

PENERAPAN GENETIC ALGORITHM (GA) UNTUK OPTIMASI PARAMETER MODEL THEVENIN BATERAI LITHIUM

Muhammad Aminuddin^{1*}, Khenza Atthaya Namira Yulianto², Moethia Faridha³, Saiful Karim⁴

¹²³Program Studi Teknik Elektro, Fakultas Teknik, Universitas Islam Kalimantan
Muhammad Arsyad Al Banjari Banjarmasin
Jalan Trans Kalimantan, Kec. Alalak, Kab. Barito Kuala 70582, Telp. 081346354133
amin.ro.7628@gmail.com

Abstract

Accurate battery modeling is essential for improving the performance of state estimation algorithms such as State of Charge (SoC) and State of Health (SoH). The first-order Thevenin model is widely used due to its simplicity and its ability to capture the dynamic voltage behavior of lithium-based batteries. The accuracy of this model strongly depends on the selection of the internal resistance (R_i), polarization resistance (R_p), and polarization capacitance (C_p). However, these parameters are often assumed to be constant, causing the battery model to lose adaptability when the cell experiences voltage dynamics during operation. To address this limitation, this study proposes the use of a Genetic Algorithm (GA) to adaptively optimize the model parameters. The GA is designed to update the parameters when the initial values begin to produce increasing voltage estimation errors, ensuring that the parameters remain representative of the battery's actual condition. Meanwhile, offline analysis and Recursive Least Squares (RLS) are employed as comparison and validation methods. Experimental results demonstrate that the parameters optimized using GA significantly improve terminal voltage estimation accuracy, achieving a minimum RMSE of 0.005 V, outperforming both the offline method (RMSE 0.0145 V) and RLS (RMSE 0.0143 V). These findings confirm that GA effectively generates dynamic and accurate parameters, enabling the Thevenin model to better represent the battery's behavior under varying operating conditions.

Keywords: Thevenin Battery Model, Parameter Identification, Battery, Genetic Algorithm, Voltage Estimation.

Abstrak

Pemodelan baterai yang akurat merupakan komponen penting dalam meningkatkan kinerja algoritma state estimation, seperti State of Charge (SoC) dan State of Health (SoH). Model Thevenin orde pertama banyak digunakan karena sederhana namun mampu menggambarkan dinamika tegangan baterai. Akurasi model ini sangat dipengaruhi oleh pemilihan parameter resistansi internal (R_i), resistansi polarisasi (R_p), dan kapasitansi polarisasi (C_p). Namun, parameter-parameter ini sering kali dianggap konstan, sehingga model baterai tidak mampu beradaptasi terhadap perubahan kondisi yang muncul ketika tegangan mengalami dinamika selama operasi. Untuk mengatasi masalah tersebut, penelitian ini mengusulkan penggunaan Genetic Algorithm (GA) untuk mengoptimalkan parameter model secara adaptif. GA dirancang untuk

melakukan pembaruan parameter ketika nilai awal yang digunakan mulai menyebabkan peningkatan eror estimasi tegangan, sehingga parameter tetap berada pada kondisi yang representatif. Sementara itu, analisis *offline* dan *Recursive Least Squares (RLS)* digunakan sebagai metode pembandingan dan validasi. Hasil eksperimen menunjukkan bahwa parameter hasil optimasi GA secara signifikan meningkatkan akurasi estimasi tegangan, dengan RMSE minimum 0,005 V, lebih baik daripada analisis *offline* (RMSE 0,0145 V) dan RLS (RMSE 0,0143 V). Temuan ini menegaskan bahwa GA efektif menghasilkan parameter dinamis yang stabil dan akurat, sehingga model Thevenin dapat merepresentasikan perilaku baterai dengan lebih baik pada kondisi operasi yang berubah-ubah.

Kata kunci: Model Baterai Thevenin, Identifikasi Parameter, Baterai, Algoritma Genetika, Estimasi Tegangan

1. PENDAHULUAN

Peningkatan kesadaran terhadap emisi karbon dan keberlanjutan lingkungan telah mempercepat adopsi energi terbarukan, khususnya pada sektor transportasi yang kini banyak beralih menuju kendaraan listrik [1], [2]. Baterai lithium-ion (Li-ion) menjadi pusat perhatian karena menawarkan kepadatan energi yang tinggi, performa stabil, serta umur siklus yang panjang [3], [4]. Selain itu, baterai ini memiliki tingkat self-discharge rendah dan mampu bekerja pada rentang suhu yang luas, menjadikannya sangat unggul dibandingkan teknologi baterai konvensional [5]. Namun, meningkatnya penggunaan juga memunculkan tantangan terkait keamanan dan degradasi performa yang semakin menuntut pengawasan akurat terhadap karakteristik dinamis baterai [3], [6].

Keandalan *Battery Management System (BMS)* bergantung pada kemampuan dalam memperkirakan kondisi internal seperti *State of Charge (SoC)* dan *State of Health (SoH)*, yang memainkan peran kunci dalam menjaga stabilitas operasi baterai [7]. Ketidakakuratan dalam estimasi parameter dapat menyebabkan pengendalian yang salah, risiko *overcharge* atau *overdischarge*, serta mempercepat degradasi elektrokimia [8]. Karena itu, diperlukan model matematis yang mampu merepresentasikan dinamika baterai secara tepat agar BMS dapat memantau dan mengendalikan kinerja baterai secara aman. Seiring berkembangnya kebutuhan akan prediksi yang lebih akurat, integrasi model fisik dan teknik estimasi adaptif menjadi semakin penting dalam sistem *modern*.

Equivalent Circuit Model (ECM) merupakan salah satu pendekatan yang paling banyak digunakan karena mampu memberikan keseimbangan yang baik antara keakuratan dan efisiensi komputasi [9], [10]. Model Thevenin, sebagai salah satu bentuk ECM yang paling luas digunakan, terdiri atas resistansi internal, resistansi polarisasi, dan kapasitansi polarisasi yang dapat memodelkan respons dinamis transien selama proses pengisian dan pengosongan. Meskipun model ini sederhana, namun parameter model dipengaruhi oleh kondisi operasi seperti perubahan kapasitas, laju arus, perubahan nilai tegangan dan tingkat degradasi baterai [11], [12]. Kondisi operasi tersebut dapat menyebabkan penyimpangan yang signifikan apabila model tidak diperbarui secara tepat.

Sejumlah metode telah digunakan untuk mengidentifikasi parameter model Thevenin, termasuk analisis *offline* dan algoritma *Recursive Least Square (RLS)*. Pada praktiknya, baik metode analisis *offline* maupun RLS konvensional umumnya menghasilkan parameter yang dianggap konstan untuk satu rentang operasi tertentu, sehingga belum mampu menangkap perubahan karakteristik baterai secara berkelanjutan [9]. Pada penelitian [13] mencoba mengatasi keterbatasan ini dengan memvariasikan

parameter model pada beberapa titik SoC atau kondisi operasi kritis. Namun, pendekatan tersebut masih belum memberikan adaptivitas penuh karena variasi parameter tidak dilakukan secara kontinu, melainkan hanya pada interval atau kondisi tertentu. Selain itu, RLS sendiri tetap menunjukkan sensitivitas terhadap *noise*, pengaturan faktor pelupa, serta variasi beban sehingga dapat menghasilkan fluktuasi besar atau nilai parameter tidak realistis seperti resistansi negatif [8], [14], [15].

Sebagai alternatif, *Genetic Algorithm* (GA) menjadi metode optimasi evolusioner yang menjanjikan karena tidak memerlukan turunan matematis dan efektif dalam menangani permasalahan non-linear dan non-konveks [16], [17]. GA telah banyak diterapkan untuk proses kalibrasi parameter awal pada model Thevenin maupun untuk optimasi pada estimator berbasis *hybrid* seperti jaringan saraf [18], [19]. Namun, sebagian besar penerapan GA yang ada masih terbatas pada penentuan parameter statis, sehingga belum mampu memberikan pembaruan parameter yang benar-benar adaptif terhadap perubahan kondisi operasi baterai. Keterbatasan ini membuka peluang penelitian untuk mengembangkan pendekatan GA yang mampu menghasilkan parameter yang lebih representatif, stabil, dan konsisten terhadap dinamika baterai yang berubah-ubah selama proses pengujian.

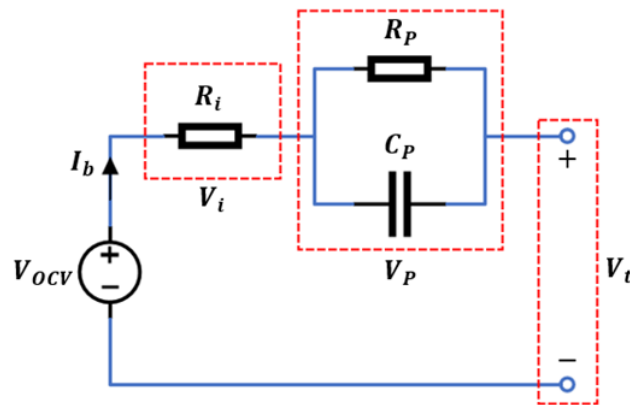
Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan metode identifikasi parameter model Thevenin yang lebih adaptif menggunakan GA. Tujuan utama riset ini adalah meningkatkan akurasi model baterai yang memungkinkan parameter model baterai Thevenin diperbarui ketika terjadi peningkatan error estimasi tegangan baterai akibat perubahan kondisi operasional baterai, sekaligus membandingkannya dengan metode analisis *offline* dan RLS sebagai *baseline*. Dengan pendekatan ini, penelitian ini diharapkan dapat memperkuat kemampuan pemodelan baterai dan mendukung pengembangan BMS yang lebih akurat, adaptif, dan andal untuk aplikasi kendaraan listrik dan sistem energi masa depan.

2. PEMODELAN BATERAI

Pemodelan baterai menggunakan pendekatan ECM banyak digunakan dalam sistem manajemen baterai karena mampu merepresentasikan dinamika tegangan secara akurat dengan struktur yang sederhana dan komputasi yang efisien [9]. Dibandingkan dengan model elektrokimia yang kompleks, ECM menawarkan keseimbangan antara akurasi dan kemudahan implementasi sehingga sesuai untuk aplikasi *real-time* pada kendaraan listrik dan sistem penyimpanan energi [4]. Dalam penelitian ini digunakan model Thevenin orde pertama, salah satu ECM yang paling umum diterapkan, karena dapat menggambarkan perilaku transien dan efek polarisasi baterai melalui kombinasi elemen resistif dan kapasitif [10]. Model Thevenin orde pertama yang digunakan dalam penelitian ini disajikan pada Gambar 1. Model ini memiliki keunggulan berupa struktur sederhana, kebutuhan komputasi rendah, serta akurasi yang memadai untuk estimasi tegangan terminal pada berbagai kondisi operasi, sehingga menjadikannya pilihan utama pada implementasi BMS

Model ini terdiri dari tiga parameter utama, yaitu R_i sebagai resistansi internal, R_p sebagai resistansi polarisasi, dan C_p sebagai kapasitansi polarisasi. Ketiga parameter tersebut merepresentasikan respons dinamis baterai, khususnya fenomena polarisasi yang muncul selama proses pengisian dan pengosongan. Nilai-nilai ini tidak diberikan secara langsung oleh pabrikan dan bersifat berubah-ubah terhadap kondisi operasi seperti suhu, arus, dan tingkat pengisian, sehingga memerlukan proses identifikasi berbasis data [11]. Persamaan matematis dari model Thevenin orde pertama dapat ditulis sebagai berikut.

$$V_{OCV}(t) - V_i(t) - V_p(t) - V_t(t) = 0 \quad (1)$$



Gambar 1. Model Thevenin orde pertama

Dengan demikian, identifikasi parameter R_i , R_p , dan C_p menjadi aspek yang sangat penting dalam pemodelan baterai, karena akurasi nilai-nilai tersebut secara langsung memengaruhi ketepatan estimasi tegangan terminal serta kinerja keseluruhan metode estimasi SoC maupun SoH.

3. METODOLOGI PENELITIAN

3.1. Analisis Offline


Metode identifikasi parameter model baterai Thevenin secara *offline* dilakukan menggunakan data hasil *pulse test discharge* yang diperoleh di laboratorium. Tujuan dari prosedur ini adalah menentukan parameter model baterai Thevenin orde pertama yang terdiri dari R_i , R_p , dan C_p . Parameter-parameter ini kemudian digunakan dalam *state estimation* seperti estimasi SoC dan SoH berbasis model. Pada pendekatan ini, hubungan tegangan terminal baterai dapat dilihat pada Persamaan (1), di mana tegangan terminal merupakan kombinasi dari tegangan rangkaian terbuka serta penurunan tegangan akibat elemen ohmik dan transien pada model Thevenin [9]. Respon tegangan baterai terhadap arus pengujian tersebut ditunjukkan pada Gambar 2.

Proses identifikasi dimulai ketika pengujian *pulse test* berakhir, yaitu pada titik 1. Kenaikan nilai tegangan sangat cepat dari titik 1 ke titik 2 mencerminkan pengaruh resistansi ohmik baterai. Kenaikan nilai tegangan secara perlahan hingga stabil dari titik 2 ke titik 3 mencerminkan respon transien yang diberikan oleh pasangan paralel resistor-kapasitor polarisasi. Nilai parameter R_i dan R_p dapat dicari berdasarkan fenomena ini menggunakan persamaan matematis sebagai berikut.

$$R_i = \frac{V_2 - V_1}{I_b} \quad (2)$$

$$R_p = \frac{V_3 - V_2}{I_b} \quad (3)$$

Setelah mendapatkan resistansi polarisasi (R_p), kapasitansi polarisasi (C_p) dapat diperoleh sebagai berikut.



Gambar 2. Grafik tegangan dan arus pada *pulse test*

Pada persamaan (4), τ merupakan konstanta waktu yang berkaitan dengan tegangan V_{12} yang dihasilkan oleh kerja rangkaian R_p - C_p . Berdasarkan Gambar 2, respons V_{12} yang muncul ketika baterai diberikan masukan berupa loncatan arus (*step input*) menunjukkan karakteristik khas sistem linear waktu-invarian (LTI) orde pertama. Pada sistem LTI orde pertama dengan masukan loncatan, konstanta waktu didefinisikan sebagai waktu yang diperlukan agar respons V_{23} mereduksi hingga sekitar 37% dari nilai awalnya. Nilai konstanta waktu tersebut dapat ditentukan melalui analisis data pengujian pulse discharge.

3.2. Recursive Least Square

Recursive Least Square (RLS) digunakan untuk mengestimasi parameter model baterai secara *online* berdasarkan hubungan linier antara arus masukan dan tegangan terminal baterai. Algoritma ini memperbarui estimasi parameter pada setiap langkah waktu sehingga dapat mengikuti perubahan karakteristik baterai secara real-time. Pengaruh data historis dikendalikan oleh *forgetting factor* (λ), di mana nilai $\lambda \approx 1$ mempertahankan kontribusi data sebelumnya, sedangkan nilai yang lebih kecil meningkatkan sensitivitas terhadap data terbaru [4], [9], [13]. Model Thevenin orde pertama dinyatakan dalam bentuk diskrit sebelum diaplikasikan pada RLS. Konversi dari bentuk kontinyu ke bentuk diskrit dilakukan menggunakan pendekatan bilinear (*Tustin's*

method), mengikuti prosedur pada studi sebelumnya [13]. Bentuk diskrit tegangan terminal kemudian ditulis sebagai berikut.

$$V(k) = -a_1V(k-1) - a_2I_b(k) - a_3I_b(k-1) \quad (5)$$

$V(k)$ merupakan selisih antara $V_t(k)$ dan $V_{OCV}(k)$, sedangkan a_0, a_1, a_2 dan a_3 merupakan parameter pada fungsi RLS untuk mendapatkan nilai parameter model baterai Thevenin orde pertama. Persamaan matematis untuk mendapatkan nilai parameter model baterai dapat ditulis sebagai berikut.

$$R_i = \frac{a_2 - a_3}{1 - a_1} \quad (5)$$

$$R_p = \frac{-2(a_1a_2 - a_3)}{(1 - a_1)^2} \quad (6)$$

$$Cp = \frac{-T(1 - a_1)^2}{4(a_1a_2 - a_3)} \quad (7)$$

Vektor regresor dan vektor parameter yang digunakan dalam algoritma RLS dirumuskan sebagai berikut.

$$\phi(k) = \begin{bmatrix} 1 \\ -V(k) \\ -I_b(k) \\ -I_b(k-1) \end{bmatrix} \quad (8)$$

$$\theta(k) = \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{bmatrix} \quad (10)$$

Langkah-langkah algoritma RLS dituliskan melalui Persamaan (11)-(15).

$$\hat{V}_t(k) = \phi(k)^T \theta(k-1) \quad (11)$$

$$e(k) = V_t(k) - \hat{V}_t(k) \quad (12)$$

$$\theta(k) = \theta(k-1) + K(k)e(k) \quad (13)$$

$$K(k) = \frac{P(k-1)\phi(k)}{\lambda + \phi(k)^T P(k-1)\phi(k)} \quad (14)$$

$$P(k) = \frac{1}{\lambda} [P(k-1) - K(k)\phi(k)^T P(k-1)] \quad (15)$$

Persamaan (7)-(11) menggambarkan proses estimasi parameter model secara rekursif menggunakan algoritma RLS. Estimasi tegangan terminal dihitung berdasarkan regresor $\phi(k)$ dan parameter sebelumnya $\theta(k-1)$, sedangkan eror estimasi diperoleh dari selisih antara tegangan terukur dan tegangan terprediksi. Nilai eror ini digunakan untuk memperbarui parameter melalui *gain* RLS yang adaptif, sebagaimana diberikan pada Persamaan (9). *Gain* dihitung menggunakan Persamaan (10), yang memperhitungkan

kovarian sebelumnya serta informasi baru dari regresor. Pembaruan matriks kovarian pada Persamaan (11) memungkinkan algoritma menyesuaikan tingkat kepercayaan parameter terhadap data baru. Dengan demikian, RLS mampu mengidentifikasi parameter model Thevenin secara *online* dan konvergen terhadap karakteristik dinamis baterai [13].

3.3. Genetic Algorithm

Genetic Algorithm (GA) merupakan metode optimasi berbasis populasi yang meniru mekanisme evolusi biologis, di mana sekumpulan solusi kandidat dikembangkan melalui proses seleksi, crossover, dan mutasi hingga diperoleh solusi dengan nilai fitness terbaik. Metode ini bersifat gradient-free dan mampu melakukan pencarian global pada ruang parameter nonlinier, sehingga banyak digunakan pada berbagai penelitian yang terkait dengan optimasi model baterai, mulai dari identifikasi parameter model fractional-order [20], pemodelan berbasis GA dengan data telemetri [21], hingga pemodelan karakteristik OCV menggunakan pendekatan evolusioner [22].

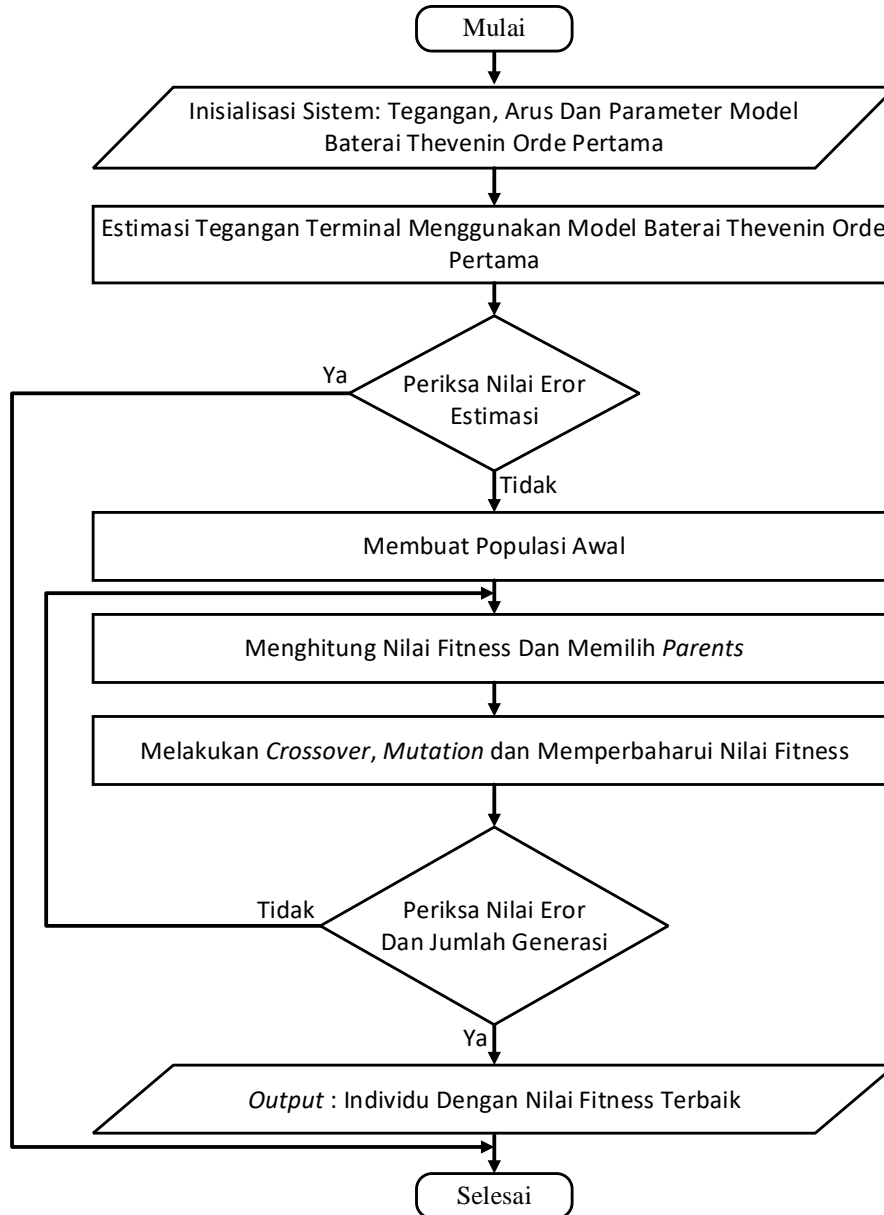
Dalam konteks penelitian ini, GA memiliki potensi yang kuat untuk mengoptimasi parameter model Thevenin orde pertama, yaitu R_i , R_p dan C_p . Ketiga parameter tersebut menentukan respons dinamis tegangan terminal terhadap perubahan arus, dan sifat hubungan yang nonlinier menjadikan GA metode yang sesuai untuk mengeksplorasi berbagai kombinasi nilai parameter dalam rentang yang ditetapkan. GA memungkinkan parameter awal yang tadinya bernilai tetap dapat diperlakukan sebagai variabel optimasi sehingga diperbarui secara iteratif hingga menghasilkan kecocokan tegangan model yang semakin baik terhadap data pengukuran. Secara umum, proses GA pada penelitian ini mengikuti tahapan klasik, mulai dari pembangkitan populasi awal, evaluasi fitness, seleksi individu terbaik, crossover, mutasi, dan pembentukan generasi baru. Alur proses GA dalam mengoptimasi parameter model baterai Thevenin orde pertama ditampilkan pada *flowchart* pada Gambar 3, yang menggambarkan keseluruhan mekanisme pembaruan parameter hingga diperoleh solusi yang optimal.

Tujuan optimasi dirumuskan melalui fungsi objektif berupa minimisasi eror antara tegangan terminal hasil estimasi model dan tegangan terminal pengukuran. Eror tersebut dihitung menggunakan *Absolute error* (AE) dari selisih kedua tegangan, sehingga parameter optimal merupakan parameter yang menghasilkan nilai AE paling kecil. Formulasi ini konsisten dengan pendekatan GA pada penelitian-penelitian sebelumnya yang menggunakan eror tegangan sebagai kriteria *fitness* [20], [21]. Untuk menjalankan proses optimasi, GA dikonfigurasi melalui beberapa parameter seperti ukuran populasi, jumlah generasi, probabilitas *crossover*, probabilitas mutasi, serta batasan nilai parameter R_i , R_p dan C_p . Konfigurasi lengkap GA yang digunakan pada penelitian ini disajikan pada Tabel 1, yang ditetapkan berdasarkan praktik umum dalam literatur [20], [21], [22], serta hasil beberapa pengujian awal untuk memperoleh keseimbangan antara beban komputasi yang ringan dan akurasi estimasi parameter yang tetap baik.

Tabel 1. Pengaturan konfigurasi GA

No.	Konfigurasi	Nilai
1	Ukuran Populasi	100
2	Laju Mutasi	0,2
3	Jumlah Parents	50
4	<i>Objective function</i>	0.012
5	Generasi Maksimal	50
6	Panjang Kromosom	16

7	Batasan Parameter	$R_i \in [0,050; 0,055]$
8	Batasan Parameter	$R_p \in [0,0001; 0,10]$
9	Batasan Parameter	$C_p \in [1; 1.000]$



Gambar 2. Diagram Alir GA

4. HASIL DAN PEMBAHASAN

Pada bagian ini disajikan hasil penelitian yang berfokus pada proses identifikasi nilai parameter model baterai Thevenin orde pertama. Identifikasi dilakukan menggunakan tiga pendekatan, yaitu analisis *offline* berbasis data uji, metode RLS, dan optimisasi berbasis GA. Setiap metode digunakan untuk memperoleh nilai parameter resistansi dan kapasitansi yang menggambarkan dinamika internal baterai dalam merespons perubahan arus dan tegangan. Parameter yang diperoleh dari masing-masing metode divalidasi melalui proses estimasi tegangan terminal menggunakan model

Thevenin. Hasil estimasi tersebut kemudian dibandingkan dengan data pengukuran aktual untuk menilai tingkat kesesuaian model. Evaluasi kinerja dilakukan dengan menghitung Root Mean Square Error (RMSE), yang digunakan sebagai indikator utama dalam mengukur akurasi estimasi tegangan terminal serta kualitas parameter yang dihasilkan. Melalui proses ini, efektivitas setiap pendekatan dalam menghasilkan parameter yang representatif dapat dianalisis secara komprehensif.

4.1. Hasil Identifikasi Parameter Model Baterai

4.1.1. Analisis Offline

Analisis *offline* dilakukan berdasarkan respon tegangan terhadap pulse test, seperti ditunjukkan pada Gambar 2. *Pulse test* dilakukan dengan interval pengosongan beban selama 30 detik dan menggunakan time sampling sebesar 0,3 detik, mulai dari SoC 100% hingga mencapai 11%. Berdasarkan pengujian tersebut diperoleh sebanyak 113 gelombang pulse, sehingga dihasilkan 113 pasangan parameter model untuk setiap siklus pulse. Nilai parameter hasil identifikasi disajikan dalam Tabel 2 sebagai ringkasan statistik yang mencerminkan karakteristik parameter resistansi dan kapasitansi.

Tabel 2. Statistik deskriptif parameter hasil analisis *offline*

Parameter	Minimal	Maksimal	Rata-rata	Rentang	Standar Deviasi
R_i	0,0475	0,0593	0,0532	0,0118	0,0019
R_p	0,0016	0,0515	0,0072	0,0499	0,0049
C_p	18,37	44.9340	92.981	44.923	14.729

Hasil identifikasi parameter model baterai Thevenin menunjukkan karakteristik yang berbeda pada masing-masing parameter. Nilai resistansi internal R_i berada pada rentang 0,0475–0,0593 Ω dengan rata-rata 0,0532 Ω dan standar deviasi 0,0019. Rentang yang sempit dan variasi yang sangat kecil mengindikasikan bahwa nilai R_i teridentifikasi secara stabil dan konsisten, sehingga parameter ini dapat merepresentasikan resistansi statis baterai dengan baik. Berbeda dengan R_i , resistansi polarisasi R_p memiliki rentang yang jauh lebih lebar, yaitu 0,0016–0,0515 Ω dengan standar deviasi 0,0049. Besarnya rentang dan variasi ini menunjukkan bahwa R_p lebih sensitif terhadap dinamika transien, perubahan beban, serta noise pengukuran, sehingga menghasilkan tingkat penyebaran parameter yang lebih tinggi. Sementara itu, kapasitansi polarisasi C_p memiliki nilai minimum 18,37 dan maksimum 44.934, dengan nilai rata-rata 92.981 dan standar deviasi 14.729.

Perbedaan yang besar antara nilai rata-rata dan rentang minimum–maksimum pada parameter C_p menunjukkan bahwa perubahan kapasitansi polarisasi bersifat tidak stabil. Ketidakstabilan ini mencerminkan karakteristik nonlinier baterai, di mana respons elektrokimia dan proses difusi ion dapat berubah secara signifikan pada kondisi beban tertentu atau pada fase pengujian yang berbeda. Akibatnya, nilai C_p menunjukkan fluktuasi yang tinggi dan menghasilkan variasi parameter yang lebih besar. Kondisi serupa juga terlihat pada parameter C_p , yang memiliki rentang dan penyebaran nilai lebih luas dibandingkan R_i . Perubahan nilai R_p dan C_p ini menunjukkan sisi nonlinier baterai yang membuat parameter-parameter tersebut sangat sensitif terhadap kondisi operasi. Sebaliknya, R_i tetap lebih stabil karena rentang perubahannya relatif kecil, menandakan bahwa resistansi internal bersifat lebih konsisten terhadap variasi arus maupun perubahan SoC.

Secara keseluruhan, hasil identifikasi dan analisis ini menunjukkan bahwa sifat nonlinier baterai tercermin secara jelas pada perubahan nilai parameter model Thevenin,

terutama pada R_p dan C_p yang menunjukkan variasi paling dinamis. Dengan demikian, memahami bagaimana parameter-parameter tersebut berubah menjadi penting untuk mendapatkan gambaran yang lebih akurat mengenai perilaku baterai serta untuk mengembangkan metode estimasi yang mampu beradaptasi terhadap perubahan kondisi baterai.

4.1.2. Recursive Least Square

Identifikasi parameter menggunakan metode RLS dilakukan secara *online* berdasarkan data arus dan tegangan yang sama dengan *pulse test*. Berbeda dengan analisis *offline* yang menghitung parameter secara terpisah untuk setiap gelombang *pulse*, metode RLS memperbarui estimasi parameter secara adaptif pada setiap sampel waktu menggunakan mekanisme pembobotan dan faktor pelupa. Proses RLS menghasilkan evolusi parameter resistansi internal dan kapasitansi model secara kontinu, hingga mencapai nilai konvergen pada kondisi *steady-state*. Nilai parameter akhir yang diperoleh dari metode ini mencerminkan hasil estimasi terbaik setelah melalui proses koreksi berulang terhadap eror prediksi. Nilai parameter hasil identifikasi disajikan dalam Tabel 3 sebagai ringkasan statistik yang mencerminkan karakteristik parameter resistansi dan kapasitansi.

Tabel 3. Statistik deskriptif parameter hasil RLS

Parameter	Minimal	Maksimal	Rata-rata	Rentang	Standar Deviasi
R_i	-0,0755	0,0591	0,0360	0,1346	0,0199
R_p	-0,0514	4.2841	0,0270	4,3355	0,1406
C_p	-19.275	72.254	30,397	26.501	1.469,6

Hasil identifikasi parameter model baterai Thevenin menggunakan metode RLS menunjukkan variasi parameter yang jauh lebih dinamis dibandingkan metode analisis *offline*. Resistansi internal R_i memiliki nilai minimum $-0,0755 \Omega$ dan maksimum $0,0591 \Omega$, dengan rata-rata $0,0360 \Omega$ dan rentang $0,1346$. Kehadiran nilai negatif pada R_i menunjukkan bahwa algoritma RLS mengalami osilasi atau *overshoot* pada beberapa titik pembaruan parameter, yang umum terjadi ketika sinyal eksitasi rendah, terdapat *noise* pengukuran, atau ketika model belum sepenuhnya konvergen pada awal iterasi. Meskipun demikian, rata-rata R_i masih positif dan berada pada orde yang wajar bagi resistansi internal baterai, menunjukkan bahwa RLS tetap mampu mengikuti dinamika parameter secara adaptif.

Resistansi polarisasi R_p menunjukkan rentang yang sangat besar, yaitu dari $-0,0514$ hingga $4,2841 \Omega$, dengan rata-rata $0,0270 \Omega$ dan standar deviasi $0,1406$. Lebarnya rentang dan munculnya nilai negatif mengindikasikan bahwa R_p sangat sensitif terhadap perubahan mendadak pada arus dan tegangan, serta terhadap *noise* selama proses identifikasi. RLS yang bersifat *real-time* memperbarui estimasi pada setiap sampel, sehingga nilai R_p dapat berfluktuasi secara signifikan terutama ketika kondisi transien terjadi. Hal ini mencerminkan sifat nonlinier baterai, di mana respon polarisasi tidak selalu mengikuti perubahan beban secara linier.

Kapasitansi polarisasi C_p juga memperlihatkan variasi yang besar, dengan nilai minimum -19.275 dan maksimum 72.254 , rata-rata 30.397 , serta standar deviasi yang sangat tinggi yaitu $1.469,6$. Nilai negatif dan penyebaran yang luas pada C_p menunjukkan bahwa parameter ini paling terpengaruh oleh dinamika nonlinier baterai dan sensitivitas tinggi dari RLS terhadap *noise*. Kapasitansi polarisasi secara fisik tidak dapat bernilai negatif, sehingga keluaran negatif ini merepresentasikan ketidakstabilan atau

ketidakmampuan RLS untuk menangkap fenomena elektrokimia secara akurat pada kondisi tertentu, terutama ketika sinyal eksitasi tidak cukup kuat atau ketika terdapat diskontinuitas pada data.

Secara keseluruhan, hasil identifikasi dengan metode RLS menunjukkan bahwa parameter model Thevenin berubah secara dinamis dan sangat dipengaruhi oleh sifat nonlinier baterai. Dibandingkan metode analisis offline yang menghasilkan parameter lebih stabil, RLS menampilkan variasi nilai yang lebih besar, terutama pada R_p dan C_p , yang menunjukkan sensitivitas tinggi terhadap kondisi operasi dan *noise* pengukuran. Temuan ini menegaskan pentingnya proses pemfilteran, pemilihan faktor pelupa, dan kualitas data pengujian untuk mencapai estimasi parameter yang lebih stabil. Selain itu, memahami pola perubahan parameter ini sangat penting agar model baterai mampu beradaptasi terhadap kondisi operasi yang berubah-ubah, serta untuk meningkatkan akurasi metode estimasi seperti Kalman Filter yang memanfaatkan parameter hasil identifikasi dinamis.

4.2. Hasil Optimasi Parameter Dan Estimasi Tegangan Terminal

Hasil identifikasi parameter menggunakan analisis *offline* dan metode RLS pada subbab sebelumnya menunjukkan bahwa nilai parameter R_p dan C_p memiliki variabilitas yang tinggi dan cenderung berubah terhadap kondisi operasi baterai. Variasi ini merupakan manifestasi dari sifat nonlinier baterai, di mana respons elektrokimia dan fenomena polarisasi tidak dapat direpresentasikan secara akurat menggunakan parameter statis. Untuk mengatasi hal tersebut, GA digunakan dengan tujuan mengoptimalkan parameter model secara adaptif, terutama ketika terjadi peningkatan error antara tegangan terminal estimasi dan tegangan terminal sebenarnya.

Pada proses ini, GA memanfaatkan nilai awal parameter hasil analisis *offline* sebagai titik awal pencarian, kemudian memperbaruinya berdasarkan nilai *fitness* yang dihitung dari error estimasi tegangan terminal. Berbeda dengan RLS yang cenderung menghasilkan sebaran parameter sangat luas dan mengandung banyak *outlier*, GA dilengkapi dengan batasan pada ruang pencarian parameter sehingga variasi yang dihasilkan tetap terkontrol. Konfigurasi ini memastikan bahwa nilai parameter tidak bergerak terlalu ekstrem, tetap berada pada rentang fisik yang masuk akal, dan tidak menghasilkan nilai negatif yang tidak realistis bagi model Thevenin. Meskipun ruang pencarian lebih terbatas, GA tetap mampu meningkatkan akurasi karena proses seleksi, *crossover*, dan mutasi mempertahankan kandidat parameter yang memberikan error minimum. Hasil optimasi parameter baterai diperlihatkan pada Gambar 3 dan Tabel 4.

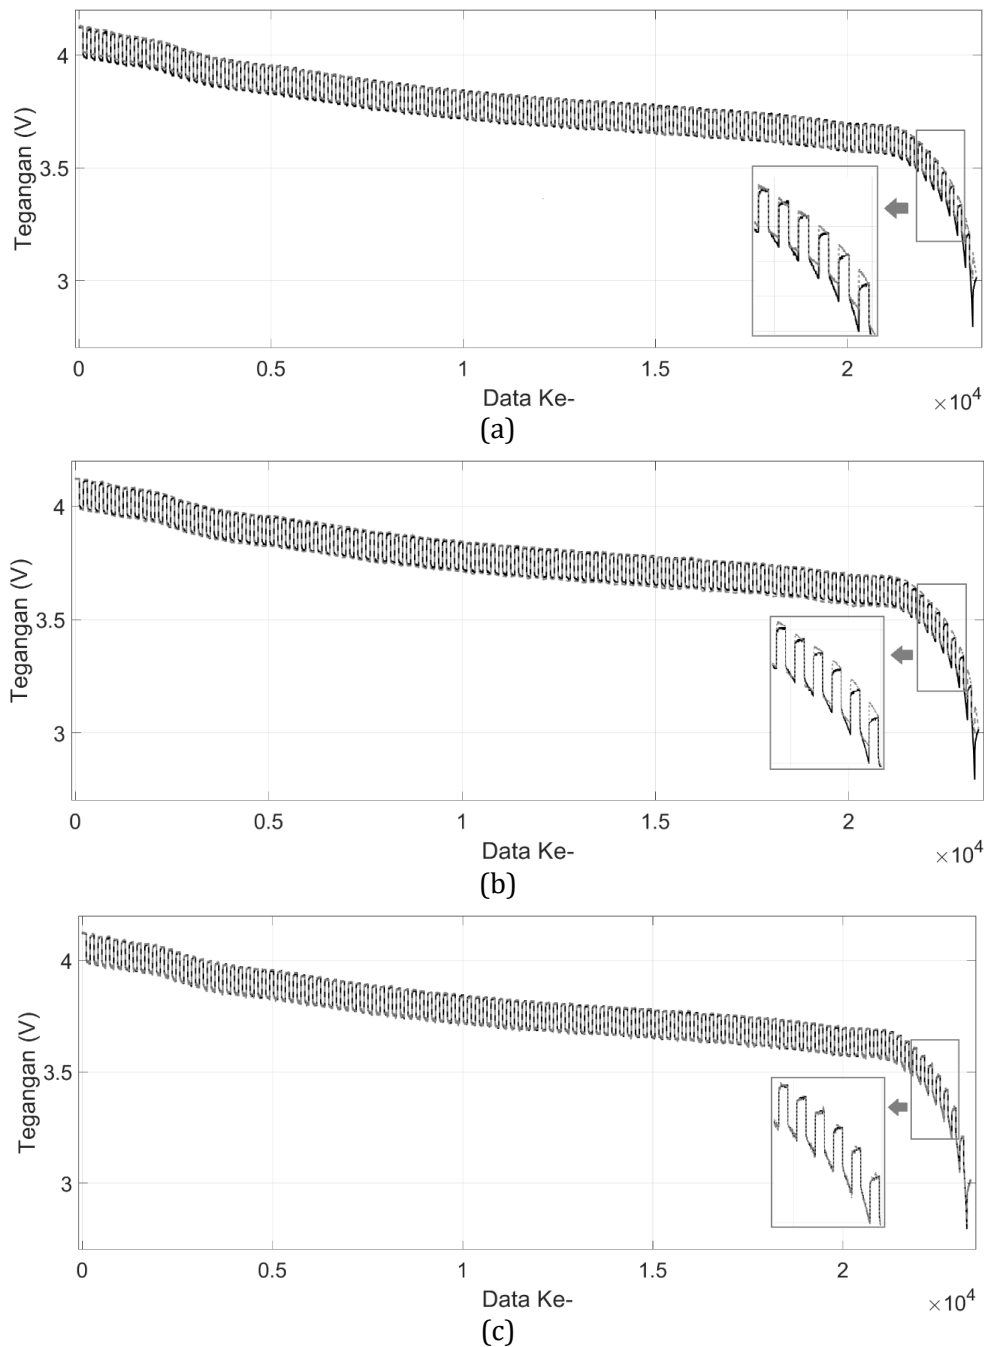
Tabel 4. Statistik deskriptif parameter hasil optimasi GA

Parameter	Minimal	Maksimal	Rata-rata	Rentang	Standar Deviasi
R_i	0,0500	0,0550	0,0517	0,0050	0,0016
R_p	0,00013	0,09988	0,0419	0,0998	0,0376
C_p	1	999	537,46	998	365,03

Hasil optimasi menunjukkan bahwa R_i berada pada rentang 0,0500–0,0550 Ω dengan rata-rata 0,0517 Ω dan standar deviasi 0,0016, yang menegaskan bahwa resistansi internal tetap menjadi parameter paling stabil. Sebaliknya, R_p memiliki rentang 0,00013–0,09988 Ω dengan standar deviasi 0,0376, dan C_p berada pada rentang 1–999 F dengan standar deviasi 365,03 F. Variabilitas R_p dan C_p tetap terlihat, namun jauh lebih teratur dibandingkan hasil RLS yang memiliki sebaran ekstrem serta nilai-nilai negatif. Hal ini menunjukkan bahwa GA mampu menjaga keseimbangan antara adaptivitas parameter dan

stabilitas nilai, sehingga parameter yang diperoleh tetap realistis secara fisik serta memberikan kemampuan representasi dinamis yang lebih baik.

Untuk mengevaluasi parameter yang diperoleh dari ketiga metode tersebut, model Thevenin dengan masing-masing parameter digunakan untuk mengestimasi tegangan terminal baterai. Hasil estimasi tersebut kemudian dibandingkan dengan tegangan terminal hasil pengukuran, dan nilai RMSE digunakan untuk menilai sejauh mana setiap metode mampu merepresentasikan perilaku baterai secara akurat. Hasil estimasi tegangan terminal disajikan pada Gambar 4.



Gambar 3. Estimasi tegangan terminal berdasarkan parameter: (a) analisis *offline*, (b) RLS, (c) Optimasi GA

Berdasarkan hasil estimasi tegangan dari ketiga metode, karakteristik performa masing-masing pendekatan menunjukkan perbedaan yang cukup jelas. Pada grafik pertama, yaitu estimasi menggunakan parameter hasil analisis offline, kurva estimasi secara umum mampu mengikuti tren tegangan sepanjang proses pengujian. Namun, pada bagian akhir terjadi peningkatan deviasi yang menunjukkan bahwa parameter yang diperoleh secara *offline* kurang adaptif terhadap perubahan kondisi baterai seiring waktu. Selanjutnya, hasil estimasi menggunakan metode RLS menunjukkan performa yang lebih responsif. Secara keseluruhan, RLS menghasilkan kurva estimasi yang mengikuti tren tegangan dengan baik, tetapi terdapat deviasi pada saat tegangan diberikan *pulse*, yang mengindikasikan adanya keterbatasan dalam menangkap dinamika cepat dari respons transien. Pada bagian akhir pengujian, deviasi kembali meningkat dengan pola yang serupa sebagaimana terlihat pada *pulse test*, menunjukkan bahwa meskipun bersifat adaptif, RLS tidak sepenuhnya mampu menyesuaikan parameter terhadap perubahan kondisi yang terjadi secara bertahap. Sementara itu, estimasi tegangan menggunakan parameter hasil optimasi GA menunjukkan kestabilan yang lebih baik baik pada awal maupun akhir pengujian. Kurva estimasi GA secara konsisten mengikuti tren tegangan tanpa peningkatan deviasi yang signifikan, menandakan bahwa proses optimasi global berhasil memperoleh parameter yang mampu merepresentasikan dinamika baterai secara lebih komprehensif. Temuan ini menunjukkan bahwa parameter hasil optimasi GA memberikan kemampuan adaptasi model yang lebih baik terhadap perubahan tegangan pada fase akhir pengujian, sebuah karakteristik yang tidak diperoleh pada dua metode lainnya.

Tabel 5. Perbandingan RMSE estimasi tegangan

Metode Identifikasi Parameter	RMSE Estimasi Tegangan
Analisis Offline	0,0145
RLS	0,0143
GA	0,0059

Secara kuantitatif, perbandingan nilai RMSE pada Tabel 5 memperlihatkan bahwa metode GA menghasilkan akurasi estimasi tegangan terbaik dengan nilai RMSE sebesar 0,0059 V. Nilai ini jauh lebih kecil dibandingkan hasil analisis *offline* yang memiliki RMSE sebesar 0,0145 V maupun RLS dengan RMSE 0,0143 V. Meskipun RLS menunjukkan performa sedikit lebih baik dibandingkan analisis *offline*, peningkatan akurasinya relatif kecil karena proses pembaruan adaptifnya masih dipengaruhi oleh noise serta ketidakstabilan parameter pada fase transien dan fase akhir pengujian. Sebaliknya, GA mampu menurunkan eror estimasi hingga lebih dari 50% dibandingkan dua metode lainnya, menandakan bahwa optimasi berbasis populasi ini tidak hanya menghasilkan parameter yang stabil secara fisik, tetapi juga paling efektif dalam meminimalkan selisih antara tegangan estimasi dan tegangan aktual. Dengan demikian, hasil kuantitatif ini memperkuat temuan sebelumnya bahwa GA memberikan tingkat representasi model Thevenin yang lebih akurat dan adaptif terhadap perubahan kondisi baterai.

5. KESIMPULAN

Berdasarkan keseluruhan hasil identifikasi parameter dan evaluasi estimasi tegangan, dapat disimpulkan bahwa masing-masing metode memiliki karakteristik performa yang berbeda dalam merepresentasikan dinamika baterai melalui model Thevenin orde pertama. Analisis *offline* menghasilkan parameter yang stabil namun kurang adaptif terhadap perubahan kondisi, terutama pada fase akhir pengujian. Metode RLS menawarkan kemampuan adaptasi yang lebih baik, tetapi masih menunjukkan deviasi

pada kondisi transien dan mengalami ketidakstabilan parameter yang berdampak pada kualitas estimasi. Sebaliknya, GA mampu menghasilkan parameter yang tidak hanya stabil secara fisik, tetapi juga memberikan akurasi estimasi tegangan paling tinggi dengan RMSE terendah, sekaligus mempertahankan kesesuaian model pada fase awal hingga akhir pengujian. Secara keseluruhan, temuan ini menunjukkan bahwa GA merupakan metode yang paling efektif dalam mengoptimalkan parameter model Thevenin untuk meningkatkan akurasi estimasi tegangan terminal, khususnya ketika model dihadapkan pada perubahan kondisi operasi baterai.

DAFTAR PUSTAKA

- [1] M.-K. Tran *dkk.*, "Environmental and Economic Benefits of a Battery Electric Vehicle Powertrain with a Zinc-Air Range Extender in the Transition to Electric Vehicles," *Vehicles*, vol. 2, no. 3, hlm. 398–412, Jun 2020, doi: 10.3390/vehicles2030021.
- [2] M.-K. Tran *dkk.*, "A comprehensive equivalent circuit model for lithium-ion batteries, incorporating the effects of state of health, state of charge, and temperature on model parameters," *Journal of Energy Storage*, vol. 43, hlm. 103252, Nov 2021, doi: 10.1016/j.est.2021.103252.
- [3] M. Elmahallawy, T. Elfouly, A. Alouani, dan A. M. Massoud, "A Comprehensive Review of Lithium-Ion Batteries Modeling, and State of Health and Remaining Useful Lifetime Prediction," *IEEE Access*, vol. 10, hlm. 119040–119070, 2022, doi: 10.1109/ACCESS.2022.3221137.
- [4] A. E. Jayasinghe, N. Fernando, S. Kumarawadu, dan L. Wang, "Review on Li-ion Battery Parameter Extraction Methods," *IEEE Access*, vol. 11, hlm. 73180–73197, 2023, doi: 10.1109/ACCESS.2023.3296440.
- [5] S. Panchal, K. Gudlanarva, M.-K. Tran, R. Fraser, dan M. Fowler, "High Reynold's Number Turbulent Model for Micro-Channel Cold Plate Using Reverse Engineering Approach for Water-Cooled Battery in Electric Vehicles," *Energies*, vol. 13, no. 7, hlm. 1638, Apr 2020, doi: 10.3390/en13071638.
- [6] Y. Wang *dkk.*, "12-A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems," *Renewable and Sustainable Energy Reviews*, vol. 131, hlm. 110015, Okt 2020, doi: 10.1016/j.rser.2020.110015.
- [7] X. Li, D. Fan, X. Liu, S. Xu, dan B. Huang, "State of health estimation for lithium-ion batteries based on improved bat algorithm optimization kernel extreme learning machine," *Journal of Energy Storage*, vol. 101, hlm. 113756, Nov 2024, doi: 10.1016/j.est.2024.113756.
- [8] N. Shi, Z. Chen, M. Niu, Z. He, Y. Wang, dan J. Cui, "State-of-charge estimation for the lithium-ion battery based on adaptive extended Kalman filter using improved parameter identification," *Journal of Energy Storage*, vol. 45, hlm. 103518, Jan 2022, doi: 10.1016/j.est.2021.103518.
- [9] M. Hossain, M. E. Haque, dan M. T. Arif, "Kalman filtering techniques for the online model parameters and state of charge estimation of the Li-ion batteries: A comparative analysis," *Journal of Energy Storage*, vol. 51, hlm. 104174, Jul 2022, doi: 10.1016/j.est.2022.104174.
- [10] M. Auch, T. Kuthada, S. Giese, dan A. Wagner, "Influence of Lithium-Ion-Battery Equivalent Circuit Model Parameter Dependencies and Architectures on the Predicted Heat Generation in Real-Life Drive Cycles," *Batteries*, vol. 9, no. 5, hlm. 274, Mei 2023, doi: 10.3390/batteries9050274.
- [11] C. Ma *dkk.*, "A Review of Parameter Identification and State of Power Estimation Methods for Lithium-Ion Batteries," *Processes*, vol. 12, no. 10, hlm. 2166, Okt 2024, doi: 10.3390/pr12102166.
- [12] H. Y. Pai, Y. H. Liu, dan S. P. Ye, "Online estimation of lithium-ion battery equivalent circuit model parameters and state of charge using time-domain assisted decoupled

- recursive least squares technique,” *Journal of Energy Storage*, vol. 62, hlm. 106901, Jun 2023, doi: 10.1016/j.est.2023.106901.
- [13] M. Aminuddin, O. Wahyunggoro, dan A. I. Cahyadi, “Improving Battery Model Accuracy Through Parameter Identification Using RLS and Pulse Test Analysis,” dalam *2024 10th International Conference on Smart Computing and Communication (ICSCC)*, Jul 2024, hlm. 438–442. doi: 10.1109/ICSCC62041.2024.10690426.
- [14] C. Ge, Y. Zheng, dan Y. Yu, “State of charge estimation of lithium-ion battery based on improved forgetting factor recursive least squares-extended Kalman filter joint algorithm,” *Journal of Energy Storage*, vol. 55, hlm. 105474, Nov 2022, doi: 10.1016/j.est.2022.105474.
- [15] X. Zhao, T. Wang, L. Li, dan Y. Cheng, “Estimation of Lithium-Ion Battery SOC Based on IFFRLS-IMMUKF,” *WEVJ*, vol. 15, no. 11, hlm. 494, Okt 2024, doi: 10.3390/wevj15110494.
- [16] C. G. Manriquez-Padilla, I. Cueva-Perez, A. Dominguez-Gonzalez, D. A. Elvira-Ortiz, A. Perez-Cruz, dan J. J. Saucedo-Dorantes, “State of Charge Estimation Model Based on Genetic Algorithms and Multivariate Linear Regression with Applications in Electric Vehicles,” *Sensors*, vol. 23, no. 6, hlm. 2924, Mar 2023, doi: 10.3390/s23062924.
- [17] T. Al Rafei, N. Yousfi Steiner, dan D. Chrenko, “Genetic Algorithm and Taguchi Method: An Approach for Better Li-Ion Cell Model Parameter Identification,” *Batteries*, vol. 9, no. 2, hlm. 72, Jan 2023, doi: 10.3390/batteries9020072.
- [18] Z. Chang dkk., “Review of SOC estimation methods for lithium battery based on EKF,” dalam *2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*, Jun 2021, hlm. 1319–1326. doi: 10.1109/IMCEC51613.2021.9482085.
- [19] E. A. Ortiz, J. Tello-Maita, D. Celeita, dan A. Marulanda Guerra, “Advanced Genetic Algorithms for Optimal Battery Siting: A Practical Methodology for Distribution System Operators,” *Energies*, vol. 18, no. 1, hlm. 109, Des 2024, doi: 10.3390/en18010109.
- [20] B. Guo, H. Sun, Z. Zhao, dan Y. Liu, “Online Parameter Identification for Fractional Order Model of Lithium Ion Battery via Adaptive Genetic Algorithm,” dalam *2023 IEEE 12th Data Driven Control and Learning Systems Conference (DDCLS)*, Xiangtan, China: IEEE, Mei 2023, hlm. 1227–1232. doi: 10.1109/DDCLS58216.2023.10166251.
- [21] A. S dan L. N, “Effect of Input Data and Parameters of Genetic Algorithm on Lithium-Ion Battery Modeling,” dalam *2023 IEEE World Conference on Applied Intelligence and Computing (AIC)*, Sonbhadra, India: IEEE, Jul 2023, hlm. 524–528. doi: 10.1109/AIC57670.2023.10263820.
- [22] S. S. Suriya Narayanan dan S. Thangavel, “Open Circuit Voltage Equation parameter identification of Lithium Ion Battery Model using Genetic Algorithm,” dalam *2020 International Conference on Inventive Computation Technologies (ICICT)*, Coimbatore, India: IEEE, Feb 2020, hlm. 1122–1127. doi: 10.1109/ICICT48043.2020.9112455.