

## **Estimasi *State of Charge* (SOC) Pada Baterai Lithium Ion Menggunakan *Long Short-Term Memory* (LSTM) Neural Network**

Alwi Azis Husien. R<sup>(1)</sup>, Novie Ayub Windarko<sup>(2)</sup>, Bambang Sumantri<sup>(3)</sup>

Politeknik Elektronika Negeri Surabaya  
Jl. Raya ITS - Kampus PENS, Kec. Sukolilo, Surabaya, Jawa Timur, Indonesia

Email: <sup>1</sup>alwiazishusienr@gmail.com, <sup>2</sup>ayub@pens.ac.id, <sup>3</sup>bambang@pens.ac.id

---

### **Tersedia Online di**

<http://www.jurnal.unublitar.ac.id/index.php/briliant>

---

### **Sejarah Artikel**

Diterima 8 Mei 2024  
Direvisi 16 Mei 2024  
Disetujui 17 Mei 2024  
Dipublikasikan 30 November 2024

---

### **Keywords:**

*State of Charge*; LSTM; Lithium Ion Battery; Neural Network

---

### **Kata Kunci:**

*State of Charge*; LSTM; Baterai Lithium Ion; Neural Network

---

### **Corresponding Author:**

Name:  
Alwi Azis Husien.R  
Email:  
[alwiazishusienr@gmail.com](mailto:alwiazishusienr@gmail.com)

**Abstract:** *Lithium-ion batteries have become one of the top choices for efficient and environmentally friendly mobility in today's era. Batteries play an important role in our digital lifestyles, from smartphones to electric cars. The use of this battery is inseparable from the challenge of estimating the State of Charge (SOC), which is a key parameter to monitor the availability of energy remaining in the battery. Therefore, an accurate SOC Estimation method is needed, which is important for efficient energy management and safe battery use. The Long Short-Term Memory (LSTM) model was chosen because of its ability to handle complex time series data and non-linear patterns in battery performance. This study provides the application of LSTM for SoC estimation and shows that LSTM is superior to the Feed Neural Network (FNN) method as evidenced by the simulation results that show that the LSTM model produces an RMSE of 4.92%, while the FNN model produces an RMSE of 7.82. From all the tests that have been carried out, the best RMSE value of 3.53% was obtained at a temperature of 25°C epoch 100.*

**Abstrak:** Baterai lithium-ion telah menjadi salah satu pilihan utama untuk mobilitas yang efisien dan ramah lingkungan di era saat ini. Baterai memainkan peran penting dalam gaya hidup digital kita, mulai dari smartphone hingga mobil listrik. Penggunaan baterai ini tidak terlepas dari tantangan dalam mengestimasi *State of Charge* (SOC), yang merupakan parameter kunci untuk memantau ketersediaan energi yang tersisa dalam baterai. Oleh karena itu diperlukan sebuah metode Estimasi SOC yang akurat, penting untuk manajemen energi yang efisien dan keamanan penggunaan baterai. Model *Long Short-Term Memory* (LSTM) dipilih karena kemampuannya menangani data deret waktu yang kompleks dan pola non-linear dalam performa baterai.

Penelitian ini memberikan penerapan LSTM untuk estimasi SoC dan menunjukkan bahwa LSTM lebih unggul dibandingkan metode *Feed Neural Network* (FNN) dibuktikan pada hasil simulasi yang menunjukkan bahwa model LSTM menghasilkan RMSE sebesar 4,92%, sementara model FNN menghasilkan RMSE sebesar 7,82. Dari seluruh pengujian yang telah dilakukan didapatkan nilai RMSE terbaik sebesar 3,53% pada temperature 25°C epoch 100.

## **PENDAHULUAN**

Perkembangan teknologi di berbagai wilayah dunia yang semakin maju beriringan dengan peningkatan permintaan energi yang semakin tinggi. Fenomena ini juga dipengaruhi oleh pertumbuhan populasi global yang terus meningkat. Sementara sumber energi listrik dari bahan bakar fosil merupakan sumber yang terbatas, yang tidak dapat diperbarui (Rahman & Velayutham, 2020) (Abdullah et al., 2020)(Adellea, 2022) (Danish et al., 2019). Oleh karena itu,

banyak perusahaan saat ini sedang berlomba-lomba dalam penelitian dan produksi energi terbarukan. Salah satu aspek yang krusial dalam mendukung penyediaan energi ini adalah penyimpanan energi, terutama melalui penggunaan baterai lithium-ion (Geng et al., 2020) (Cui et al., 2022a).

Baterai lithium-ion telah menjadi pilihan utama untuk mobilitas yang efisien dan ramah lingkungan di era ketika teknologi menjadi dasar masyarakat modern. Baterai ini memainkan peran penting dalam gaya hidup digital kita, mulai dari smartphone hingga mobil listrik (Yang et al., 2021) (Kartika Tresya Mauriraya 1)\*, 2022). Namun, penggunaan baterai ini tidak terlepas dari tantangan dalam mengestimasi *State of Charge* (SOC), yang merupakan parameter kunci untuk memantau ketersediaan energi yang tersisa dalam baterai (Cui et al., 2022b). Ketidakmampuan dalam mengestimasi SOC dengan akurat dapat mengakibatkan pengurangan masa pakai baterai, penurunan kinerja sistem, bahkan resiko keamanan (Hosen et al., 2021).

*State of Charge* (SOC) yang merupakan indikator penting dari tingkat daya yang tersisa dalam baterai, sangat penting untuk menghindari situasi tidak terduga (How et al., 2019). Oleh karena itu, perkiraan *State of Charge* (SOC) yang akurat dan dapat diandalkan sangat diinginkan dalam lingkungan yang memanfaatkan baterai. Sejumlah faktor memengaruhi kinerja baterai, termasuk kapasitas dan hasil keluaran energinya. Contohnya, jika dibandingkan dengan baterai baru, kapasitas penyimpanan baterai cenderung menurun seiring waktu, dipengaruhi oleh suhu dan periode penyimpanannya (Ningrum et al., 2021).

Penelitian sebelumnya telah banyak dilakukan untuk membuat metode estimasi *State of Charge* (SOC) namun masih memiliki keterbatasan dalam mencapai tingkat akurasi yang diinginkan (Chen et al., 2019). Metode konvensional sering mengalami kesulitan dalam menangani non-linearitas dan dinamika sistem baterai Baterai lithium ion. Akibatnya, untuk meningkatkan akurasi estimasi SOC, diperlukan pendekatan yang lebih canggih dan adaptif (How et al., 2019)(Dao et al., 2021).

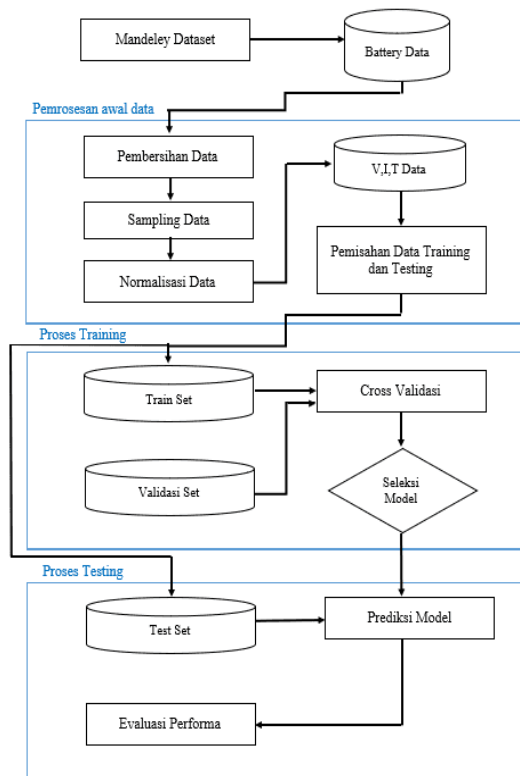
Untuk mengatasi masalah estimasi SOC pada baterai Baterai lithium ion, berbagai solusi telah dikembangkan. Metode seperti estimasi *coulomb counting* dan metode kalman filter menjadi opsi yang sering digunakan. Namun, mereka masih memiliki keterbatasan ketika berurusan dengan integrasi dan dinamika sistem yang kompleks (Ningrum et al., 2021)(Movassagh et al., 2021). Metode berbasis kecerdasan buatan, seperti penggunaan *Neural Network* (NN), telah menunjukkan potensi yang luar biasa untuk meningkatkan akurasi estimasi SOC. Namun, metode *Neural Network* saat ini memiliki kekurangan, terutama dalam hal menangani masalah variabilitas lingkungan yang tinggi dan perubahan keadaan sistem yang cepat (Cui et al., 2022a).

Menghadapi tantangan tersebut, pendekatan yang inovatif dan canggih perlu diambil untuk mengatasi permasalahan estimasi SOC pada baterai Baterai lithium ion. Salah satu pendekatan yang menjanjikan adalah penggunaan *Long Short-Term Memory* (LSTM) *Neural Network* (Bhagavatula et al., 2020). Dalam konteks estimasi *State of Charge* (SOC), penggunaan LSTM NN dapat meningkatkan kemampuan model untuk mengantisipasi perubahan keadaan sistem dengan lebih baik dan meningkatkan akurasi estimasi SOC (Bhagavatula et al., 2020) (Vidal et al., 2020).

Dalam paper ini, kami akan mengusulkan sebuah model estimasi SOC berbasis LSTM *Neural Network* untuk meningkatkan akurasi estimasi *State of Charge* (SOC) pada baterai Baterai lithium ion. Kami akan mengevaluasi kinerja model kami melalui simulasi untuk membuktikan efektivitasnya dalam mengatasi masalah yang dihadapi dalam estimasi *State of Charge* (SOC).

## **METODE**

Metode penelitian dilakukan dengan tujuan untuk menguraikan cara yang digunakan untuk menyelesaikan masalah. Pada penelitian ini terdapat tahapan yang dilakukan untuk mengestimasi *State of Charge* pada baterai lithium ion dengan pemodelan *Long Short-Term Memory* (LSTM) *Neural Network*.



Gambar 1. Diagram Alir Penelitian

Berikut ini merupakan penjelasan dari diagram alir penelitian yang dilakukan

1. Pengumpulan Data

Pada tahap ini diawali dengan pencarian data baterai yang dibutuhkan untuk melakukan penelitian ini. Data baterai yang digunakan ialah data tegangan, arus dan suhu.

2. Pemilihan Data

Setelah mendapatkan data yang telah dikumpulkan, maka selanjutnya data-data tersebut dipilih berdasarkan fungsi yang berkaitan dengan penelitian.

3. Data *Preprocessing*

Data *preprocessing* dilakukan dengan cara membuat dataframe untuk menyeleksi data yang akan digunakan, membagi data menjadi data training dan data testing, dan melakukan normalisasi.

4. Pengujian Metode LSTM

Pada tahapan ini dilakukan tujuan utama dari penelitian yaitu melakukan estimasi *State of Charge* (SOC) menggunakan metode LSTM NN yang sebelumnya telah dirancang.

Adapun tahapan yang akan dilakukan untuk estimasi SoC adalah sebagai berikut:

A. Penentuan struktur *Long Short Term Memory* (LSTM) *Neural Network* seperti input layer, hidden layer dan output layer.

B. Metode Optimasi

Metode optimasi *Adaptive Moment Estimation* (ADAM) adalah metode yang secara adaptif menghitung tingkat pembelajaran untuk setiap parameter. Optimizer Adam dapat mengendalikan masalah sparse gradient.

C. Input *Hyperparameter*

Hyperparameter yang ditentukan adalah nilai *Learn Rate Drop Period*, nilai *Initial Learn Rate*, nilai epoch dan nilai *Learn Rate Drop Factor*

D. Melakukan validasi rancangan model

Validasi rancangan model adalah proses memeriksa keandalan dan kualitas desain model sebelum memasukkannya ke dalam tahap implementasi atau produksi.


5. Hasil dan Analisa Data

Tahapan ini untuk menguji tingkat keakuratan dari hasil *State of Charge* (SoC) dengan melihat nilai yang dihasilkan melalui langkah pemrosesan seperti blok diagram lstm yang telah dirancang, sehingga akan didapatkan keakuratan dari hasil SoC tersebut.


6. Evaluasi Sistem

Untuk evaluasi kinerja dari model LSTM yang telah dibangun, perlu digunakan *Root Mean Square Error* (RMSE) untuk mengukur matrik standart. Jika nilai RMSE mendekati 0 maka kinerja model akan semakin baik.

Algoritam *Long Short-Term Memory* (LSTM) adalah subtype jaringan saraf yang menggunakan kembali informasi dari langkah waktu sebelumnya dalam loop tertutup. *Long Short-Term Memory* (LSTM) dikembangkan untuk mengatasi vanishing gradient pada *recurrent neural network* (RNN). Keunggulan dari LSTM terdapat pada blok memorinya, yang dapat menentukan nilai-nilai yang akan dipilih dan diproses sebagai output yang relevan berdasarkan input yang telah diberikan..LSTM digunakan pertama kali diperkenalkan di (Aksoy et al., 2018) dan terdiri dari kandidat memori saat ini  $\tilde{C}_k(1)$ , sebagai input gate  $V_k(2)$ , sebuah forget gate  $F_k(3)$  dan memory block  $C_k(4)$ .



Gambar 2. Representasi grafis dari lapisan LSTM



Gambar 3. Lapisan LSTM terbuka tepat waktu

$$\tilde{C}_k = \tanh(W_{\tilde{C}}\Psi_k + R_C H_{k-1} + b_C) \tag{1}$$

$$V_k = \sigma(W_V \Psi_k + R_V H_{k-1} + b_V) \tag{2}$$

$$F_k = \sigma(W_F \Psi_k + R_F H_{k-1} + b_F) \tag{3}$$

$$C_k = F_k \odot C_{k-1} + V_k \odot \tilde{C}_k \tag{4}$$

$$U_k = \sigma(W_U \Psi_k + R_U H_{k-1} + b_U) \tag{5}$$

$$H_k = U_k \odot \tanh(C_k) \tag{6}$$

Di mana gerbang output  $U_k$  (5), dan keadaan tersembunyi  $H_k$  (6), dimana  $k$  indikasi  $k^{\text{th}}$  Langkah waktu dari data input. Dalam persamaan.(1)-(6),  $\sigma$  adalah fungsi sigmoid, dan  $R, W$  dan  $b$  dengan subskripnya masing-masing, masing-masing mewakili bobot berulang, bobot masukan, dan bias.


Subskripnya mewakili gerbang mana yang dikaitkan, misalnya untuk mana  $W_F$  matriks bobot berasal dari forget gate  $F_k$ . akhirnya,  $\Psi_k$  mewakili matriks masukan. Gambar 2 menunjukkan representasi grafis tentang bagaimana gerbang, masukan, dan keluaran saling berhubungan dalam lapisan LSTM. Forget gate  $F_k$  menentukan berapa banyak informasi sebelumnya yang disimpan dalam blok memori  $C_{k-1}$  dipertahankan sementara input gate  $V_k$  menentukan berapa banyak calon memori  $\tilde{C}_k$  dipertahankan, seperti yang dijelaskan dalam (1), persamaan untuk keadaan memori baru  $C_k$ . Output gate  $U_k$  lalu mengontrol berapa banyak status memori baru  $C_k$  akan membuat keadaan tersembunyi baru  $H_k$ .

Karena sifatnya yang berulang, LSTM juga dapat direpresentasikan berlangsung dalam waktu, seperti yang ditunjukkan dalam Gambar 2, di mana pada setiap langkah waktu  $k$ , Memori menyatakan  $C_k$  dan status tersembunyi  $H_k$  diperbarui tanpa memodifikasi parameter bobot dan bias yang dapat dipelajari. Bobot dan bias hanya dimodifikasi selama proses pelatihan, tetapi keadaan tersembunyi dan keadaan memori berubah setiap kali langkah selama operasi.

Konfigurasi LSTM jauh lebih sederhana. Untuk pekerjaan ini, tiga input digunakan, dan matriks input adalah

$$\Psi_k = [t_k, v_k, i_k] \quad (7)$$

dimana  $v_k$  adalah tegangan terminal baterai,  $i_k$  adalah arus, dan  $t_k$  adalah temperature baterai, seperti yang ditunjukkan pada Gambar 4 berikut ini.



**Gambar 4.** Struktur LSTM

Data masukan dimasukkan ke dalam satu lapisan LSTM, dan jumlah unit tersembunyi LSTM, juga ditunjukkan pada Gambar 4. Keluaran model  $\hat{o}_k$  adalah perkiraan SOC yang diwakili oleh  $\widehat{soc}_k$  pada langkah waktu  $k$  dan dihitung dari *Rectified Linear Unit* (ReLU) yang terpotong dan lapisan yang terhubung sepenuhnya. *Rectified Linear Unit* (ReLU) adalah fungsi aktivasi yang sederhana secara komputasi. Proses *forward* dan *backward* melalui ReLU hanya melibatkan kondisi if. Jika suatu elemen memiliki nilai negatif, maka nilainya diatur menjadi 0. Tidak ada operasi eksponensial, perkalian, atau pembagian yang terlibat. Dengan karakteristik seperti itu, keunggulan ReLU terwujud ketika berhadapan dengan jaringan dengan jumlah neuron yang besar, yang secara signifikan mengurangi waktu training dan testing.

Jumlah parameter yang dapat dipelajari ( $LP_{LSTM}$ ) dapat dihitung dari jumlah *Hidden Unit* (HU) dan jumlah input untuk LSTM. Setiap berat input  $W$  adalah sebuah  $NI \times HU$  matriks neuron, setiap berat berulang  $R$  adalah  $HU \times HU$  neuron, dan setiap bias  $b$  adalah  $1 \times HU$  neuron. Ada total empat  $W$ ,  $R$ , dan  $b$  matriks, seperti yang ditunjukkan pada Persamaan. (1)-(5). Lapisan keluaran juga mencakup matriks  $1 \times HU$  dari parameter yang dapat dipelajari dan satu nilai bias. Oleh karena itu, jumlah parameter yang dapat dipelajari untuk LSTM dapat dihitung menggunakan persamaan (8)

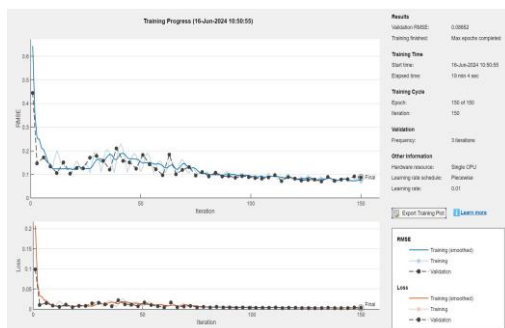
$$LP_{LSTM} = 4(NxHU + HUxHU + HU) + HU + 1 \quad (8)$$

Untuk algoritma pembelajaran yang diawasi menggunakan parameter yang dapat dipelajari, yaitu bobot dan bias, disesuaikan secara iteratif untuk meminimalkan kesalahan antara nilai estimasi dan target. Nilai target diwakili oleh vektor, yang untuk pekerjaan di sini diukur SOC. Fungsi kerugian pekerjaan ini adalah *Root mean square error* (RMSE), di mana K adalah jumlah total elemen untuk data dan merupakan SOC yang diperkirakan oleh algoritma.


$$RMSE = \sqrt{\sum_{k=1}^K \frac{(\hat{o}_k - o_k)^2}{K}}$$

## HASIL DAN PEMBAHASAN

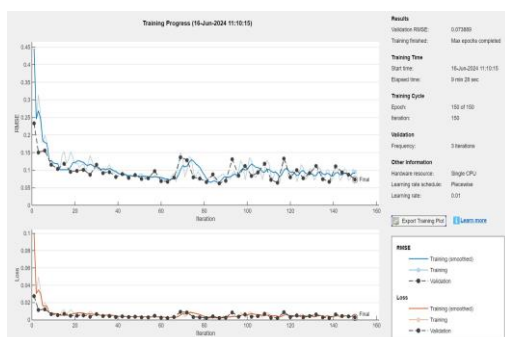
Pada tahapan ini akan menampilkan pengujian simulasi yang dilakukan 3 kali percobaan dengan 3 kondisi temperature yang berbeda yaitu pada 0°C, 10°C dan 25°C dengan memvariasikan beberapa parameter sehingga algoritma *Long Short-Term Memory Neural Network* diharapkan menghasilkan nilai estimasi dengan error semimumimum mungkin dan mendekati nilai asli dari data observasi yang telah didapatkan. Tiga input digunakan yaitu tegangan, arus, dan temperature yang diperoleh dari dataset. Sebagai pembandingan dari algoritma *Long Short Term Memory* (LSTM) digunakan algoritma *Feed Neural Network* (FNN). (Vidal et al., 2020). Simulasi dilakukan pada gambar 5-8, dilakukan pada temperature 0°C. Parameter utama yang digunakan 150 *epoch*, 1000 *Learn Rate Drop Period*, 0,01 *Initial Learn Rate*, 25 *Hidden unit*.



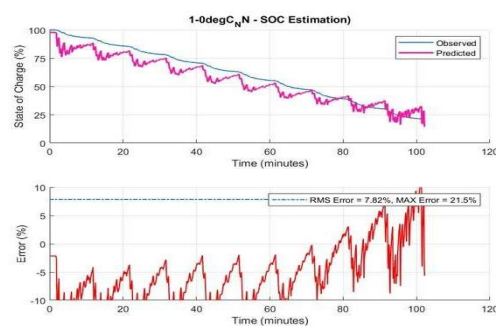
Gambar 5. Grafik train dan validation LSTM



Gambar 6. Grafik prediksi SoC LSTM



Gambar 7. Grafik train dan validation FNN



Gambar 8. Grafik prediksi SoC FNN

Pada hasil simulasi diatas model LSTM menunjukkan RMSE sebesar 4,92%, sementara model FNN menunjukkan RMSE sebesar 7,82%. Hal ini menunjukkan bahwa LSTM lebih efektif dalam menangkap dinamika temporal dari data SoC, yang cenderung memiliki ketergantungan jangka panjang dan pola yang kompleks. Sebaliknya, FNN yang hanya mempertimbangkan hubungan statis antar input tidak mampu menangkap pola temporal ini dengan baik.

Berikut ini merupakan beberapa hasil simulasi yang telah dilakukan. Untuk mengetahui hasil terbaik dari model LSTM maka simulasi dilakukan dengan mengubah parameter yang telah ditentukan. Percobaan ini akan dilakukan pada Temperature 0°C, 10°C dan 25°C, masing-masing temperature akan divariasikan menggunakan nilai parameter *Epoch*, *Learn Rate Drop Period*, *Initial Learn Rate*, *Learn Rate Drop Factor*, *validation Frequency* dan *Hidden Unit*.

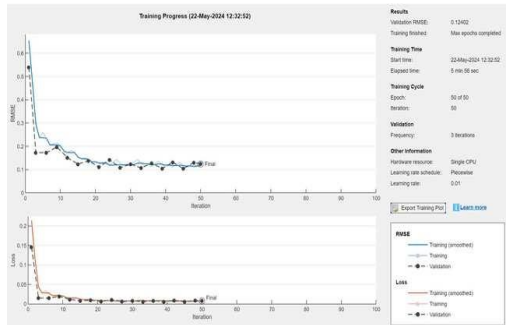
1. Pengujian State of Charge pada Temperature 0°C

Pada pengujian pertama dilakukan dengan menggunakan parameter 50,70 dan 100 *Epoch*, 1000 *Learn Rate Drop Period*, 0,01 *Initial Learn Rate*, 1 *Learn Rate Drop Factor*, 3 *validation Frequency* dan 20 *Hidden Unit*. Jumlah data yang digunakan untuk simulasi diperoleh dari dataset dapat dilihat pada tabel 1 berikut ini.


Tabel 1. Informasi dari dataset

Dataset	Jumlah
Train data	19428
Validasi data	6856
Test Data	12565
Observed	8064
Predicted	8064
Tegangan(V)	8163
Arus (I)	8163
Temperatur(T)	8163

Grafik train dan validation RMSE pada Temperature 0°C epoch 50 dapat dilihat pada gambar 9&10 berikut.

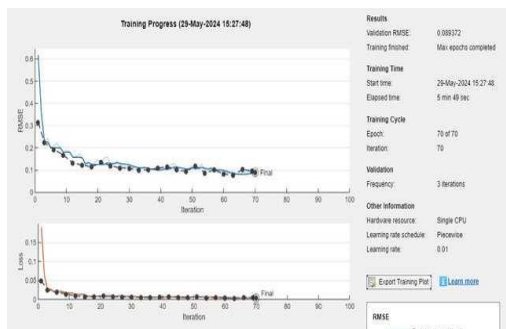


Gambar 9. Grafik train dan validation RMSE




Gambar 10. Grafik prediksi SoC

Grafik train dan validation RMSE pada Temperature 0°C epoch 70 dapat dilihat pada gambar 11&12 berikut.




Gambar 11. Grafik train dan validation RMSE




Gambar 12. Grafik prediksi SoC

Grafik train dan validation RMSE pada Temperature 0°C epoch 100 dapat dilihat pada gambar 13&14 berikut.



Gambar 13. Grafik train dan validation RMSE



Gambar 14. Grafik prediksi SoC

Grafik *State of Charge* (SoC) diatas menggambarkan tingkat estimasi terhadap baterai. Ini adalah parameter yang mencerminkan seberapa tepat model LSTM bekerja pada titik waktu tertentu. Kurva atau garis pada grafik menunjukkan perubahan SoC dari awal hingga akhir simulasi. Pada simulasi pengujian 1 berdasarkan nilai parameter yang telah ditentukan, nilai dari *state of charge* diamati dan diprediksi menghasilkan nilai error terkecil terdapat pada epoch 100 yaitu 5,67%.


## 2. Pengujian State of Charge pada Temperature 10°C

Pada pengujian kedua dilakukan dengan menggunakan parameter 50,70 dan 100 *Epoch* , 1000 *Learn Rate Drop Period*, 0,01 *Initial Learn Rate*, 1 *Learn Rate Drop Factor*, 3 *validation Frequency* dan 20 *Hidden Unit*. Jumlah data yang digunakan untuk simulasi diperoleh dari dataset dapat dilihat pada tabel 2 berikut ini.

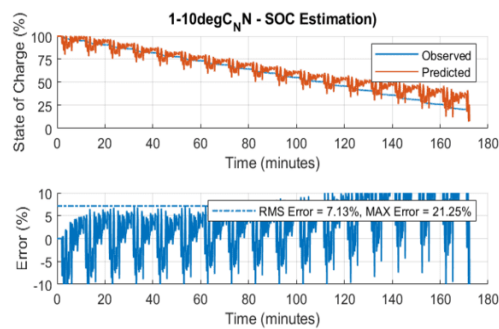
Tabel 2. Informasi dari dataset

Dataset	Jumlah
Train data	19428
Validasi data	6856
Test Data	12565
Observed	12468
Predicted	12468
Tegangan(V)	12567
Arus (I)	12567
Temperatur(T)	12567

Grafik train dan validation RMSE pada Temperature 10°C epoch 50 dapat dilihat pada gambar 15&16 berikut.




Gambar 15. Grafik train dan validation RMSE




Gambar 16. Grafik prediksi SoC



Grafik train dan validation RMSE pada Temperature 10°C epoch 70 dapat dilihat pada gambar 17&18 berikut.

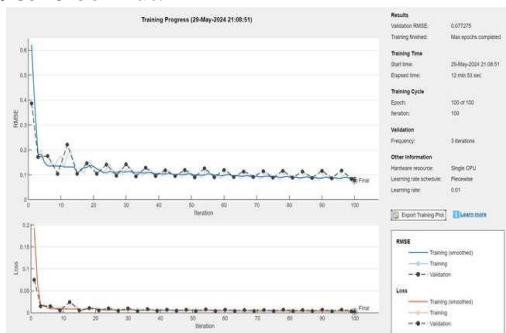


Gambar 17. Grafik train dan validation RMSE




Gambar 18. Grafik prediksi SoC

Grafik train dan validation RMSE pada Temperature 10°C epoch 100 dapat dilihat pada gambar 19&20 berikut.



Gambar 19. Grafik train dan validation RMSE



Gambar 20. Grafik prediksi SoC

Grafik *State of Charge* (SoC) diatas menggambarkan tingkat estimasi terhadap baterai. Ini adalah parameter yang mencerminkan seberapa tepat model LSTM bekerja pada titik waktu tertentu. Kurva atau garis pada grafik ini menunjukkan perubahan SoC dari awal hingga akhir simulasi. Pada simulasi pengujian 2 berdasarkan nilai parameter yang telah ditentukan, nilai dari *state of charge* diamati dan diprediksi menghasilkan nilai error terkecil terdapat pada epoch 100 yaitu 3,47%.

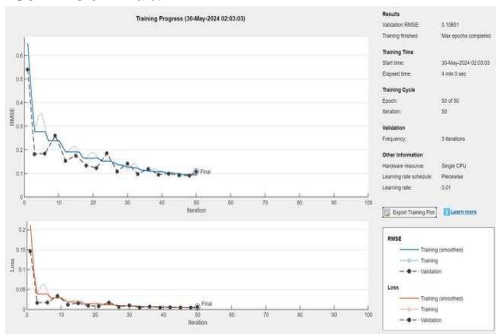
### 3. Pengujian State of Charge pada Temperature 25°C

Pada pengujian ketiga dilakukan dengan menggunakan parameter 50,70 dan 100 *Epoch* , 1000 *Learn Rate Drop Period*, 0,01 *Initial Learn Rate*, 1 *Learn Rate Drop Factor*, 3 *validation Frequency* dan 20 *Hidden Unit*. Jumlah data yang digunakan untuk simulasi diperoleh dari dataset dapat dilihat pada tabel 3 berikut ini.

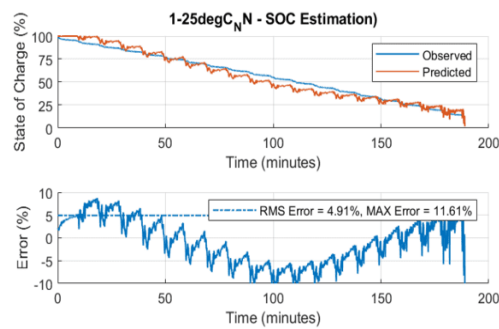
Tabel 3. Informasi dari dataset

Dataset	Jumlah
Train data	19428
Validasi data	6856
Test Data	12565
Observed	11337
Predicted	11337
Tegangan(V)	11436
Arus (I)	11436
Temperatur(T)	11436

Grafik train dan validation RMSE pada Temperature 25°C epoch 50 dapat dilihat pada gambar 21&22 berikut.




Gambar 21. Grafik train dan validation RMSE




Gambar 22. Grafik prediksi SoC

Grafik train dan validation RMSE pada Temperature 25°C epoch 70 dapat dilihat pada gambar 19 berikut.

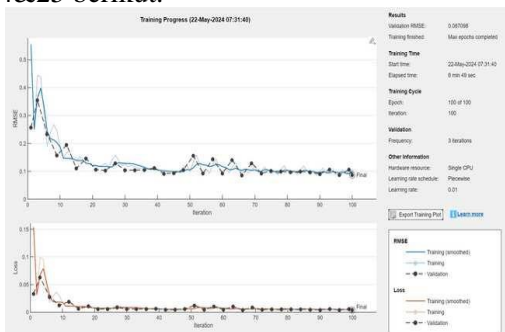


Gambar 22. Grafik train dan validation RMSE

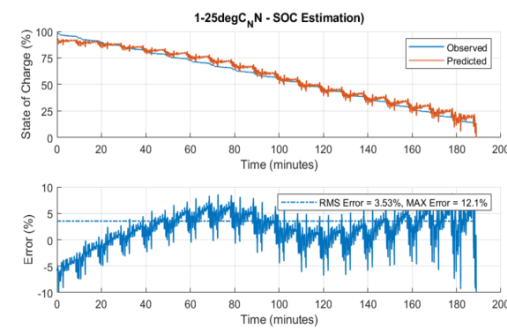


Gambar 23. Grafik prediksi SoC

Grafik train dan validation RMSE pada Temperature 25°C epoch 100 dapat dilihat pada gambar 24&25 berikut.



Gambar 24. Grafik train dan validation RMSE



Gambar 25. Grafik prediksi SoC

Grafik *State of Charge* (SoC) diatas menggambarkan tingkat estimasi terhadap baterai. Ini adalah parameter yang mencerminkan seberapa tepat model LSTM bekerja pada titik waktu tertentu. Kurva atau garis pada grafik ini menunjukkan perubahan SoC dari awal hingga akhir simulasi. Pada simulasi pengujian 3 berdasarkan nilai parameter yang telah ditentukan, nilai dari *state of charge* diamati dan diprediksi menghasilkan nilai error terkecil terdapat pada epoch 100 yaitu 3,53%. Hasil dari seluruh pengujian yang telah dilakukan dapat dilihat sebagai berikut:

Tabel 4. Hasil seluruh pengujian

Temperature	Epoch	RMSE	Validation RMSE
0°C	50	7,87%	0,12402
	70	6,60%	0,08937
	100	5,67%	0,06363
10°C	50	7,13%	0,08618

	70	8,35%	0,08289
	100	3,47%	0,07727
25°C	50	4,91%	0,10851
	70	4,81%	0,08354
	100	3,53%	0,08709

Berdasarkan tabel diatas dapat dilihat bahwa jika dilakukan variasi nilai pada setiap parameter dan khususnya nilai epoch dapat mempengaruhi nilai RMSE, dengan akurasi terbaik yaitu mendekati nilai 0 yang diperoleh pada temperature 25°C.

## SIMPULAN

Pada penelitian ini berhasil melakukan prediksi *estimasi state of charge* pada baterai lithium ion menggunakan model *Long Short-Term Memory* (LSTM) yang telah dibangun dan didapatkan hasil prediksi yang akurat. Pada algoritma ini optimasi dilakukan dengan bertujuan untuk meningkatkan tingkat akurasi dari prediksi data. Pengujian dilakukan dengan memvariasikan nilai parameter setiap temperature dan beberapa nilai variasi epoch yaitu 50, 70 dan 100. Penelitian ini tidak fokus kepada nilai epoch dari setiap pengujian, namun nilai dari setiap parameter *Learn Rate Drop Period*, *Initial Learn Rate*, *Learn Rate Drop Factor*, *validation Frequency* dan *Hidden Unit* dapat mempengaruhi nilai RMSE yang akan dihasilkan.

RMSE digunakan untuk mengevaluasi validitas data pada training dan testing. Nilai RMSE terkecil dihasilkan pada Temperature 25°C yaitu sebesar 3,53% dan memiliki nilai 0.08709 pada nilai validation RMSE. Hal ini terbukti dari nilai RMSE yang didapatkan mendekati nilai 0 sehingga model ini dapat dikatakan berhasil.

Sebagai pembandingan dari algoritma Long Short-Term Memory (LSTM) digunakan algoritma Feed Neural Network (FNN) dilakukan pada temperature 0°C. Pada hasil simulasi model LSTM menunjukkan RMSE sebesar 4,92%, sementara model FNN menunjukkan RMSE sebesar 7,82%. Hal ini menunjukkan bahwa LSTM lebih efektif dalam menangkap dinamika temporal dari data SoC, yang cenderung memiliki ketergantungan jangka panjang dan pola yang kompleks. Sebaliknya, FNN yang hanya mempertimbangkan hubungan statis antar input tidak mampu menangkap pola temporal ini dengan baik.

## DAFTAR RUJUKAN

- Abdullah, Javed, A., Ashraf, J., & Khan, T. (2020). The impact of renewable energy on GDP. *International Journal of Management and Sustainability*, 9(4), 239–250. <https://doi.org/10.18488/journal.11.2020.94.239.250>
- Adellea, A. J. (2022). Implementation of New Energy and Renewable Energy Policy in the Context of National Energy Security. *Indonesian State Law Review (ISLRev)*, 4(2), 43–51. <https://doi.org/10.15294/islrev.v4i2.61093>
- Aksoy, A., Ertürk, Y. E., Erdoğan, S., Eyduran, E., & Tariq, M. M. (2018). Estimation of honey production in beekeeping enterprises from eastern part of Turkey through some data mining algorithms. *Pakistan Journal of Zoology*, 50(6), 2199–2207. <https://doi.org/10.17582/journal.pjz/2018.50.6.2199.2207>
- Bhagavatula, S. V., Yellamraju, V. R. B., Eltem, K. C., Bobba, P. B., & Marati, N. (2020). ANN based Battery Health Monitoring - A Comprehensive Review. *E3S Web of Conferences*, 184, 1–7. <https://doi.org/10.1051/e3sconf/202018401068>
- Chen, C., Xiong, R., Yang, R., Shen, W., & Sun, F. (2019). State-of-charge estimation of lithium-ion battery using an improved neural network model and extended Kalman filter. *Journal of Cleaner Production*, 234(5), 1153–1164. <https://doi.org/10.1016/j.jclepro.2019.06.273>
- Cui, Z., Wang, L., Li, Q., & Wang, K. (2022a). A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network. *International Journal of Energy Research*, 46(5), 5423–5440. <https://doi.org/10.1002/er.7545>

- Cui, Z., Wang, L., Li, Q., & Wang, K. (2022b). A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network. *International Journal of Energy Research*, *46*(5), 5423–5440. <https://doi.org/10.1002/er.7545>
- Danish, Baloch, M. A., Mahmood, N., & Zhang, J. W. (2019). Effect of natural resources, renewable energy and economic development on CO<sub>2</sub> emissions in BRICS countries. *Science of the Total Environment*, *678*, 632–638. <https://doi.org/10.1016/j.scitotenv.2019.05.028>
- Dao, V. Q., Dinh, M. C., Kim, C. S., Park, M., Doh, C. H., Bae, J. H., Lee, M. K., Liu, J., & Bai, Z. (2021). Design of an effective state of charge estimation method for a lithium-ion battery pack using extended kalman filter and artificial neural network. *Energies*, *14*(9). <https://doi.org/10.3390/en14092634>
- Geng, P., Xu, X., & Tarasiuk, T. (2020). *LITHIUM-ION BATTERIES IN ALL-ELECTRIC SHIPS*. *27*(107), 100–108.
- Hosen, M. S., Jaguemont, J., Van Mierlo, J., & Bercibar, M. (2021). Battery lifetime prediction and performance assessment of different modeling approaches. *IScience*, *24*(2), 102060. <https://doi.org/10.1016/j.isci.2021.102060>
- How, D. N. T., Hannan, M. A., Hossain Lipu, M. S., & Ker, P. J. (2019). State of Charge Estimation for Lithium-Ion Batteries Using Model-Based and Data-Driven Methods: A Review. *IEEE Access*, *7*, 136116–136136. <https://doi.org/10.1109/ACCESS.2019.2942213>
- Kartika Tresya Mauriraya 1)\*, N. P. A. F. dan C. 4). (2022). Analisis Karakteristik Baterai Lithium-Ion Pada Kendaraan Listrik Di Institut Teknologi Pln. *Prosiding NCIET*, *3*, 95–102.
- Movassagh, K., Raihan, A., Balasingam, B., & Pattipati, K. (2021). A critical look at coulomb counting approach for state of charge estimation in batteries. *Energies*, *14*(14), 1–33. <https://doi.org/10.3390/en14144074>
- Ningrum, P., Windarko, N. A., & Suhariningsih, S. (2021). Estimation of State of Charge (SoC) Using Modified Coulomb Counting Method With Open Circuit Compensation For Battery Management System (BMS). *JAREE (Journal on Advanced Research in Electrical Engineering)*, *5*(1), 15–20. <https://doi.org/10.12962/jaree.v5i1.150>
- Rahman, M. M., & Velayutham, E. (2020). Renewable and non-renewable energy consumption-economic growth nexus: New evidence from South Asia. *Renewable Energy*, *147*(2020), 399–408. <https://doi.org/10.1016/j.renene.2019.09.007>
- Vidal, C., Malysz, P., Kollmeyer, P., & Emadi, A. (2020). Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art. *IEEE Access*, *8*, 52796–52814. <https://doi.org/10.1109/ACCESS.2020.2980961>
- Yang, B., Wang, J., Cao, P., Zhu, T., Shu, H., Chen, J., Zhang, J., & Zhu, J. (2021). Classification, summarization and perspectives on state-of-charge estimation of lithium-ion batteries used in electric vehicles: A critical comprehensive survey. *Journal of Energy Storage*, *39*(November 2020), 102572. <https://doi.org/10.1016/j.est.2021.102572>