

ESTIMASI STATE OF CHARGE PADA ULTRAKAPASITOR MENGUNAKAN METODE ELMAN BACKPROPAGATION NEURAL NETWORK

**Rindy Ayu Dwi Wardani¹⁾, Rachma Prilian Eviningsih¹⁾ dan Novie Ayub
Windarko¹⁾**

¹⁾Teknik Elektro Industri, Politeknik Elektronika Negeri Surabaya, Jl. Raya ITS,
Surabaya, 60111
E-mail: rindyadw@mail.com

Abstract

Ultracapacitors are currently an effective and promising energy storage solution for the future. Ultracapacitors have high power density, fast charging and discharging, and longer service lives compared to batteries. This ensures that ultracapacitors can complement or replace batteries in various application fields, such as hybrid electric vehicles (HEV). To maintain optimal performance and prevent damage to ultracapacitors, an accurate estimation of the State of Charge (SoC) is required. In this paper, ultracapacitors are used under constant-current charging conditions. SoC estimation on ultracapacitors is carried out using a serial RC model for ultracapacitor modeling to analyze ultracapacitor performance, and the estimation method uses the Elman Backpropagation Neural Network, which is compared with the Feed Forward Backpropagation Neural Network through hardware simulations and experiments. SoC estimation using the EBNN in the simulation has an error of 0.0702%, and on hardware it is 0.128%. Meanwhile, the SoC estimation using the FFBNN in the simulation has an error of 0.084%, and on hardware, it has an error of 0.806%. Based on simulations and hardware data, it shows that SoC estimation using the EBNN achieves higher accuracy than using the FFBNN.

Keywords: *Elman Backpropagation Neural Network, Ultracapacitors.*

Abstrak

Ultrakapasitor saat ini menjadi solusi penyimpanan energi yang efektif dan menjanjikan untuk masa depan. Ultrakapasitor memiliki kepadatan daya yang tinggi, pengisian dan pengosongan yang cepat, serta masa pakai yang lebih lama dibandingkan dengan baterai. Hal ini memastikan ultrakapasitor dapat melengkapi atau mengganti baterai di berbagai bidang aplikasi, seperti *Hybrid Electric Vehicles* (HEV). Untuk mempertahankan performa optimal dan mencegah kerusakan pada ultrakapasitor, diperlukan estimasi yang akurat dari *State of Charge* (SoC). Dalam makalah ini, ultrakapasitor digunakan pada kondisi pengisian dengan arus konstan. Estimasi SoC pada ultrakapasitor dilakukan dengan menggunakan model RC serial untuk pemodelan ultrakapasitor untuk menganalisis kinerja ultrakapasitor, dan metode estimasi menggunakan *Elman Backpropagation Neural Network* (EBNN), yang dibandingkan dengan *Feed Forward Backpropagation Neural Network* (FFBNN) melalui simulasi dan eksperimen perangkat keras. Estimasi SoC menggunakan EBNN pada simulasi memiliki error sebesar 0.0702% dan pada perangkat keras sebesar 0.128%. Sedangkan estimasi SoC menggunakan FFBNN pada simulasi memiliki error sebesar 0.084% dan pada perangkat keras memiliki error sebesar 0.806%. Berdasarkan simulasi dan data perangkat keras menunjukkan bahwa estimasi SoC menggunakan EBNN mencapai akurasi yang lebih tinggi dibandingkan menggunakan FFBNN.

Kata Kunci: *Elman Backpropagation Neural Network, Ultrakapasitor.*

PENDAHULUAN

Ultrakapasitor saat ini merupakan solusi yang menjanjikan dan efektif dalam hal penyimpanan energi. Keunggulan ultrakapasitor terletak pada daya yang tinggi, kemampuan pengisian dan pengosongan yang cepat, masa pakai yang baik, kemampuan menghasilkan arus jangka pendek yang tinggi, serta operasi yang aman (Zhang et al., 2018). Karena keunggulannya, ultrakapasitor digunakan sebagai sumber daya dalam kendaraan *Hybrid Electric Vehicles* (HEV) seperti bus listrik dengan menggunakan ultrakapasitor dan baterai yang digunakan secara bersamaan untuk meningkatkan optimal kinerja dan memperpanjang umur baterai penyimpanan (Hussain et al., 2019).


Proses pengisian ultrakapasitor adalah mengisi energi ke dalamnya dengan mengalirkan arus listrik ke dalam komponen ultrakapasitor. Ultrakapasitor memiliki kemampuan untuk melakukan pengisian pada tingkat tegangan pengisian apa pun. Ultrakapasitor dapat menerima arus pengisian yang bervariasi. Semakin besar arus pengisian maka semakin singkat waktu pengisian (Duan et al., 2018). Proses berhentinya pengisian daya ditentukan oleh tercapainya tegangan maksimum pada ultrakapasitor.

Kinerja ultrakapasitor dijaga agar tetap optimal diperlukan estimasi *State of Charge* (SoC). Pemantauan SoC dapat menghindarkan dari kondisi *overcharge* pada ultrakapasitor. Pada makalah ini untuk memperkirakan SoC membutuhkan pemodelan ultrakapasitor untuk menentukan karakteristik kinerja dari ultrakapasitor yaitu model RC seri (Şahin, 2021) dan mengusulkan menggunakan metode sebagai estimator yaitu *Elman Backpropagation Neural Network* yang memiliki keakuratan tinggi karena memiliki lapisan konteks sebagai penyimpan informasi tentang kondisi sebelumnya (Rupesh & Tegampure, 2022). Metode estimator EBNN akan dibandingkan dengan *Feed Forward Neural Network* yang umum digunakan saat ini pada simulasi dan pengujian langsung yang dilakukan pada perangkat keras.

METODE PENELITIAN

Pemodelan Ultrakapasitor

Model rangkaian ekuivalen yang sederhana untuk menganalisis kinerja ultrakapasitor adalah model RC seri (Afandi et al., 2020) dengan menggunakan prinsip Hukum *Kirchoff* tegangan pada persamaan (1).



Gambar 1 Rangkaian RC Seri

$$V_o = v_c + i \times R_s \quad (1)$$

Berdasarkan persamaan (1) V_o adalah tegangan pengisian, v_c merupakan tegangan riil selama pengisian, i adalah arus pengisian ultrakapasitor, dan R_s merupakan resistansi internal pada ultrakapasitor dengan nilai yang sama.


Estimasi *State of Charge* (SoC)

State of Charge (SoC) ultrakapasitor adalah rasio dari kapasitas energi yang tersisa hingga mencapai kapasitas energi penuh yang bervariasi antara 0 hingga 1 menandakan kosong atau 0 hingga 100% menandakan penuh. Oleh karena itu, SoC pada ultrakapasitor dengan membagi tegangan riil kapasitor dengan tegangan maksimum ultrakapasitor ditunjukkan persamaan (2)

$$SoC = \frac{v_c}{v_{max}} \times 100\% \quad (2)$$

Elman Backpropagation Neural Network

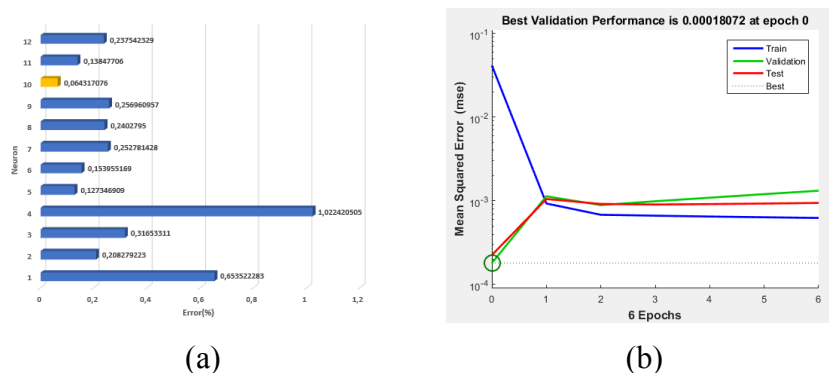
Elman Backpropagation Neural Network (EBNN), adalah jenis jaringan saraf berulang yang menggunakan unit memori lokal. Pada EBNN terdiri dari lapisan *input* yaitu tegangan dan arus ultrakapasitor, satu lapisan tersembunyi yang berfungsi untuk memproses informasi, satu lapisan konteks yang menyimpan informasi sebelumnya, dan satu lapisan *output* yang menghasilkan estimasi nilai SoC ultrakapasitor (Cui et al., 2022). Struktur tersebut ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur EBNN

Pengujian pada EBNN menggunakan *software* MATLAB. Proses penentuan jumlah neuron saat *training* di MATLAB dengan mencoba jumlah neuron mulai dari 1 hingga 12

Berdasarkan pengujian neuron ditunjukkan pada Gambar 3 (a) jumlah neuron yang baik adalah 10 dengan nilai tingkat error sebesar 0.064%. Setelah menentukan jumlah neuron dilakukan proses *training* pada EBNN menggunakan algoritma *Lavenberg-Marquardt* dengan Mean Squared Error 0.00018072 seperti pada Gambar 3 (b).



Gambar 3. (a) Pengujian Jumlah Neuron EBNN (b) Error *Training* dengan *Epoch* 6

Berikut alur kerja dari *Elman Backpropagation Neural Network* :

1) Normalisasi *Input*

Nilai input ilai tegangan dan arus pada *layer input* perlu menjalani proses normalisasi yang bertujuan untuk mengubah data asli menjadi nilai yang lebih kecil namun tetap mempertahankan karakteristiknya.

$$x = (u - x_{min}) \times \frac{(y_{max} - y_{min})}{(x_{max} - x_{min})} + Y_{min} \quad (3)$$

Pada persamaan (3) nilai x merupakan hasil normalisasi input. Variabel x_{min} dan x_{max} mengacu pada nilai terkecil dan terbesar dari seluruh nilai input. Nilai y_{max} adalah 1, sedangkan y_{min} adalah -1.

2) *Layer* 1 dan *Layer* 2

Pada bagian ini hasil dari normalisasi *input* akan diolah dengan bantuan bobot dan bias.

$$L_n = (x + w_{in}) + B_{in} \quad (4)$$

Pada persamaan (4), nilai n merupakan jumlah *neuron*, w_{in} merupakan *weight*, dan B_{in} merupakan bias yang didapatkan dari proses *training* pada *software* MATLAB yang selanjutnya masuk ke proses *Tansig* ditunjukkan persamaan 5.

$$\text{Tan} = \frac{2}{1 + e^{(-2(L_n))}} - 1 \quad (5)$$


3) Denormalisasi *Output*

Denormalisasi *output* adalah bentuk konversi dari nilai *output Elman Backpropagation Neural Network* menjadi nilai *output* sebenarnya dengan persamaan s ditunjukkan pada persamaan (6).

$$s = \left((Ln - Y_m) \times \frac{X_{max} - X_{min}}{Y_{max} - Y_{min}} \right) + X_{min} \quad (6)$$

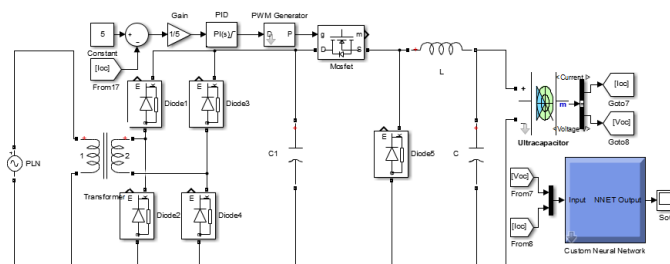
Blok Diagram Sistem

Di dalam blok diagram sistem ditunjukkan pada Gambar 4 menggunakan sumber dari PLN yang diturunkan menggunakan trafo *step down* dan disearahkan menjadi tegangan DC menggunakan *full wave rectifier uncontrolled* yang menjadi *input* dari konverter Buck diturunkan sampai nilai tegangan maksimum ultrakapasitor yaitu 13.5 V terpenuhi dan arus pengisian konstan 5A. Saat pengisian dilakukan estimasi SoC menggunakan estimator EBNN yang dibandingkan dengan FFBNN pada simulasi dan perangkat keras estimasi SoC pada ultrakapasitor ditunjukkan pada Gambar 5 dan Gambar 6.




Gambar 4 Blok Diagram Sistem

Sistem Simulasi



Gambar 5 Rangkaian Simulasi untuk Pengujian Estimasi *State of Charge*


Sistem Perangkat Keras



Gambar 6. Perangkat Keras untuk Pengujian Estimasi *State of Charge*

HASIL DAN PEMBAHASAN

Setelah melakukan *running* sistem terjadi proses pengisian ultrakapasitor dan didapatkan karakteristik ultrakapasitor tegangan dan arus ditunjukkan Gambar 7 (a) dan (b).



Gambar 7 Pengujian saat Proses Pengisian (a) Tegangan (b) arus

Nilai tegangan akan terus meningkat hingga tegangan maksimum 13.5V dengan arus konstan 5A. Nilai tegangan dan arus pengisian digunakan sebagai *input* dan Estimasi SoC yang didapatkan dari pemodelan rangkaian RC seri sebagai *output* maka dapat dilakukan proses *training* sehingga dapat dilakukan estimasi SoC. Akurasi estimasi SoC sangat baik apabila nilai pembacaan SoC yang dihasilkan mendekati nilai Estimasi SoC.

Tabel 1
 Hasil Simulasi estimasi SoC dengan Menggunakan EBNN dan FFBNN

Tegangan (V)	Arus (A)	Estimasi SoC (%)	SoC dengan EBNN (%)	SoC dengan FFBNN (%)	Error (%) EBNN	Error (%) FFBNN
10.57	5.014	77.72	77.721	77.711	0.001	0.012
11.57	5.014	85.128	85.125	85.124	0.003	0.003
12.57	5.013	92.535	92.536	92.517	0.001	0.019
13.5	5.01	99.424	99.150	99.12	0.276	0.306

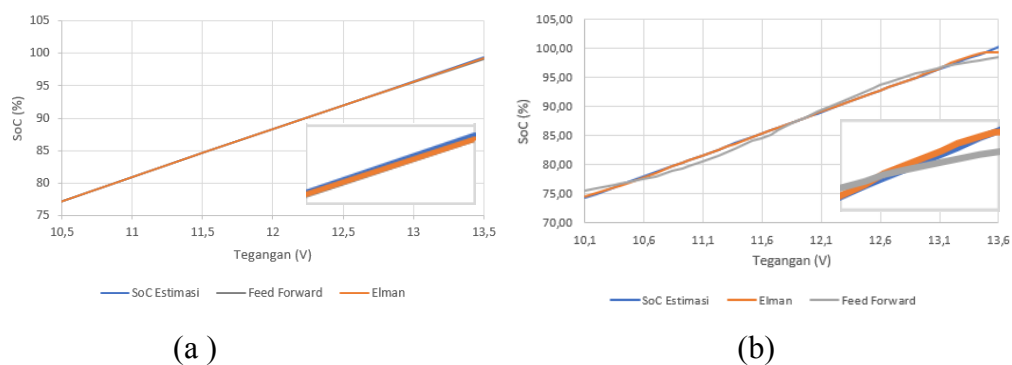
Pada Tabel 1 menunjukkan data estimasi *State of Charge* (SoC) pada simulasi. Pada tegangan pengisian 12.57V dengan arus 5.013A pada Estimasi SoC menggunakan

pemodelan ultrakapasitor didapatkan nilai sebesar 92.535%. Dengan menggunakan EBNN pembacaan estimasi SoC 92.536% sedangkan FFBNN pembacaan estimasi SoC 92.517% sehingga estimasi SoC EBNN lebih mendekati nilai estimasi SoC dengan rata-rata error 4 sample sebesar 0.0702% sedangkan FBNN sebesar 0.0949%.

Pada Tabel 2 menunjukkan estimasi *State of Charge* (SoC) perangkat keras. Pada tegangan pengisian 13.08V dengan arus 5.03A untuk Estimasi SoC sama caranya dengan simulasi didapatkan estimasi SoC sebesar 96.33%. Dengan menggunakan EBNN pembacaan estimasi SoC 96.38% sedangkan FFBNN pembacaan estimasi SoC 96.61% sehingga estimasi SoC EBNN memiliki keakuratan yang lebih tinggi dengan rata-rata error 0.128% dan rata-rata error 4 *sample* data pada FBNN sebesar 0.806%

Tabel 2.
Hasil Perangkat Keras estimasi SoC dengan Menggunakan EBNN dan FFBNN

Tegangan (V)	Arus (A)	Estimasi SoC (%)	SoC dengan EBNN (%)	SoC dengan FFBNN (%)	Error (%) EBNN	Error (%) FFBNN
10.59	5.18	77.86	77.74	77.45	0.165	0.54
11.59	5.0	85.296	85.26	84.46	0.042	0.98
13.08	5.03	96.33	96.38	96.61	0.051	0.29
13.49	5.0	99.37	99.36	98.22	0.010	1.16



Gambar 8 Perbandingan Pengujian (a) Simulasi dan (b) Perangkat Keras untuk Estimasi SoC dengan EBNN dan FFBNN

Berdasarkan grafik pengujian ditunjukkan pada Gambar 8 (a) dan (b). Estimasi *State of Charge* menggunakan EBNN yang ditunjukkan warna orange selalu mendekati grafik berwarna biru yang merupakan grafik SoC estimasi dibandingkan grafik berwarna abu-abu yaitu FFBNN. Akurasi SoC baik apabila nilai SoC yang dihasilkan mendekati nilai

Estimasi SoC. Sehingga estimasi SoC berdasarkan grafik pada Gambar 8 (a) dan (b) yang memiliki keakuratan tinggi dengan nilai error kecil dimiliki oleh estimator EBNN.

SIMPULAN

Nilai *State of Charge* (SoC) yang akurat apabila nilai estimasi mendekati nilai estimasi SoC. Nilai *State of Charge* (SoC) yang akurat apabila nilai estimasi mendekati nilai Estimasi SoC. Perbandingan antara estimasi SoC menggunakan *Elman Backpropagation Neural Network* dan *Feed Forward Backpropagation Neural Network* dilakukan dalam simulasi dan percobaan perangkat keras. Ketika menggunakan EBNN error rata-rata estimasi SoC sebesar 0.0702% dan error rata-rata 0.128% dalam perangkat keras yang dibandingkan dengan nilai Estimasi SoC. Sedangkan saat pengujian dengan menggunakan FFBNN error rata-rata didapatkan sebesar 0.084% dalam simulasi dan 0.806% dalam perangkat keras. Berdasarkan hasil yang diperoleh dari simulasi dan percobaan perangkat keras, EBNN menunjukkan akurasi yang lebih tinggi dalam SoC ultrakapasitor.

DAFTAR PUSTAKA

- Afandi, A., Sumantri, B., & Windarko, N. A. (2020). Estimation state of charge (soc) of ultracapacitor based on classical equivalent circuit using extended kalman filter. *IES 2020 - International Electronics Symposium: The Role of Autonomous and Intelligent Systems for Human Life and Comfort*, 31–36. <https://doi.org/10.1109/IES50839.2020.9231736>
- Cui, Z., Wang, L., Li, Q., & Wang, K. (2022). A comprehensive review on the state of charge estimation for lithium-ion battery based on neural network. *International Journal of Energy Research*, 46(5), 5423–5440. <https://doi.org/10.1002/er.7545>
- Duan, M., Cao, X., Zhang, Q., & Chen, X. (2018). *Research and Application of Supercapacitor Charging System*. 5, 1–6. <https://doi.org/10.4236/oalib.1104544>
- Hussain, S., Ali, M. U., Park, G., Nengroo, S. H., Khan, M. A., & Kim, H. (2019). A Real-Time Bi-Adaptive Controller-Based Energy Hybrid Electric Vehicles. *Energies*, 12(4662), 1–24.
- Rupesh, M., & Tegampure, V. S. (2022). Cascade feedforward neural network and deep neural network controller on photovoltaic system with cascaded multilevel inverters: Comparison on standalone and grid integrated system. *Journal of Mechatronics, Electrical Power, and Vehicular Technology*, 13(2), 157–178. <https://doi.org/10.14203/j.mev.2022.v13.157-178>
- Şahin, M. (2021). Modelling of Supercapacitors Based on Simplified Equivalent Circuit. *CPSS Transactions on Power Electronics and Applications*, 6(1), 31–39. <https://doi.org/10.24295/cpsstpea.2021.00003>
- Zhang, L., Hu, X., Wang, Z., Sun, F., & Dorrell, D. G. (2018). A review of supercapacitor

modeling, estimation, and applications: A control/management perspective. *Renewable and Sustainable Energy Reviews*, 81(June 2016), 1868–1878. <https://doi.org/10.1016/j.rser.2017.05.283>