

Estimasi *State of Charge* Baterai *Lithium-Ion* Menggunakan Algoritma CNN-LSTM dengan *Attention* *Layer* Berbasis Data *Pulse Test*

Riyo Aji Sembodo^{*1}, Yusuf M. Edward², Azizah Kusuma Dewi³, Desi Fitriana⁴, Hasan Adi Prasetyo⁵, Elizabeth Januarti Sirait⁶

^{1,2,3,4,5,6}Teknik Elektronika/Fakultas Vokasi/Universitas Negeri Yogyakarta

^{*}Corresponding author, email: riyoaji.2021@student.uny.ac.id

Abstrak	INFO.
<p>Estimasi State of Charge (SoC) yang akurat sangat penting untuk memastikan kinerja optimal Battery Management System (BMS), khususnya dalam kondisi operasional yang dinamis dan berubah-ubah. Penelitian ini mengusulkan model estimasi SoC berbasis deep learning dengan menggunakan arsitektur gabungan Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM), yang dilengkapi dengan Attention Layer. Model ini dirancang untuk mengekstraksi fitur spasial dan temporal dari data baterai secara efektif guna meningkatkan akurasi prediksi. Akuisisi data dilakukan melalui pengujian pulse test berbasis mikrokontroler yang merekam arus dan tegangan secara real-time. Data yang dikumpulkan dipraproses melalui normalisasi, ekstraksi kondisi diam (rest) untuk mendapatkan hubungan Open Circuit Voltage (OCV) terhadap SoC, serta estimasi resistansi internal menggunakan algoritma Recursive Least Squares (RLS). Dataset hasil praproses digunakan untuk pelatihan dan pengujian model. Hasil evaluasi menunjukkan bahwa model CNN-LSTM dengan Attention Layer memberikan performa estimasi yang lebih akurat dan stabil dibandingkan metode LSTM konvensional, serta berpotensi tinggi untuk diimplementasikan dalam sistem manajemen baterai cerdas dan adaptif.</p>	<p>Info. Artikel: No. 026 Received. October 20, 2025 Revised. October 28, 2025 Accepted. November 12, 2025 Page. 97 – 108</p>
Abstract	Kata kunci:
<p><i>Accurate State of Charge (SoC) estimation is crucial for ensuring the optimal performance of Battery Management Systems (BMS), especially under dynamic and fluctuating operational conditions. This study proposes a deep learning-based SoC estimation model utilizing a hybrid architecture that combines Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM), enhanced with an Attention Layer. The model is designed to effectively extract both spatial and temporal features from battery data to improve prediction accuracy. Data acquisition is conducted through a microcontroller-based pulse test system that records real-time current and voltage readings. The collected data is preprocessed through normalization, extraction of rest conditions to establish the relationship between Open Circuit Voltage (OCV) and SoC, and internal resistance estimation using the Recursive Least Squares (RLS) algorithm. The resulting dataset is then used to train and evaluate the model. Evaluation results show that the CNN-LSTM with Attention Layer achieves more accurate and stable SoC estimation than conventional LSTM, and holds high potential for implementation in smart and adaptive battery management systems.</i></p>	<ul style="list-style-type: none"> ✓ <i>State of Charge</i> ✓ <i>Convolutional Neural Network</i> ✓ <i>Long Short-Term Memory</i> ✓ <i>Attention Layer</i> ✓ <i>Pulse Test</i> ✓ <i>Lithium-Ion</i>

PENDAHULUAN

Baterai *lithium-ion* telah menjadi sumber energi utama dalam berbagai aplikasi, mulai dari perangkat elektronik portabel hingga kendaraan listrik [1]. Seiring meningkatnya kebutuhan akan teknologi penyimpanan energi yang efisien dan ramah lingkungan, pemahaman yang lebih baik tentang kondisi dan performa baterai menjadi sangat penting [2]. Salah satu parameter penting dalam manajemen baterai adalah *State of Charge* (SoC), yang merepresentasikan jumlah energi yang tersimpan di dalam baterai [3]. Estimasi SoC yang akurat diperlukan untuk menjaga kinerja optimal, memperpanjang umur baterai, serta mencegah kerusakan akibat *overcharge* atau *overdischarge* [4].

Namun demikian, akurasi estimasi SoC masih menjadi tantangan, terutama dalam kondisi operasional yang bervariasi. Metode konvensional, seperti pengukuran tegangan dan arus secara langsung, sering kali tidak akurat dan sangat dipengaruhi oleh faktor eksternal seperti suhu, usia baterai, dan karakteristik beban [5]. Oleh karena itu, pendekatan berbasis pembelajaran mesin mulai banyak digunakan dalam penelitian

terbaru. Algoritma seperti *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) terbukti memiliki potensi besar dalam menangani permasalahan ini. CNN unggul dalam mengekstraksi fitur spasial dari data kompleks [6], sementara LSTM efektif dalam memproses data urutan dan menangkap hubungan temporal [7]. Kombinasi keduanya, yang diperkuat dengan *Attention Layer*, diharapkan mampu meningkatkan akurasi dan stabilitas prediksi SoC dengan fokus pada informasi yang paling relevan dari data masukan.

Penelitian ini mengusulkan pengembangan sistem estimasi SoC berbasis *deep learning* dengan arsitektur CNN-LSTM yang dilengkapi *Attention Layer* [8]. Sistem ini menggunakan data dari hasil pengujian *pulse test* yang diperoleh melalui perangkat uji berbasis mikrokontroler untuk merekam arus dan tegangan baterai secara *real-time*. Model yang telah dilatih diekspor dalam format .h5 dan diimplementasikan pada perangkat Jetson Nano, untuk membuktikan bahwa solusi ini tidak hanya efektif secara simulasi, tetapi juga dapat diterapkan pada perangkat keras dengan keterbatasan sumber daya [9].

Permasalahan yang menjadi fokus penelitian ini adalah bagaimana membangun sistem akuisisi data berbasis *pulse test* dan bagaimana penerapan algoritma CNN-LSTM dengan *Attention Layer* dapat meningkatkan akurasi estimasi SoC dibandingkan metode konvensional [10]. Oleh karena itu, tujuan utama dari proyek ini yaitu untuk merancang perangkat uji *pulse test* berbasis mikrokontroler untuk memperoleh data operasional baterai secara *real-time*, serta mengembangkan dan mengevaluasi model estimasi SoC berbasis algoritma CNN-LSTM dengan *Attention Layer*, sebagai solusi yang adaptif, akurat, dan layak untuk implementasi praktis dalam sistem manajemen baterai modern [11].


METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Research and Development* (R&D) untuk merancang sistem prediksi *State of Charge* (SoC) baterai *lithium-ion* berbasis *deep learning* dengan arsitektur CNN-LSTM yang dilengkapi *Attention Layer*. Model dilatih menggunakan data hasil pengujian *pulse test* pada baterai *lithium-ion* [12]. Untuk menjelaskan alur sistem secara menyeluruh, disajikan blok diagram pengolahan data yang menggambarkan keterkaitan antar komponen utama perangkat lunak, mulai dari input data hingga keluaran estimasi SoC [13]. Selain itu, *flowchart* algoritma turut ditampilkan untuk menjelaskan tahapan detail pemrosesan model, seperti inisialisasi parameter, pembentukan data sekuensial, hingga proses prediksi. Visualisasi ini menjadi acuan dalam implementasi sistem, guna memastikan pengembangan dilakukan secara terstruktur, efisien, dan sesuai dengan tujuan penelitian untuk memperoleh estimasi SoC yang akurat.

1. Blok Diagram Pengolahan Data *Pulse Test*

Blok diagram yang ditampilkan menggambarkan alur pengolahan data hasil *pulse test* baterai *lithium-ion* yang digunakan dalam penelitian ini, mulai dari tahap akuisisi data hingga data siap untuk pelatihan model CNN-LSTM dengan *Attention Layer*. Proses dimulai dengan pengumpulan data berupa tegangan, arus, dan waktu dari pengujian menggunakan rangkaian berbasis mikrokontroler ESP32. Data direkam secara berkala oleh sensor arus dan pembagi tegangan, kemudian disimpan dalam format .csv untuk memudahkan pengolahan lanjutan.

Tahap *preprocessing* dilakukan untuk membersihkan data dari nilai tidak valid dan duplikat, serta melakukan normalisasi menggunakan metode *Min-Max Scaling*. Selanjutnya, dilakukan ekstraksi fitur untuk memperoleh relasi antara *Open Circuit Voltage* (OCV), arus, dan waktu terhadap SoC dalam bentuk deret waktu (*time series window*). Agar model memperoleh data yang bervariasi namun tetap representatif, diterapkan data *augmentation* melalui pengacakan urutan dan pemisahan interval waktu tertentu. Setelah semua tahapan selesai, data siap digunakan untuk melatih model *deep learning*, sehingga menghasilkan dataset terstruktur yang mendukung estimasi SoC secara akurat dan efisien.



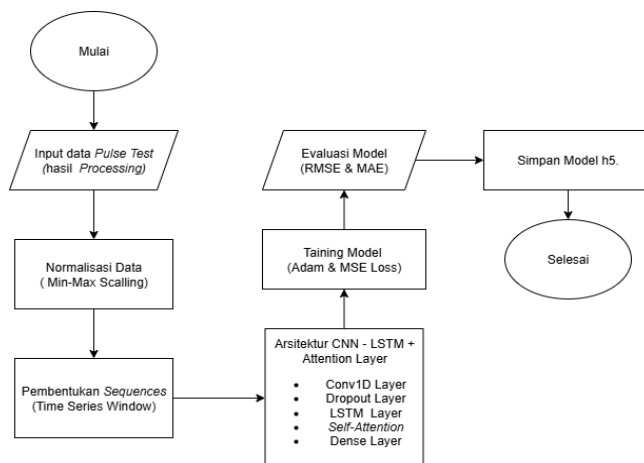
Gambar 1. Blok Diagram Pengolahan Data *Pulse Test*

2. Flowchart Algoritma CNN-LSTM + Attention Layer

Penelitian ini mengimplementasikan algoritma gabungan CNN–LSTM dengan *Attention Layer* untuk menghasilkan estimasi *State of Charge* (SoC) yang akurat dan adaptif terhadap karakteristik data deret waktu. Alur pelaksanaan algoritma ditunjukkan pada Gambar 4, dimulai dari proses inialisasi sistem hingga penyimpanan model akhir. Data input berupa hasil pengujian *pulse test* dimasukkan setelah melalui tahapan *preprocessing*, yang mencakup pembersihan data, sinkronisasi waktu, serta pemilihan parameter utama seperti arus dan tegangan. Selanjutnya, data dinormalisasi menggunakan *Min–Max Scaling* agar berada dalam rentang seragam dan mendukung stabilitas pelatihan.

Data yang telah dinormalisasi dibentuk menjadi *time series window* agar model LSTM dapat mengenali pola temporal, khususnya relasi antara OCV dan SoC. Arsitektur model terdiri dari Conv1D Layer untuk ekstraksi fitur lokal, *Dropout Layer* untuk mengurangi *overfitting*, LSTM Layer untuk mempelajari hubungan jangka panjang, serta *Attention Layer* untuk memberikan fokus pada bagian data yang paling relevan terhadap prediksi SoC. Output akhir dihasilkan melalui *Dense Layer*.

Model dilatih menggunakan Adam *Optimizer* dengan fungsi kerugian *Mean Squared Error* (MSE) dan dievaluasi menggunakan metrik RMSE dan MAE. Model terbaik disimpan dalam format .h5, memungkinkan penggunaan ulang tanpa pelatihan ulang. Proses ini mengakhiri seluruh rangkaian pengembangan dan evaluasi sistem estimasi SoC berbasis CNN–LSTM dengan *Attention Layer*.



Gambar 2. Flowchart Algoritma CNN-LSTM + Attention Layer

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi dan evaluasi model estimasi *State of Charge* (SoC) berbasis CNN–LSTM dengan *Attention Layer*. Pembahasan difokuskan pada analisis kinerja model terhadap data pengujian, serta interpretasi hasil estimasi untuk menilai akurasi dan efektivitas metode yang diusulkan.

1. Pengolahan Data *Pulse Test*

Pada tahap pengolahan data *pulse test*, mikrokontroler ESP32 berfungsi sebagai unit kendali utama yang mengatur kerja MOSFET sekaligus merekam arus dan tegangan melalui sensor INA219. Data hasil pengukuran dikirim secara *real-time* ke komputer melalui komunikasi serial dan disimpan dalam format .csv

untuk dianalisis lebih lanjut. Pengujian dimulai dari kondisi baterai terisi penuh (*State of Charge* 100%) dan dilakukan proses pelepasan muatan (*discharge*) secara bertahap menggunakan metode *pulse test* dengan pola beban aktif selama 10 detik, diikuti fase *drain* selama 30 detik dan fase istirahat (*rest phase*) selama 30 detik. Beban yang digunakan berupa resistor daya yang dikendalikan oleh rangkaian saklar elektronik berbasis MOSFET atau relay di bawah kendali mikrokontroler. Saat saklar aktif, arus mengalir dari baterai menuju beban sesuai hukum Ohm ($I = V/R$), menyebabkan penurunan tegangan terminal baterai. Fase *drain* berfungsi untuk menjaga kestabilan arus setelah fase pelepasan awal, sedangkan fase *rest* memberikan waktu bagi tegangan untuk kembali mendekati nilai *Open Circuit Voltage* (OCV) yang lebih merepresentasikan kondisi elektrokimia internal baterai. Siklus *pulse test* diulang hingga tegangan terminal mencapai sekitar 3,0 V atau SoC mendekati 0%, menghasilkan sekitar 20.700 sampel data dengan interval pencatatan setiap 1 detik. Setiap sampel mencakup parameter tegangan, arus, kapasitas terpakai, nilai SoC, dan status operasi yang menandai kondisi *rest* atau *drain*. Skema pengujian ini memungkinkan pengamatan menyeluruh terhadap respons dinamis tegangan terhadap arus pulsa di seluruh rentang kapasitas baterai, sehingga dataset yang dihasilkan sangat representatif untuk digunakan sebagai data pelatihan model estimasi SoC berbasis algoritma CNN-LSTM dengan *Attention Layer*. Dataset lengkap yang digunakan dalam penelitian ini tersedia secara daring dan dapat diakses pada tautan https://s.id/TARiyo_Dataset

Tabel 1. Pengolahan Data *Pulse Test*

Tegangan (V)	Arus (mA)	Total Drained (mAh)	SoC (%)	Status
4,156	-0,7	-0,000194	97,51	REST
4,156	-0,5	-0,000333	97,51	REST
4,084	-934,1	-0,259806	97,50	DRAIN
4,080	-934,0	-0,519250	97,49	DRAIN
4,084	-934,1	-0,778722	97,48	DRAIN

1.1 Estimasi Hambatan Internal Baterai dengan RLS

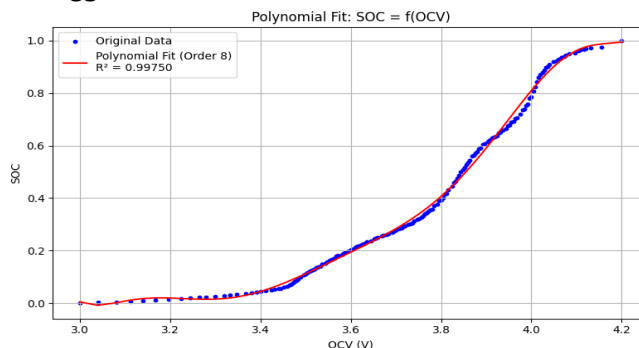


Gambar 3. Resistansi Internal Baterai Menggunakan Algoritma *Recursive Least Squares* (RLS)

Resistansi internal baterai adalah parameter penting karena mempengaruhi performa baterai. Estimasi dilakukan menggunakan algoritma *Recursive Least Square* (RLS) yang memodelkan hubungan antara tegangan, arus, dan resistansi. Pada Gambar 5, hasil perhitungan menunjukkan bahwa resistansi internal meningkat seiring dengan menurunnya SoC. Hal ini sesuai dengan teori bahwa pada kondisi SoC rendah, baterai cenderung mengalami peningkatan resistansi akibat degradasi kimia internal. Estimasi resistansi internal menunjukkan adanya fluktuasi pada tahap awal. Kondisi ini wajar karena algoritma RLS masih berada pada fase adaptasi, sehingga parameter awal belum sepenuhnya sesuai dengan kondisi aktual. Setelah beberapa kali pembaruan, hasil estimasi mulai stabil dan konvergen pada rentang 0,074– 0,079 Ω .

Hasil pengujian membuktikan bahwa algoritma RLS dapat diandalkan untuk memantau resistansi internal baterai selama proses *discharge* serta memberikan gambaran yang representatif terhadap kondisi internal sel. Tahap selanjutnya adalah melakukan ekstraksi data *pulse test* pada kondisi *rest*, yaitu saat arus berhenti mengalir dan tegangan baterai mendekati nilai OCV. Data *extracted* dapat diakses pada link berikut https://s.id/TaRiyo_ExtractedData

1.2 Penambahan Dataset Menggunakan Polinomial



Gambar 4. Model Polinomial SoC-OCV

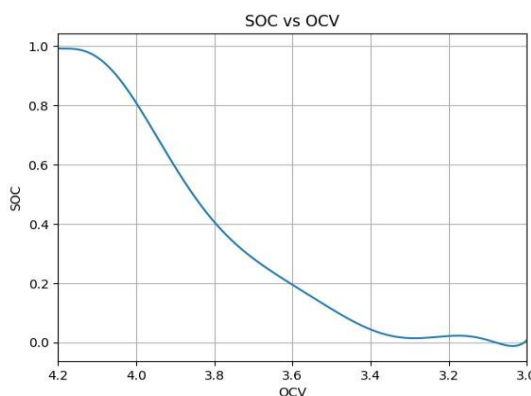
Dataset hasil *pulse test* memiliki jumlah data yang terbatas. Agar model *deep learning* tidak mudah mengalami *overfitting*, dilakukan penambahan menggunakan metode polinomial. Teknik ini menghasilkan variasi data baru berdasarkan kurva *fitting polinomial* dari data asli. Dengan augmentasi ini, model mendapatkan lebih banyak variasi pola untuk dipelajari sehingga dapat meningkatkan kemampuan generalisasi pada data uji. https://s.id/TARiyo_SocPol

Tabel 2. Hasil Evaluasi Kinerja Model CNN–LSTM + *Attention Layer*

Data	SoC	OCV
1	0,99396	4,2
2	0,99393	4,19987
3	0,99389	4,19975
4	0,99385	4,19963
5	0,99381	4,19951

Data pada Tabel 2 menunjukkan hasil augmentasi data menggunakan metode polinomial yang menghasilkan hubungan SoC dan OCV dengan distribusi data yang lebih rapat. Dataset hasil augmentasi inilah yang selanjutnya digunakan tahap pelatihan model dengan algoritma CNN-LSTM dengan *Attention Layer*.

1.3 Visualisasi Kurva SOC-OCV



Gambar 5. Hubungan SoC Terhadap OCV pada Baterai *Lithium-Ion*

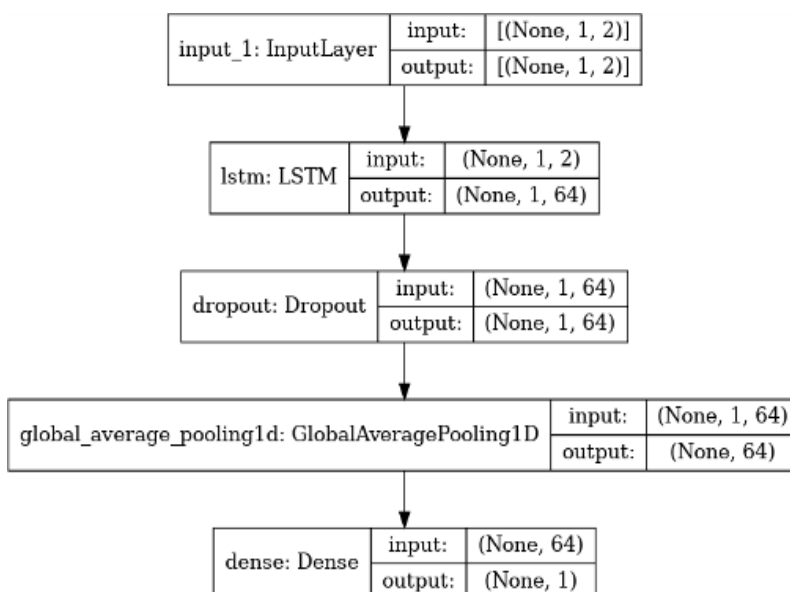
Gambar 7 memperlihatkan hubungan antara *State of Charge* (SoC) dan *Open Circuit Voltage* (OCV) pada baterai *lithium-ion*. Secara umum, kurva menunjukkan karakteristik non-linier, di mana nilai OCV menurun seiring dengan berkurangnya SoC. Pada kondisi SoC mendekati 100%, tegangan OCV berada pada kisaran 4.2 V. Selanjutnya, penurunan SoC diikuti oleh penurunan OCV yang cukup tajam hingga sekitar 3.7 V. Setelah melewati titik tersebut, penurunan OCV berlangsung lebih landai hingga mendekati 3.0 V. Bentuk kurva ini menegaskan bahwa OCV dapat dijadikan indikator untuk memperkirakan SoC, meskipun sifat non-linieritasnya menuntut adanya pendekatan pemodelan matematis atau algoritma berbasis pembelajaran mesin agar estimasi lebih akurat. Dengan demikian, grafik ini sekaligus memperkuat alasan perlunya penerapan metode *machine learning* seperti CNN-LSTM dengan *attention layer* dalam penelitian ini.

2. Pembuatan Model CNN-LSTM + Attention Layer

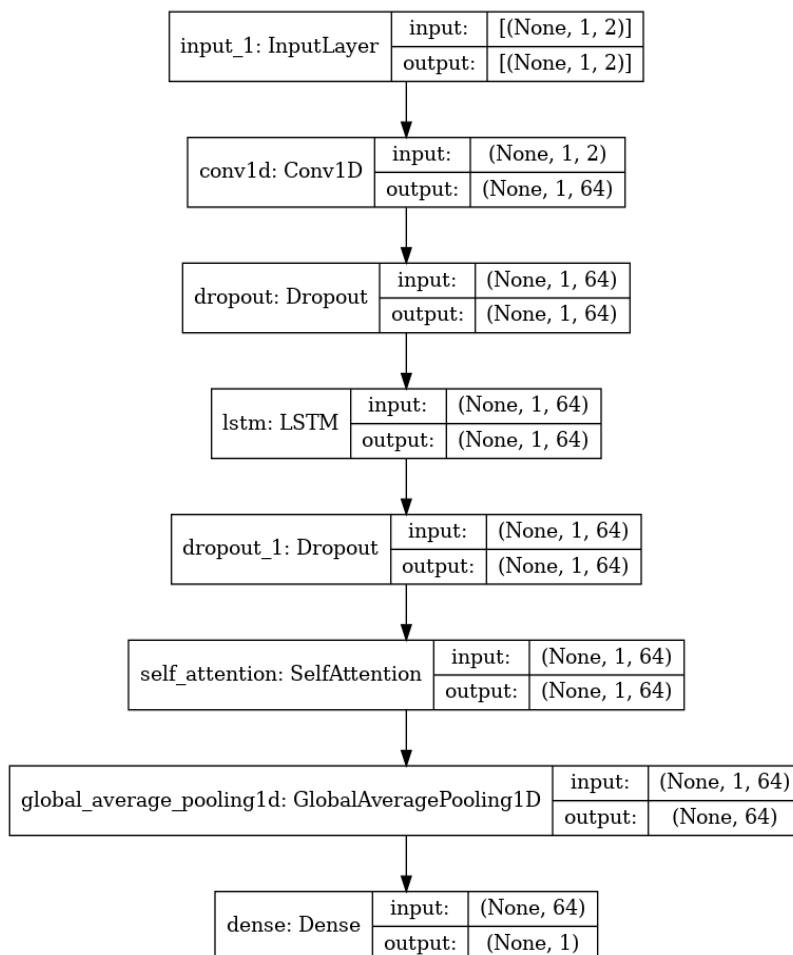
Model CNN-LSTM dengan Attention Layer dirancang untuk meningkatkan akurasi estimasi *State of Charge* (SoC) baterai berbasis data hasil *pulse test*. Arsitektur model memproses data deret waktu tegangan, arus, dan kapasitas baterai melalui tiga tahap utama. Pertama, data masukan diolah oleh lapisan *Convolutional Neural Network* (CNN) untuk mengekstraksi pola lokal yang merepresentasikan perubahan singkat tegangan dan arus. Hasil ekstraksi fitur kemudian diteruskan ke lapisan *Long Short-Term Memory* (LSTM) yang berfungsi menangkap ketergantungan temporal jangka panjang dalam data deret waktu, sehingga tren perubahan SoC dapat terpelajari secara kontekstual. Setelah itu, ditambahkan *Attention Layer* guna memberikan bobot lebih besar pada langkah waktu yang paling relevan, menjadikan model lebih adaptif terhadap kondisi dinamis baterai. Keluaran akhir dari lapisan *attention* diproyeksikan melalui *dense layer* menjadi nilai estimasi SoC. Model dilatih menggunakan algoritma Adam *optimizer* dengan fungsi kerugian *Mean Squared Error* (MSE), serta dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE). Kombinasi CNN, LSTM, dan *Attention* menghasilkan sistem yang mampu mempelajari hubungan nonlinier antara tegangan, arus, dan kapasitas secara menyeluruh, sehingga memberikan estimasi SoC yang lebih presisi dan stabil pada kondisi operasi baterai yang dinamis.

2.1 Perbandingan Arsitektur Model

Gambar 8 dan Gambar 9 berikut ini menunjukkan rancangan arsitektur model yang digunakan dalam penelitian ini untuk estimasi *State of Charge* pada baterai *lithium-ion*.



Gambar 6. Grafik Estimasi SoC pada Data Pelatihan LSTM



Gambar 7. Grafik Estimasi SoC pada Data Pelatihan CNN-LSTM + Attention Layer

Model LSTM dan CNN–LSTM dengan Attention Layer memiliki perbedaan signifikan dalam cara mempelajari pola data untuk estimasi State of Charge (SoC) baterai. Arsitektur LSTM terdiri dari lapisan input, LSTM, dropout, global average pooling 1D, dan dense layer sebagai output. Struktur ini efektif dalam menangkap hubungan temporal dan tren perubahan SoC dari waktu ke waktu, dengan LSTM menyimpan informasi jangka panjang, dropout mengurangi overfitting, serta pooling mereduksi dimensi fitur untuk mempertahankan informasi esensial. Namun, model LSTM murni kurang optimal dalam mengenali pola lokal atau fluktuasi cepat yang sering terjadi akibat dinamika tegangan dan arus baterai.

Sebaliknya, model CNN–LSTM dengan Attention Layer menggabungkan kemampuan Conv1D untuk mengekstraksi fitur lokal dengan kekuatan LSTM dalam menangkap ketergantungan temporal. Penambahan Attention Layer memungkinkan model menekankan bagian data yang paling relevan terhadap prediksi SoC. Kombinasi ini menjadikan model lebih adaptif dan akurat terhadap variasi data dinamis.

Secara keseluruhan, meskipun lebih kompleks, arsitektur gabungan CNN–LSTM dengan Attention Layer menunjukkan performa estimasi yang unggul dibanding LSTM murni. Evaluasi menunjukkan bahwa model ini menghasilkan nilai RMSE, MAE, dan Error (%) yang lebih rendah, terutama pada rentang tegangan rendah yang bersifat nonlinier, membuktikan efektivitas integrasi CNN dan Attention dalam meningkatkan akurasi dan stabilitas estimasi SoC.

2.2 Perbandingan Hyperparameter Model CNN-LSTM + dan LSTM

Perbandingan dilakukan untuk melihat perbedaan konfigurasi hyperparameter yang digunakan pada model CNN–LSTM dengan Attention Layer dan model LSTM murni. Pemilihan hyperparameter dilakukan melalui serangkaian uji coba untuk memperoleh kombinasi yang memberikan hasil pelatihan paling stabil dan tingkat kesalahan terkecil pada data validasi.

Tabel 3. Perbandingan *Hyperparameter* Model CNN–LSTM + Attention Layer dan LSTM

Parameter	CNN-LSTM + Attention Layer	LSTM
Jumlah unit LSTM	64	64
Jumlah filter CNN	64	-
Ukuran kernel CNN	1	-
Lapisan <i>dropout</i>	2 (<i>rate</i> = 0,2)	1 (<i>rate</i> = 0,2)
Lapisan <i>attention</i>	Ada	Tidak ada
<i>Optimizer</i>	Adam	Adam
<i>Loss function</i>	MSE	MSE
Metrik evaluasi	MAE	MAE
<i>Batch size</i>	64	64
Jumlah <i>epoch</i>	20	20

Perbandingan konfigurasi *hyperparameter* dilakukan untuk menganalisis pengaruh kompleksitas arsitektur terhadap performa model dalam mengestimasi *State of Charge* (SoC). Model CNN–LSTM dengan Attention Layer menggunakan 64 *filters* pada lapisan konvolusional satu dimensi (*Conv1D*) dengan fungsi aktivasi ReLU dan ukuran *kernel* sebesar 1. Lapisan ini diikuti oleh dua *Dropout Layer* dengan rasio 0,2 guna mencegah *overfitting*. Selanjutnya, lapisan LSTM berisi 64 unit dengan opsi *return_sequences=True* agar keluaran setiap urutan dapat diproses oleh mekanisme Self-Attention, yang kemudian diringkas melalui Global Average Pooling 1D. Lapisan keluaran (*Dense Layer*) memiliki satu neuron dengan fungsi aktivasi linear untuk menghasilkan estimasi akhir SoC. Model dikompilasi menggunakan fungsi kerugian *Mean Squared Error* (MSE), dioptimalkan dengan algoritma Adam, dan dievaluasi dengan metrik *Mean Absolute Error* (MAE).

Sementara itu, model LSTM murni memiliki konfigurasi yang lebih sederhana, terdiri dari satu lapisan LSTM dengan 64 unit, satu *Dropout Layer* sebesar 0,2, diikuti *Global Average Pooling 1D*, dan satu *Dense Layer* linear sebagai keluaran. Fungsi kerugian, algoritma optimasi, dan metrik evaluasi dibuat seragam agar perbandingan antar model lebih objektif.

Hasil perbandingan menunjukkan bahwa model CNN–LSTM dengan *Attention Layer* memiliki kompleksitas lebih tinggi karena penambahan lapisan konvolusional dan mekanisme perhatian, namun hal ini memberikan kemampuan lebih baik dalam mengekstraksi fitur lokal serta menonjolkan informasi yang paling relevan. Sebaliknya, LSTM murni unggul dari sisi efisiensi dan waktu pelatihan, tetapi kurang adaptif terhadap variasi data yang kompleks dan nonlinier. Dengan demikian, konfigurasi *hyperparameter* pada model CNN–LSTM–*Attention* merepresentasikan keseimbangan antara kompleksitas dan ketelitian estimasi, menghasilkan akurasi yang lebih tinggi tanpa mengorbankan stabilitas pelatihan secara signifikan.

2.3 Perbandingan Nilai RMSE, MAE, dan *Absolute Error* Estimasi *State of Charge* (SoC) pada Tahap Pelatihan dan Pengujian

Pada bagian ini berisi tabel perbandingan nilai antara LSTM dan CNN-LSTM + *Attention Layer*, pada pelatihan (*training*) dan pengujian (*testing*). Tujuannya adalah menunjukkan seberapa akurat dan representatif dari masing-masing model dalam memperkirakan SoC berdasarkan metrik RMSE, MAE, *absolute error*.

Tabel 4. Perbandingan Hasil Evaluasi Kinerja Model

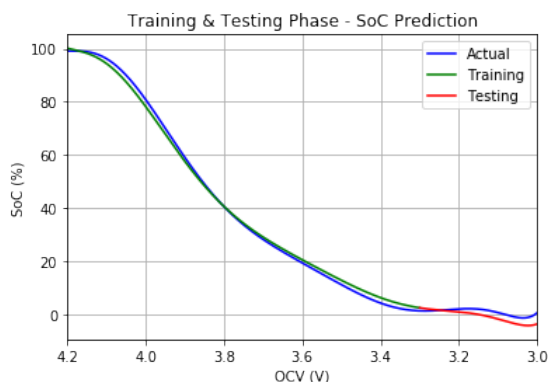
Model	RMSE		MAE		<i>Absolute Error</i>	
	<i>Train</i>	<i>Test</i>	<i>Train</i>	<i>Test</i>	<i>Train</i>	<i>Test</i>
LSTM	0,0157	0,0203	0,0140	0,0176	1,4011	1,4011
CNN-LSTM + <i>Attention Layer</i>	0,0153	0,0099	0,0127	0,0083	0,0923	0,1879

Secara keseluruhan, hasil evaluasi membuktikan bahwa arsitektur CNN–LSTM dengan *Attention Layer* mampu memberikan peningkatan performa yang signifikan dalam proses estimasi *State of Charge* (SoC) baterai *lithium-ion*. Penambahan lapisan konvolusional memungkinkan model untuk mengenali pola-pola lokal pada sinyal arus dan tegangan yang bersifat cepat dan fluktuatif, sementara *Attention Layer* memberikan fleksibilitas bagi model untuk menitikberatkan pembelajaran pada bagian data yang paling berpengaruh terhadap hasil estimasi. Kombinasi kedua mekanisme ini menjadikan model lebih tangguh terhadap variasi data serta mampu menangani karakteristik nonlinier pada kondisi tegangan rendah yang sulit diidentifikasi oleh model LSTM konvensional.

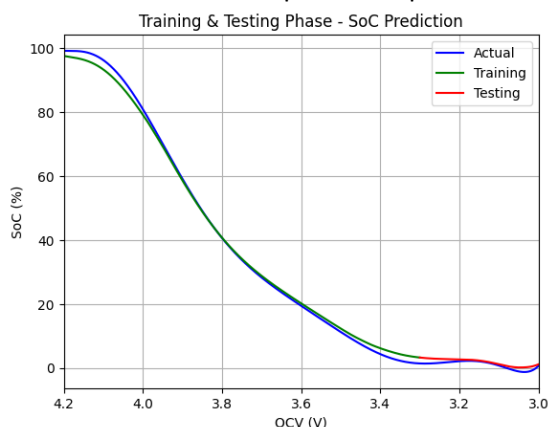
Selain itu, hasil pengujian menunjukkan bahwa model CNN–LSTM dengan *Attention Layer* tidak hanya memiliki akurasi lebih tinggi, tetapi juga menunjukkan stabilitas yang lebih baik pada data pengujian dibandingkan model LSTM murni. Hal ini terlihat dari perbedaan nilai RMSE dan MAE yang tetap konsisten rendah, menandakan kemampuan generalisasi yang baik terhadap data baru. Dengan demikian, model gabungan ini dinilai lebih layak untuk diimplementasikan pada sistem *Battery Management System* (BMS) berbasis perangkat tertanam (*embedded system*), karena menawarkan keseimbangan antara akurasi prediksi, efisiensi komputasi, dan ketahanan terhadap dinamika operasi baterai di kondisi nyata.

2.4 Perbandingan kombinasi Grafik Estimasi SoC Pada Tahap Pelatihan dan Pengujian

Pada bagian ini menampilkan perbandingan hasil estimasi *State of Charge* (SoC) terhadap data aktual pada tahap pelatihan dan pengujian untuk dua model, yaitu LSTM konvensional dan CNN–LSTM dengan *Attention Layer*.



Gambar 8. Grafik kombinasi Estimasi SoC pada data pelatihan dan Pengujian LSTM



Gambar 9. Grafik Kombinasi Estimasi SoC pada data pelatihan dan Pengujian CNN- LSTM + *Attention Layer*

Analisis hasil estimasi pada Gambar 10 menunjukkan bahwa model LSTM mampu mengikuti pola umum hubungan antara *Open Circuit Voltage* (OCV) dan *State of Charge* (SoC) baik pada data pelatihan maupun pengujian. Kurva prediksi (garis hijau dan merah) relatif mendekati data aktual (garis biru), tetapi terlihat adanya deviasi pada rentang tegangan rendah di bawah 3,3 V, di mana model kurang mampu menangkap sifat nonlinier karakteristik baterai. Hal ini menunjukkan bahwa meskipun LSTM efektif dalam


mempelajari ketergantungan temporal antar data, kemampuannya masih terbatas dalam mengekstraksi variasi fitur lokal yang kompleks pada sinyal dinamis hasil *pulse test*.

Sebaliknya, hasil estimasi pada Gambar 11 memperlihatkan bahwa model CNN-LSTM dengan *Attention Layer* mampu menghasilkan kurva prediksi yang hampir sepenuhnya berimpit dengan data aktual pada seluruh rentang OCV, baik di area tegangan tinggi maupun rendah. Kombinasi lapisan konvolusional (CNN) dan LSTM terbukti efektif dalam mengekstraksi pola lokal sekaligus menangkap hubungan jangka panjang antar urutan data. Penambahan *Attention Layer* juga meningkatkan kemampuan model untuk fokus pada bagian data yang paling berpengaruh terhadap hasil prediksi SoC, sehingga estimasi yang dihasilkan menjadi lebih stabil, presisi, dan adaptif terhadap variasi kondisi baterai.

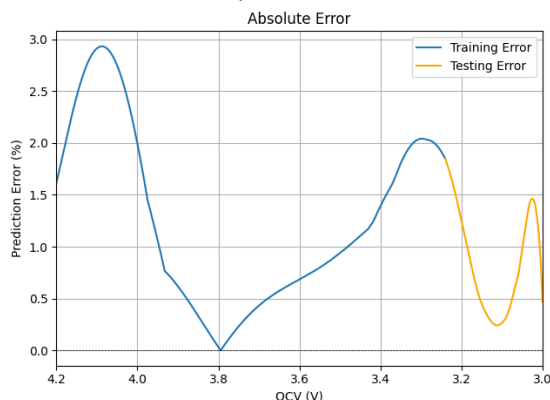
Secara keseluruhan, model CNN-LSTM dengan *Attention Layer* menunjukkan kemampuan generalisasi yang lebih baik dibandingkan model LSTM konvensional. Deviasi antara kurva pelatihan dan pengujian tampak lebih kecil, dengan hasil prediksi yang lebih halus dan konsisten terhadap data aktual. Dengan demikian, integrasi CNN dan mekanisme *attention* terbukti memberikan peningkatan signifikan terhadap akurasi dan konsistensi estimasi SoC baterai *lithium-ion* berbasis data *pulse test*.

2.5 Perbandingan Hasil *Absolute Error* Estimasi *State of Charge* pada Tahap Pelatihan dan Pengujian

Pada bagian ini menampilkan grafik *absolute error* antara hasil prediksi *State of Charge* pada tahap pelatihan dan pengujian untuk masing - masing model LSTM dan CNN-LSTM + *Attention Layer*. Perbandingan model ini digunakan untuk mengetahui besaran kesalahan prediksi.



Gambar 10. Grafik *Absolute Error* pada Data Pelatihan dan Pengujian LSTM



Gambar 11. Grafik *Absolute Error* pada Data Pelatihan dan Pengujian CNN- LSTM + *Attention Layer*

Perbandingan grafik *absolute error* antara tahap pelatihan dan pengujian ditunjukkan pada Gambar 12 dan Gambar 13. Nilai *absolute error* merepresentasikan selisih antara hasil estimasi model terhadap nilai aktual (*ground truth*) pada setiap titik *Open Circuit Voltage* (OCV), sehingga memberikan gambaran lebih detail mengenai tingkat akurasi estimasi *State of Charge* (SoC).

Grafik *absolute error* model CNN–LSTM dengan *Attention Layer* menunjukkan tingkat kesalahan yang rendah dan stabil di sepanjang rentang OCV. Puncak kesalahan hanya muncul pada tegangan sekitar 4,2 V dengan nilai sedikit di atas 3%, namun secara keseluruhan fluktuasi *error* sangat kecil dan menurun secara konsisten hingga di bawah 1% pada tegangan di bawah 3,2 V. Pola ini menandakan bahwa model mampu menjaga kestabilan performa baik pada tahap pelatihan maupun pengujian. Secara kuantitatif, rata-rata *absolute error* tercatat sebesar 0.0923% pada pelatihan dan 0.1879% pada pengujian, menandakan tingkat akurasi yang sangat tinggi dan generalisasi yang baik terhadap data baru.

Sebaliknya, model LSTM murni menunjukkan fluktuasi *absolute error* yang lebih besar. Kesalahan prediksi mencapai puncak sekitar 2,8% pada OCV 4,1 V, dan meningkat kembali di bawah 3,2 V akibat kesulitan model dalam menangkap karakteristik nonlinier pada area tegangan rendah. Rata-rata *absolute error* model LSTM mencapai 1.4011%, menandakan keterbatasan dalam mengenali variasi cepat perubahan SoC dan fitur lokal yang kompleks.

Hasil ini memperkuat bahwa integrasi CNN dan *Attention Layer* berkontribusi besar terhadap peningkatan akurasi dan kestabilan estimasi SoC. Lapisan CNN efektif mengekstraksi pola lokal dari data OCV dan arus, sedangkan *Attention Layer* meningkatkan sensitivitas model terhadap bagian data yang paling relevan. Kombinasi keduanya menghasilkan distribusi kesalahan yang lebih merata, tren *error* yang lebih stabil, serta kemampuan generalisasi yang lebih baik terhadap data pengujian berbasis *pulse test* baterai *lithium-ion*.

KESIMPULAN

Berdasarkan hasil perancangan, pengujian, serta analisis yang telah dilakukan, berikut merupakan kesimpulan dari penelitian ini.

- a. Perangkat uji *pulse test* berbasis mikrokontroler ESP32 berhasil dirancang dan dibangun dengan baik. Sistem ini mampu menghasilkan arus terputus-putus serta mencatat data tegangan dan arus baterai secara melalui sensor INA219. Data yang diperoleh kemudian dapat diproses lebih lanjut untuk menghasilkan informasi penting, seperti estimasi resistansi internal dan kurva hubungan SoC–OCV, yang menjadi landasan utama dalam pelatihan model estimasi.
- b. Model estimasi *State of Charge* berbasis CNN–LSTM dengan tambahan *Attention Layer* menunjukkan kinerja yang lebih baik dibandingkan dengan metode LSTM konvensional. Hasil evaluasi menggunakan metrik RMSE dan MAE memperlihatkan bahwa model CNN–LSTM + *Attention* mampu mengikuti tren perubahan SoC dengan lebih presisi serta menghasilkan tingkat kesalahan prediksi yang lebih rendah. Hal ini membuktikan bahwa integrasi CNN, LSTM, dan *Attention Layer* dapat meningkatkan akurasi estimasi SoC pada baterai *lithium-ion*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] X. Song, F. Yang, D. Wang, and K. L. Tsui, "Combined CNN-LSTM Network for State-of-Charge Estimation of Lithium-Ion Batteries," *IEEE Access*, vol. 7, pp. 88894–88902, 2019, doi: 10.1109/ACCESS.2019.2926517.
- [2] A. D. Isnaini, Suwandi, and R. F. Iskandar, "ESTIMASI STATE OF CHARGE PADA BATERAI LITHIUM ION MENGGUNAKAN METODE PERHITUNGAN COULOMB," *e-Proceeding of Engineering*, vol. 4, no. 1, pp. 650–57, 2017.
- [3] Y. Afrida, A. Afandi, Jeckson, and Ubaidah, "Studi Penentuan State Of Charge (SOC) pada Baterai Valve Regulated Lead Acid NP7-12 Menggunakan MATLAB," *ELECTRICIAN – Jurnal Rekayasa dan Teknologi Elektro*, vol. 17, no. 2, pp. 146–150, 2023.

-
- [4] A. M. S. M. H. S. Attanayaka, J. P. Karunadasa, and K. T. M. U. Hemapala, "Estimation of state of charge for lithium-ion batteries - A Review," *AIMS Energy*, vol. 7, no. 2, pp. 186–210, 2019, doi: 10.3934/ENERGY.2019.2.186.
- [5] P. Ningrum and N. A. Windarko, "Estimation of State of Charge (SoC) Using Modified Coulomb Counting Method with Open Circuit Compensation for Battery Management System (BMS)," *Journal on Advanced Research in Electrical Engineering*, vol. 5, no. 1, pp. 15–20, 2021.
- [6] E. N. Arrofiqoh and Harintaka, "IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI," *GEOMATIKA*, vol. 24, no. 2, pp. 61–68, 2018, doi: 10.24895/jig.2018.24-2.810.
- [7] B. S. Hantono, A. I. Cahyadi, and G. N. P. Pratama, "LSTM for State of Charge Estimation of Lithium Polymer Battery on Jetson Nano," *3th International Conference on Information Technology and Electrical Engineering (ICITEE)*, pp. 80–85, 2021.
- [8] M. Zhang and Z. Wang, "Soc estimation for lithium batteries using a cnn- attention-lstm model," *J Energy Storage*, 2025.
- [9] W. Zhou, Y. Zheng, Z. Pan, and Q. Lu, "Review on the Battery Model and SOC Estimation Method," *Processes*, vol. 9, no. 9, pp. 1–23, Sep. 2021, doi: 10.3390/pr9091685.
- [10] R. D. W. Santosa, Moch. A. Bijaksana, and A. Romadhony, "Implementasi Algoritma Long Short-Term Memory (LSTM) untuk Mendeteksi Penggunaan Kalimat Abusive Pada Teks Bahasa Indonesia," *e-Proceeding of Engineering*, vol. 8, no. 1, pp. 691–702, 2021.
- [11] X. Guo, X. Xu, J. Geng, X. Hua, Y. Gao, and Z. Liu, "SOC Estimation with an Adaptive Unscented Kalman Filter Based on Model Parameter Optimization," *Applied Sciences*, vol. 9, no. 19, 2019, doi: 10.3390/app9194177.
- [12] A. A. H. R, N. A. Windarko, and B. Sumantri, "Estimasi State Of Charge (Soc) Pada Baterai Lithium Ion Menggunakan Long Short-Term Memory (LSTM) Neural Network," *Briliant: Jurnal Riset dan Konseptual*, vol. 9, no. 4, pp. 986–997, 2024, doi: 10.28926/briliant.v9i4.1955.
- [13] G. Chen, W. Peng, and F. Yang, "An LSTM-SA model for SOC estimation of lithium-ion batteries under various temperatures and aging levels," *J Energy Storage*, vol. 84, no. 4, 2024.