

# Perbandingan *Time Step* pada Model Prediksi *State of Health* Baterai *Lithium-ion* Berbasis BiLSTM

I Bagus Ngurah Alit Putra Wiryawan<sup>1\*</sup>

<sup>1</sup>Departemen Fisika, Universitas Pendidikan Ganesha, Singaraja, Indonesia

\*[i.bagus31@ui.ac.id](mailto:i.bagus31@ui.ac.id)

## ABSTRAK

Perkembangan teknologi penyimpanan berbasis baterai *Lithium-ion* saat ini menuntut adanya sistem keamanan penggunaannya. Baterai *Lithium-ion* sebagai sistem elektrokimia mengalami penurunan seiring penggunaan jangka panjang dan berdampak pada pengoperasiannya. Keamanan dan reliabilitasnya perlu dipastikan melalui beberapa indikator seperti *state of charge* (SOC), *state of health* (SOH), dan *remaining useful life* (RUL). SOH memiliki peran penting dalam mengkarakterisasi kinerja dan penuaan baterai. Oleh karena itu, prediksi SOH baterai *Lithium-ion* yang tepat menjadi tantangan karena proses penuaan baterai yang nonlinier. Penelitian ini bertujuan untuk membuat model prediksi SOH baterai *Lithium-ion* menggunakan *Bidirectional Long Short-term Memory* (BiLSTM) dengan membandingkan *time step* prediksinya. Dataset yang digunakan dalam pembuatan model berasal dari CALCE *University of Maryland*, menggunakan baterai *Lithium Cobalt Oxide* (LCO) dengan kode CS2- 35, CS2-36, CS2-37, dan CS2-38. Data train terdiri dari 3 set data dan data test terdiri dari 1 set data. Evaluasi performa menggunakan MAPE dan RMSE. Hasil penelitian menunjukkan bahwa penggunaan *time step* 10 dan 25 tidak memiliki perbedaan, namun memiliki perbedaan pada *time step* 50 dan 100. Performa terbaik ada pada penggunaan *time step* 50 pada setiap dataset baterai. Sehingga, prediksi SOH baterai terbaik menggunakan 50 data sebelumnya untuk menghasilkan 1 data baru.

**Kata Kunci:** BiLSTM, *Lithium-ion*, SOH, *Time step*

## 1. PENDAHULUAN

Baterai *Lithium-ion* merupakan penyimpan energi yang terus berkembang dan digunakan pada berbagai alat. Produk ini memainkan peranan penting pada kendaraan listrik seperti motor dan mobil, dan alat-alat berbasis listrik. Berbagai keunggulan dari baterai *Lithium-ion* diantaranya: densitas energi yang tinggi, *self-discharge rate* yang rendah, densitas daya yang tinggi, dan masa pakai yang lama (Shu dkk., 2022; Zhao dkk., 2024). Penggunaan baterai *Lithium-ion* juga sangat mencuri perhatian karena ramah lingkungan (Oyucu dkk., 2024). Sementara itu, baterai *Lithium-ion* pasti mengalami kerusakan secara bertahap, yang dapat dilihat dari penurunan kapasitas. Saat ini, kapasitas baterai *Lithium-ion* yang tersisa dapat ditentukan dengan eksperimen yang dirancang khusus atau estimasi yang tepat, dan informasi kapasitas yang akurat khususnya pada *Battery Management System* (BMS). Namun, pengukuran kapasitas langsung baterai *Lithium-ion* masih menantang karena sulitnya eksperimen, sehingga menginspirasi para peneliti untuk mengembangkan algoritma untuk memperkirakan kapasitas baterai secara tidak langsung berdasarkan pengukuran eksternal yang tersedia.

Saat ini, penelitian yang ada mengenai estimasi kapasitas yang tersisa secara garis besar dapat dibagi menjadi pengukuran langsung menggunakan metode pemodelan (*model-based method*) dan metode berbasis data (*data driven method*). Metode berbasis model menggambarkan proses kerusakan baterai dari model empiris yang mensimulasikan tren kerusakan baterai *Lithium-ion* (Liu dkk., 2024). Umumnya, metode ini menggunakan model *equivalent circuit* dan model elektrokimia. Metode berbasis model ini dilaporkan memiliki performa yang stabil dan akurasi yang tinggi (Mirzaee & Kamrava, 2023). Namun, model ini memiliki tantangan pada pembuatannya, pengetahuan yang kompleks tentang reaksi kimia baterai, dan akurasinya bergantung pada akurasi model baterai yang sudah ada. Sehingga, untuk mengatasi kelemahan ini, peneliti banyak mengembangkan metode berbasis data.

Metode berbasis data berupaya untuk memastikan pola perubahan SOH baterai *Lithium-ion* secara langsung dari data. Metode ini lebih banyak menggunakan *machine learning* dalam analisisnya. Berbagai teknik *machine learning* pernah digunakan dari berbagai kajian untuk memprediksi keadaan baterai *Lithium-ion*. Berbagai teknik tersebut diantaranya *Support Vector Machine* (SVM), *Support Vector Regression* (SVR) (Xue dkk., 2020), *Random Forest* (Shu dkk., 2022), *Artificial Neural Network* (ANN), *Long Short-term Memory Network* (LSTM) (Wu dkk., 2020). SVM dan SVR digunakan untuk menyelesaikan masalah klasifikasi dan regresi menggunakan perbedaan antara dataset. Berbeda dengan, RF yang mengidentifikasi pola dalam dataset dan membuat prediksi, *neural network* lebih disukai dalam memodelkan hubungan dengan arsitektur kompleks seperti pada jaringan otak manusia. Model ANN dan LSTM digunakan untuk menganalisis hubungan antara variabel dependen dan independen, dan membuat

prediksinya (Oyucu dkk., 2024). Penggunaan teknik *machine learning* dan *deep learning* dengan penggunaan alat yang begitu luas dapat menjadi solusi masalah kompleks, seperti prediksi SOH pada Lithium-ion.

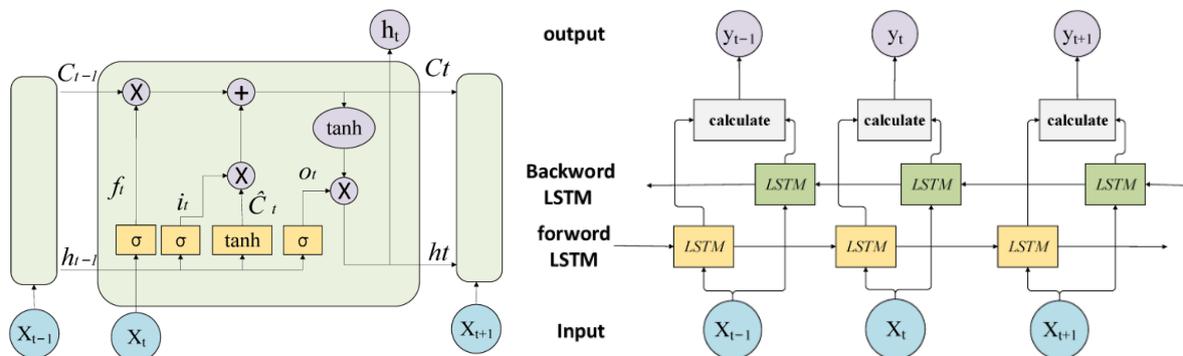
*Recurrent Neural Network* (RNN) seperti LSTM dan *Gated Recurrent Unit* (GRU), sering digunakan dalam estimasi dan prediksi *State of Charge* (SOC) dan *State of Health* (SOH) baterai Lithium-ion. Model RNN digunakan karena metode berbasis data tidak memerlukan bagaimana perubahan keadaan elektrokimia dalam baterai yang tidak dapat diukur. Pada studi ini, digunakan *Bidirectional Long Short-term Memory Network* (BiLSTM) yang merupakan pengembangan model LSTM. Selama masa pakai baterai, SOH adalah *time series*, dan nilai SOH dalam deret tersebut tidak hanya terkait dengan perubahan tren dalam data maju, tetapi juga merupakan dasar untuk perubahan data SOH mundur. Dibandingkan dengan jaringan LSTM, jaringan BiLSTM menganalisis dan memproses hubungan temporal dua arah dari data SOH baterai. Jaringan ini melakukan ekstraksi memori dari fitur data masa lalu dan masa depan, sehingga semakin meningkatkan akurasi prediksi model (Sun dkk., 2022).

Kajian penggunaan model BiLSTM pada estimasi SOH dengan berbagai seleksi fitur telah banyak dilakukan. Namun, masih sedikit penelitian yang melakukan prediksi terhadap nilai SOH baterai Lithium-ion. Model prediksi umumnya menggunakan *time step* untuk menentukan nilai kedepannya. *Time step* ini akan sangat berkaitan erat dengan dataset yang digunakan. Penelitian pada variasi *time step* belum banyak dilakukan, sehingga pada studi ini peneliti mengkaji variasi *time step* pada model BiLSTM dalam memprediksi nilai SOH baterai Lithium-ion.

## 2. KAJIAN PUSTAKA

### 2.1 Bidirectional Long Short-Term Memory (BiLSTM)

*Recurrent Neural Network* (RNN) adalah model *deep learning* yang khusus digunakan pada penyelesaian masalah deret waktu. Model BiLSTM merupakan pengembangan dari model *Long Short-Term Memory* (LSTM), yang mana LSTM menjadi pengembangan dari RNN. Model BiLSTM terdiri atas dua bagian utama, satu model LSTM yang memproses fitur input masa lalu dalam arah maju, dan LSTM lain untuk mengatur fitur input masa depan dalam arah mundur. Karakteristik inilah yang menyebabkan model BiLSTM sangat baik dalam performa prediksi, termasuk dalam data sekuensial yang panjang (Guo dkk., 2022; Sherkatghanad dkk., 2024). Struktur dan skema dari BiLSTM disajikan pada Gambar 1.



Gambar 1(a). Struktur Model LSTM, (b) Skema Model BiLSTM.

Sumber: Sun dkk. (2022)

BiLSTM yang merupakan algoritma jaringan LSTM yang telah disempurnakan, memiliki struktur jaringan seperti yang ditunjukkan pada Gambar 1b. Selama proses pembelajaran jaringan BiLSTM, urutan input dimasukkan ke jaringan *forward LSTM* dalam urutan positif, dan jaringan *backward LSTM* dimasukkan dalam urutan terbalik. Jaringan *forward* dan *backward* masing-masing melakukan ekstraksi fitur dan memori pengetahuan dari konteks urutan input. Hasil output akhir jaringan BiLSTM dapat diperoleh dengan mengintegrasikan hasil output dari hasil output maju dan mundur. Jaringan *forward LSTM* dan *backward LSTM* memiliki komposisi dan prinsip kerja yang sama, tetapi dengan urutan input yang berlawanan (Sun dkk., 2022).

### 2.1 State of health (SOH)

Penuaan baterai Sebagian besar ditandai dengan peningkatan internal dan penurunan kapasitas yang tersedia. Oleh karena itu, SOH baterai Lithium-ion digambarkan dalam dua variabel, resistansi internal dan kapasitas. Resistansi internal dari baterai akan meningkat seiring dengan penuaan baterai, sehingga SOH baterai dapat dinyatakan sebagai berikut (Yao dkk., 2021):

$$SOH = \frac{R_e - R}{R_e - R_n} \quad (1)$$

$R$  merupakan resistansi internal dibawah keadaan tegangan,  $R_e$  merupakan resistansi internal dari baterai ketika masa akhir (*end of life*), dan  $R_n$  merupakan resistansi internal dari baterai baru. SOH baterai juga dapat ditentukan dari kapasitasnya yang dinyatakan sebagai berikut (Yao dkk., 2021):

$$SOH = \frac{Q_m}{Q_r} \quad (2)$$

$Q_r$  merupakan kapasitas terukur dan  $Q_m$  merupakan kapasitas maksimum yang dimiliki oleh baterai. Baterai dianggap tidak layak digunakan Ketika kapasitasnya telah mencapai 70% atau 80% dari kapasitas inisialnya (Liu dkk., 2024).

### 3. METODE

#### 3.1 Dataset Penelitian

Penelitian ini menggunakan dataset yang dipublikasikan oleh *Center for Advanced Life Cycle Engineering (CALCE), University of Maryland (CALCE, 2011)*. Dataset yang diambil menggunakan jenis *Lithium Cobalt Oxide (LCO)*. Prosedur untuk *battery cycling* menggunakan alat Arbin Instruments BT2000 dan dianalisis menggunakan Arbin Mits Pro Software (Shah dkk., 2024). Pengaturan ini didesain untuk estimasi keadaan baterai, prediksi remaining useful life, pemodelan percepatan degradasi, dan analisis reabilitas. Baterai pada dataset ini menggunakan kapasitas 1.1Ah (Pham dkk., 2023). Baterai diisi (*charge*) menggunakan *constant current* sebesar 1A. Ketika arus menurun hingga 0.5A selama penggunaan, dilakukan penukaran *charging mode* ke *constant voltage* hingga tegangan mencapai 4.2V (D. Chen dkk., 2022). Saat *discharge*, baterai dikosongkan dengan laju hingga tegangan turun menjadi 2.7V (Zhao dkk., 2024). Penelitian ini menggunakan empat baterai dalam CALCE Dataset CS2 seperti pada Tabel 1. *Cycle threshold* menunjukkan banyaknya *cycle* yang telah dicapai oleh baterai hingga batas SOH sebesar 0.8 atau 80% dari kapasitas nominalnya.

Tabel 1. Deskripsi Dataset Penelitian

Baterai	CALCE Code	Cycle Life	Capacity Rated	Cycle until Threshold
1	CS2-35	932	1.1 Ah	515
2	CS2-36	973	1.1 Ah	475
3	CS2-37	1038	1.1 Ah	554
4	CS2-38	1078	1.1 Ah	478

#### 3.2 Prosedur Penelitian

##### 3.2.1 Data Preprocessing

Pra pemrosesan data merupakan langkah yang penting dalam mempersiapkan data untuk pemodelan dan analisis. Bentuk intuitif dari degradasi baterai adalah penurunan kapasitas, yang sebagian besar terkait dengan SOH baterai. *Data preprocessing* pada penelitian ini dilakukan untuk membersihkan dan menormalisasi data. Dataset yang diperoleh dari CALCE diambil nilai tegangan (V), arus (I), dan waktu (t) untuk mendapatkan nilai kapasitas *discharge* menggunakan Persamaan (3) (Yao dkk., 2021).

$$Q = \int I dt \quad (3)$$

Nilai kapasitas yang diperoleh dari Persamaan (3) dilakukan pembersihan dengan menghilangkan *outlier* dan nilai yang hilang. *Data preprocessing* ini memastikan bahwa tidak ada nilai yang salah sehingga tidak mengacaukan model yang dibuat. Terdapat beberapa definisi dari bentuk SOH baterai dengan perbedaan karakteristik di dalamnya, seperti berbasis resistansi internal dan berbasis kapasitas. SOH merupakan indikator kuantitatif dari tingkat degradasi baterai. Pada penelitian ini, definisi SOH menggunakan basis kapasitas yang ditunjukkan pada Persamaan (4).

$$SOH = \frac{C_i}{C_0} \quad (4)$$

Setelah dilakukan pra-pemrosesan data, dilakukan pembuatan model prediksi. Model prediksi SOH *time series* digunakan dalam pembuatan mengikuti persamaan (5).

$$SOH_{p+1} = f(SOH_p, SOH_{p-1}, \dots, SOH_{p-q}), q < p \quad (6)$$

Normalisasi data SOH yang diterapkan dalam pemodelan ini menggunakan [-1,1] *normalization*. Normalisasi ini menggunakan metode maksimum-minimum, dengan data berskala antara 0 hingga 1. Hal ini dijelaskan pada Persamaan (7).

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (7)$$

$x_n$  menunjukkan data yang diproses,  $x$  menunjukkan data asli,  $x_{max}$ ,  $x_{min}$  masing-masing mewakili nilai maksimum dan nilai minimum dari data asli. Penentuan nilai  $x$  dan  $y$  pada model mengikuti Persamaan (8).

$$\begin{aligned} x_1 &= \{SOH_1, SOH_2, \dots, SOH_{10}\}, y_1 = \{SOH_{11}\} \\ x_2 &= \{SOH_2, SOH_3, \dots, SOH_{11}\}, y_2 = \{SOH_{12}\} \\ &\vdots \\ x_n &= \{SOH_n, SOH_{n+1}, \dots, SOH_m\}, y_n = \{SOH_{m+1}\} \\ x_{train} &= \{x_1, x_2, \dots, x_n\}, y_{train} = \{y_1, y_2, \dots, y_n\} \end{aligned} \quad (8)$$

Penggunaan *time step* 10 menggunakan Persamaan (8) sebagai berikut: apabila menentukan  $y_1$  (SOH ke-11) maka akan digunakan nilai 10 data SOH sebelumnya (SOH ke-1 hingga SOH ke-10) sebagai  $x_1$ . Ketika menentukan  $y_2$  (SOH ke-12) maka akan digunakan nilai 10 data sebelumnya (SOH ke-2 hingga SOH ke-11) sebagai  $x_2$ . Perhitungan Persamaan (8) akan digunakan dalam menentukan  $x$  dan  $y$  pada variasi *time step* sesuai penelitian ini yaitu 10, 25, 50 dan 100.

### 3.2.2 Data Training and Testing

Data  $x$  dan  $y$  merupakan variabel independen dan variabel dependen pada penelitian ini yaitu nilai SOH yang dihitung berdasarkan *time step* sesuai Persamaan (8). Berdasarkan dataset, maka dilakukan pemisahan untuk membagi data menjadi data train dan data test. Pembagian dataset disajikan pada Tabel 2.

Tabel 2. Pembagian Data Training dan Data Testing

<i>Data Testing</i>	Jumlah Cycle	<i>Data Training</i>	Jumlah Cycle
CS2-35	515	CS2-36, CS2-37, CS2-38	1507
CS2-36	475	CS2-35, CS2-37, CS2-38	1547
CS2-37	554	CS2-35, CS2-36, CS2-38	1468
CS2-38	478	CS2-35, CS2-36, CS2-37	1544

Pembuatan model BiLSTM memerlukan parameter-parameter dalam arsitekturnya. Adapun pengaturan parameter tersebut disajikan pada Tabel 3.

Tabel 3. Pengaturan Parameter pada Model BiLSTM

Parameter	Deskripsi	Pengaturan
Extractor Model Parameters	Number of inputs/ Time step	10, 25, 50, 100
	Length of input sequence	10, 25, 50, 100
	Input size (BiLSTM Layer 1 unit)	64
Estimator Model Parameters	Input size (BiLSTM Layer 2 unit)	32
	Dense unit	16 (activation ReLu)
	Output size	1
	Batch size	32
Training Hyperparameters	Epoch	100
	Learning rate	0.001
	Loss function	Mean square error (MSE)
	Optimizer	Adam

### 3.3 Matrik Evaluasi

Evaluasi performa dari model prediksi, digunakan tiga matrik yaitu koefisien determinasi ( $R^2$ ), *mean absolute error* (MAE) dan *root mean square error* (RMSE). Koefisien determinasi menunjukkan kesesuaian antara nilai prediksi dan nilai aktual, dihitung berdasarkan persamaan berikut (K. Chen dkk., 2024):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y(i) - \hat{y}(i))^2}{\sum_{i=1}^n (y(i) - \bar{y}(i))^2} \quad (9)$$

MAE merupakan indikator yang digunakan untuk mengukur perbedaan antara nilai prediksi dan nilai aktual, yang mana direpresentasikan dalam rata-rata kesalahan absolut diantara estimasi individu dan rata-rata aritmatika, dihitung berdasarkan persamaan (Zhaofan dkk., 2024):

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

RMSE mengindikasikan deviasi antara nilai prediksi dan nilai aktual, dan menjadi fungsi umum dalam matrik evaluasi akurasi prediksi (Gu dkk., 2023), dihitung berdasarkan persamaan (Zhaofan dkk., 2024):

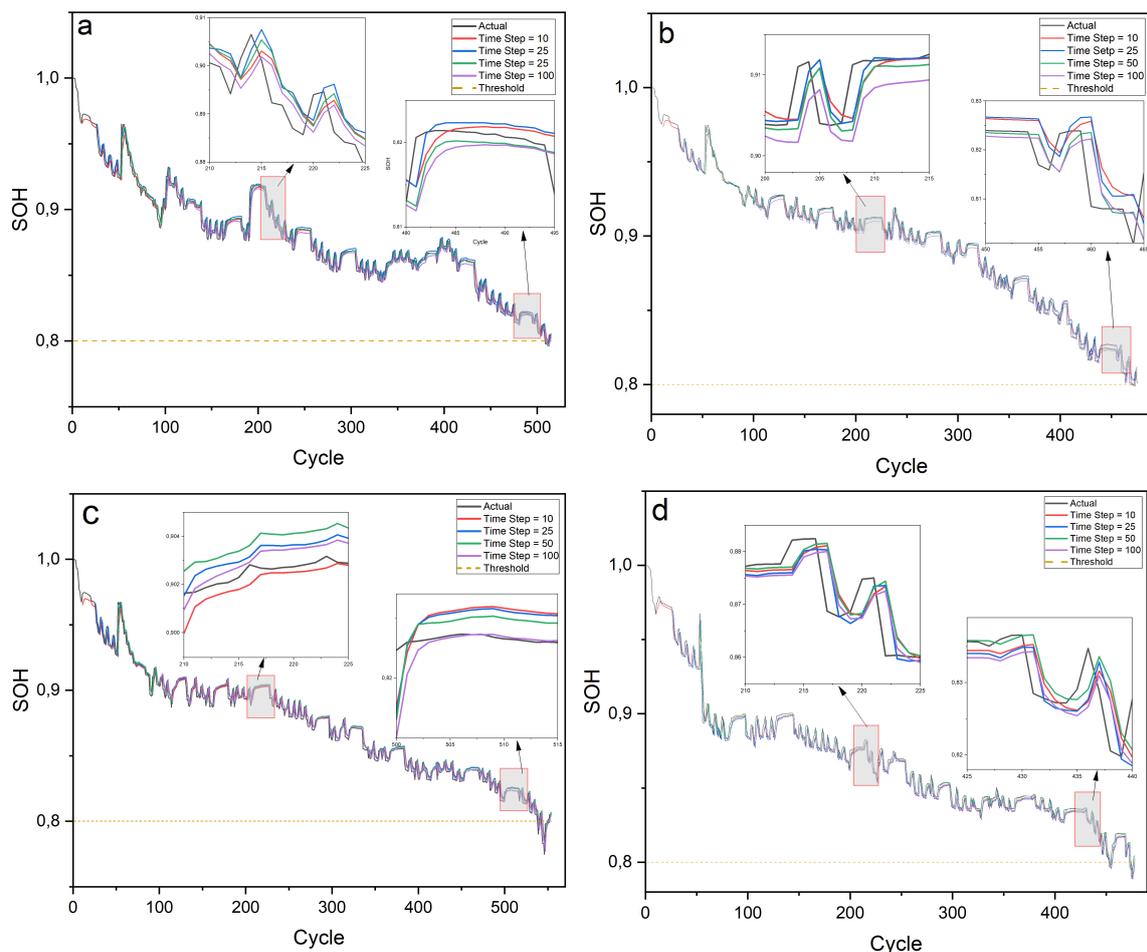
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y(i) - \hat{y}(i))^2} \quad (11)$$

Yang mana  $n$  adalah panjang sekuen,  $y(i)$  dan  $\hat{y}(i)$  mengindikasikan nilai aktual dan nilai prediksi dari prediksi ke- $i$ .

## 4. TEMUAN DAN DISKUSI

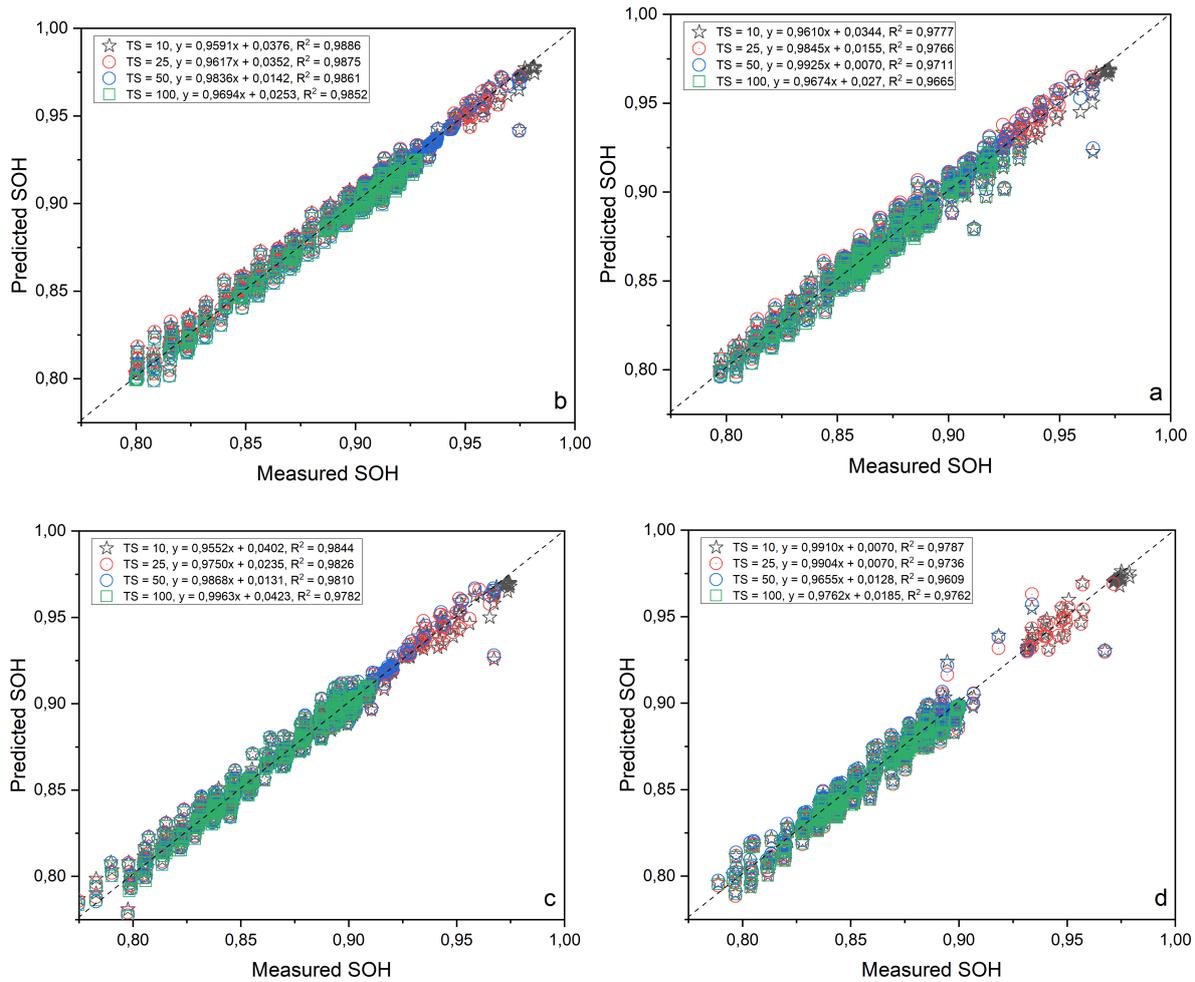
### 4.1 Temuan

Penelitian ini berhasil membuat model prediksi SOH baterai Lithium-ion berbasis BiLSTM dengan variasi *time step* 10, 25, 50, dan 100. Hasil nilai prediksi SOH dan aktual disajikan pada Gambar 2.



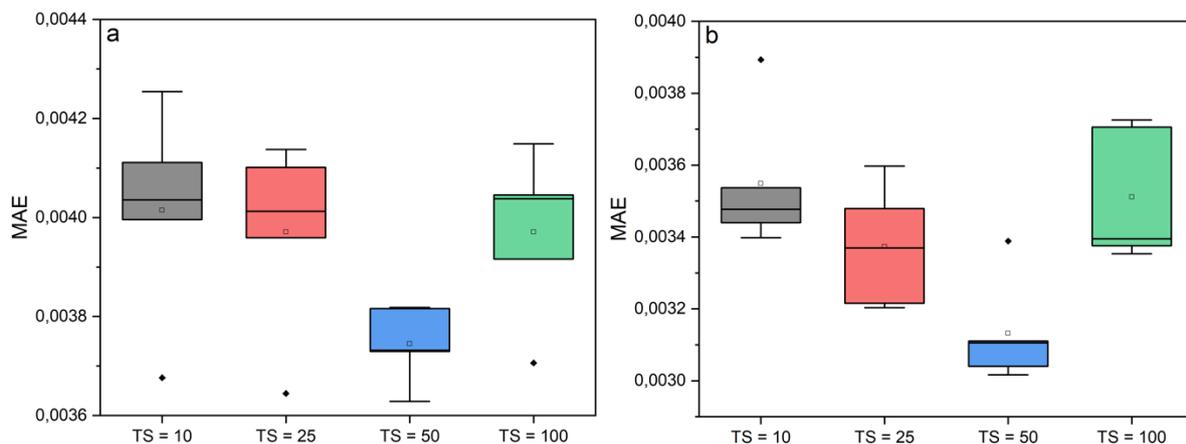
Gambar 2. Grafik Nilai Aktual dan Prediksi SOH Baterai terhadap Cycle pada Berbagai Time Step (a) Baterai CS2-35, (b) Baterai CS2-36, (c) Baterai CS2-37, (d) Baterai CS2-38

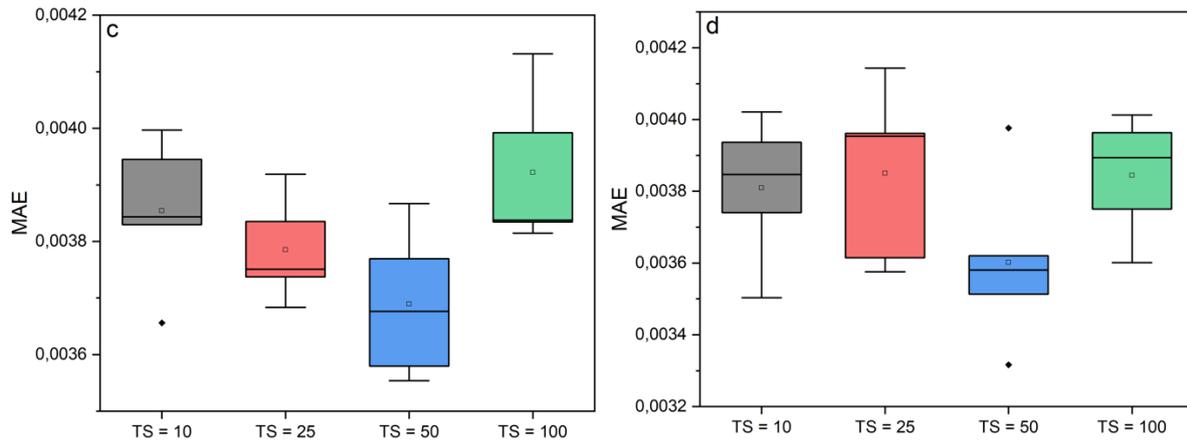
Berdasarkan Gambar 2 yang menampilkan hasil prediksi SOH baterai Lithium-ion menggunakan model BiLSTM dengan empat variasi *time step* yang berbeda: 10, 25, 50, dan 100. Pada setiap grafik (a, b, c, dan d), dapat diamati bahwa pola degradasi SOH yang dimulai dari nilai 1.0 (100%) dan menurun secara bertahap hingga mencapai sekitar 0.8 (80%), dengan garis *threshold* ditetapkan pada nilai 0.8 sebagai batas minimum SOH yang dapat diterima. Masing-masing *time step* ditunjukkan dengan warna yang berbeda - merah untuk time step 10, biru untuk 25, hijau untuk 50, dan ungu untuk 100, sementara garis hitam merepresentasikan nilai aktual SOH.



Gambar 3. Grafik Sebaran Nilai Prediksi terhadap Nilai Aktual SOH pada (a) Baterai CS2-35, (b) Baterai CS2-36, (c) Baterai CS2-37, (d) Baterai CS2-38

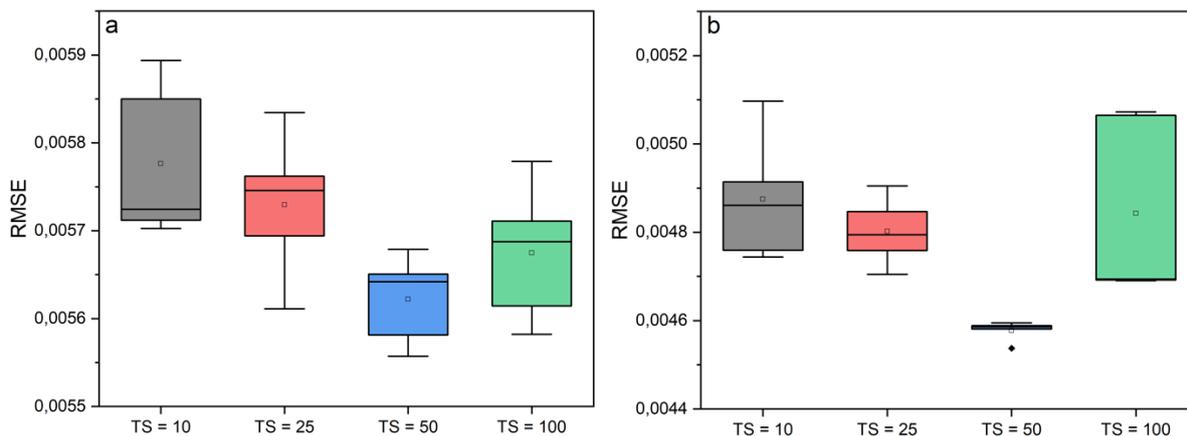
Gambar 3 menunjukkan *scatter plot* yang membandingkan nilai SOH yang diprediksi dengan nilai SOH yang diukur, menggunakan model BILSTM dengan variasi time step (TS) yang berbeda: 10, 25, 50, dan 100. Setiap grafik menunjukkan performa model dengan  $R^2$  (koefisien determinasi) yang sangat baik, berkisar antara 0,96-0,98, mengindikasikan bahwa model memiliki kemampuan prediksi yang kuat. *Scatter plot* membentang dari nilai SOH sekitar 0,80 hingga 0,95, dengan garis putus-putus diagonal sebagai referensi prediksi sempurna. Penyebaran titik-titik data yang rapat mengikuti garis diagonal menunjukkan konsistensi prediksi model di berbagai nilai SOH. Tidak terlihat perbedaan performa yang signifikan antar variasi *time step*, menunjukkan bahwa model BILSTM cukup *robust* terhadap perubahan parameter *time step* dalam rentang yang diuji.

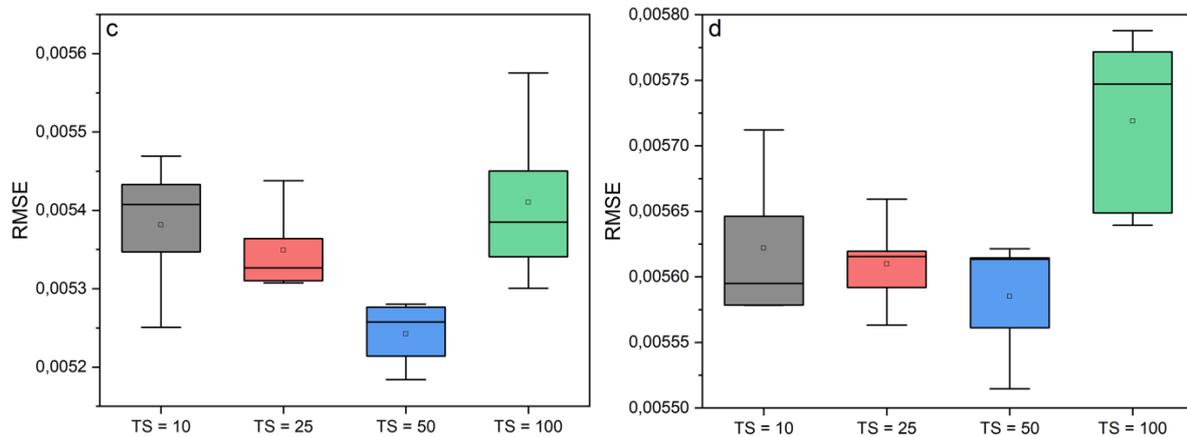




Gambar 4. Grafik *Mean Absolute Error* Nilai Prediksi terhadap Nilai Aktual SOH pada (a) Baterai CS2-35, (b) Baterai CS2-36, (c) Baterai CS2-37, (d) Baterai CS2-38

Berdasarkan Gambar 4. terlihat perbandingan nilai *Mean Absolute Error* (MAE) untuk empat *time step* yang berbeda. Secara umum, nilai MAE berfluktuasi di kisaran 0,0030 hingga 0,0044. Untuk grafik a, nilai MAE tertinggi ditemukan pada TS=10 (sekitar 0,0041), kemudian cenderung menurun pada TS=25 dan TS=50, namun kembali meningkat sedikit pada TS=100. Pada baterai CS2-35, TS=50 menunjukkan nilai MAE terendah (sekitar 0,0037). Pada grafik b yang merupakan baterai CS2-36, tren yang berbeda terlihat dimana nilai MAE tertinggi ada pada TS=100 (sekitar 0,0037), sementara nilai terendah ditemukan pada TS=50 (sekitar 0,0031). Grafik c dengan baterai CS2-37, distribusi MAE menunjukkan pola yang mirip dengan grafik a, dimana TS=100 memiliki nilai MAE tertinggi (sekitar 0,0039), sedangkan TS=50 menunjukkan nilai terendah (sekitar 0,0037). Untuk grafik d dengan baterai CS2-38, variasi nilai MAE relatif lebih stabil dibandingkan grafik lainnya. TS=25 menunjukkan rentang nilai MAE yang lebih lebar, sementara TS=50 memiliki rentang yang lebih sempit. Nilai MAE terendah ditemukan pada TS=50 (sekitar 0,0036). Secara keseluruhan, time step 50 (TS=50) cenderung menghasilkan nilai MAE yang lebih rendah dibandingkan variasi *time step* lainnya, mengindikasikan bahwa penggunaan 50 *time step* memberikan hasil prediksi yang lebih akurat dalam model BiLSTM untuk prediksi SOH. Hal ini mengindikasikan bahwa penggunaan *time step* 50 memiliki hasil yang baik dengan melihat nilai MAE yang kecil dari seluruh jenis data baterai CS2 dalam model BiLSTM.





Gambar 5. Grafik *Root Mean Square Error* Nilai Prediksi terhadap Nilai Aktual SOH pada (a) Baterai CS2-35, (b) Baterai CS2-36, (c) Baterai CS2-37, (d) Baterai CS2-38

Berdasarkan Gambar 5 menunjukkan *boxplot Root Mean Square Error* (RMSE) untuk empat *time step* dari empat data baterai CS2. Seiring peningkatan *time step* dari 10 ke 100, kinerja model BiLSTM dalam memprediksi SOH semakin membaik, dengan TS=50 menunjukkan median RMSE terendah meskipun dengan variabilitas yang lebih tinggi.

Tabel 3. Perbandingan Evaluasi Prediksi SOH pada Berbagai *Time Step* dan Model

Kode Baterai	Time Step	BiLSTM		LSTM		DNN		SVR	
		MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
CS2-35	10	0.00401	0.00577	0.00466	0.00628	0.00513	0.00688	0.00629	0.00788
	25	0.00397	0.00572	0.00513	0.00666	0.00546	0.00703	0.00660	0.00820
	50	0.00374	0.00562	0.00507	0.00659	0.00501	0.00669	0.00742	0.00920
	100	0.00397	0.00567	0.00534	0.00667	0.00576	0.00733	0.00848	0.01078
CS2-36	10	0.00354	0.00487	0.00403	0.00523	0.00437	0.00560	0.00816	0.00966
	25	0.00337	0.00480	0.00356	0.00485	0.00408	0.00529	0.00660	0.00793
	50	0.00313	0.00457	0.00355	0.00482	0.00407	0.00528	0.00656	0.00819
	100	0.00351	0.00480	0.00419	0.00523	0.00441	0.00544	0.00848	0.01056
CS2-37	10	0.00385	0.00538	0.00429	0.00574	0.00548	0.00682	0.00738	0.00880
	25	0.00378	0.00534	0.00464	0.00586	0.00586	0.00658	0.00627	0.00771
	50	0.00368	0.00524	0.00423	0.00571	0.00544	0.00770	0.00642	0.00792
	100	0.00392	0.00541	0.00542	0.00662	0.00737	0.00866	0.00675	0.00819
CS2-38	10	0.00380	0.00562	0.00483	0.00652	0.00629	0.00787	0.00733	0.00973
	25	0.00384	0.00560	0.00446	0.00622	0.00465	0.00628	0.00630	0.00872
	50	0.00360	0.00558	0.00430	0.00605	0.00464	0.00630	0.00715	0.01067
	100	0.00384	0.00571	0.00443	0.00561	0.00501	0.00622	0.00773	0.00919

Tabel 3 menunjukkan perbandingan pada berbagai model prediksi dengan variasi *time step* pada data baterai CS2. Model yang digunakan sebagai pembandingan diantaranya *Support Vector Regression* (SVR), *Deep Neural Network* (DNN), LSTM, dan BiLSTM. Evaluasi yang digunakan sebagai pembandingan adalah MAE dan RMSE. Berdasarkan Tabel 3 terlihat bahwa model SVR dibandingkan model *neural network*, memiliki hasil prediksi yang berbeda. Model *neural network* seperti DNN, LSTM dan BiLSTM memiliki *error* terkecil pada *time step* 50 untuk semua jenis baterai CS2, sedangkan SVR memiliki *error* terkecil pada *time step* yang berbeda-beda.

#### 4.2 Diskusi

Berdasarkan Gambar 2. prediksi model BiLSTM terlihat bahwa *time step* yang lebih kecil (10 dan 25) cenderung menghasilkan prediksi yang lebih detail dan mampu mengikuti fluktuasi data aktual dengan lebih baik. Sementara itu, *time step* yang lebih besar (50 dan 100) menghasilkan kurva yang lebih halus namun terkadang tidak dapat menangkap detail-detail fluktuasi yang terjadi. Berdasarkan MAE dan RMSE yang disajikan pada Gambar 3 dan Gambar 4, prediksi model BiLSTM pada variasi *time step* terlihat bahwa semakin meningkat *time step* yang digunakan, akan mengurangi *error* yang dimiliki. Namun, hal tersebut

berbalik ketika menggunakan time step yang sangat tinggi, akan menambah erornya. Hasil menunjukkan bahwa time step 50 memberikan nilai *MAE* dan *RMSE* yang kecil untuk semua data baterai CS2.

Secara keseluruhan, semua variasi *time step* menunjukkan kemampuan yang baik dalam mengikuti tren degradasi SOH, namun dengan karakteristik yang berbeda-beda. *Time step* yang lebih kecil menunjukkan keunggulan dalam menangkap perubahan mendadak dan fluktuasi jangka pendek, sementara *time step* yang lebih besar lebih efektif dalam memprediksi tren jangka panjang meskipun kurang detail dalam menangkap fluktuasi. Pemilihan *time step* yang optimal akan sangat bergantung pada kebutuhan aplikasi spesifik - apakah lebih mementingkan detail fluktuasi jangka pendek atau fokus pada tren jangka panjang. *Trade-off* ini menjadi pertimbangan penting dalam implementasi model, yang mana *time step* kecil menawarkan detail yang lebih baik namun mungkin lebih sensitif terhadap *noise*, sedangkan *time step* besar memberikan prediksi yang lebih halus namun berisiko melewatkan perubahan-perubahan penting dalam jangka pendek.

Hasil ini sejalan dengan penelitian yang dilakukan oleh C. Chen et al (2023) yang menunjukkan bahwa model LSTM dengan *time step* 200 lebih baik dibandingkan *time step* 300 dan 400. Hasil ini dilihat dari data test berupa CS2-35 dengan nilai *MAE* dan *RMSE* pada *time step* 200 sebesar 0.0442 dan 0.0579. Umumnya penelitian menggunakan performa yang baik pada *time step* menengah (kisaran 30-500). Hasil penelitian ini memiliki *MAE* yang lebih rendah (0.0030 - 0.0044) dengan range *time step* yang lebih komprehensif, dan konsistensi performa lebih baik. Berdasarkan hasil penggunaan model BiLSTM dengan variasi *time step* pada prediksi SOH baterai Lithium-ion dapat dinyatakan bahwa terdapat pengaruh *time step* yang digunakan. *Time step* yang sedikit memberikan keunggulan dalam menangkap tren SOH dalam jangka pendek, namun ketika penggunaan *time step* yang besar dapat menimbulkan *bias* dan mengurangi keakuratan. Oleh karena itu, *time step* yang terbaik dalam penelitian ini adalah penggunaan *time step* medium sebesar 50.

## 5. KESIMPULAN

Model prediksi SOH baterai Lithium-ion berbasis BiLSTM telah berhasil dibuat dengan variasi *time step*. Penggunaan *time step* yaitu 10, 25, 50, dan 100 memberikan hasil akurasi yang berbeda dilihat dari nilai  $R^2$ , *MAE*, dan *RMSE*. Koefisien determinasi menunjukkan model BiLSTM pada variasi *time step* memiliki prediksi yang sangat baik dengan nilai  $R^2$  diantara 0.96-0.8. Ini mengindikasikan juga bahwa model prediksi cukup *robust* terhadap variasi *time step* yang dimiliki. Berdasarkan nilai *MAE* dan *RMSE* menunjukkan bahwa model BiLSTM dengan variasi *time step* memiliki hasil yang paling baik pada *time step* 50 dengan nilai *MAE* dan *RMSE* terkecil dibandingkan *time step* 10, 25 dan 100. Potensi pengembangan penelitian masih terbuka untuk dilakukan. Penelitian berikutnya dapat fokus pada *range time step* 40-60 dan dapat mempertimbangkan arsitektur *hybrid* dengan basis model LSTM ataupun BiLSTM. Implementasi adaptif atau *dynamic time step* masih layak untuk dikembangkan dengan optimasi komputasional. Hal ini dipertimbangkan apabila memiliki data *real-time* yang masih terbatas datanya, sehingga prediksi SOH masih dapat dilakukan dengan optimal apabila *time step* terbaik sudah dilakukan kajian.

## 6. UCAPAN TERIMA KASIH

Penelitian ini didukung melalui pembiayaan oleh Lembaga Pengelola Dana Pendidikan (LPDP) Kementerian Keuangan Republik Indonesia. Penulis menyampaikan terimakasih atas pemberian dukungan dalam penelitian dan publikasi ini.

## 7. DAFTAR PUSTAKA

- CALCE. (2011). *Center for Advanced Life Cycle Engineering (CALCE) University of Maryland Battery Dataset*. <https://calce.umd.edu/battery-data>
- Chen, C., Wei, J., & Li, Z. (2023). Remaining Useful Life Prediction for Lithium-Ion Batteries Based on a Hybrid Deep Learning Model. *Processes*, 11(8), 1–17. <https://doi.org/10.3390/pr11082333>
- Chen, D., Hong, W., & Zhou, X. (2022). Transformer Network for Remaining Useful Life Prediction of Lithium-Ion Batteries. *IEEE Access*, 10, 19621–19628. <https://doi.org/10.1109/ACCESS.2022.3151975>
- Chen, K., Li, J., Liu, K., Bai, C., Zhu, J., Gao, G., Wu, G., & Laghrouche, S. (2024). State of health estimation for lithium-ion battery based on particle swarm optimization algorithm and extreme learning machine. *Green Energy and Intelligent Transportation*, 3(1), 100151. <https://doi.org/10.1016/j.geits.2024.100151>
- Gu, X., See, K. W., Li, P., Shan, K., Wang, Y., Zhao, L., Lim, K. C., & Zhang, N. (2023). A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model. *Energy*, 262(PB), 125501. <https://doi.org/10.1016/j.energy.2022.125501>

- Guo, Y., Yang, D., Zhao, K., & Wang, K. (2022). State of health estimation for lithium-ion battery based on Bi-directional long short-term memory neural network and attention mechanism. *Energy Reports*, 8, 208–215. <https://doi.org/10.1016/j.egy.2022.10.128>
- Liu, S., Chen, Z., Yuan, L., Xu, Z., Jin, L., & Zhang, C. (2024). State of health estimation of lithium-ion batteries based on multi-feature extraction and temporal convolutional network. *Journal of Energy Storage*, 75(July 2023), 109658. <https://doi.org/10.1016/j.est.2023.109658>
- Mirzaee, H., & Kamrava, S. (2023). Estimation of internal states in a Li-ion battery using BiLSTM with Bayesian hyperparameter optimization. *Journal of Energy Storage*, 74(PB), 109522. <https://doi.org/10.1016/j.est.2023.109522>
- Oyucu, S., Doğan, F., Aksöz, A., & Biçer, E. (2024). Comparative Analysis of Commonly Used Machine Learning Approaches for Li-Ion Battery Performance Prediction and Management in Electric Vehicles. *Applied Sciences (Switzerland)*, 14(6). <https://doi.org/10.3390/app14062306>
- Pham, T., Truong, L., Bui, H., Tran, T., Garg, A., Gao, L., & Quan, T. (2023). Towards Channel-Wise Bidirectional Representation Learning with Fixed-Point Positional Encoding for SoH Estimation of Lithium-Ion Battery. *Electronics (Switzerland)*, 12(1). <https://doi.org/10.3390/electronics12010098>
- Shah, S. A. A., Niazi, S. G., Deng, S., Hamza Azam, H. M., Mian Muhammad Yasir, K., Kumar, J., Xu, Z., & Wu, M. (2024). A novel positional encoded attention-based Long short-term memory network for state of charge estimation of lithium-ion battery. *Journal of Power Sources*, 590(August 2023), 233788. <https://doi.org/10.1016/j.jpowsour.2023.233788>
- Sherkatghanad, Z., Ghazanfari, A., & Makarenkov, V. (2024). A self-attention-based CNN-Bi-LSTM model for accurate state-of-charge estimation of lithium-ion batteries. *Journal of Energy Storage*, 88(March), 111524. <https://doi.org/10.1016/j.est.2024.111524>
- Shu, X., Shen, J., Chen, Z., Zhang, Y., Liu, Y., & Lin, Y. (2022). Remaining capacity estimation for lithium-ion batteries via co-operation of multi-machine learning algorithms. *Reliability Engineering and System Safety*, 228(June), 108821. <https://doi.org/10.1016/j.res.2022.108821>
- Sun, S., Sun, J., Wang, Z., Zhou, Z., & Cai, W. (2022). Prediction of Battery SOH by CNN-BiLSTM Network Fused with Attention Mechanism. *Energies*, 15(12). <https://doi.org/10.3390/en15124428>
- Wu, J., Hu, K., Cheng, Y., Zhu, H., Shao, X., & Wang, Y. (2020). Data-driven remaining useful life prediction via multiple sensor signals and deep long short-term memory neural network. *ISA Transactions*, 97, 241–250. <https://doi.org/10.1016/j.isatra.2019.07.004>
- Xue, Z., Zhang, Y., Cheng, C., & Ma, G. (2020). Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression. *Neurocomputing*, 376, 95–102. <https://doi.org/10.1016/j.neucom.2019.09.074>
- Yao, L., Xu, S., Tang, A., Zhou, F., Hou, J., Xiao, Y., & Fu, Z. (2021). A review of lithium-ion battery state of health estimation and prediction methods. *World Electric Vehicle Journal*, 12(3). <https://doi.org/10.3390/wevj12030113>
- Zhao, Y., Li, Q., Li, X., Zhang, G., Shi, H., & Li, Q. (2024). State of health estimation of individual batteries through incremental curve analysis under parameter uncertainty. *IET Renewable Power Generation*, January, 1–11. <https://doi.org/10.1049/rpg2.12971>
- Zhaofan, X., Chen, Z., Yang, L., & Zhang, S. (2024). State of health estimation for lithium-ion batteries based on incremental capacity analysis and Transformer modeling. *Applied Soft Computing Journal*, 165(112072). <https://doi.org/10.1016/j.asoc.2024.112072>