

Strategi Optimasi Antrian SPKLU dengan Algoritma Genetika untuk Mengurangi Waktu Tunggu dan Ketidakseimbangan Slot

^{1*} Yuliarman Saragih, ² Resi Sujiwo Bijokangko, ³ Setiyo Budiyo, ⁴ Carolan Ignatius Saragih

¹ Program Studi Teknik Elektro, Universitas Singaperbangsa Karawang, Karawang

^{2,3} Teknik Elektro, Universitas Mercu Buana, Jakarta

³ Teknik Elektro, Sekolah Tinggi Teknologi Bina Tunggal, Bekasi

Article Info

Keyword:

Kendaraan listrik, SPKLU, Genetic Algorithm, optimasi beban, sistem antrian

Copyright © 2025 -SNTE
All rights reserved

ABSTRACT

Pertumbuhan penggunaan kendaraan listrik (EV) memicu kebutuhan akan sistem manajemen Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) yang efisien, khususnya dalam mengoptimalkan penjadwalan pengisian dan pemerataan beban antar stasiun. Penelitian ini mengusulkan penerapan *Genetic Algorithm* (GA) untuk mengoptimalkan penugasan EV ke SPKLU dengan mempertimbangkan jarak, perkiraan waktu tiba (*Estimated Time of Arrival*), kapasitas slot, dan durasi pengisian. Metode ini dibandingkan dengan pendekatan konvensional tanpa AI yang hanya mengandalkan jarak terdekat. Dataset yang digunakan bersifat sintetis, mencakup 30 EV dan 6 SPKLU dengan kapasitas slot bervariasi (5–7 slot). Simulasi dijalankan menggunakan estimasi waktu ketibaan *OpenRouteService* untuk perhitungan jarak dan waktu tempuh aktual. Hasil menunjukkan bahwa GA mampu menurunkan rata-rata waktu tunggu EV sebesar 64,4% (dari 11,8 menit menjadi 4,2 menit), mempercepat total waktu penyelesaian dari 410 menit menjadi 320 menit, serta mengurangi variansi utilisasi slot antar SPKLU sebesar 67,86%. Temuan ini membuktikan bahwa GA tidak hanya meningkatkan efisiensi operasional, testimoni waktu ketibaanpi juga pemerataan beban infrastruktur pengisian. Penelitian ini memberikan kontribusi terhadap pengembangan strategi optimasi SPKLU berbasis AI dan membuka peluang untuk penerapan realtime dengan integrasi data lalu lintas dinamis.

Corresponding Author:

Yuliarman Saragih,

Program Studi Teknik Elektro, Universitas Singaperbangsa Karawang, Karawang

Alamat Institusi.

Email: yuliarman@staff.unsika.ac.id

I. PENDAHULUAN

Perkembangan kendaraan listrik (EV) di berbagai negara, termasuk Indonesia, mengalami pertumbuhan signifikan dalam beberapa tahun terakhir seiring dengan meningkatnya kesadaran terhadap isu lingkungan dan kebutuhan akan sumber energi terbarukan [1], [2]. Pemerintah Indonesia melalui Peraturan Presiden No. 55 Tahun 2019 telah mendorong percepatan program kendaraan bermotor listrik berbasis baterai (KBLBB), termasuk penyediaan infrastruktur pendukung seperti Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) [3].

Seiring bertambahnya jumlah kendaraan listrik, tantangan baru muncul pada manajemen operasional SPKLU, khususnya terkait waktu tunggu dan pemanfaatan slot pengisian. Antrian yang panjang dapat menurunkan kenyamanan pengguna, mengurangi efisiensi operasional, dan pada akhirnya menghambat adopsi EV secara luas [4]. Tantangan ini semakin kompleks ketika mempertimbangkan faktor variabel seperti lokasi SPKLU, distribusi kendaraan, kapasitas daya, dan waktu tempuh menuju lokasi [5].

Pendekatan konvensional dalam pengelolaan antrian SPKLU umumnya mengandalkan metode *First-Come, First-Served (FCFS)* tanpa mempertimbangkan optimasi rute dan waktu kedatangan. Metode ini sering kali tidak optimal, menghasilkan waktu tunggu rata-rata yang tinggi serta distribusi beban kerja yang tidak merata antar slot pengisian [6]. Oleh karena itu, diperlukan solusi yang lebih adaptif dan cerdas untuk meminimalkan waktu tunggu dan meningkatkan utilisasi SPKLU.

Salah satu metode optimasi yang menjanjikan adalah Algoritma Genetika (Genetic Algorithm, GA), sebuah algoritma bio-inspiratif yang memanfaatkan mekanisme seleksi alam seperti reproduksi, mutasi, dan crossover. Metode ini telah banyak diaplikasikan pada optimasi infrastruktur pengisian kendaraan listrik, termasuk penentuan lokasi dan kapasitas SPKLU untuk meminimalkan waktu tunggu dan biaya transportasi pengguna [7].

Penelitian lain menunjukkan bahwa GA efektif dalam menjadwalkan slot pengisian berdasarkan matriks kejadian pengisian dan mekanisme antrian, sehingga mengurangi beban puncak dan mendistribusikan slot pengisian dengan lebih seimbang [8]. Dengan mengintegrasikan model GA ke dalam sistem manajemen antrian SPKLU, diproyeksikan akan terjadi penurunan rata-rata waktu tunggu sekaligus peningkatan efisiensi distribusi slot pengisian dibandingkan skenario tanpa optimasi.

Penelitian ini bertujuan untuk mengembangkan dan menguji sistem optimasi antrian SPKLU menggunakan Algoritma Genetika serta membandingkannya dengan metode konvensional. Evaluasi dilakukan dengan mengukur metrik seperti rata-rata waktu tunggu, total waktu penyelesaian, dan variansi pemanfaatan slot.

II. TINJAUAN PUSTAKA

A. Manajemen Antrian dan Penjadwalan di SPKLU

Adopsi kendaraan listrik (EV) meningkat pesat secara global, mendorong kebutuhan infrastruktur pengisian publik yang andal dan tersebar merata [9], [10]. Ketersediaan dan penempatan Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) berdampak langsung pada pengalaman pengguna serta laju adopsi EV [11]. Tantangan utama meliputi perencanaan kapasitas, reliabilitas, dan biaya implementasi jaringan SPKLU [12].

Operasi SPKLU dapat dimodelkan sebagai sistem antrian multi-server (beberapa slot per stasiun). Praktik umum seperti *First-Come, First-Served (FCFS)* cenderung sederhana namun rentan menghasilkan penumpukan beban pada stasiun populer, sehingga memanjangkan waktu tunggu [13], [14]. Berbagai pendekatan telah dikaji: *priority-based scheduling* untuk memprioritaskan kondisi kritis (SoC rendah) [15], *load balancing* lintas stasiun [16], dan optimasi multi-objektif yang menyeimbangkan waktu tunggu, jarak tempuh, serta utilisasi [17].

Algoritma Genetika (GA) merupakan estimasi waktu ketibaan heuristik evolusioner yang efektif untuk masalah kombinatorial berskala besar—termasuk penugasan, routing, dan penjadwalan—tanpa memerlukan informasi turunan [7], [8]. GA banyak dipakai pada *Vehicle Routing Problem (VRP)*, penjadwalan produksi, serta re-konfigurasi jaringan daya [18-20]. Dalam konteks SPKLU, GA dimanfaatkan untuk meminimalkan waktu tunggu dan meratakan beban slot, terutama saat keputusan harus mempertimbangkan waktu tempuh aktual dan antrian dinamis [21], [22].

Integrasi layanan estimasi waktu ketibaan digital seperti OpenRouteService (ORS) memungkinkan sistem mengambil jarak dan estimasi waktu ketibaan berbasis jaringan jalan aktual (bukan garis lurus), sehingga hasil optimasi lebih realistis [23], [24].

B. Penelitian Terdahulu

Penelitian terkait optimasi penugasan dan penjadwalan SPKLU telah dilakukan dengan berbagai pendekatan. Beberapa fokus pada penempatan infrastruktur, sementara yang lain pada optimasi operasional (penjadwalan dan pengelolaan antrean). Perbedaan utama antar studi terlestimasi waktu ketibaank pada model data (estimasi waktu ketibaan riil atau estimasi), pendekatan optimasi (heuristik, mestimasi waktu ketibaan, heuristik, atau eksak), serta output yang diukur (waktu tunggu, utilisasi, biaya operasional).

TABEL I
PENELITIAN TERDAHULU

Peneliti & Tahun	Fokus Penelitian	Metode	Kelebihan	Keterbatasan
Gnann et al., 2018 [11]	Kebutuhan infrastruktur pengisian cepat di masa depan	Analisis spasial & statistik	Memberikan proyeksi kebutuhan stasiun secara makro	Tidak membahas penjadwalan operasional
Zhao et al., 2019 [15]	Strategi prioritas pengisian EV	<i>Priority-based scheduling</i>	Mengurangi waktu tunggu EV dengan SoC rendah	Tidak mempertimbangkan distribusi beban lintas stasiun
Wu et al., 2020 [16]	Load balancing antar SPKLU	Algoritma <i>load balancing</i> heuristik	Mendistribusikan beban antar stasiun untuk menghindari bottleneck	estimasi waktu ketibaan dihitung statis, tidak dari estimasi waktu ketibaan riil
Wang et al., 2020 [17]	Penempatan optimal SPKLU	<i>Multi-objective optimization</i>	Menimbang biaya, jarak, dan aksesibilitas	Tidak membahas pengoperasian sehari-hari
Liu et al., 2019 [21]	Penjadwalan pengisian real-time	<i>Genetic Algorithm</i>	Mengoptimalkan waktu tunggu dan utilisasi slot	Tidak integrasikan estimasi waktu ketibaan dari layanan estimasi waktu ketibaan
Chen et al., 2020 [22]	Smart charging EV	<i>Machine Learning + GA</i>	Menggabungkan prediksi permintaan dengan optimasi penjadwalan	Butuh data historis besar, sulit diterapkan di daerah baru
Zilske et al., 2018 [24]	Integrasi OSM dan ORS untuk analisis aksesibilitas	Analisis GIS	Menyediakan estimasi waktu ketibaan berbasis jaringan jalan aktual	Tidak digunakan untuk optimasi penjadwalan EV

III. METODE PENELITIAN

Penelitian ini dirancang untuk mengembangkan dan menguji sistem optimasi penugasan kendaraan listrik (Electric Vehicle, EV) pada Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) dengan memanfaatkan informasi *Estimated Time Arrival* (estimasi waktu ketibaan) dan jarak tempuh yang diperoleh secara real-time melalui OpenRouteService (ORS). Tujuan utama penelitian adalah meminimalkan waktu tunggu dan distribusi beban antar SPKLU dengan mempertimbangkan keterbatasan jumlah slot pengisian. Sistem

dibangun menggunakan bahasa Python dengan integrasi API ORS untuk perhitungan jarak dan waktu tempuh, serta algoritma genetika (*Genetic Algorithm*, GA) sebagai metode optimasi utama.

A. Desain Penelitian

Penelitian ini menggunakan kombinasi data sintesis dan data hasil pemanggilan API OpenRouteService (ORS). Dataset sintesis dibentuk dengan menentukan parameter awal berupa titik pusat area penelitian, radius cakupan, jumlah SPKLU, dan jumlah EV. Lokasi setiap SPKLU dan EV dibangkitkan secara acak dalam radius yang telah ditentukan, dengan kapasitas slot SPKLU bervariasi antara 5–7 slot. Tingkat muatan baterai awal (State of Charge, SoC) EV dihasilkan menggunakan distribusi acak uniform pada rentang 0.1–0.9. Setelah lokasi dihasilkan, API ORS digunakan untuk menghitung jarak (km) dan Estimated Time Arrival (estimasi waktu kedatangan) setiap EV menuju seluruh SPKLU. Data ini kemudian membentuk matriks jarak/waktu yang digunakan dalam proses optimasi. Selanjutnya, data tersebut diproses untuk membentuk matriks jarak/waktu tempuh T , di mana setiap elemen t_{ij} merepresentasikan waktu tempuh dari kendaraan i menuju SPKLU j .

Model optimasi diformulasikan sebagai masalah Vehicle-to-Charger Assignment, di mana setiap kendaraan harus dialokasikan ke satu SPKLU dengan kapasitas terbatas. Fungsi objektif penelitian ini adalah meminimalkan kombinasi waktu perjalanan dan waktu tunggu total. Secara matematis, tujuan optimasi dituliskan pada persamaan (1).

$$\min Z = \alpha \sum_{i=1}^n \sum_{j=1}^m t_{ij} x_{ij} + \beta \sum_{j=1}^m W_j \quad (1)$$

Dengan x_{ij} adalah variabel biner yang menunjukkan penugasan kendaraan i ke SPKLU j , t_{ij} adalah waktu tempuh, W_j adalah waktu tunggu di SPKLU j , serta α dan β adalah bobot kepentingan perjalanan dan waktu tunggu. Kendala optimasi meliputi bahwa setiap kendaraan hanya dapat ditugaskan ke satu SPKLU, dan jumlah kendaraan yang dialokasikan ke suatu SPKLU tidak boleh melebihi kapasitas slot yang tersedia.

B. Pengumpulan dan Pembentukan Dataset

Algoritma genetika digunakan untuk mencari solusi optimal penugasan EV–SPKLU. Representasi kromosom menggunakan vektor integer yang menunjukkan ID SPKLU untuk setiap EV. Populasi awal dibentuk secara acak dan sebagian mengadopsi strategi jarak terdekat. Proses seleksi menggunakan tournament selection, crossover dilakukan dengan metode Partially Mapped Crossover (PMX), dan mutasi dilakukan dengan teknik pertukaran posisi (swap mutation). Fungsi fitness dihitung berdasarkan total waktu tempuh dan total waktu tunggu sesuai fungsi objektif. Proses evolusi berlanjut hingga mencapai generasi maksimum atau ketika konvergensi tercapai.

Evaluasi kinerja dilakukan melalui simulasi berbasis waktu diskrit yang memodelkan perjalanan, antrean, dan proses pengisian EV pada SPKLU. Pada simulasi, setiap EV bergerak menuju SPKLU yang telah ditentukan, menunggu jika slot penuh, dan melakukan pengisian hingga selesai. Waktu tunggu dihitung dari saat EV tiba hingga slot tersedia. Utilisasi slot diukur sebagai proporsi waktu penggunaan terhadap total durasi simulasi. Parameter simulasi yang digunakan dapat dilihat pada Tabel 2.

TABEL II
PARAMETER SIMULASI SPKLU

Parameter	Nilai / Rentang	Keterangan
Titik pusat area penelitian	Koordinat GPS (lat, lon)	Titik referensi pusat wilayah simulasi
Radius area penelitian	2–5 km	Jarak maksimum dari pusat untuk penempatan EV dan SPKLU
Jumlah SPKLU	6	Ditestimasi waktu ketibaan sesuai skenario uji

Kapasitas slot SPKLU	5–7 slot	Bervariasi antar SPKLU secara acak
Jumlah EV	30	Jumlah kendaraan listrik yang disimulasikan
SoC awal EV	0.1–0.9	Diacak dengan distribusi uniform
Durasi pengisian	$3 \times \text{SoC}$ menit	Sesuai aturan pengisian baterai
Waktu jeda antar EV	2 menit	Waktu transisi slot sebelum digunakan <i>EV</i> berikutnya
Sumber jarak dan estimasi waktu ketibaan	<i>API OpenRouteService</i>	Berdasarkan data jaringan jalan aktual
Algoritma optimasi	<i>Genetic Algorithm</i> (GA)	Digunakan pada skenario AI
Metode pembandingan	FCFS & NCA	Skenario tanpa AI untuk perbandingan
Generasi GA	50–100	Iterasi evolusi algoritma genetika
Ukuran populasi GA	20–50 kromosom	Jumlah solusi dalam satu populasi
Probabilitas crossover	0.8	Peluang pertukaran gen antar kromosom
Probabilitas mutasi	0.1	Peluang perubahan gen pada kromosom

Sebagai pembandingan, digunakan metode konvensional tanpa AI, yaitu First-Come-First-Served (FCFS) dan Nearest Charger Assignment (NCA). Pada metode ini, *EV* hanya dialokasikan berdasarkan kedatangan atau jarak terdekat tanpa mempertimbangkan beban SPKLU secara global. Kedua pendekatan diuji pada dataset yang sama, kemudian dibandingkan menggunakan tiga metrik: rata-rata waktu tunggu, total waktu penyelesaian, dan variansi pemanfaatan slot SPKLU.

IV. HASIL PENELITIAN

A. Ringkasan Metrik Agregat

Pengujian dilakukan pada skenario representatif menggunakan dataset sintesis dengan konfigurasi: area studi berada di zona perkotaan padat (pusat kota), radius cakupan antara 3–5 km, 30 unit Electric Vehicle (EV) yang masing-masing memiliki State of Charge (SoC) acak, serta 6 unit Stasiun Pengisian Kendaraan Listrik Umum (SPKLU) yang masing-masing memiliki kapasitas slot pengisian berbeda, yaitu 5–7 slot aktif. Seluruh percobaan dijalankan pada kondisi lingkungan simulasi yang sama, sehingga perbedaan kinerja hanya dipengaruhi oleh strategi penugasan *EV* ke SPKLU — baik menggunakan algoritma *Genetic Algorithm* (GA) maupun pendekatan konvensional tanpa optimasi AI (No-AI).

TABEL III
RINGKASAN METRIK AGREGAT

Metrik Kinerja	GA	No-AI	Efisiensi (%)
Rata-rata waktu tunggu per EV	4,2 menit	11,8 menit	64,4%
Total waktu penyelesaian (maks. finish time semua EV)	320 menit	410 menit	21,95%
Variansi utilisasi slot antar SPKLU	1,8	5,6	67,86%

Waktu tunggu dihitung sebagai selisih antara waktu kedatangan *EV* di SPKLU dan waktu dimulainya proses pengisian. Pada skenario GA, rata-rata waktu tunggu turun drastis dari 11,8 menit menjadi 4,2 menit.

Penurunan sebesar 64,4% ini menunjukkan bahwa GA secara efektif meredistribusi kendaraan ke stasiun yang lebih seimbang dalam hal antrian, walaupun terkadang memilih jalur yang sedikit lebih panjang. Hal ini penting secara operasional, karena persepsi pelanggan sering kali lebih dipengaruhi oleh lamanya menunggu daripada jarak tempuh ke stasiun.

Makespan didefinisikan sebagai waktu saat EV terakhir menyelesaikan proses pengisian. Pada simulasi ini, GA menyelesaikan semua pengisian dalam 320 menit, sedangkan metode No-AI membutuhkan 410 menit. Pengurangan sebesar 21,95% menunjukkan peningkatan throughput sistem, yang secara langsung berarti kapasitas pelayanan per satuan waktu meningkat.

Secara praktis, pengurangan makespan ini akan memberi manfaat besar bagi operator SPKLU dalam periode sibuk (peak hours), karena lebih banyak kendaraan dapat dilayani dalam rentang waktu yang sama tanpa menambah infrastruktur fisik.

Variansi utilisasi slot digunakan untuk mengukur tingkat pemerataan beban antar SPKLU. Nilai variansi yang tinggi mengindikasikan adanya stasiun yang kelebihan beban (overutilized) dan stasiun lain yang underutilized. Pada skenario GA, variansi hanya 1,8, sedangkan pada No-AI mencapai 5,6. Penurunan sebesar 67,86% menandakan distribusi beban yang jauh lebih merata, sehingga semua SPKLU digunakan secara optimal.

Distribusi yang seimbang ini juga memiliki implikasi strategis jangka panjang: mengurangi keausan berlebih pada infrastruktur tertentu, memperpanjang umur operasional peralatan, dan menghindari bottleneck yang dapat mengganggu kinerja keseluruhan jaringan.

Ketiga indikator di atas saling berhubungan. GA berhasil menekan waktu tunggu, yang kemudian berkontribusi pada penurunan makespan, dan keduanya dicapai melalui pemerataan utilisasi slot. Hasil ini memperkuat bukti bahwa optimasi berbasis mestimasi waktu ketibaan heuristik seperti GA memiliki keunggulan signifikan dalam konteks penjadwalan pengisian EV, terutama pada jaringan SPKLU dengan kapasitas terbatas.

Secara konseptual, mekanisme GA yang melakukan pencarian global dalam ruang solusi memungkinkan penugasan yang mempertimbangkan keseimbangan antrian, waktu tempuh (estimasi waktu ketibaan), kapasitas slot, dan durasi pengisian sekaligus, sehingga mampu menghindari keputusan myopic (hanya mempertimbangkan jarak terdekat) yang sering muncul pada metode konvensional.

B. Analisis kuantitatif trade-off: perjalanan vs. waktu tunggu

Implementasi GA cenderung melakukan trade-off antara waktu perjalanan (estimasi waktu ketibaan) dan waktu tunggu: GA dapat memilih menugaskan beberapa EV ke SPKLU yang secara jarak atau menit sedikit lebih jauh daripada pilihan terdekat, dengan tujuan mengurangi waktu tunggu total. Fenomena ini akan tampak pada dua indikator:

1. Rata-rata waktu perjalanan (estimasi waktu ketibaan) per EV: pada beberapa eksperimen kita mendapati nilai estimasi waktu ketibaan rata-rata untuk GA meningkat tipis (biasanya 10–20%) dibandingkan No-AI, karena beberapa EV diarahkan ke SPKLU lebih jauh untuk meratakan beban. Kenaikan ini umumnya kecil relatif terhadap pengurangan waktu tunggu.
2. Rata-rata waktu tunggu per EV: penurunan signifikan pada GA (dalam contoh: 11.8 menjadi 4.2 menit) menunjukkan bahwa biaya tambahan perjalanan seringkali lebih kecil dibandingkan pengurangan waktu tunggu yang dihasilkan. Dengan kata lain, total pengalaman pengguna (*travel time + waiting time*) umumnya membaik pada GA.

Secara metrik objektif yang dipakai oleh GA (kombinasi bobot α untuk arrival/ estimasi waktu ketibaan dan β untuk completion/finish), perbaikan tercapai karena GA meminimalkan fungsi biaya agregat yang menggabungkan komponen-komponen tersebut. Dalam situasi nyata operator dapat menyesuaikan bobot α/β untuk menekankan minimisasi waktu tunggu (mis. pelanggan sensitif terhadap antrian) atau minimisasi waktu perjalanan (mis. biaya bahan bakar/energi).

C. Analisis estimasi waktu ketibaan hasil simulasi

Estimasi waktu ketibaan hasil simulasi (lihat Gbr. 1) memvisualisasikan posisi SPKLU, posisi awal EV, dan rute yang dibentuk berdasarkan hasil penugasan. Untuk membedakan dua skenario, estimasi waktu

ketibaan dibuat berlapis: jalur dan marker hasil No-AI diberi warna merah, sedangkan jalur dan marker hasil GA diberi warna biru. Beberapa hal penting yang teramati:

1. Pola penugasan No-AI (merah): sebagian besar kendaraan memilih SPKLU yang paling dekat menurut estimasi waktu ketibaan. Secara visual terlihat kluster panah/garis menuju beberapa SPKLU populer. Kumpulan ini menyebabkan peningkatan antrean dan waktu tunggu yang tampak pada popup marker.
2. Pola penugasan GA (biru): jalur-jalur biru relatif lebih tersebar. GA menugaskan beberapa kendaraan ke stasiun yang sedikit lebih jauh sehingga beban total antar SPKLU menjadi lebih merata. Pada estimasi waktu ketibaan, hal ini terlihat sebagai distribusi marker EV yang lebih menyebar ke seluruh SPKLU, bukan terkonsentrasi.
3. Dampak rute ORS terhadap keputusan: karena ORS memberikan estimasi waktu ketibaan berbasis jaringan jalan (bukan jarak Euclidean), ada kasus di mana SPKLU yang lebih dekat secara garis lurus justru memiliki estimasi waktu ketibaan lebih besar karena kondisi jalan atau rute berbelit. GA memanfaatkan estimasi waktu ketibaan (bukan hanya jarak) sehingga estimasi waktu ketibaan menampilkan beberapa keputusan non-intuitif (lebih jauh secara jarak tetapi estimasi waktu ketibaan lebih cepat waktu tempuh), yang seringkali menguntungkan.
4. Garis rute dan visual utilitas: pada estimasi waktu ketibaan kami menyertakan popup terperinci pada setiap marker SPKLU (slot terpakai / slot total, rata-rata waktu tunggu saat itu) dan pada setiap marker EV (SoC, estimasi waktu ketibaan ke tujuan, prediksi start/finish). Hal ini membantu pembaca melihat langsung mengapa sebuah EV diarahkan ke SPKLU tertentu.



Gbr 1. Estimasi waktu ketibaan hasil simulasi

D. Pembahasan

Hasil pengujian mempunyai beberapa implikasi untuk perencanaan dan operasional SPKLU. Pertama, penggunaan GA memberikan manfaat operasional nyata pengurangan waktu tunggu dan pemerataan beban yang dapat meningkatkan kepuasan pelanggan dan mengurangi kebutuhan penambahan slot segera. Kedua, adanya trade-off sedikit peningkatan waktu perjalanan dapat diterima apabila operator atau pengguna lebih

menghargai pengurangan waktu tunggu; keputusan ini dapat dikontrol dengan mengatur bobot dalam fungsi objektif. Ketiga, integrasi estimasi waktu ketibaan berbasis ORS membuat sistem lebih realistis untuk aplikasi dunia nyata karena keputusan penugasan mempertimbangkan kondisi jaringan jalan.

Perlu dicatat bahwa hasil bergantung pada skenario simulasi (jumlah EV, distribusi posisi, kapasitas slot, bobot α/β). Dalam beberapa kondisi ekstrem (mis. semua SPKLU padat di sekeliling area, atau jumlah EV jauh melebihi total slot), perbedaan antara GA dan No-AI bisa berkurang karena keterbatasan fisik slot. Selain itu, penggunaan ORS menghendaki ketersediaan *API key* dan kuota; pada kondisi data estimasi waktu ketibaan buruk atau latency tinggi, estimasi waktu ketibaan dapat mengandung noise yang mempengaruhi optimasi.

V. PENUTUP

A. Kesimpulan

Berdasarkan hasil pengujian dan analisis simulasi sistem penjadwalan pengisian daya kendaraan listrik di SPKLU menggunakan *Genetic Algorithm* (GA) dibandingkan dengan metode konvensional tanpa AI, dapat ditarik beberapa kesimpulan sebagai berikut:

1. GA berhasil menurunkan rata-rata waktu tunggu EV sebesar 64,4% (dari 11,8 menit menjadi 4,2 menit). Hal ini menunjukkan bahwa optimasi penugasan EV ke SPKLU tidak hanya mengurangi beban antrean, testimasi waktu ketibaanpi juga meningkatkan kepuasan pengguna.
2. Dengan GA, semua proses pengisian selesai dalam 320 menit, lebih cepat 90 menit dibandingkan metode konvensional. Ini berarti sistem dapat melayani lebih banyak kendaraan dalam periode waktu yang sama.
3. GA mengurangi variansi utilisasi slot dari 5,6 menjadi 1,8, menandakan distribusi beban yang jauh lebih merata. Hal ini mengurangi risiko bottleneck dan memperpanjang umur infrastruktur.
4. Dengan mempertimbangkan estimasi waktu ketibaan (*Estimated Time of Arrival*) dan kapasitas slot secara bersamaan, GA mampu membuat keputusan yang seimbang antara jarak, waktu tempuh, dan ketersediaan fasilitas, yang tidak dapat dicapai oleh metode jarak terdekat semata.

Secara keseluruhan, penerapan GA pada sistem manajemen SPKLU terbukti memberikan keunggulan signifikan dalam efisiensi operasional dan pemerataan beban dibandingkan metode tanpa AI.

B. Saran

Berdasarkan temuan penelitian ini, beberapa saran yang dapat diberikan adalah:

1. Implementasi GA pada sistem SPKLU sebaiknya dilakukan secara realtime dengan integrasi data lalu lintas, status ketersediaan slot terkini, dan prediksi kedatangan kendaraan untuk meningkatkan akurasi keputusan.
2. Sistem dapat dikembangkan dengan integrasi API estimasi waktu ketibaan seperti *OpenRouteService* atau *Google Maps* untuk memperhitungkan kondisi lalu lintas dinamis sehingga estimasi waktu ketibaan lebih akurat.
3. Perlu dilakukan pengujian pada jumlah SPKLU dan EV yang lebih besar untuk menilai kinerja sistem dalam skala kota atau regional, termasuk skenario peak demand.
4. Selain GA, metode optimasi lain seperti Particle Swarm Optimization (PSO) atau Reinforcement Learning (RL) dapat dieksplorasi untuk membandingkan performa dan fleksibilitas pengambilan keputusan.
5. Optimasi dapat diperluas dengan mempertimbangkan tarif listrik dinamis, prioritas kendaraan darurat, serta manajemen daya berbasis beban puncak (peak shaving) untuk efisiensi energi.

REFERENSI

- [1]. IEA, "Global EV Outlook 2023," International Energy Agency, 2023.
- [2]. BloombergNEF, "Electric Vehicle Outlook 2023," Bloomberg Finance L.P., 2023.

-
- [3]. Presiden Republik Indonesia, “Peraturan Presiden Republik Indonesia Nomor 55 Tahun 2019 Tentang Percepatan Program Kendaraan Bermotor Listrik Berbasis Baterai,” 2019.
 - [4]. X. Zhang, et al., “Charging Infrastructure Planning for Promoting Electric Vehicles: An Activity-Based Approach Using GPS Data,” *Transportation Research Part C*, vol. 52, pp. 255–276, 2015.
 - [5]. H. Li, et al., “Optimal Deployment of Charging Stations for Electric Vehicles Considering Traffic and User Behavior,” *Energy*, vol. 150, pp. 735–744, 2018.
 - [6]. R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*, 2nd ed., MIT Press, 2018.
 - [7]. A. Lazari and A. P. Chassiakos, “Optimal Siting and Sizing of Electric Vehicle Charging Stations Using Genetic Algorithms,” *Applied Sciences*, vol. 13, no. 8, pp. 4867, Apr. 2023. DOI: 10.3390/app13084867
 - [8]. H. Sun, J. Lin, Z. Xu, and X. Li, “Genetic Algorithm-Based Charging Scheduling for Electric Vehicles Considering Queueing Effect,” *Energies*, vol. 15, no. 10, pp. 3827, May 2022. DOI: 10.3390/en15103827
 - [9]. IEA, “Global EV Outlook 2023,” International Energy Agency, 2023.
 - [10]. BloombergNEF, “Electric Vehicle Outlook 2023,” Bloomberg Finance L.P., 2023.
 - [11]. T. Gnann, et al., “Fast charging infrastructure for electric vehicles: Today’s situation and future needs,” *Transp. Res. Part D*, vol. 62, pp. 314–329, 2018.
 - [12]. Z. Chen, et al., “Deployment of electric vehicle charging stations: A spatial-temporal planning approach,” *Energy*, vol. 195, 2020.
 - [13]. X. Yang, et al., “Queueing Analysis and Optimization of EV Charging Stations,” *IEEE Trans. ITS*, vol. 22, no. 8, pp. 4985–4996, 2021.
 - [14]. R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*, 2nd ed., MIT Press, 2018.
 - [15]. H. Zhao, et al., “Priority-based charging strategies for EVs,” *Applied Energy*, vol. 239, pp. 390–402, 2019.
 - [16]. J. Wu, et al., “Load balancing strategy for EV charging stations,” *IEEE Access*, vol. 8, pp. 102743–102753, 2020.
 - [17]. F. Wang, et al., “Multi-objective optimization for EV charging station placement,” *IEEE Trans. Smart Grid*, 2020.
 - [18]. S. Tan, et al., “VRP with time windows based on GA,” *Procedia Computer Science*, 2022.
 - [19]. M. Gen, R. Cheng, and L. Lin, “Multi-objective GA for production scheduling,” Springer, 2021.
 - [20]. Y. Sun, et al., “GA for distribution network reconfiguration,” *IEEE Trans. Power Systems*, 2019.
 - [21]. Y. Liu, et al., “Real-time EV charging scheduling using GA,” *IEEE Access*, 2019.
 - [22]. Z. Chen, et al., “ML + GA for smart charging of EVs,” *Applied Energy*, 2020.
 - [23]. OpenRouteService, “API Documentation,” Heidelberg Institute for Geoinformation Technology, 2023.
 - [24]. M. Zilske, et al., “Using OpenStreetMap and ORS for accessibility analyses,” *J. Transport Geography*, vol. 73, pp. 72–80, 2018.