

Sistem Estimasi *State of Charge* untuk Aplikasi Sistem Tertanam Berbasis *Neural Networks*

Muhammad Adib Kamali¹, Wansu Lim²

¹Departemen Teknologi Informasi dan Bisnis, IT Telkom Surabaya, 60231, Surabaya, INDONESIA, (tel.: +62 31 8280800; email: adibkamali@ittelkom-sby.ac.id)

²Department of Aeronautics, Mechanical, and Electronic Convergence Engineering, Kumoh National Institute of Technology, 39177, Gumi, KOREA SELATAN (tel.: +82-54-478-7489; email: wansu.lim@kumoh.ac.kr)

[Diterima: 20 Februari 2023, Revisi: 4 Mei 2023]

Corresponding Author: Muhammad Adib Kamali

INTISARI — Model estimasi *state of charge* (SOC) konvensional memiliki beberapa masalah seperti akurasi dan reliabilitas. Untuk mewujudkan estimasi SOC yang kuat pada aplikasi tertanam, makalah ini berfokus pada tiga perhatian model estimasi SOC yang ada, yaitu akurasi, ketahanan, dan kepraktisan. Pertama, dalam meningkatkan akurasi dan ketahanan estimasi, makalah ini memperhitungkan dinamika SOC aktual yang disebabkan oleh proses pengisian (*charging*) dan pengosongan (*discharging*) yang dinamis. Dalam praktiknya, proses pengisian dan pengosongan memiliki karakteristik tersendiri yang perlu diperhatikan untuk mewujudkan estimasi SOC yang *robust*. Kedua, estimasi SOC berbasis model yang dikembangkan berdasarkan model baterai virtual menimbulkan kesulitan untuk aplikasi *real-time*. Selain itu, estimasi SOC berbasis model tidak dapat diekstrapolasi secara andal ke berbagai jenis baterai. Dalam menentukan perilaku berbagai jenis baterai, estimasi SOC berbasis model harus diperbarui. Oleh karena itu, makalah ini menggunakan estimasi SOC berbasis data berdasarkan *neural networks* atau jaringan saraf tiruan (JST) dan data baterai terukur. Model JST yang memiliki kemampuan beradaptasi yang baik terhadap sistem nonlinier digunakan untuk meningkatkan akurasi. Selain itu, dengan menggunakan data baterai terukur seperti tegangan dan sinyal arus, model estimasi SOC cocok untuk aplikasi tertanam. Hasil menunjukkan bahwa memperkirakan SOC dengan model yang diusulkan dapat mengurangi kesalahan sehubungan dengan kumpulan data aktual. Untuk memvalidasi kepraktisan model yang diusulkan, makalah ini telah melakukan estimasi *online* pada sistem tertanam menggunakan mikrokontroler *real-time* C2000. Hasil menunjukkan bahwa model yang diusulkan dapat dijalankan dalam sistem tertanam dengan memanfaatkan data baterai terukur.

KATA KUNCI — JST, BMS, Sistem Tertanam, Baterai Litium, *State of Charge*.

I. PENDAHULUAN

Baterai litium (Li-ion) telah banyak diaplikasikan pada berbagai perangkat elektronik [1]. Baterai harus segera dikelola untuk memastikan operasinya aman dan memperpanjang umurnya. Tugas pengelolaan dan pemantauan baterai dapat dilakukan dengan menggunakan sistem manajemen baterai (*battery management system*, BMS) [2]. Tugas penting BMS adalah estimasi *state of charge* (SOC). Estimasi SOC baterai digunakan sebagai indikator utama kesehatan baterai [3]. SOC baterai memberikan informasi tentang jumlah siklus pengisian (*charging*) yang tersisa di baterai dan memberikan perkiraan waktu pengisian baterai. SOC adalah ukuran kapasitas yang masih dapat digunakan pada kapasitas maksimum yang tersedia. Dalam praktiknya, fungsi SOC mirip dengan pengukur bahan bakar pada kendaraan listrik (*electric vehicle*, EV) yang merupakan fungsi penting dalam memantau keadaan baterai [4]. Oleh karena itu, untuk EV dan peralatan lain yang menggunakan baterai sebagai sumber tenaga, diperlukan pendekatan estimasi SOC yang tepat.

Estimasi SOC yang akurat masih menjadi isu terbuka karena dinamika internal baterai sering kali diestimasi dengan buruk. Selain itu, berbagai kondisi pengoperasian, seperti suhu baterai, regenerasi kapasitas dinamis, dan penuaan baterai, tetap menjadi masalah yang sulit ditangani dalam mencapai estimasi SOC yang akurat. Beberapa metode estimasi SOC telah disajikan dengan berbagai pendekatan [3]-[5]. Metode estimasi SOC dapat diklasifikasikan menjadi tiga kelompok, yaitu metode dasar, metode berbasis model, dan metode estimasi berbasis data.

Metode dasar estimasi SOC menggunakan perhitungan dasar dan pemodelan sederhana untuk memperkirakan SOC baterai yang sebenarnya. Metode dasar meliputi tabel pencarian

dan metode integral ampere-jam [5]. Metode ini bergantung pada kapasitas awal dan maksimum yang tersedia. Dalam praktiknya, data tersebut tidak selalu tersedia saat baterai sudah tua. Estimasi SOC berbasis model dikembangkan berdasarkan model baterai virtual, kemudian pengamat menghasilkan serangkaian estimasi status yang sepadan dengan SOC aktual baterai. Metode estimasi SOC berbasis model meliputi model elektrokimia (*electrochemical models*, EM) [6], dan model sirkuit ekuivalen (*equivalent circuit model*, ECM) [7]. EM terdiri atas beberapa persamaan diferensial parsial (*partial differential equation*, PDE) yang digunakan untuk menggambarkan reaksi elektrokimia [7]. Namun, beberapa parameter EM tidak dapat diambil secara langsung tanpa bantuan dari produsen baterai. Dalam hal perhitungan biaya selama inferensi, penyelesaian PDE juga merupakan pekerjaan yang mahal. Aplikasi *real-time* terhambat oleh kekurangan ini. Selain itu, estimasi SOC berbasis model memanfaatkan pengamat seperti pengamat Luenberger [8], dan pengamat mode geser [9] untuk memperkirakan SOC baterai berdasarkan model baterai virtual.

Metode estimasi SOC berbasis data telah menarik banyak perhatian. Metode ini kurang rentan terhadap perubahan karakteristik baterai dan beradaptasi dengan baik pada berbagai jenis baterai. Metode estimasi berbasis data untuk estimasi SOC mengandalkan model kotak hitam. Metode ini meliputi metode *data fusion*, *neural network* (NN) [10], dan *support vector machine* (SVM) [11]. Secara khusus, model NN dikenal karena kemampuannya dalam mempelajari hubungan nonlinier yang kompleks, membuatnya sangat cocok untuk pemodelan perilaku SOC baterai yang akurat dan kuat [10]. Metode berbasis NN dan berbasis SVM mengestimasi SOC menggunakan parameter baterai (sinyal diukur dari baterai Li-

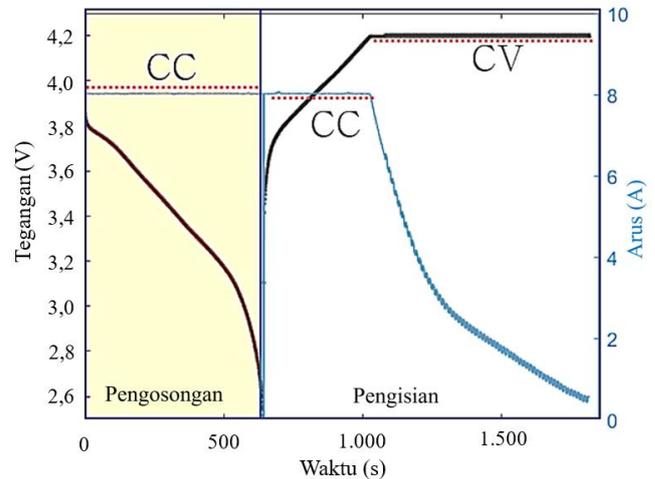
TABEL I
PROFIL PENGISIAN DAN PENGOSONGAN DARI DATASET BEXEL

Data-set	Pengisian			Pengosongan	
	Arus Konstan (A)	Tegangan Atas (V)	Arus Cut-Off (mA)	Arus Konstan (A)	Tegangan Cut-Off (V)
Sel #7	8	4,2	4,0	8	3,85
Sel #13	8	4,2	4,2	8	3,81

ion). Metode ini mempelajari hubungan nonlinier antara parameter terukur dan SOC. Hubungan antara data terukur digunakan untuk membuat model estimasi SOC. SOC dapat diestimasi menggunakan jaringan saraf tiruan (JST) pada berbagai tingkat penuaan baterai [12]. Baru-baru ini, pendekatan berbasis JST telah menarik lebih banyak minat dari komunitas ilmiah karena kapasitas komputasi unit pemrosesan grafis yang telah meningkat. Jaringan *feedforward neural network* (FNN) yang paling dasar telah digunakan untuk estimasi SOC [13]. Model JST dengan filter Kalman [14], model *recurrent neural network* [15], dan *exogenous autoregressive* dengan *input-based neural network* [16] telah digunakan untuk mengestimasi SOC.

Meskipun beberapa studi tersebut [12]-[17] telah menunjukkan efektivitas penggunaan NN untuk estimasi SOC, tantangan praktis penerapan estimasi SOC berbasis NN pada sistem tertanam belum ditangani. Penelitian yang ada terutama berfokus pada proses untuk memaksimalkan akurasi tanpa mempertimbangkan keterbatasan praktis yang mungkin dihadapi dalam aplikasi tertanam [18]. Hal ini dapat menimbulkan kesulitan saat pengimplementasian model tersebut dalam sistem tertanam *real-time*, yang tidak hanya membutuhkan akurasi tinggi, tetapi juga ketahanan dan kepraktisan. Tujuan makalah ini adalah mengatasi masalah tersebut dengan mempertimbangkan kepraktisan model yang diusulkan. Makalah ini menggunakan model NN yang dapat menangkap ketidakpastian SOC baterai dengan tetap mengutamakan kepraktisan implementasi dalam sistem tertanam.

Dalam makalah ini, model estimasi SOC yang mempertimbangkan kekhawatiran dari model estimasi SOC yang ada diusulkan. Untuk mewujudkan model estimasi SOC yang kuat dan akurat, makalah ini memperhitungkan dinamika SOC aktual yang disebabkan oleh proses pengisian dan pengosongan (*discharging*) dinamis yang memengaruhi SOC aktual. Akurasi estimasi sering berkurang karena dinamika pengisian dan pengosongan SOC aktual. Hal ini berlaku jika model estimasi SOC mengasumsikan pengisian dan pengosongan akan selalu sama, yang tidak terjadi dalam implementasi sebenarnya. Asumsi ini akan menghasilkan kesalahan yang tinggi. Dengan memasukkan perilaku SOC baterai dinamis ini ke dalam model yang diusulkan, nantinya kesalahan estimasi dapat dikurangi, dibandingkan dengan metode yang ada. Selanjutnya, model JST yang memiliki kemampuan adaptasi yang kuat terhadap sistem nonlinier digunakan sebagai metode estimasi SOC. Hal ini memungkinkan hubungan yang kompleks dan nonlinier antara masukan (sinyal arus dan tegangan) dan keluaran (SOC baterai) ditangkap lebih akurat daripada metode estimasi SOC berbasis model yang biasanya mengasumsikan hubungan linier sederhana. Penggunaan model JST juga menghindari kebutuhan akan model matematika yang rumit dan penyediaan parameter, yang memakan waktu dan rawan kesalahan.



Gambar 1. Metode CCCV untuk pengisian dan pengosongan baterai.

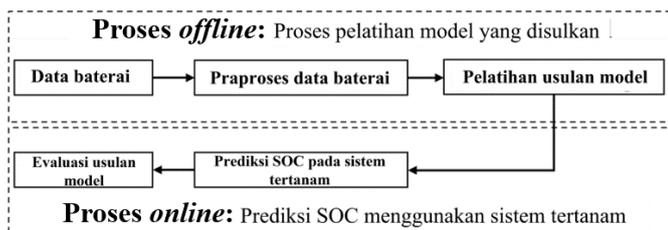
Dalam hal kepraktisan untuk mencapai sistem *real-time* dalam aplikasi tertanam, model yang diusulkan menggunakan data baterai terukur dan JST. Data baterai terukur, seperti arus dan tegangan, biasanya diukur dalam BMS. Dengan menggunakan sinyal ini, SOC dapat diestimasi secara *real-time* tanpa memerlukan sensor tambahan, sehingga mengurangi biaya dan kompleksitas. Makalah ini juga telah disimulasikan dalam aplikasi *real-time*. Eksperimen dilakukan menggunakan sistem tertanam dan diberikan data baterai aktual.

II. STRUKTUR DATASET

Makalah ini menggunakan kumpulan data baterai yang disediakan oleh BEXEL, sebuah perusahaan baterai terkemuka, hanya untuk tujuan penelitian dan pengembangan [19]. Kumpulan data dikumpulkan dari fasilitas pengujian baterai di BEXEL menggunakan baterai Li-ion. Data ini terdiri atas lebih dari 50.000 titik data untuk setiap set data baterai dan direkam selama enam bulan. Kumpulan data ini mencakup pengukuran tegangan, arus, dan kapasitas, yang terdiri atas tiga profil operasi yang berbeda pengisian, pemakaian, dan waktu istirahat. Makalah ini menggunakan dua *dataset* baterai yang berbeda yang disebut sel BEXEL #7 dan BEXEL #13. Untuk mengidentifikasi sel, BEXEL menetapkan nomor ini sebagai *ID* sel. Profil *dataset* dari dua data baterai tercantum dalam Tabel I.

Seperti tercantum dalam tabel, sel BEXEL #7 dan #13 memiliki nilai arus konstan dalam proses pengisian dan pengosongan. Hal ini disebabkan metode yang digunakan untuk mengukur *dataset* saat pengisian adalah metode *constant current constant voltage* (CCCV) dan saat pengosongan adalah metode *constant current* (CC). Secara khusus, pada fase pengisian daya, pengisi daya akan mulai mengisi daya baterai menggunakan mode CC terlebih dahulu. Ketika tegangan baterai mencapai nilai tegangan yang lebih tinggi, pengisi daya secara otomatis berubah ke mode CV dan akan terus mengisi daya hingga arus pemutusan baterai tercapai. Pada fase pengosongan, baterai dikosongkan menggunakan mode CC. Metode pengisian CCCV digunakan untuk menghindari pengisian yang berlebihan [20]. Mode CCCV pada fase pengisian dan mode CC pada fase pengosongan baterai ditunjukkan pada Gambar 1.

Dalam hal konfigurasi *dataset* selama pelatihan model, digunakan 149.278 sampel sel BEXEL #7, yang dibagi secara acak menjadi tiga set sebagai berikut: 70% (104.494 sampel) untuk pelatihan, 15% (223.92 sampel) untuk validasi, dan 15%



Gambar 2. Diagram alir estimasi SOC berbasis ANN.

(22.392 sampel) untuk pengujian. Data sel BEXEL #7 yang tersisa digunakan untuk pengujian dalam proses estimasi SOC online. Skema ini dilakukan kembali menggunakan sel BEXEL #13.

III. SISTEM ESTIMASI SOC BERBASIS JST

Makalah ini bertujuan untuk mengembangkan estimasi SOC untuk aplikasi tertanam hanya menggunakan pengukuran arus dan tegangan tanpa mengandalkan pengukuran SOC langsung. Hal ini dilakukan karena pengukuran langsung SOC dapat membutuhkan banyak biaya dan sulit diperoleh dalam aplikasi tertanam. Oleh karena itu, dalam aplikasi tertanam, estimasi SOC menggunakan pengukuran tidak langsung, seperti sinyal arus dan tegangan yang mudah diperoleh dengan menggunakan aplikasi tertanam, akan menguntungkan.

Dalam mengembangkan model estimasi SOC, model berbasis matematika yang kompleksitas komputasinya lebih rendah diuji untuk memodelkan sinyal SOC berikut. Proses pengisian dan pengosongan diuji menggunakan pertumbuhan eksponensial dan peluruhan linier. Hasil menunjukkan bahwa solusi matematis hanya cocok untuk jangka waktu tertentu. Namun, seiring bertambahnya usia baterai, sinyal SOC dapat berubah secara berkala, sehingga sulit untuk menemukan model matematis bentuk tertutup untuk jenis sinyal ini. Oleh karena itu, estimasi SOC berbasis matematika tidak akan berlaku untuk periode waktu atau kondisi baterai lain, dan model matematika yang berbeda perlu dikembangkan untuk skenario tersebut.

Berbeda dengan model matematis, model JST adalah pendekatan yang lebih fleksibel yang dapat disesuaikan dengan berbagai skenario dan kondisi. Makalah ini menggunakan model JST untuk mengestimasi SOC. Keseluruhan proses diilustrasikan pada Gambar 2. Model yang diusulkan dibagi menjadi dua proses utama: (1) proses offline yang berfokus pada pelatihan model estimasi SOC dan (2) proses online yang mengestimasi SOC menggunakan model yang dilatih dan sistem tertanam. Proses offline meliputi pengumpulan data, praproses data, dan pelatihan model. Semua langkah dalam proses offline hanya dilakukan satu kali. Pada saat yang sama, proses online mencakup estimasi SOC dengan data baterai aktual baru dan evaluasi kinerja. Untuk memvalidasi keakuratan dan keandalan estimasi SOC yang diusulkan, nilai SOC terukur dari dataset BEXEL digunakan sebagai ground truth (y) dan dibandingkan dengan nilai SOC yang diestimasi dari model.

A. PRAPROSES DATA

Data mentah yang dikumpulkan, seperti tegangan, arus, dan kapasitas, diubah menjadi data dengan format yang berguna dan efisien. Untuk melakukan praproses data, data kapasitas yang dikumpulkan pertama kali digunakan untuk menghitung SOC sebenarnya. SOC aktual didefinisikan sebagai rasio kapasitas yang tersisa terhadap kapasitas maksimum atau kapasitas awal [21], yang dinyatakan sebagai (1).

TABEL II
KORELASI ANTARA TARGET SOC DAN TEGANGAN

SOC	Tegangan	Koefisien Korelasi
Semua	Semua	0,3703
Hanya pengisian	Hanya pengisian	0,8891
Hanya pengosongan	Hanya pengosongan	0,7276

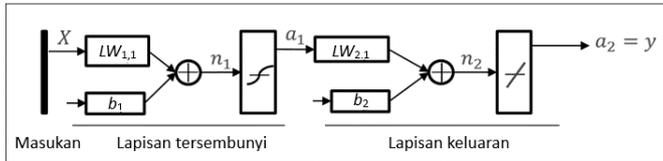
$$SOC = \left[\frac{Q(t) - \min Q}{\max Q - \min Q} \right] \times 100\% \quad (1)$$

dengan Q adalah kapasitas (Ah), $\min Q$ adalah kapasitas minimum (Ah), $\max Q$ adalah kapasitas maksimum (Ah), dan t adalah waktu (s). Jumlah keseluruhan siklus yang diperoleh pada proses ini adalah 434 siklus. SOC aktual yang diperoleh digunakan dalam pelatihan dan pengujian estimasi SOC. Tegangan, arus, dan SOC aktual digunakan dalam pembersihan dan normalisasi data. Untuk menghindari *underfitting*, *outlier* dihapus dari data menggunakan pembersihan data dan data diskalakan ke nilai antara 0 dan 1 melalui normalisasi [22]. Dengan demikian, hasil praproses data adalah format data tegangan, arus, dan SOC aktual yang efisien. Artinya, tidak ada *outlier* dalam data ini dan nilainya antara 0 dan 1.

Data masukan dan target harus ditentukan untuk melatih model estimasi SOC. Dalam makalah ini, data arus dan tegangan dipilih sebagai masukan data latih, sedangkan data SOC aktual dipilih sebagai data target. Tidak seperti data SOC aktual, tegangan dan arus dapat diukur secara langsung selama inferensi. Untuk meningkatkan akurasi, model estimasi SOC dilatih dengan pengisian dan pengosongan secara terpisah. Proses pelatihan model estimasi SOC dilakukan untuk dua model estimasi SOC, yaitu estimasi SOC selama pengisian dan pengosongan. Pada akhir proses, hasil pengisian dan pengosongan digabungkan untuk mendapatkan hasil siklus penuh.

Data tegangan selama pengosongan digunakan untuk mengestimasi SOC selama pengosongan, sedangkan data tegangan selama pengisian digunakan untuk mengestimasi SOC pengisian. Data tegangan bukan satu-satunya fitur yang digunakan pada fase pengisian. Data arus juga digunakan sebagai fitur bersama dengan data tegangan. Hal ini dilakukan karena dataset baterai sebenarnya menggunakan metode pengisian CCCV, yang memvariasikan data arus dan tegangan dalam proses pengisian. Sementara itu, pada proses pengisian, hanya data tegangan yang berubah seiring waktu. Skema ini memungkinkan model untuk mengurangi estimasi kesalahan karena profil pengisian dan pengosongan yang berbeda. Hal ini juga mengurangi konsumsi memori dengan hanya menggunakan fitur-fitur penting.

Makalah ini menghitung koefisien korelasi Pearson dari variabel-variabel tersebut untuk menyoroti hubungan antara tegangan masukan pemisah dan SOC target. Koefisien korelasi Pearson mewakili korelasi linier antara dua tegangan fitur dan data SOC target, yang diperoleh dengan menggunakan rasio antara *covariance* dari data tegangan dan SOC dan *product* dari standar deviasinya. Dengan kata lain, secara umum, hal ini merupakan pengukuran kovarians yang dinormalisasi. Koefisien korelasi Pearson antara data tegangan dan SOC disajikan pada Tabel II. Seperti yang tertera pada tabel, koefisien korelasi semua SOC dan semua tegangan adalah 0,3703. Pada saat yang sama, hasil koefisien korelasi Pearson yang memisahkan SOC dan tegangan masing-masing adalah 0,8891 dan 0,7276 untuk pengisian dan pengosongan. Hal ini



Gambar 3. Arsitektur jaringan JST yang digunakan.

menunjukkan bahwa kualitas fitur dapat ditingkatkan dengan membagi SOC dan tegangan menjadi dua fase di seluruh siklus, yaitu pengisian dan pengosongan. Fitur yang ditingkatkan dapat berdampak positif pada kinerja model JST yang digunakan dalam makalah ini. Dengan memasukkan fitur berkualitas tinggi ini ke dalam model, model ini mampu mengestimasi nilai SOC dengan lebih akurat selama setiap fase siklus baterai, yang mengarah pada peningkatan kinerja secara keseluruhan.

B. MODEL TRAINING

Model JST digunakan untuk memodelkan lintasan SOC aktual dan untuk memprediksi SOC aktual dengan memberikan tegangan dan arus sebagai masukan data. Dalam pemilihan masukan dan data target, data tegangan digunakan sebagai masukan dan data SOC digunakan sebagai keluaran untuk model estimasi SOC selama pengosongan. Data tegangan dan arus digunakan sebagai masukan dan data SOC digunakan sebagai keluaran untuk estimasi model SOC selama pengisian. Karena penggunaan sejumlah besar neuron tersembunyi meningkatkan kompleksitas model, satu neuron tersembunyi JST digunakan untuk membangun model estimasi SOC dengan mempertimbangkan persyaratan aplikasi *real-time*.

Arsitektur jaringan dari model JST ditunjukkan pada Gambar 3. Seperti yang ditunjukkan, jaringan *feedforward* dua lapis dengan fungsi transfer *sigmoid* pada lapisan tersembunyi dan fungsi transfer linier pada lapisan keluaran membentuk desain jaringan JST. Matriks bobot lapisan dan matriks bobot masukan digunakan untuk menghubungkan setiap lapisan LW. Masukan X mewakili tegangan dan arus; b_1 dan b_2 adalah nilai *bias* untuk lapisan 1 pada larik ($N \times 1$) dan lapisan 2 pada larik (1×1); dan N adalah jumlah lapisan tersembunyi. Nilai keluaran (a_2) mewakili estimasi SOC. Selain itu, persamaan yang mewakili arsitektur JST diberikan sebagai berikut.

$$a_1 = \text{tansig}(IW * X + b1) \quad (2)$$

$$y = LW * (\text{tansig}(IW * X + b1)) + b2 \quad (3)$$

$$a_2 = y = \left(\left(\frac{2}{1 + \exp(-2*(B*X + b1))} \right) - 1 \right) + b2. \quad (4)$$

Parameter model pada (4) diperoleh selama proses pelatihan. Data masukan X merepresentasikan data tegangan dan arus, sedangkan data target y merepresentasikan SOC sebenarnya. Selama proses pelatihan, model yang diusulkan belajar memetakan data masukan ke data target dengan menyesuaikan parameternya untuk meminimalkan kesalahan estimasi pada set pelatihan. Setelah dilatih, model yang diusulkan dapat digunakan untuk memperkirakan SOC secara *real-time* hanya dengan memasukkan pengukuran tegangan dan arus.

Dalam pelatihan model estimasi SOC, digunakan algoritma pelatihan Levenberg-Marquardt. Algoritma pelatihan ini mempertimbangkan hasil generalisasi dalam proses pelatihan [23]. Secara khusus, ketika generalisasi mencapai *plateau*, proses pelatihan berakhir secara otomatis. Kenaikan *mean*

TABEL III
PARAMETER KONSTAN MODEL JST YANG DIGUNAKAN

Parameter	Pengisian	Pengosongan
b_1	3,0559	-2,1176
IW_{-1}	[0,1775 -2,9987]	2,7579
b_2	0,7396	0,2770
LW_{2-1}	-2,1208	1,2974

square error (MSE) dari sampel validasi dapat digunakan untuk mengilustrasikan perbaikan generalisasi. Kenaikan MSE pada set validasi selama pelatihan dapat menjadi tanda bahwa model dapat lebih digeneralisasikan dan tidak terlalu rentan terhadap *overfitting*. Jumlah perbedaan kuadrat antara SOC aktual dan yang diproyeksikan dikenal sebagai MSE dan didefinisikan dalam (5).

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

dengan y_i dan \hat{y}_i masing-masing adalah SOC aktual dan estimasi SOC, sedangkan N adalah jumlah sampel. Nilai MSE dan regresi R adalah metrik kinerja yang digunakan untuk mengevaluasi hasil pelatihan. Perhitungan selisih kuadrat rata-rata antara keluaran dan target menghasilkan MSE, seperti yang terlihat pada (5). Nilai regresi R mengacu pada korelasi antara keluaran dan target.

Nilai regresi R menunjukkan jumlah variasi yang proporsional dalam respons SOC nyata, yang dijelaskan oleh tegangan masukan dan data arus yang disediakan. Jumlah variabilitas antara masukan yang diberikan dan SOC aktual yang dapat dijelaskan oleh model regresi linier meningkat dengan meningkatnya nilai R regresi. Dengan kata lain, nilai R = 1 menunjukkan hubungan yang kuat, sedangkan nilai 0 menunjukkan hubungan acak. Nilai R untuk regresi didefinisikan sebagai (6).

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (6)$$

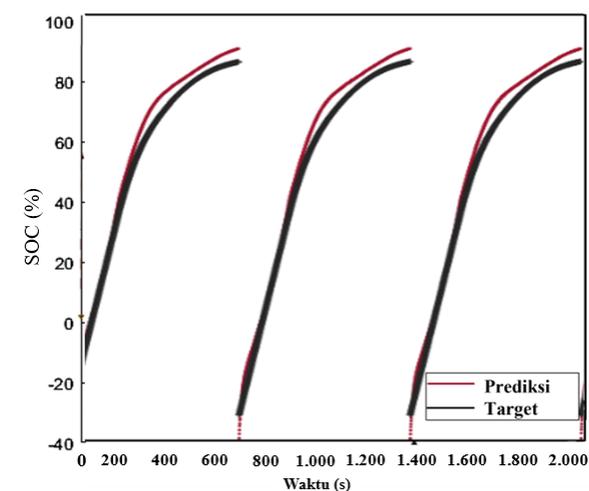
dengan R^2 adalah nilai regresi R, SSE adalah jumlah kesalahan kuadrat, SSR adalah jumlah regresi kuadrat, dan SST adalah jumlah total kuadrat. Nilai MSE dan R antara masukan yang diberikan dan SOC aktual (target) untuk pelatihan, validasi, dan pengujian, masing-masing kurang dari 2,2 dan 0,9. Hal ini menunjukkan bahwa model perkiraan SOC terlatih umumnya akurat untuk semua set data, dengan nilai R 0,9 di setiap kasus.

Keluaran akhir dari proses pelatihan adalah fungsi beserta parameter yang digunakan untuk mengestimasi SOC. Konstanta JST yang dihasilkan dari model estimasi SOC yang diusulkan ditunjukkan pada Tabel III. Parameter ini meliputi nilai *bias* untuk lapisan 1 dan lapisan 2, bobot masukan, dan bobot lapisan untuk pengisian dan pengosongan. Nilai optimal dari parameter ini digunakan sebagai fungsi untuk memperkirakan SOC baterai.

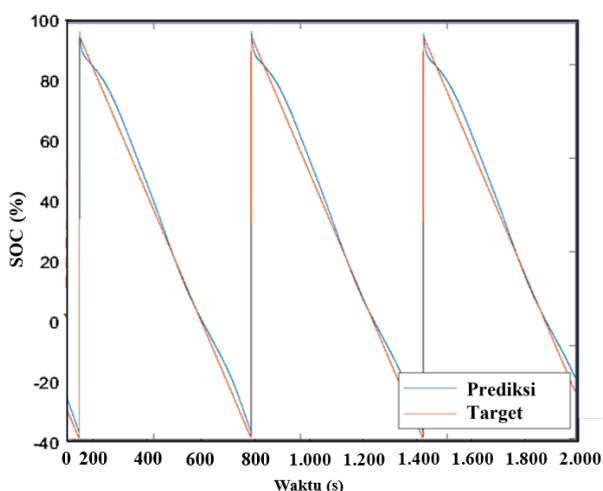
IV. HASIL DAN PEMBAHASAN

Dilakukan estimasi berbasis simulasi (*offline*) dan estimasi *online* terhadap model yang diusulkan. Estimasi SOC *offline* dilakukan pada MATLAB, sedangkan estimasi SOC *online* dijalankan pada Simulink MATLAB dan perangkat Edge C2000 F28379D.

C2000 adalah papan mikrokontroler yang dapat digunakan untuk berbagai aplikasi. Papan C2000 digunakan untuk melakukan dua tugas, yaitu akuisisi dan pemrosesan data. Akuisisi data meliputi proses pengambilan sampel sinyal



(a)



(b)

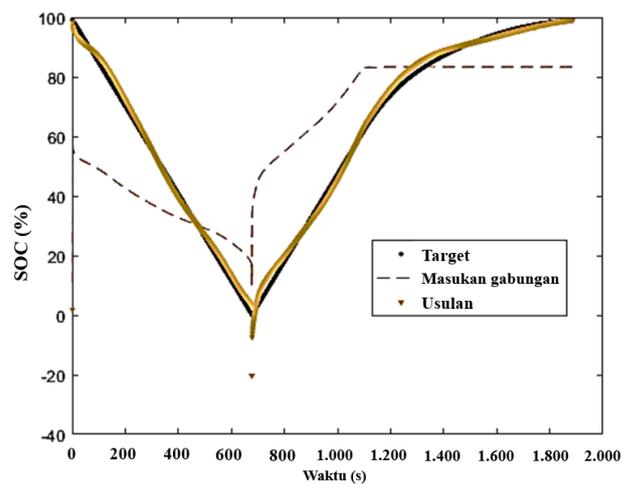
Gambar 4. Hasil estimasi dengan dataset BEXEL, (a) pengisian, (b) pengosongan.

analog yang mencoba mengukur bentuk fisik sebenarnya dari baterai dan juga mengubah sinyal analog sampel menjadi nilai numerik digital yang dapat diproses oleh komputer. Dalam makalah ini, akuisisi data dilakukan untuk mengukur dan mengumpulkan nilai tegangan dan arus untuk proses pengisian dan pengosongan. Tugas lain dari papan C2000 adalah pemrosesan data yang meliputi estimasi SOC.

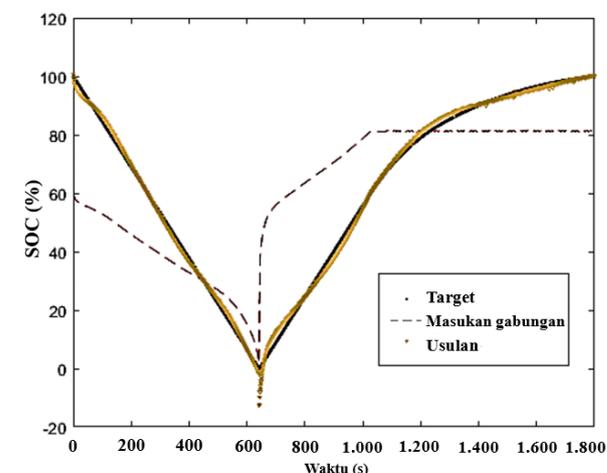
A. HASIL UJI MODEL BERBASIS SIMULASI (OFFLINE)

Hasil estimasi SOC yang diusulkan selama pengisian ditunjukkan pada Gambar 4(a). Sumbu x mewakili waktu, sedangkan sumbu y mewakili persentase SOC. Seperti yang ditunjukkan pada Gambar 4(a), garis hitam adalah SOC sebenarnya, sedangkan garis merah adalah estimasi SOC. Angka tersebut menunjukkan bahwa model yang diusulkan dapat menangkap SOC aktual selama pengisian daya. Model yang diusulkan mampu memperkirakan SOC aktual dengan akurasi tinggi pada awal proses pengisian. Akurasi berkurang saat baterai hampir terisi penuh. Akurasi yang menurun disebabkan oleh kurva SOC yang dinamis pada bagian akhir proses pengisian.

Selanjutnya, hasil estimasi SOC selama pengosongan ditunjukkan pada Gambar 4(b). Model yang diusulkan mampu memperkirakan lintasan SOC yang sebenarnya. Akurasi model yang diusulkan pada awal pengosongan lebih kecil daripada di tengah pengosongan. Hal ini terjadi karena



(a)



(b)

Gambar 5. Hasil estimasi menggunakan metode yang diusulkan dan metode masukan gabungan, (a) BEXEL#7, (b) BEXEL #13.

pengosongan/pemakaian baterai terjadi dengan profil arus konstan dinamis, berbeda dengan hasil estimasi SOC saat pengisian, yang memiliki akurasi paling tinggi di awal pengisian.

Dalam percobaan, makalah ini juga melakukan estimasi SOC berdasarkan JST dengan gabungan masukan pengisian dan pengosongan yang dinotasikan sebagai gabungan estimasi SOC berbasis masukan. Hasil dari metode yang diusulkan dibandingkan dengan metode berbasis masukan gabungan. Hasil sampel dari kombinasi metode berbasis masukan dan model yang diusulkan ditunjukkan pada Gambar 5(a) dan Gambar 5(b), yang masing-masing menggunakan sel BEXEL #7 dan #13. Seperti yang ditunjukkan pada gambar, SOC aktual, hasil masukan gabungan, dan usulan (masukan terpisah) direpresentasikan menggunakan titik hitam, garis merah, dan segitiga kuning. Angka tersebut menunjukkan bahwa hasil masukan gabungan jauh dari SOC yang sebenarnya. Sementara itu, hasil model yang diusulkan dapat mengestimasi SOC sebenarnya untuk pengisian dan pengosongan. Ini juga menunjukkan bahwa metode yang diusulkan mengurangi kesalahan estimasi, yang menunjukkan bahwa metode ini lebih kuat dan akurat.

Metode berbasis masukan gabungan menganggap pengisian dan pengosongan sinyal sebagai masukan tunggal ke model, yang dapat menghasilkan model estimasi SOC yang lebih kompleks dan kurang akurat. Di sisi lain, model estimasi

TABEL IV
PERBANDINGAN KINERJA METODE YANG DIUSULKAN DENGAN METODE
DASAR

Metrik Kinerja	Sel #	Masukan Gabungan	Baseline [12]	Metode yang Diusulkan
MAE	7	18,10	5,49	1,45
	13	28,10		2,23
RMSE	7	21,82	6,87	2,83
	13	22,29		1,49
MAPE	7	43,03	16,5	9,90
	13	32,73		8,87

SOC yang diusulkan memisahkan sinyal pengisian dan pengosongan dan menggunakannya sebagai masukan terpisah ke model, yang memungkinkan model menjadi lebih sederhana dan lebih akurat. Selanjutnya, hasil menunjukkan bahwa metode yang diusulkan dapat secara akurat mengestimasi SOC aktual untuk proses pengisian dan pengosongan. Hal ini penting untuk estimasi SOC *real-time* dalam aplikasi tertanam karena memungkinkan estimasi SOC yang akurat dan andal selama siklus pengisian dan pengosongan.

Untuk mengevaluasi keakuratan model yang diusulkan, makalah ini menggunakan *mean absolute error* (MAE) sebagai metrik kinerja utama, yang biasa digunakan dalam analisis regresi. Selain itu, dua metrik lain yang banyak digunakan, yaitu *root mean square error* (RMSE) dan *mean absolute percentage error* (MAPE), juga digunakan untuk mengevaluasi keakuratan model yang diusulkan. RMSE dan MAPE sering digunakan untuk mengevaluasi keakuratan model peramalan [24]. Metrik ini dapat memberikan wawasan lebih lanjut tentang kinerja model [24]. Rumus untuk MAE, RMSE, dan MAPE adalah sebagai berikut.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

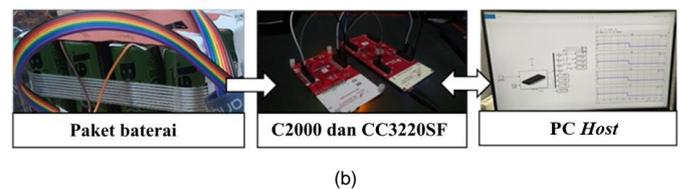
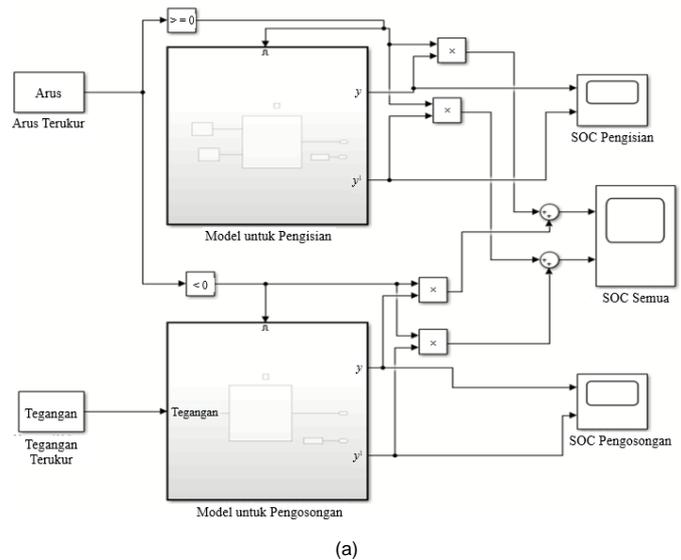
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (11)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \quad (12)$$

dengan y_i dan \hat{y}_i adalah SOC aktual dan estimasi SOC, serta N adalah jumlah keseluruhan sampel.

Makalah ini memperhitungkan proses pengisian dan pengosongan dinamis, yang merupakan karakteristik unik dari setiap jenis baterai. Dengan memasukkan karakteristik dinamis ini, model estimasi SOC yang diusulkan dapat memperkirakan SOC baterai dengan lebih akurat, yang pada gilirannya meningkatkan kekokohan estimasi SOC. Selain itu, model estimasi SOC yang diusulkan menggunakan estimasi SOC berbasis data dengan data baterai terukur dan JST, yang juga berkontribusi pada peningkatan ketahanan model. Metode berbasis data kurang sensitif terhadap perubahan karakteristik baterai dan lebih mudah beradaptasi dengan jenis baterai yang berbeda. Secara umum, metode yang diusulkan meningkatkan ketangguhan estimasi SOC dengan memasukkan karakteristik dinamis baterai dan menggunakan model JST, yang dapat menangani hubungan nonlinier dan beradaptasi dengan jenis baterai yang berbeda.

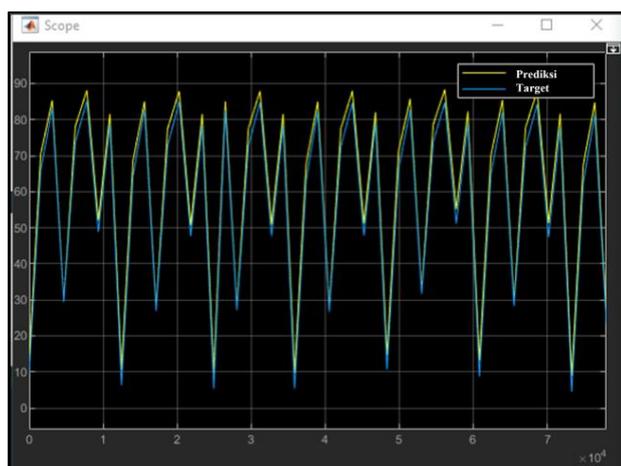
Hasil estimasi *error* komputasi menggunakan sel BEXEL #7 dan #13 ditunjukkan pada Tabel IV. Model yang diusulkan, yang memisahkan pengisian dan pengosongan, menunjukkan kinerja yang jauh lebih baik daripada masukan gabungan. Nilai MAE, RMSE, dan MAPE untuk metode masukan gabungan



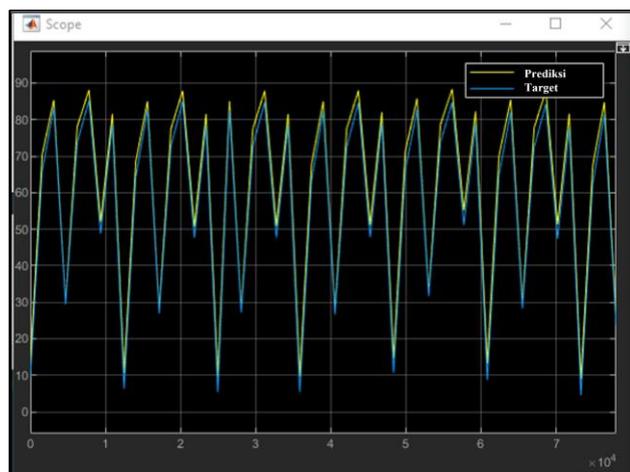
Gambar 6. Konfigurasi percobaan estimasi *online*, (a) model Simulink MATLAB, (b) mikrokontroler *real-time* C2000.

untuk sel #7 masing-masing adalah 18,10, 21,82, dan 43,03; sedangkan model yang diusulkan mengurangi nilai ini menjadi 1,45, 2,83, dan 9,90. Model yang diusulkan memiliki kinerja yang lebih baik karena telah dikembangkan dengan mempertimbangkan dinamika pengisian dan pengosongan. Dengan kata lain, makalah ini hanya menggunakan masukan yang memiliki hubungan kuat antara masukan dan SOC aktual target. Hubungan yang kuat antara masukan dan target memungkinkan terjadinya peningkatan akurasi estimasi. Perbandingan kinerja menggunakan sel #13 menunjukkan tren yang sama dengan sel #7. Metode yang diusulkan memiliki kesalahan yang lebih rendah daripada masukan gabungan untuk semua metrik kinerja MSE, RMSE, dan MAPE.

Makalah ini memilih model SOC yang disarankan dalam model dasar [12] sebagai tolok ukur untuk menampilkan peningkatan akurasi dan ketahanan yang dicapai oleh model yang diusulkan. Model ini dipilih sebagai *baseline* karena model ini juga menggunakan model berbasis JST untuk memperkirakan SOC, mirip dengan model yang diusulkan. Namun, berbeda dengan model yang diusulkan, *baseline* mengabaikan dinamika profil pengisian dan pemakaian dan tidak menekankan pengembangan estimasi SOC untuk aplikasi tertanam. Selanjutnya, model *baseline* terdiri atas dua neuron lapisan masukan, sembilan neuron lapisan tersembunyi, dan satu neuron lapisan keluaran. Lapisan masukan dan keluaran menggunakan tegangan terminal, arus pelepasan, dan SOC baterai. Menurut hasil yang disajikan pada Tabel IV, dapat disimpulkan bahwa model yang diusulkan mengungguli model dasar dalam hal MAE, RMSE, dan MAPE, dengan nilai yang lebih rendah menunjukkan akurasi yang lebih baik. Secara khusus, model yang diusulkan menghasilkan nilai MAE, RMSE, dan MAPE yang lebih rendah untuk sel #7 (1,45, 2,83, dan 9,90) daripada metode masukan gabungan (5,49, 6,82, dan 16,5). Perbandingan kinerja menggunakan sel #13 menunjukkan tren yang sama dengan sel #7.



(a)



(b)

Gambar 7. Sampel dari hasil estimasi *online*, (a) pengisian, (b) pengosongan.

B. HASIL UJI MODEL BERBASIS SISTEM TERTANAM (ONLINE)

Untuk memvalidasi kepraktisan model yang diusulkan, proses estimasi *online* dijalankan pada *platform* target C2000. Secara khusus, model yang diusulkan yang telah dikonversi ke *platform* Simulink, seperti pada Gambar 6(a), diunggah ke C2000. Konfigurasi percobaan untuk estimasi *online* diperlihatkan pada Gambar 6(b). Estimasi *online* dimulai dengan akuisisi data tegangan dan arus. Tegangan dan arus sebagai masukan dikumpulkan setiap detik. C2000 adalah papan mikrokontroler yang dapat digunakan untuk berbagai aplikasi. Papan C2000 digunakan untuk melakukan dua tugas, yaitu akuisisi dan pemrosesan data.

Akuisisi data meliputi proses pengambilan sampel sinyal analog yang berupaya mengukur bentuk fisik baterai sebenarnya dan juga mengubah sinyal analog sampel menjadi nilai numerik digital yang dapat diproses oleh komputer. Dalam hal ini, akuisisi data dilakukan untuk mengukur dan mengumpulkan nilai tegangan dan arus untuk proses pengisian dan pengosongan. Tugas lain dari papan C2000 adalah pemrosesan data.

Estimasi *online* dimulai dengan akuisisi data tegangan dan arus. Tegangan dan arus sebagai masukan dikumpulkan setiap detik. Kemudian, data masukan ini digunakan untuk mengestimasi SOC. Untuk mengevaluasi kinerja model yang diusulkan, hasil estimasi *online* dibandingkan dengan SOC sebenarnya. Hasil estimasi *online* dari metode yang

diusulkan ditunjukkan pada Gambar 7(a) dan Gambar 7(b). Angka-angka yang ditampilkan pada gambar tersebut menunjukkan sampel estimasi SOC dan SOC aktual selama pengisian dan pengosongan. Sumbu x dan sumbu y masing-masing mewakili pengukuran waktu dalam detik dan SOC dalam persentase. Seperti yang ditunjukkan pada gambar, model yang diusulkan dapat menangkap SOC sebenarnya mulai dari awal hingga akhir proses pengisian dan pengosongan.

Hasil estimasi juga mengungkapkan bahwa model yang diusulkan cocok untuk aplikasi *real-time*. Ini terjadi karena metode yang diusulkan menggunakan model dengan kompleksitas komputasi yang lebih kecil dan data terukur, seperti arus dan tegangan. Waktu inferensi terjadi setiap detik. Hal ini membuktikan bahwa model yang diusulkan dapat mengatasi dua tantangan utama dalam estimasi SOC *real-time*. Pertama, model yang diusulkan menghilangkan kebutuhan akan fitur komputasi yang mahal dan rumit dengan menggunakan parameter baterai yang mudah diukur. Kedua, model ini mengurangi ketergantungan pada perangkat lunak tertentu. Model estimasi SOC berbasis JST yang diusulkan, yang awalnya mengandalkan perangkat lunak MATLAB, berhasil diubah menjadi model mandiri yang hanya membutuhkan sistem operasi untuk beroperasi. Pencapaian ini sangat penting karena memungkinkan model yang diusulkan dapat dengan mudah diimplementasikan pada sistem tertanam apa pun tanpa memerlukan perangkat lunak tambahan. Dengan menghilangkan persyaratan kebutuhan akan perangkat lunak tertentu, model yang diusulkan menjadi lebih praktis dan mudah digunakan. Konversi ini tidak mengurangi akurasi dan kinerja model yang diusulkan, seperti yang ditunjukkan oleh hasil percobaan. Keberhasilan proses konversi ini menegaskan kelayakan dan kepraktisan model yang diusulkan untuk estimasi SOC *real-time* dalam sistem tertanam.

V. KESIMPULAN

Makalah ini mengusulkan pendekatan alternatif untuk meningkatkan akurasi, ketahanan, dan kepraktisan estimasi SOC untuk aplikasi tertanam. Makalah ini menunjukkan bahwa dengan mempertimbangkan proses pengisian dan pengosongan dinamis, akurasi dan ketahanan estimasi dapat meningkat. Hasil menunjukkan bahwa model yang diusulkan berhasil mereduksi nilai MSE, RMSE, dan MAPE. Ini menunjukkan bahwa model tersebut memiliki akurasi yang lebih tinggi dan kinerja yang lebih baik dalam memprediksi SOC. Algoritma *deep learning* lanjutan dapat digunakan untuk mencapai akurasi yang lebih tinggi. Dalam hal kepraktisan, model yang diusulkan menggunakan model JST dengan kompleksitas komputasi rendah dan data terukur. Skema ini digunakan untuk memastikan bahwa sistem yang diusulkan cocok untuk aplikasi *real-time*.

KONFLIK KEPENTINGAN

Penulis tidak memiliki konflik dengan pihak mana pun selama penulisan dan jalannya penelitian ini. Setiap informasi yang disampaikan adalah hasil asli seperti yang diperoleh saat melakukan penelitian dan tidak dipengaruhi oleh pendapat atau kepentingan pribadi.

UCAPAN TERIMA KASIH

Pekerjaan ini sebagian didukung oleh Kementerian UKM dan Start-Up Korea Selatan, di bawah Hibah S3010704; sebagian oleh National Research Foundation of Korea di bawah

Hibah 2020R1A4A1017775 dan Hibah 2021R1I1A3056900, serta sebagian oleh Institut Hibah Teknologi Telkom Surabaya.

REFERENSI

- [1] M.D. Ashidqi, M. Anwar, C. Hermanu B.A., A. Ramelan, dan F. Adriyanto, "Fuzzy Logic Implementation for Accurate Electric Car Battery SOC measurement," *J. Nas. Tek. Elekt., Teknol. Inf.*, Vol. 10, No. 3, hal. 257–264, Agu. 2021, doi:10.22146/jnteti.v10i3.1885.
- [2] M.A. Kamali, A.C. Caliwag, dan W. Lim, "Novel SOH Estimation of Lithium-Ion Batteries for Real-Time Embedded Applications," *IEEE Embed. Syst. Lett.*, Vol. 13, No. 4, hal. 206–209, Des. 2021, doi: 10.1109/LES.2021.3078443.
- [3] C. Pan dkk., "Adaptive Neural Network-Based Prescribed-Time Observer for Battery State-of-Charge Estimation," *IEEE Trans. Power Electron.*, Vol. 38, No. 1, hal. 165–176, Jan. 2023, doi: 10.1109/TPEL.2022.3205437.
- [4] R. Guo dan W. Shen, "Lithium-Ion Battery State of Charge and State of Power Estimation Based on a Partial-Adaptive Fractional-Order Model in Electric Vehicles," *IEEE Trans. Ind. Electron.*, Vol. 70, No. 10, hal. 10123–10133, Okt. 2023, doi: 10.1109/TIE.2022.3220881.
- [5] Y. Wei dan L. Ling, "State-of-Charge Estimation for Lithium-Ion Batteries Based on Temperature-Based Fractional-Order Model and Dual Fractional-Order Kalman Filter," *IEEE Access*, Vol. 10, hal. 37131–37148, Mar. 2022, doi: 10.1109/ACCESS.2022.3163413.
- [6] R. Hasan dan J. Scott, "Comments on 'State of Charge-Dependent Polynomial Equivalent Circuit Modeling for Electrochemical Impedance Spectroscopy of Lithium-Ion Batteries,'" *IEEE Trans. Power Electron.*, Vol. 35, No. 4, hal. 4448–4448, Apr. 2020, doi: 10.1109/TPEL.2019.2938508.
- [7] Y. Song, M. Park, M. Seo, dan S.W. Kim, "Improved SOC Estimation of Lithium-Ion Batteries with Novel SOC-OCV Curve Estimation Method Using Equivalent Circuit Model," *4th Int. Conf. Smart, Sustain. Technol. (SpliTech)*, 2019, hal. 1–6, doi: 10.23919/SpliTech.2019.8783149.
- [8] X. Hu, F. Sun, dan Y. Zou, "Estimation of State of Charge of a Lithium-Ion Battery Pack for Electric Vehicles Using an Adaptive Luenberger Observer," *Energies*, Vol. 3, No. 9, hal. 1586–1603, Sep. 2010, doi: 10.3390/en3091586.
- [9] X. Chen, W. Shen, Z. Cao, dan A. Kapoor, "A Novel Approach for State of Charge Estimation Based on Adaptive Switching Gain Sliding Mode Observer in Electric Vehicles," *J. Power Sources*, Vol. 246, hal. 667–678, Jan. 2014, doi: 10.1016/j.jpowsour.2013.08.039.
- [10] C. Pan dkk., "Adaptive Neural Network-Based Prescribed-Time Observer for Battery State-of-Charge Estimation," *IEEE Trans. Power Electron.*, Vol. 38, No. 1, hal. 165–176, Jan. 2023, doi: 10.1109/TPEL.2022.3205437.
- [11] L. Zhang dkk., "A Sparse Least Squares Support Vector Machine Used for SOC Estimation of Li-Ion Batteries," *IFAC-Papers OnLine*, Vol. 52, No. 11, hal. 256–261, 2019, doi: 10.1016/j.ifacol.2019.09.150.
- [12] Q. Wang, P. Wu, dan J. Lian, "SOC Estimation Algorithm of Power Lithium Battery Based on AFSA-BP Neural Network," *J. Eng.*, Vol. 2020, No. 13, hal. 535–539, Jul. 2020, doi: 10.1049/joe.2019.1214.
- [13] C. Pan dkk., "Adaptive Neural Network-Based Event-Triggered SOC Observer with Application to a Stochastic Battery Model," *IEEE Trans. Neural Netw., Learn. Syst.*, early access, 21-Sep-2022, doi: 10.1109/TNNLS.2022.3205040.
- [14] Q. Wang dkk., "State of Charge Estimation for Lithium-Ion Battery Based on NARX Recurrent Neural Network and Moving Window Method," *IEEE Access*, Vol. 9, hal. 83364–83375, Jun. 2021, doi: 10.1109/ACCESS.2021.3086507.
- [15] Y. Che, Y. Liu, Z. Cheng, dan J. Zhang, "SOC and SOH Identification Method of Li-Ion Battery Based on SWPSO-DRNN," *IEEE J. Emerg. Sel. Top. Power Electron.*, Vol. 9, No. 4, hal. 4050–4061, Agu. 2021, doi: 10.1109/JESTPE.2020.3004972.
- [16] M. Wei dkk., "State of Charge Estimation of Lithium-Ion Batteries Using LSTM and NARX Neural Networks," *IEEE Access*, Vol. 8, hal. 189236–189245, Okt. 2020, doi: 10.1109/ACCESS.2020.3031340.
- [17] M.A. Kamali, A. Caliwag, dan W. Lim, "Deep Learning Based SOC Estimation for Hybrid Energy Storage System," *8th Commun., Inf. Joint Conf. (JCCI'98)*, 2022, hal. 452–454.
- [18] Y. Song, M. Park, M. Seo dan S.W. Kim, "Online State-of-Charge Estimation for Lithium-Ion Batteries Considering Model Inaccuracies Under Time-Varying Current Conditions," *IEEE Access*, Vol. 8, hal. 192419–192434, Okt. 2020, doi: 10.1109/ACCESS.2020.3032752.
- [19] "SM 벅셀 배터리사업부문," [bexel.co.kr, https://www.bexel.co.kr/html/index/index.php](https://www.bexel.co.kr/html/index/index.php), tanggal akses: 1-Jan-2023.
- [20] Y. Gao dkk., "Classification and Review of the Charging Strategies for Commercial Lithium-Ion Batteries," *IEEE Access*, Vol. 7, hal. 43511–43524, Mar. 2019, doi: 10.1109/ACCESS.2019.2906117.
- [21] Z. Ren dan C. Du, "State of Charge Estimation for Lithium-Ion Batteries Using Extreme Learning Machine and Extended Kalman Filter," *IFAC-PapersOnLine*, Vol. 55, No. 24, hal. 197–202, 2022, doi: 10.1016/j.ifacol.2022.10.284.
- [22] M. Kim dkk., "State of Charge Estimation for Lithium-Ion Battery Based on Reinforcement Learning," *IFAC-PapersOnLine*, Vol. 51, No. 28, hal. 404–408, 2018, doi: 10.1016/j.ifacol.2018.11.736.
- [23] J. Wen dkk., "State of Charge Estimation for Lithium Battery Based on Levenberg-Marquardt Back-Propagation Neural Network with Momentum Term," *Proc. 2022 5th Int. Conf. Algorithms Comput., Artif. Intell.*, Des. 2022, hal. 1–5, doi:10.1145/3579654.3579696.
- [24] A.A. A'ziziyah, B.A.S. Aji, dan M.A. Kamali "Rekomendasi Pemilihan Program Studi Menggunakan Support Vector Regression," *Indonesian J. Comput., Inf. Technol. (IJCIT)*, Vol. 7, No. 2, hal. 143–150, Nov. 2022, 10.31294/ijcit.v7i2.14120.