

Estimasi SOC Saat *Discharging* pada Baterai VRLA berbasis *Elman Backpropagation*

**DAH SEPTI YANARATRI, SUTEDJO, ACHMAD DICKY FIRMANSYAH,
IRIANTO, RENNY RAKHMAWATI, AHMAD FIRYAL ADILA**

Teknik Elektro Industri, Politeknik Elektronika Negeri Surabaya, Indonesia
Email : diahsepti@pens.ac.id

Received 26 Juli 2024 | *Revised* 20 September 2024 | *Accepted* 30 September 2024

ABSTRAK

Penurunan performa baterai terjadi akibat siklus pengisian dan pengosongan berulang yang melebihi batas, mempercepat degradasi. Penelitian ini bertujuan untuk meningkatkan akurasi estimasi State of Charge (SOC) baterai menggunakan Artificial Neural Network (ANN) dengan algoritma Elman Backpropagation. Metode digunakan karena menambahkan lapisan context neuron yang mampu menangkap pola dinamis pada data baterai. Pengujian dilakukan dengan membandingkan hasil estimasi SOC dari metode ini dengan metode Coulomb Counting. SOC baterai diestimasi dari 100% hingga 60%, dan hasil menunjukkan bahwa meskipun Coulomb Counting awalnya memberikan SOC lebih tinggi, estimasi dari kedua metode menjadi lebih mirip seiring waktu. Error estimasi berkisar antara 0,1% hingga 14,7%. Algoritma Elman Backpropagation terbukti mampu memberikan estimasi SOC yang lebih akurat, namun masih memerlukan kalibrasi lebih lanjut untuk meningkatkan presisi.

Kata kunci: Artificial Neural Network, Baterai, Coulomb Counting, Elman Backpropagation, State of Charge.

ABSTRACT

The decline in battery performance occurs due to repeated charge and discharge cycles that exceed limits, accelerating degradation. This study aimed to improve the accuracy of State of Charge (SOC) estimation using an Artificial Neural Network (ANN) with the Elman Backpropagation algorithm. The method used was unique in adding a context neuron layer capable of capturing dynamic patterns in battery data. Testing was conducted by comparing SOC estimates from this method with the Coulomb Counting method. The battery's SOC was estimated from 100% to 60%, and the results showed that although Coulomb Counting initially provided higher SOC estimates, the estimates from both methods became more similar over time. Estimation errors ranged from 0.1% to 14.7%. The Elman Backpropagation algorithm proved to provide more accurate SOC estimates, although further calibration is needed to improve precision.

Keywords: Artificial Neural Network, Battery, Coulomb Counting, Elman Backpropagation, State of Charge.

1. PENDAHULUAN

Dalam era modern ini, permintaan akan energi terbarukan terus meningkat, mendorong perkembangan teknologi penyimpanan energi yang efisien. Baterai lead acid tetap menjadi pilihan utama untuk berbagai aplikasi penyimpanan energi karena biaya yang relatif rendah dan kemampuannya untuk menyediakan energi yang dapat diandalkan. Namun, salah satu tantangan utama dalam penggunaan baterai lead acid adalah estimasi akurat dari State of Charge (SOC) untuk mengoptimalkan kinerja dan memperpanjang umur baterai. Metode konvensional seperti Coulomb Counting sering kali kurang akurat dalam kondisi operasional yang dinamis. Coulomb Counting bekerja dengan menghitung arus yang masuk dan keluar dari baterai, namun metode ini tidak mempertimbangkan faktor degradasi baterai, efisiensi pengisian yang menurun, atau perubahan suhu, sehingga menghasilkan estimasi SOC yang tidak stabil, terutama dalam penggunaan jangka panjang. **(Rakhmawati, dkk, 2023).**

Sebaliknya, metode Artificial Neural Network (ANN) berbasis Elman Backpropagation menunjukkan potensi besar dalam memperbaiki akurasi estimasi SOC. Algoritma Elman Recurrent Neural Network (ERNN), dengan penggunaan lapisan konteks neuron, memiliki keunggulan dalam menangani data temporal, memungkinkan sistem untuk mengingat informasi dari kondisi operasi sebelumnya. Ini menjadikan ERNN unggul dalam lingkungan operasional yang dinamis, di mana perubahan arus, tegangan, dan kondisi baterai terjadi secara terus-menerus. Dibandingkan dengan Coulomb Counting, metode ini mampu memperhitungkan berbagai variabel yang memengaruhi performa baterai dalam jangka waktu yang lebih panjang dan memberikan estimasi SOC yang lebih konsisten. **(Rakhmawati, dkk., 2023).**

Penelitian oleh Achmad Afandi (2022) yang menggunakan metode Extended Kalman Filter (EKF) berbasis model sirkuit ekuivalen menunjukkan peningkatan keakuratan estimasi SOC dibandingkan Coulomb Counting, terutama pada ultrakapasitor. Meskipun diterapkan pada perangkat berbeda, pendekatan berbasis model ini memberikan wawasan penting bahwa algoritma berbasis matematika lanjutan dapat memberikan akurasi lebih tinggi dibandingkan metode sederhana seperti Coulomb Counting, yang kurang responsif terhadap kondisi yang berubah-ubah. **(Afandi, dkk, 2022).**

Lebih lanjut, studi oleh Enggar Bima Ihza Febian (2022) mengkaji berbagai metode estimasi SOC seperti ANFIS dan Fuzzy Logic Control (FLC). Hasil studi tersebut menunjukkan bahwa ANN berbasis Elman Backpropagation unggul dalam hal akurasi dan efisiensi dibandingkan metode lain. Hal ini disebabkan oleh kemampuan jaringan saraf dalam belajar dari data masa lalu dan memperhitungkan perubahan yang terjadi secara dinamis dalam pengisian dan pengosongan baterai. **(Febian, dkk, 2022).**

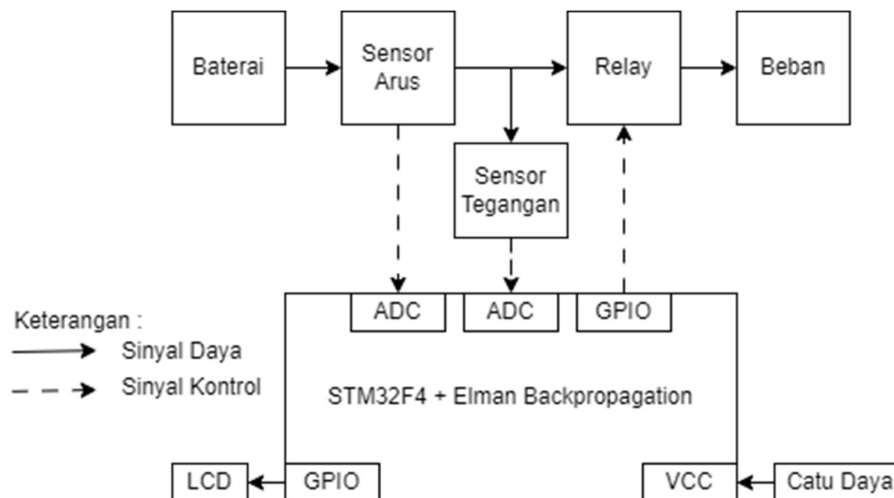
Penelitian oleh Kamanditya & Kusumoputro (2020) yang menerapkan ERNN pada kontrol kuadrotor menunjukkan fleksibilitas algoritma ini dalam berbagai aplikasi, termasuk estimasi SOC baterai. Keunggulan ERNN dalam adaptabilitas terhadap data temporal dan lingkungan operasional yang bervariasi membuatnya menjadi pilihan yang andal, tidak hanya dalam sistem kontrol, tetapi juga dalam estimasi SOC yang memerlukan penyesuaian dengan kondisi baterai yang dinamis. **(Kusumoputro, dkk, 2020)**

Dengan mempertimbangkan hasil dari berbagai penelitian ini, jelas bahwa metode ANN berbasis Elman Backpropagation menawarkan keunggulan yang signifikan dibandingkan metode konvensional seperti Coulomb Counting. Meskipun Coulomb Counting lebih sederhana dan lebih umum digunakan, keterbatasannya dalam menangani kondisi operasi yang dinamis membuat metode ini kurang optimal untuk estimasi SOC yang presisi. Sebaliknya, pendekatan

ANN berbasis Elman Backpropagation menawarkan peningkatan akurasi dan efisiensi yang sangat dibutuhkan dalam manajemen energi terbarukan, khususnya dalam penggunaan baterai lead acid.

2. METODE PENELITIAN

Metode jaringan syaraf tiruan dengan algoritma *Elman Backpropagation* digunakan untuk memperkirakan SOC baterai berdasarkan pengukuran arus dan tegangan dari sensor. Jaringan *Elman* merupakan jenis jaringan saraf berulang yang dapat memodelkan sistem dinamis. Jaringan dilatih berdasarkan data historis untuk mempelajari hubungan antara pengukuran sensor dan SOC baterai. Setelah dilatih, jaringan dapat digunakan untuk memperkirakan SOC secara *real-time* berdasarkan pengukuran arus dan tegangan. Perkiraan SOC kemudian dapat ditampilkan pada LCD untuk dilihat pengguna. Secara ringkas Gambar 1. Sistem blok diagram menunjukkan sistem estimasi SOC baterai menggunakan jaringan syaraf tiruan dengan algoritma *Elman backpropagation*. Sistem mengukur arus dan tegangan baterai dan menggunakan jaringan syaraf untuk memperkirakan SOC berdasarkan pengukuran ini. Perkiraan SOC kemudian ditampilkan pada LCD untuk dilihat pengguna.



Gambar 1. Sistem Blok Diagram

2.1 Baterai *Valve Regulated Lead Acid*

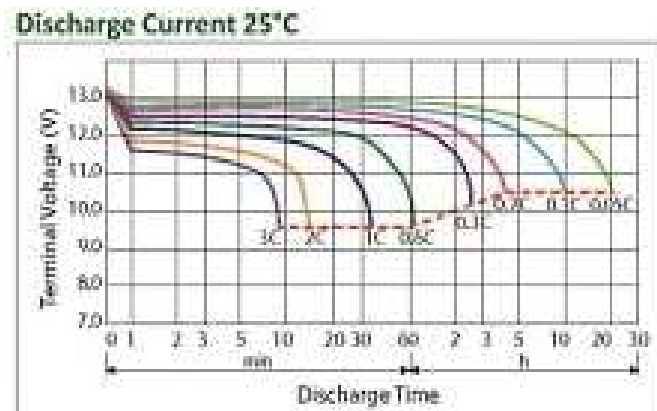
Baterai *Valve Regulated Lead Acid* adalah jenis baterai sekunder yang banyak digunakan dalam aplikasi otomotif, penyimpanan energi, dan cadangan daya. Ditemukan oleh Gaston Planté pada tahun 1859, baterai ini terkenal karena biaya produksinya yang rendah dan kemampuan untuk memberikan arus tinggi. Baterai *Valve Regulated Lead* terdiri dari dua elektroda: elektroda positif yang terbuat dari timbal dioksida (PbO_2) dan elektroda negatif yang terbuat dari timbal (Pb), serta elektrolit berupa larutan asam sulfat (H_2SO_4). Struktur dasar ini memungkinkan terjadinya reaksi kimia yang menghasilkan listrik (Daud, dkk, 2019).



Gambar 2. Baterai Valve Regulated Lead (Samoto, 2024)

Pada saat *charging*, terdapat reaksi balik, mengembalikan elektroda ke kondisi asalnya dengan mengkonsumsi listrik dari sumber eksternal. Proses ini memungkinkan baterai untuk digunakan kembali setelah pengisian ulang (Wang, dkk, 2016). Pada Gambar 2. Baterai *valve regulated lead* memiliki beberapa keunggulan utama, seperti biaya produksi yang relatif murah dibandingkan dengan jenis baterai lain, kemampuan menyediakan arus besar yang diperlukan untuk aplikasi seperti starter kendaraan, serta memiliki sejarah panjang penggunaan yang menunjukkan keandalannya dalam berbagai kondisi. Namun, baterai ini juga memiliki beberapa kelemahan, seperti berat yang relatif besar, efisiensi energi yang lebih rendah dibandingkan dengan baterai modern lainnya, dan mengandung timbal yang berbahaya bagi lingkungan jika tidak dikelola dengan baik (Daud, dkk, 2019).

Proses pengosongan atau *discharging* pada baterai *Lead Acid* terjadi ketika baterai digunakan untuk mensuplai beban, dapat dilihat pada Gambar 3. Grafik karakteristik *discharging* baterai *lead acid* samoto yang mepakan karakteristik baterai *Lead Acid* ketika *discharging*. Saat *discharging*, terdapat dua aliran yang terjadi: aliran internal di dalam baterai (*internal circuit*) dan aliran eksternal di beban (*external circuit*). *Discharging* menyebabkan perubahan kimiawi dalam baterai, mengubah timbal dioksida dan timbal menjadi timbal sulfat dan air (Kumar, dkk, 2017). Ketika baterai *discharging*, tegangan baterai akan menurun seiring dengan berkurangnya kapasitas yang tersisa (Wang, dkk, 2016).



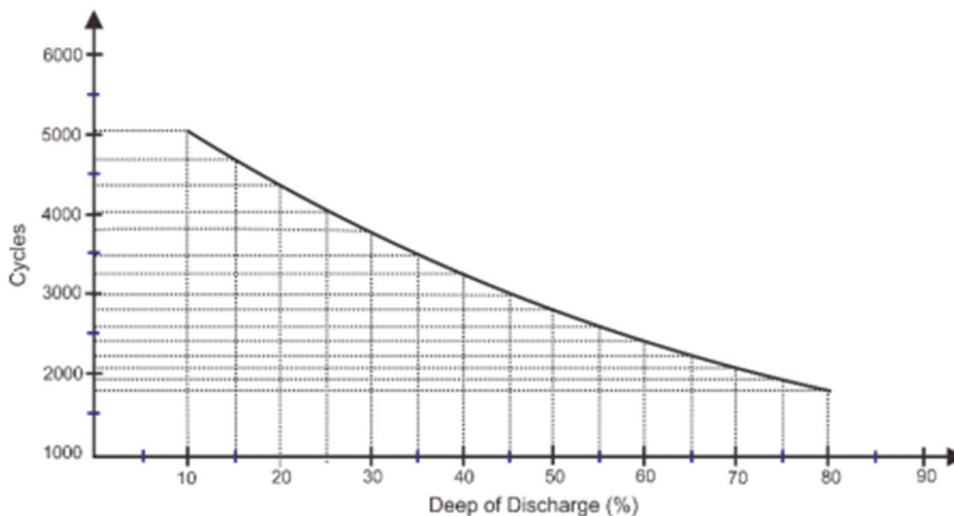
Gambar 3. Grafik Karakteristik Discharging Baterai Lead Acid Samoto (Samoto, 2024)

State of Charge (SOC) adalah parameter penting yang menunjukkan perbandingan antara energi yang tersisa dalam baterai dengan kapasitas energi maksimum yang dapat disimpan oleh baterai. Nilai SOC dinyatakan dalam persentase, dengan 0% menunjukkan baterai kosong dan 100% menunjukkan baterai penuh seperti pada Tabel 1. *State of charge* (SOC) baterai *lead acid* dengan estimasi SOC yang akurat sangat penting untuk menghindari kerusakan sistem, mencegah *overcharge* dan *overdischarge* yang dapat menyebabkan kerusakan permanen pada baterai (Zhou, dkk, 2014). SOC juga digunakan untuk mengoptimalkan kinerja baterai dan memperpanjang masa pakai baterai (Wang, dkk, 2016).

Tabel 1. State Of Charge (SOC) Baterai Lead Acid

<i>State of Charge</i>	Tegangan 12V	Volts per Cells
100%	12,7	2,12
90%	12,5	2,08
80%	12,42	2,07
70%	12,32	2,05
60%	12,2	2,03
50%	12,06	2,01
40%	11,9	1,98
30%	11,75	1,96
20%	11,58	1,93
10%	11,31	1,89
0%	10,5	1,75


Dalam praktiknya, SOC diukur dengan memantau tegangan dan arus baterai. Informasi SOC yang akurat sangat penting sebagai dasar untuk sistem manajemen baterai (*Battery Management System*) yang mengatur pengisian dan pengosongan baterai untuk memastikan kinerja optimal dan umur panjang baterai (Daud, dkk, 2019). *Depth of Discharge* (DOD) merupakan kebalikan dari SOC dan menunjukkan jumlah kapasitas baterai yang telah digunakan. DOD dinyatakan sebagai persentase dari kapasitas total baterai, yang juga mempunyai pengaruh terhadap DOD seperti pada Gambar 4. (Kumar, dkk, 2017).



Gambar 4. Pengaruh Nilai DOD Terhadap Cycles Pada Baterai (Rahmawan, 2018)


2.2 *Elman Backpropagation Neural Network*

Elman Neural Network (ENN), diperkenalkan oleh J.L. *Elman* pada tahun 1990, merupakan sebuah jenis jaringan saraf berulang (*recurrent neural network*, RNN) yang menggunakan mekanisme konteks lokal untuk meningkatkan kemampuan prediktifnya.



Gambar 5. Struktur *Elman Backpropagation Neural Network* (Gayatri, dkk, 2020)

Pada Gambar 5. Struktur *elman backpropagation neural network* ini terdiri dari beberapa lapisan, termasuk *input layer* yang menerima data masukan, *hidden layer* yang mengolah informasi, serta *context layer* yang menambahkan unit memori lokal untuk menyimpan informasi keadaan sebelumnya (Chen, dkk, 2021). Konteks ini memungkinkan jaringan untuk memahami dan memprediksi urutan data, seperti dalam kasus estimasi *State of Charge* (SOC) dalam baterai yang memerlukan analisis deret waktu (Zeng, dkk, 2023). Selain itu, koneksi *feedback* lokal antara lapisan tersembunyi dan konteks memperkuat kemampuan jaringan dalam mempertahankan dan memanfaatkan informasi historis untuk meningkatkan akurasi prediksi (Zhang, dkk, 2020). Melalui proses *training* menggunakan algoritma *backpropagation*, *elman neural network* dapat mengoptimalkan bobot koneksi antar unit dalam jaringan berdasarkan gradien dari fungsi kesalahan yang dihitung selama proses *training* (Li, dkk, 2021). Dengan demikian, jaringan ini tidak hanya efektif dalam memprediksi data berurutan, tetapi juga dalam aplikasi praktis seperti estimasi SOC, di mana pemahaman terhadap data deret waktu dan memori terhadap kondisi sebelumnya memainkan peran krusial, untuk itu dapat dilihat pada Gambar 6. Yang merupakan Arsitektur Jaringan Syaraf Tiruan Elman Backpropagation yang divisualisasikan menggunakan MATLAB (Li, dkk, 2021).



Gambar 6. Arsitektur Jaringan Syaraf Tiruan *Elman Backpropagation* yang divisualisasikan menggunakan MATLAB

2.3 Metode *Coulomb Counting*

Coulomb counting didasarkan pada pengukuran muatan listrik (*coulomb*) yang masuk dan keluar dari baterai. Arus listrik (I) didefinisikan sebagai laju perpindahan muatan listrik per satuan waktu (dt) (Hu, dkk, 2014) (Wang, dkk, 2016). Dengan mengintegrasikan arus listrik terhadap waktu, total muatan listrik (Q) yang terakumulasi dalam baterai dapat dihitung:

$$Q = \int (I \times dt)$$

SOC baterai kemudian dapat diperoleh dengan persamaan berikut:

$$SOC(\%) = \left(\frac{Q}{Q_{max}} \right) \times 100$$

di mana:

- Q : Muatan listrik terakumulasi (*coulomb*)
- Q_{max} : Kapasitas maksimum baterai (*coulomb*)

Efisiensi pengisian/pengosongan baterai (η) perlu dimasukkan untuk akurasi estimasi SOC yang lebih baik. Efisiensi ini mewakili energi yang benar-benar tersimpan atau dilepaskan selama proses. Efisiensi umumnya bervariasi antara 0,95 hingga 0,99 tergantung pada jenis dan kondisi baterai (Wang, dkk, 2017). Dengan memasukkan efisiensi, persamaan SOC menjadi:

$$SOC(\%) = \left(\frac{\eta \times Q}{Q_{max}} \right) \times 100$$

Akurasi estimasi SOC sangat bergantung pada nilai initial SOC (SOC(to)) (Zhang, dkk, 2020) (Baronti, dkk, 2015). Beberapa cara untuk mendapatkan nilai initial SOC:

- a. Pengukuran langsung menggunakan *Battery Management System* (BMS).
- b. Pengisian penuh baterai dan menganggap SOC awal 100%.
- c. Estimasi berdasarkan data historis SOC baterai.

Kerentanan terhadap kesalahan pengukuran arus dan waktu. Akurasi menurun seiring waktu akibat akumulasi kesalahan (Yang, dkk, 2018) (Li, dkk, 2021). Beberapa penelitian mengusulkan peningkatan metode, seperti:

- a. Jaringan syaraf buatan untuk memperhitungkan faktor selain arus dan waktu (Yang, dkk, 2018)
- b. Modifikasi persamaan Coulomb Counting untuk mengurangi akumulasi kesalahan (Li, dkk, 2021)

3. HASIL DAN PEMBAHASAN

3.1 Pengujian Validasi Arus

Pengujian validasi arus dilakukan untuk memastikan keandalan dan konsistensi arus yang mengalir dalam sebuah sistem elektrik atau elektronik. Proses ini penting untuk memastikan arus yang diukur sesuai dengan kebutuhan menjaga kinerja sistem dalam kondisi optimal.

Tabel 2. Hasil Pengujian Validasi Arus Untuk Beban Pompa Dan Lampu

Keterangan	Menit	Tegangan (V)	Arus Beban (A)
Pompa & lampu	0	12,6	1,367
Pompa & lampu	10	12,6	1,25
Pompa & lampu	20	12,6	1,22
Pompa & lampu	30	12,6	1,22
Pompa & lampu	40	12,6	1,24
Pompa & lampu	50	12,6	1,23
Pompa & lampu	60	12,6	1,23
Pompa & lampu	70	12,6	1,23
Pompa & lampu	80	12,6	1,22
Pompa & lampu	90	12,6	1,21
Pompa & lampu	100	12,6	1,23
Pompa & lampu	110	12,6	1,24
Pompa & lampu	120	12,6	1,21
Pompa & lampu	130	12,6	1,25
Pompa & lampu	140	12,6	1,24
Pompa & lampu	150	12,6	1,21
Pompa & lampu	160	12,6	1,23
Pompa & lampu	170	12,6	1,22
Pompa & lampu	180	12,6	1,21
	Rata-rata		1,2345 Ampere

Hasil pengujian pada Tabel 2. hasil pengujian validasi arus untuk beban pompa dan lampu menunjukkan bahwa tegangan baterai stabil pada 12,6V sepanjang pengujian, sedangkan arus beban bervariasi antara 1,21A hingga 1,25A. Rata-rata arus beban selama pengujian adalah 1,234A. Dengan menggunakan data ini, daya yang dikonsumsi oleh pompa dan lampu dapat diestimasi sekitar 15,56 watt. Berdasarkan estimasi ini, baterai dapat bertahan sekitar 5 jam 49 menit 55 detik hingga habis jika terus digunakan pada tingkat konsumsi ini. Analisis ini memberikan gambaran yang jelas tentang penggunaan daya dan estimasi waktu operasional untuk pompa dan lampu yang terhubung ke baterai dengan tegangan 12,6V.

Tabel 3. Hasil Pengujian Validasi Arus Untuk Beban Pompa

Keterangan	Menit	Tegangan (V)	Arus Beban (A)
Pompa	0	12,6	1,02
Pompa	10	12,6	1,09
Pompa	20	12,6	1,005
Pompa	30	12,6	0,99
Pompa	40	12,6	0,98
Pompa	50	12,6	0,984
Pompa	60	12,6	0,995
Pompa	70	12,6	0,988
Pompa	80	12,6	0,98
Pompa	90	12,6	0,984
Pompa	100	12,6	0,995
Pompa	110	12,6	0,988
Pompa	120	12,6	0,984
Pompa	130	12,6	0,995
Pompa	140	12,6	0,988
Pompa	150	12,6	0,98
Pompa	160	12,6	0,984
Pompa	170	12,6	0,995
Pompa	180	12,6	0,98
	Rata-rata		0,995 Ampere

Hasil pengujian validasi arus dengan beban pompa pada Tabel 3. hasil pengujian validasi arus untuk beban pompa menunjukkan bahwa tegangan tetap stabil pada 12,6V sepanjang periode pengujian, sementara arus beban bervariasi antara 0,98A hingga 1,09A. Rata-rata arus beban yang tercatat selama pengujian adalah sekitar 0,995A. Dari data ini, konsumsi daya pompa dapat dihitung sekitar 12,54 watt. Berdasarkan konsumsi daya ini, estimasi waktu operasional pompa adalah sekitar 7 jam dan 14 menit atau 434 menit jika baterai terus digunakan pada tingkat konsumsi ini. Analisis ini memberikan pemahaman yang jelas tentang efisiensi penggunaan daya oleh pompa dan seberapa lama pompa dapat beroperasi dengan satu kali pengisian baterai. Hasil ini menunjukkan bahwa pompa mengkonsumsi daya lebih besar dibandingkan lampu, yang berarti waktu operasionalnya lebih pendek dengan beban yang sama.

Tabel 4. Hasil Pengujian Validasi Arus Untuk Beban Lampu

Keterangan	Menit	Tegangan (V)	Arus Beban (A)
Lampu	0	12,6	0,185
Lampu	10	12,6	0,206
Lampu	20	12,6	0,208
Lampu	30	12,6	0,206
Lampu	40	12,6	0,206
Lampu	50	12,6	0,206
Lampu	60	12,6	0,206
Lampu	70	12,6	0,206
Lampu	80	12,6	0,204
Lampu	90	12,6	0,203
Lampu	100	12,6	0,203
Lampu	110	12,6	0,204
Lampu	120	12,6	0,204
Lampu	130	12,6	0,203
Lampu	140	12,6	0,204
Lampu	150	12,6	0,204
Lampu	160	12,6	0,204
Lampu	170	12,6	0,204
Lampu	180	12,6	0,203
Rata-rata			0,2036 Ampere

Hasil pengujian validasi arus pada Tabel 4. hasil pengujian validasi arus untuk beban lampu diatas dengan beban lampu menunjukkan bahwa tegangan tetap stabil pada 12,6V sepanjang periode pengujian, sementara arus beban sedikit berfluktuasi antara 0,185A dan 0,208A. Rata-rata arus beban yang tercatat selama pengujian adalah sekitar 0,204A. Dari data ini, konsumsi daya lampu dapat dihitung sekitar 2,57 watt. Berdasarkan konsumsi daya ini, estimasi waktu operasional lampu adalah sekitar 35 jam dan 21 menit atau 2121 menit jika baterai terus digunakan pada tingkat konsumsi ini. Analisis ini memberikan pemahaman yang jelas tentang efisiensi penggunaan daya oleh lampu dan seberapa lama lampu dapat beroperasi dengan satu kali pengisian baterai.

3.2 Pengujian *Coulomb Counting* dengan *Elman Backpropagation*

Pengujian dilakukan untuk memprediksi persentase *State of Charge* (SOC) dari sisi Ah pada baterai lead acid 12V, 18Ah dengan menggunakan dua beban yaitu lampu 12V, 2,57Watt dan pompa 12V, 12,54W dengan menggunakan metode *coulumb counting* untuk data uji awal dan perbandingan. Metode *coulumb counting* ini dilakukan untuk pengambilan awal data yang berdasarkan penggunaan arus sehingga bisa mengestimasi *State of Charge* baterai, dan nantinya digunakan sebagai data training dan uji untuk *Elman Backpropagation*.

Tabel 5. Hasil *Coulomb Counting* Dengan *Elman Backpropagation* Untuk Beban Pompa Dan Lampu

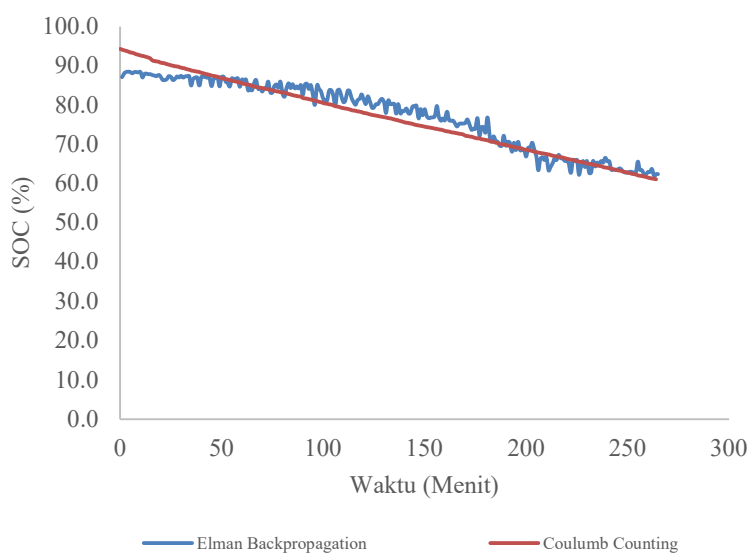
Keterangan	Menit	Tegangan Baterai (V)	Tegangan Discharge (V)	Arus Beban (A)	COULUMB COUNTING		ELMAN BP		Sisa Waktu (Menit)	% Error
					SOC %	AH	SOC%	AH		
Tanpa beban	0	12,59		-	94,5	17,01	88,76	15,976		
Pompa & lampu	27		12,14	1,33	90	16,2	86,624	15,592	244,1	3,8
Pompa & lampu	65		12,08	1,22	85,1	15,31	83,714	15,069	222,8	1,6
Pompa & lampu	105		12	1,2	80,1	14,41	82,521	14,854	181,5	3,0
Pompa & lampu	146		11,92	1,29	75	13,5	69,830	12,569	127,0	6,9
Pompa & lampu	189		11,85	1,18	70	12,6	72,149	12,987	92,0	3,1
Pompa & lampu	233		11,81	1,2	65	11,69	65,778	11,840	45,5	1,2
Pompa & lampu	265		11,75	1,17	61,1	11	62,397	11,232	11,3	2,1

Pada Tabel 5. hasil *coulomb counting* dengan *elman backpropagation* untuk beban pompa dan lampu diatas menunjukkan perbandingan antara metode Coulomb Counting dan Elman Backpropagation (BP) dalam menghitung State of Charge (SOC) dan Ampere-hour (AH) menunjukkan bahwa pada awalnya, metode Coulomb Counting menghasilkan SOC yang lebih tinggi (94.5%) dibandingkan dengan Elman BP (88.76%). Hal ini dapat mengindikasikan bahwa Coulomb Counting lebih sensitif terhadap kondisi awal baterai, tetapi seiring waktu, perbedaan antara kedua metode ini menjadi semakin kecil. Error yang bervariasi dari 1.2% hingga 6.9% menunjukkan bahwa Elman BP bisa memberikan hasil yang cukup akurat, namun dalam beberapa kondisi, seperti pada menit ke-146, terjadi peningkatan error hingga 6.9%. Ini bisa menjadi indikasi bahwa pada kondisi tertentu, seperti ketika terjadi perubahan dinamis pada arus atau tegangan, Elman BP membutuhkan penyesuaian lebih lanjut untuk meningkatkan performanya. Variasi error yang terjadi dalam interval waktu ini menunjukkan bahwa meskipun Elman BP memiliki potensi yang baik untuk estimasi SOC, konsistensinya dalam jangka waktu panjang masih memerlukan perbaikan agar error tetap terkendali.

Tabel 6. Hasil *Coulomb Counting* Dengan *Elman Backpropagation* Untuk Beban Pompa

Keterangan	Menit	Tegangan Baterai (V)	Tegangan Discharge (V)	Arus Beban (A)	COULUMB COUNTING		ELMAN BP		Sisa Waktu (Menit)	% Error
					SOC %	AH	SOC%	AH		
Tanpa beban	0	12,5		-	90,0	16,2	86,740	15,613		
Pompa	45		11,94	1,13	85,0	15,31	84,950	15,291	239	0,1
Pompa	93		11,84	1,13	80,0	14,41	79,013	14,222	192	1,3
Pompa	141		11,78	1,21	75,0	13,50	63,987	11,518	134	14,7
Pompa	189		11,72	1,12	70,0	12,60	63,890	11,500	97	8,8
Pompa	199		11,69	1,12	69,0	12,41	62,443	11,240	86	9,4
Pompa	208		11,67	1,1	68,0	12,24	61,833	11,130	79	9,1
Pompa	218		11,64	1,06	67,0	12,05	62,243	11,204	71	7,0

Pada Tabel 6. Hasil *coulomb counting* dengan *elman backpropagation* untuk beban pompa diatas perbandingan estimasi SOC tanpa beban dan saat beban diaktifkan menunjukkan bahwa pada awalnya, estimasi SOC dengan Coulomb Counting (90%) dan Elman BP (86,74%) relatif dekat. Ketika beban dinyalakan, SOC secara bertahap menurun, dan error tetap kecil pada awalnya (seperti pada menit ke-45, dengan error 0.1%). Namun, pada menit ke-141, perbedaan yang lebih signifikan muncul, dengan error mencapai 14.7%. Ini menunjukkan bahwa pada kondisi beban yang berubah secara dinamis, Elman BP cenderung memiliki ketidakakuratan yang lebih tinggi dibandingkan metode Coulomb Counting. Variasi error dari 7% hingga 9.4% pada interval waktu selanjutnya menunjukkan bahwa Elman BP dapat memberikan hasil yang berbeda secara signifikan dibandingkan Coulomb Counting, terutama ketika sistem baterai berada dalam kondisi yang lebih variabel. Ini bisa menunjukkan kelemahan Elman BP dalam menangani perubahan kondisi beban secara real-time, tetapi juga menyoroti potensi perbaikan melalui kalibrasi lebih lanjut.



Gambar 7. Grafik Estimasi SOC dengan *Elman BP*

Pada Gambar 7, grafik estimasi SOC menggunakan Elman Backpropagation (BP) menunjukkan penurunan SOC baterai dari 100% pada menit ke-0 hingga mencapai sekitar 60% pada menit ke-260. Penurunan ini terjadi secara bertahap dengan rata-rata laju penurunan sekitar 0,15% per menit. Hasil estimasi Elman BP mengakomodasi perubahan kecil dan fluktuasi SOC dengan cukup baik, seperti terlihat dari variasi yang ada pada kurva sekitar $\pm 1\%$. Namun, metode Elman BP menghasilkan error yang bervariasi, dengan error rata-rata mencapai 0,1% hingga 14,7%, terutama ketika data input mengalami perubahan atau ketika baterai dibebani secara fluktuatif. Sebaliknya, metode Coulomb Counting memberikan hasil yang lebih stabil, tetapi cenderung menunjukkan SOC awal yang lebih tinggi dari realita, sekitar 5% lebih tinggi dibandingkan Elman BP pada awal pengujian. Meski demikian, perbedaan antara kedua metode ini semakin mengecil seiring waktu, dengan selisih SOC sekitar 2% pada menit ke-260. Dari perbandingan ini, Coulomb Counting lebih cocok untuk implementasi sederhana dan estimasi jangka pendek, sedangkan Elman BP menawarkan keakuratan yang lebih baik untuk estimasi jangka panjang dan kondisi yang lebih dinamis.

4. KESIMPULAN

Penerapan Artificial Neural Network (ANN) berbasis Elman Backpropagation untuk estimasi state of charge (SOC) baterai lead acid selama proses discharging menunjukkan peningkatan akurasi prediksi, terutama dalam kondisi dinamis. Dengan kemampuannya menangkap dinamika temporal, model Elman BP memberikan estimasi SOC yang cukup akurat, dengan rata-rata error 2.9% pada beban pompa dan lampu, serta rata-rata error 5.3% pada beban pompa saja. Penggunaan algoritma Backpropagation dalam pelatihan jaringan memungkinkan pembaruan bobot yang efisien berdasarkan data historis, memastikan bahwa jaringan dapat belajar dan beradaptasi dengan baik terhadap pola yang terjadi dalam sistem baterai. Hasil penelitian ini menunjukkan bahwa model Elman Backpropagation dapat diintegrasikan ke dalam sistem manajemen baterai di aplikasi dunia nyata untuk memberikan informasi real-time yang lebih akurat mengenai SOC. Informasi yang lebih akurat mengenai SOC ini akan sangat membantu dalam pengambilan keputusan terkait penggunaan, pemeliharaan, dan manajemen beban baterai, yang penting dalam berbagai aplikasi, mulai dari kendaraan listrik hingga sistem penyimpanan energi. Dengan demikian, Elman BP menawarkan solusi yang lebih cerdas untuk memperpanjang umur baterai dan meningkatkan efisiensi penggunaannya. Namun, meskipun Elman BP terbukti efektif dalam banyak kasus, penelitian ini juga menemukan bahwa error masih dapat meningkat pada kondisi beban yang lebih dinamis, seperti ketika beban pompa bekerja sendiri (rata-rata error 5.3%). Hal ini menunjukkan bahwa sistem Elman BP masih sensitif terhadap perubahan data input dan fluktuasi yang terjadi pada baterai saat mengalami variasi beban. Keterbatasan ini menunjukkan pentingnya pengembangan lebih lanjut, seperti penyesuaian model dan kalibrasi yang lebih baik untuk menangani variasi kondisi operasi yang lebih kompleks. Dalam aplikasi dunia nyata, pengembangan ini akan memastikan bahwa prediksi SOC tetap konsisten dan akurat meskipun terjadi perubahan beban atau kondisi baterai. Secara keseluruhan, ANN berbasis Elman Backpropagation menawarkan solusi yang efisien dan efektif untuk estimasi SOC baterai lead acid, dengan kemampuan yang baik untuk mengakomodasi fluktuasi SOC kecil. Namun, untuk aplikasi skala besar dan jangka panjang, diperlukan penelitian lanjutan dan optimasi untuk meminimalkan error yang terjadi dalam kondisi yang lebih dinamis dan beragam.

DAFTAR RUJUKAN

- Afandi, A., Windarko, N. A., Sumantri, B. & Fakhuruddin, H. H. (2022). Estimasi State of Charge (SoC) Ultrakapasitor menggunakan Extended Kalman Filter Berbasis Ladder Equivalent Circuit Model. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika.*, 10(1), pp. 61-75.
- Baronti, F. (2015). State of charge estimation enhancing of supercapacitors in electric vehicles. *IEEE Transactions on Industrial Electronics*, 62(12), 7699-7708.
- Chen, J., Wang, T., Wu, Y. & Xu, Z. (2021). Short-term load forecasting based on Elman neural network optimized by genetic algorithm. *IEEE Transactions on Smart Grid*, 12(2), 1341-1350.
- Daud, A., Wibawa, K. P. & Rachmawati, E. (2019). *Lead Acid Battery: Advances and Applications*. s.l.:Elsevier.
- Febian, E. B. I., Rakhmawati, R. & Suhariningsih, S. (2022). Comparison of ANFIS and FLC as Charging Battery Based on Zeta Converter. *INTEK: Jurnal Penelitian*, 9(1), 49-57.

- Gayatri, M. (2020). Implementation of Epileptic EEG using Recurrent Neural Network. *International Journal of Computer Science and Network Security*, 10.
- Hu, X., Li, S. & Peng, H., (2014). A comparative study of equivalent circuit models for Li-ion batteries. *Journal of Power Sources*, 198(15), 359-367.
- Kumar, S. & Patra, A. (2017). *Advances in Battery Technologies for Electric Vehicles*. s.l.:Woodhead Publishing.
- Kusumoputro, Kamanditya, B. & Benyamin, (2020). Elman Recurrent Neural Networks Based Direct Inverse Control for Quadrotor Attitude and Altitude Control. London, United Kingdom, *International Conference on Intelligent Engineering and Management (ICIEM)*.
- Li, J., Zhang, T. & Chen, X., 2021. Improved Coulomb counting method for state of charge estimation of lithium-ion batteries in electric vehicles. *Journal of Cleaner Production*, 310, 127408.
- Li, M. (2021). Research on electric vehicle state of health estimation model based on improved Elman neural network. *Energy Reports*, Osa/vuosikerta, 7, 279-288.
- Rahmawan, Z., (2018). *Estimasi State of Charge (SOC) pada Baterai Lead-Acid dengan Menggunakan Metode Coulomb Counting pada PV Hybrid*, s.l.: Institut Teknologi Sepuluh Nopember.
- Rakhmawati, R., Sutedjo, Oktaviani, F. N. & Irianto. (2023). Estimasi State of Charge pada Baterai Lead Acid menggunakan Elman Recurrent Neural Network.. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika.*, 11(4), 864-874.
- Samoto. (2024). *SAMOTO Battery & Digital Stabilizer*. [Online] Available at: <https://samoto.co.id/products/smt-1218/> [Haettu 1 Juni 2024].
- Wang, D., Liu, G. & Sun, B., (2017). A comprehensive review on the key technologies for state of charge estimation of lithium-ion batteries. *Renewable and Sustainable Energy Reviews*, 79, 1341-1352.
- Wang, Q., Jiang, B. & Li, B. (2016). *Battery Management Systems: Modeling, Integration, and Optimization*. 1 toim. s.l.:Wiley.
- Yang, X., Zhang, C. & Xie, W. (2018). State-of-charge estimation of lithium-ion batteries using a neural network based on an improved genetic algorithm. *Journal of Energy Storage*, 15, 1-11.
- Yu, L. (2021). Financial time series prediction using a novel Elman neural network with multi-indicators. *Expert Systems with Applications*, 171, 114663.

- Zeng, W., Huang, C., Zhang, X. & Wang, Y. (2023). Short-term traffic flow prediction based on hybrid Elman neural network with improved deep learning. *Journal of Advanced Transportation*, 2023(1), pp. 1-12.
- Zhang, T. & Tang, Y. (2020). *Advances in Lead-Acid Batteries*. s.l.:CRC Press.
- Zhang, X., Zhang, X., Zhang, L. & Zhang, Y. (2020). A novel chaotic Elman neural network with application in time series prediction. *Neurocomputing*, 408(1), pp. 82-92.
- Zhou, Z., Yin, G. & Liu, W. (2014). *Battery Technology Handbook*. s.l.:Springer.