijelaskan sebagai bentuk dari algoritma gradient descent yang dioptimalkan dengan cara efisien untuk

menghitung gradien hanya melalui dua tahap utama: satu proses maju (forward pass) dan satu proses mundur (backward pass). Algoritma ini menghitung gradien error jaringan dengan mempertimbangkan semua parameter dalam model, sehingga memungkinkan penyesuaian bobot dan bias secara akurat untuk meminimalkan kesalahan. Setelah gradien diperoleh, proses dilanjutkan dengan penerapan gradient descent, dan seluruh siklus ini diulang hingga jaringan mencapai hasil konvergen terhadap solusi yang optimal.

Struktur MLP terbagi menjadi tiga komponen utama:

1. Input Layer

- 1.1 Lapisan pertama yang menerima fitur-fitur input dari data.
- 1.2 Jumlah neuron = jumlah fitur dalam dataset (misal: jumlah piksel, atribut geografis, jarak, dll).

2. Hidden Layer

- 2.1 Satu atau lebih lapisan tersembunyi.
- 2.2 Masing-masing neuron di hidden layer melakukan operasi:
$$z = w \cdot x + bz = w \cdot x + bz = w \cdot x + b \dots\dots\dots (2.1)$$
 dan dilanjutkan dengan fungsi aktivasi:
$$a = f(z) a = f(z) a = f(z) \dots\dots\dots (2.2)$$
- 2.3 Fungsi aktivasi umum: ReLU, Sigmoid, Tanh.

3. Output Layer

- 3.1 Lapisan akhir yang memberikan hasil prediksi.
- 3.2 Fungsi aktivasi output bergantung pada jenis tugas:
 - 3.2.1 Softmax / Sigmoid untuk klasifikasi.
 - 3.2.2 Linear untuk regresi.

Ilustrasi perhitungan manual Multi-Layer Perceptron (MLP) :

Variabel input (X):

X_1 : Populasi Miskin

X_2 : Jumlah Kendaraan Bermotor

X_3 : Kepadatan Penduduk

X_4 : Jumlah RT

X_5 : Populasi Minoritas

X_6 : Indeks Pendidikan

X_7 : Total Populasi

X_8 : Pengangguran

X_9 : Pengeluaran per Kapita

X_{10} : Persentase Miskin

X_{11} : Jumlah Individu Usia Produktif

Data Sampel (diambil dari dataset)

Untuk memudahkan perhitungan manual, nilai dinormalisasi sederhana (0–1).

Dataset 1

Variabel	Nilai	Variabel	Nilai
KDE	2	X_6	69.14
X_1	204500	X_7	40845
X_2	307404	X_8	142818
X_3	3.196	X_9	12500000
X_4	14296	X_{10}	4.8
X_5	164728	X_{11}	2354038

Normalisasi dataset

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Variabel	Norm	Variabel	Norm
KDE	0.5	X_6	0.6
X_1	0.4	X_7	0.1
X_2	0.7	X_8	0.7
X_3	0.005	X_9	0.4
X_4	0.1	X_{10}	0.3
X_5	0.6	X_{11}	0.6

1. Arsitektur MLP yang digunakan

1. Input layer : 11 neurons ($X_1 - X_{11}$)

2. Hidden layer : 1-layer dengan 2 neuron
3. Output layer : 1 neuron (KDE)
4. Fungsi aktivasi hidden: Sigmoid
5. Fungsi aktivasi output: Linear

Struktur: 11-2-1

2. Asumsi Bobot dan Bias

Bobot Input → Hidden

1. Semua bobot ke Hidden-1 = 0.10
2. Semua bobot ke Hidden-2 = 0.05
3. Bias hidden = 0.20

Bobot Hidden → Output

1. $w_1 = 0.7$
2. $w_2 = 0.3$
3. Bias output = 0.10

3. Forward Propagation

Langkah 1: Penjumlahan Input

$$\sum X = 0.4 + 0.7 + 0.005 + 0.1 + 0.6 + 0.6 + 0.1 + 0.7 + 0.4 + 0.3 + 0.6 = 4.505$$

Langkah 2: Hidden Layer

1. Hidden Neuron 1

$$z_1 = (4.505 \times 0.10) + 0.20 = 0.6505$$

2. Hidden Neuron 2

$$z_2 = (4.505 \times 0.05) + 0.20 = 0.42525$$

Langkah 3: Aktivasi Sigmoid

$$h_1 = \frac{1}{1 + e^{-0.6505}} \approx 0.657$$

$$h_2 = \frac{1}{1 + e^{-0.42525}} \approx 0.605$$

Langkah 4: Output Layer (Linear)

$$\hat{KDE} = (0.657 \times 0.7) + (0.605 \times 0.3) + 0.10$$
$$\hat{KDE} = 0.460 + 0.182 + 0.10 = 0.742$$

4. Asumsi Skema Normalisasi KDE

Karena KDE kelas = {1, 2, 3}, maka normalisasi:

$$KDE_{norm} = \frac{KDE - 1}{3 - 1}$$

Sehingga:

1. KDE = 1 $\rightarrow$ 0,0
2. KDE = 2 $\rightarrow$ 0,5
3. KDE = 3 $\rightarrow$ 1,0

5. Denormalisasi Output MLP

Output MLP = 0,742

$$KDE_{pred} = (0,742 \times (3 - 1)) + 1$$

$$KDE_{pred} = (0,742 \times 2) + 1$$

$$KDE_{pred} = 1,484 + 1 = 2,484$$

6. Prediksi nilai KDE MLP

$$KDE_{act} = 2$$

$$KDE_{pred} = 2,484 \approx 2 \text{ (Nearest Class)}$$

2.2.7 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan salah satu metode dalam algoritma supervised learning yang sering dimanfaatkan untuk menyelesaikan permasalahan klasifikasi maupun regresi (Guido, R. C., et al., 2024). Dibandingkan dengan metode klasifikasi lainnya, SVM memiliki landasan matematis yang kuat dan terdefinisi secara jelas. SVM dapat digunakan untuk memproses data yang bersifat linier maupun non-linier.

Algoritma ini bekerja dengan cara menemukan hyperplane optimal di dalam ruang berdimensi-N, yang dapat secara tegas memisahkan data ke dalam kategori berbeda (Jason C. Hsu., et al, 2022). Hyperplane ini berfungsi sebagai garis pemisah antara kelas-kelas data yang berbeda. Dalam konteks dua dimensi, pemisah ini berbentuk garis lurus, sedangkan dalam ruang tiga dimensi berupa bidang datar (plane) yang memisahkan data secara efektif di ruang fitur yang lebih kompleks.

Beberapa keunggulan utama dari algoritma SVM antara lain (Chapelle, O., et al. 2021):

1. Sangat berguna meskipun informasi awal mengenai data sangat minim.
2. Cocok untuk data yang tidak memiliki distribusi yang jelas atau tidak diketahui distribusinya.
3. Memiliki pendekatan kernel trick yang sangat efektif dalam menyelesaikan masalah non-linear dengan cara memetakan data ke ruang berdimensi lebih tinggi.
4. Tahan terhadap overfitting, terutama ketika terdapat margin yang jelas antara kelas-kelas data.
5. Mampu menangani data dalam dimensi yang tinggi dengan tetap mempertahankan performa.
6. Memberikan akurasi prediksi yang tinggi serta kecepatan pemrosesan yang baik.
7. Dapat digunakan pada pembelajaran semi-supervised, di mana sebagian data tidak berlabel.
8. Kompleksitas komputasi lebih efisien dibandingkan beberapa algoritma klasifikasi lainnya.
9. Tetap dapat digunakan meskipun data pelatihan mengandung bias.
10. Mendukung proses normalisasi data, yang penting untuk menjaga performa model pada skala fitur yang berbeda.

Ilustrasi perhitungan manual Support Vector Machine (SVM) :

Variabel input (X):

X_1 : Populasi Miskin

X_2 : Jumlah Kendaraan Bermotor

X_3 : Kepadatan Penduduk

X_4 : Jumlah RT

X_5 : Populasi Minoritas

X_6 : Indeks Pendidikan

X_7 : Total Populasi

X_8 : Pengangguran

X_9 : Pengeluaran per Kapita

X_{10} : Persentase Miskin

X_{11} : Jumlah Individu Usia Produktif

Data Sampel (diambil dari dataset)

Untuk memudahkan perhitungan manual, nilai dinormalisasi sederhana (0–1).

Dataset 1

Variabel	Nilai	Variabel	Nilai
KDE	2	X_6	69.14
X_1	204500	X_7	40845
X_2	307404	X_8	142818
X_3	3.196	X_9	12500000
X_4	14296	X_{10}	4.8
X_5	164728	X_{11}	2354038

Normalisasi dataset

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Variabel	Norm	Variabel	Norm
KDE	0.5	X_6	0.6

X_1	0.4	X_7	0.1
X_2	0.7	X_8	0.7
X_3	0.005	X_9	0.4
X_4	0.1	X_{10}	0.3
X_5	0.6	X_{11}	0.6

1. Asumsi 2 support vector hasil training:

$$SV_1 = [0.5, 0.6, 0.01, 0.2, 0.5, 0.5, 0.2, 0.6, 0.3, 0.2, 0.5]$$

$$SV_2 = [0.3, 0.8, 0.004, 0.1, 0.7, 0.7, 0.1, 0.8, 0.5, 0.4, 0.7]$$

2. Fungsi Kernel RBF

Kernel RBF didefinisikan sebagai:

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2)$$

Asumsi parameter:

$$\gamma = 0.5$$

3. Hitung Jarak Euclidean Kuadrat

Jarak ke Support Vector 1

$$\|x - SV_1\|^2 = (0.4 - 0.5)^2 + (0.7 - 0.6)^2 + \dots + (0.6 - 0.5)^2 \approx 0.050$$

Jarak ke Support Vector 2

$$\|x - SV_2\|^2 = (0.4 - 0.3)^2 + (0.7 - 0.8)^2 + \dots + (0.6 - 0.7)^2 \approx 0.060$$

4. Hitung Nilai Kernel RBF

Kernel terhadap SV_1

$$K_1 = \exp(-0.5 \times 0.050) = \exp(-0.025) \approx 0.975$$

Kernel terhadap SV_2

$$K_2 = \exp(-0.5 \times 0.060) = \exp(-0.030) \approx 0.970$$

5. Fungsi Keputusan SVM RBF

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y_i K(\mathbf{x}, \mathbf{SV}_i) + b$$

Asumsi parameter:

$$\alpha_1 = 0.6, y_1 = +1$$

$$\alpha_2 = 0.4, y_2 = +1$$

$$\text{Bias } b = -0.5$$

6. Hitung Nilai Keputusan

$$f(\mathbf{x}) = (0.6 \times 1 \times 0.975) + (0.4 \times 1 \times 0.970) - 0.5$$

$$f(\mathbf{x}) = 0.585 + 0.388 - 0.5 = 0.473$$

7. Keputusan Klasifikasi

Aturan SVM:

Jika $f(\mathbf{x}) > 0 \rightarrow$ kelas positif

karena:

$$f(\mathbf{x}) = 0.473 > 0$$

maka data diklasifikasikan ke kelas KDE target (kelas 2)

2.2.8 Evaluasi Model

Evaluasi model merupakan langkah penting dalam pengembangan sistem berbasis machine learning, termasuk dalam model alokasi Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) (Géron, A., 2022). Dalam konteks ini, evaluasi bertujuan untuk mengukur seberapa baik model dalam melakukan prediksi dan alokasi lokasi SPKLU yang optimal. Beberapa metrik yang umum digunakan untuk mengevaluasi kinerja model adalah Precision, Accuracy, Recall, dan F1 Score (owers, D. M. W., 2021). Metrik-metrik ini memberikan gambaran yang komprehensif mengenai efektivitas model, terutama dalam konteks klasifikasi.

Berikut beberapa metrik evaluasi model (Ioannis Markoulidakis, et al, 2021):

1 Precision

Precision merupakan perbandingan antara jumlah prediksi positif yang benar terhadap keseluruhan prediksi yang diklasifikasikan sebagai positif. dengan jumlah seluruh prediksi positif yang dihasilkan oleh model atau mengukur seberapa akurat prediksi positif model (berapa banyak yang benar dari semua yang diprediksi positif) (Géron, A., 2022). Dalam konteks alokasi SPKLU, precision dapat diartikan sebagai proporsi lokasi yang diprediksi sebagai lokasi SPKLU yang benar-benar sesuai untuk pembangunan. Misalnya, jika model memprediksi bahwa 10 lokasi layak untuk SPKLU, tetapi hanya 6 dari lokasi tersebut yang benar-benar layak, maka precision model adalah 0.6 atau 60%. Precision yang tinggi menentukan bahwa model mempunyai kemampuan yang baik dalam menghindari false positives, yang dapat menghemat sumber daya dan biaya dalam pembangunan infrastruktur SPKLU [(Sokolova & Lapalme, 2009)]. Metrik tersebut dapat dihitung dengan rumus :

$$Precision = \frac{TP}{TP+FP} \cdot \dots\dots\dots(2.3)$$

Berikut beberapa alasan penggunaan evaluasi model precision ini adalah :

1. Presisi sangat penting saat prediksi positive (False Positif) dapat menimbulkan konsekuensi yang signifikan.
2. Dalam penerapan pada SPKLU, apabila sistem menyatakan suatu lokasi “layak” padahal sebenarnya “tidak layak”, maka bisa terjadi pembangunan infrastruktur yang tidak efektif dan efisien, pemborosan anggaran, serta potensi ketidakpuasan pengguna.
3. Model ini baik digunakan ketika lebih aman untuk tidak merekomendasikan suatu lokasi sama sekali daripada menyarankan lokasi yang ternyata tidak tepat.

2 Accuracy

Accuracy adalah ukuran yang menunjukkan seberapa besar proporsi prediksi yang tepat dibandingkan dengan seluruh prediksi yang dihasilkan oleh model, atau dapat dikatakan sebagai tingkat keberhasilan model dalam menghasilkan prediksi yang benar dari total jumlah prediksi yang dilakukan. Metrik ini dihitung dengan rumus:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(2.4)$$

di mana TP ialah true positive, TN merupakan true negative, FP ialah nilai false positive, dan FN merupakan false negative. Dalam konteks alokasi SPKLU, accuracy memberikan gambaran umum tentang seberapa baik model dalam mengklasifikasikan lokasi yang layak dan tidak layak. Misalnya, jika dari 100 lokasi yang diuji, 80 lokasi diklasifikasikan dengan benar, maka accuracy model adalah 80%.

Adapun alasan penggunaan model accuracy :

1. Menunjukkan kinerja umum dari model secara keseluruhan.
2. Akurasi efektif apabila distribusi kelas pada dataset relatif seimbang, yaitu jumlah data positif dan negatif hampir sama.
3. Pada proses awal evaluasi model akurasi sering digunakan sebagai tolak ukur utama untuk melihat frekuensi keberhasilan model dalam memprediksi yang benar.

3 Recall

Recall, atau sensitivitas, merupakan metrik untuk mengukur kemampuan model dalam menemukan semua instance positif yang benar atau dengan kata lain mengukur seberapa banyak data positif yang berhasil diklasifikasikan dengan benar. Dalam konteks alokasi SPKLU, recall menunjukkan seberapa banyak lokasi layak yang berhasil diidentifikasi oleh model dibandingkan dengan total lokasi layak yang ada. Rumus untuk recall adalah:

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(2.5)$$

Misalnya, jika terdapat 50 lokasi layak dan model berhasil mengidentifikasi 40 lokasi, maka recall model adalah 0.8 atau 80%. Recall yang tinggi sangat penting dalam konteks ini karena dapat memastikan bahwa sebagian besar lokasi yang layak untuk SPKLU tidak terlewatkan dalam proses alokasi [(Davis & Goadrich, 2006)].

Berikut yang menjadikan alasan dalam penggunaan evaluasi model Recall :

1. Recall sangat bermanfaat ketika perlu meminimalkan terjadinya kesalahan False Negative (FN).

2. Pada kasus SPKLU, False Negative menunjukkan bahwa model tidak berhasil mendeteksi lokasi yang sesungguhnya layak, sehingga lokasi tersebut tidak diprioritaskan untuk pembangunan SPKLU, meskipun memiliki potensi besar.
3. Nilai recall yang tinggi menjamin bahwa lokasi yang seharusnya dipertimbangkan tidak terlewat, terutama wilayah dengan potensi pengguna kendaraan listrik yang tinggi.

4 F1 Score

F1 Score merupakan metrik evaluasi yang menyatukan nilai precision dan recall ke dalam satu indikator tunggal. Metrik ini sangat berguna untuk memberikan penilaian yang lebih seimbang terhadap performa model, terutama saat terjadi kompromi antara precision dan recall. F1 Score merupakan rata-rata harmonik dari kedua metrik tersebut, dan digunakan untuk menggambarkan keseimbangan model dalam mengidentifikasi kelas positif secara tepat dan menyeluruh. Nilai F1 Score dihitung dengan rumus sebagai berikut:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.6)$$

Metrik ini sangat berguna dalam konteks alokasi SPKLU, di mana baik precision maupun recall sama-sama penting. Misalnya, jika model memiliki precision 0.6 dan recall 0.8, maka F1 Score-nya adalah 0.68. F1 Score yang tinggi menunjukkan bahwa model tidak hanya mampu mengidentifikasi lokasi yang layak, tetapi juga melakukannya dengan akurasi yang baik [(Saito & Rehmsmeier, 2015)].

Adapun alasan penggunaan model F1 Score berikut :

1. F1 Score berfungsi untuk mencerminkan keseimbangan antara precision dan recall.
2. F1 sangat relevan dalam konteks ini karena kita tidak hanya ingin memaksimalkan presisi (menghindari rekomendasi salah), tetapi juga recall (agar tidak melewatkan lokasi potensial).
3. Dengan model F1 score, kita bisa menilai apakah model mampu menjaga keseimbangan antara tidak terlalu “berani” dan tidak terlalu “hati-hati” dalam menghindari kesalahan.

2.3 Flowchart

Flowchart merupakan gambaran berbentuk suatu grafik yang disertai langkah-langkah dan urutan suatu prosedur dari suatu program (Malabay, 2016). Flowchart dapat membantu proses analisis, perancangan dan pengkodean untuk memecahkan masalah kedalam bagian-bagian yang lebih kecil untuk pengoperasiannya. Flowchart biasanya mempermudah penyelesaian suatu masalah pada evaluasi lebih lanjut. Pengertian lain Flowchart dapat dikatakan sebuah diagram dengan simbol-simbol grafis yang menyatakan aliran proses yang menampilkan beberapa langkah-langkah yang disimbol-kan atau dapat diartikan sebagai penggambaran secara grafik dari langkah-langkah atau urutan-urutan dari suatu prosedur program yang mempunyai fungsi tertentu. Fungsi Flowchart di-gunakan untuk memberikan gambaran suatu proses produksi agar mudah dipahami dan mudah dilihat berdasarkan urutan langkahnya dari proses yang satu ke proses yang lainnya. Selanjutnya memberikan kesederhanaan pada rangkaian proses untuk memudahkan pemahaman pengguna terhadap informasi yang dibutuhkan. Adapun petunjuk pembuatan Flowchart adalah sebagai berikut:


1. Flowchart digunakan atau digambarkan dengan halaman atas ke bawah dan dari kiri ke kanan.
2. Kegiatan yang digambarkan harus dapat dimengerti oleh penggunanya.
3. Harus ada kejelasan untuk awal dan akhirnya.
4. Tahapan dari aktivitas harus diuraikan dengan menggunakan deskripsi kata kerja.
5. Tahapan langkah dari kegiatannya harus berada pada urutan yang tepat.
6. Ruang lingkup kegiatan yang berjalan harus ditelusuri dengan seksama.
7. Disarankan penggunaan simbol-simbol Flowchart yang baku.

Pada umumnya simbol-simbol Flowchart yang biasanya dipakai adalah simbol-simbol Flowchart standar seperti dibawah ini :

Tabel 2.1 Simbol-simbol Flowchart

No.	Nama	Simbol	Artinya
1.	Process		Persegi panjang pada flowchart menunjukkan langkah aliran proses yang normal pada sebuah sistem.
2.	Connector		Lingkaran dengan label pada flowchart menunjukkan adanya lompatan dalam alir proses.
3.	Terminator		Simbol berbentuk oval yang terdapat di dalam flowchart menunjukkan bagian awal dan akhir pada prosedur atau proses.
4.	Decision		Berlian atau belah ketupat pada sebuah flowchart menggambarkan percabangan pada situasi yang berbeda di alam alir proses.
5.	Data		Simbol jajar genjang di dalam flowchart menggambarkan masukan (input) dan keluaran (output) data di dalam proses atau sistem.
6.	Flow		Garis atau anak panah pada flowchart merupakan arah alur dalam prosedur atau sistem. Anak panah selalu diletakkan di antara satu simbol dan simbol lainnya.]
7.	Off page connector		Seperti namanya, simbol ini menjadi penghubung atau konektor alur pada halaman yang berbeda
8.	On page connector		Simbol yang menghubungkan alur pada satu halaman yang sama.

2.4 Kerangka Pemikiran



Gambar 2.2 Kerangka Pemikiran

1. Input

Tahap Input merupakan tahapan awal yang meliputi proses pengumpulan, identifikasi, dan persiapan data spasial yang akan digunakan dalam pemodelan lokasi SPKLU. Tahapan ini bertujuan untuk memastikan bahwa seluruh data yang digunakan relevan, akurat, dan sesuai dengan kebutuhan analisis.

Data yang dikumpulkan meliputi data spasial dari OpenStreetMap (OSM) yang digunakan untuk memperoleh informasi mengenai jaringan jalan, sebaran permukiman, apartemen, fasilitas parkir, serta berbagai amenitas seperti sekolah, rumah sakit, hotel, dan pusat perbelanjaan. Selain itu, digunakan pula data batas administrasi wilayah Provinsi Jawa Barat pada tingkat kecamatan untuk membatasi dan memfokuskan analisis pada wilayah studi.

Tahap ini juga mencakup pengumpulan data lokasi SPKLU eksisting sebagai referensi untuk mengetahui distribusi fasilitas pengisian kendaraan listrik yang telah tersedia saat ini. Data tersebut penting untuk mengidentifikasi wilayah yang masih memiliki keterbatasan akses terhadap infrastruktur pengisian daya.

Selain data spasial, digunakan pula data sosial-ekonomi (socio-economic) yang mencerminkan kondisi demografi dan ekonomi masyarakat, seperti jumlah penduduk, kepadatan penduduk, jumlah kendaraan bermotor, tingkat pengangguran, pengeluaran per kapita, dan indikator sosial lainnya. Data ini berfungsi sebagai variabel prediktor dalam proses pemodelan untuk mengidentifikasi potensi kebutuhan pembangunan SPKLU.

2. Proses

Tahap Proses merupakan tahapan pengolahan dan transformasi data spasial yang telah dikumpulkan pada tahap input agar siap digunakan dalam pemodelan. Pada tahap ini dilakukan serangkaian analisis spasial seperti *proximity analysis* untuk menghitung jarak suatu lokasi terhadap jaringan jalan, permukiman, amenitas, dan SPKLU eksisting.

Selanjutnya, data dalam format vektor dikonversi ke dalam format raster (*rasterization*) untuk menyeragamkan resolusi spasial antarvariabel. Setelah itu dilakukan proses *overlay* untuk menggabungkan berbagai layer sehingga menghasilkan informasi spasial baru yang mencerminkan kombinasi beberapa parameter.

Hasil dari proses ini kemudian diekstraksi ke dalam bentuk data tabular (data frame) yang berisi nilai piksel sebagai variabel prediktor dan variabel respon. Dataset tersebut selanjutnya dibagi menjadi data pelatihan (*training data*) dan data pengujian (*testing data*) guna mendukung proses pemodelan dan evaluasi.

3. Algoritma

Tahap Algoritma merupakan inti dari penelitian, yaitu proses pemodelan menggunakan metode *machine learning* untuk mengklasifikasikan lokasi potensial SPKLU. Pada tahap ini digunakan dua algoritma, yaitu Support Vector Machine (SVM) **dan** Multi-Layer Perceptron (MLP).

Algoritma SVM digunakan untuk membangun model klasifikasi berbasis pemisahan hyperplane optimal dengan kernel non-linear (Radial Basis Function), sehingga mampu menangkap hubungan kompleks antarvariabel. Sementara itu, algoritma MLP digunakan sebagai pendekatan jaringan saraf tiruan (*Artificial Neural Network*) yang terdiri dari beberapa lapisan (*hidden layers*) untuk mempelajari pola hubungan non-linear secara lebih mendalam.

Kedua algoritma dilatih menggunakan data pelatihan dan kemudian diuji menggunakan data pengujian untuk melihat performa klasifikasinya. Tahap ini bertujuan untuk menghasilkan model prediksi yang paling akurat dalam menentukan prioritas lokasi pembangunan SPKLU.

4. Output

Tahap Output merupakan hasil akhir dari seluruh rangkaian proses analisis dan pemodelan. Pada tahap ini dilakukan evaluasi performa model menggunakan *confusion matrix* serta metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score* untuk menentukan model terbaik.

Model dengan performa tertinggi kemudian digunakan untuk menghasilkan peta klasifikasi lokasi potensial SPKLU yang dibagi ke dalam beberapa kelas prioritas (rendah, sedang, dan tinggi). Peta hasil klasifikasi ini menjadi rekomendasi spasial yang dapat digunakan sebagai dasar pengambilan keputusan dalam perencanaan pembangunan infrastruktur kendaraan listrik secara berkelanjutan di Provinsi Jawa Barat.