

Estimasi *State of Charge* pada Baterai *Lead Acid* menggunakan *Elman Recurrent Neural Network*

RENNY RAKHMAWATI, SUTEDJO, FITROTIN NAFISA OKTAVIANI, IRIANTO,
DIAH SEPTI YANARATRI, AHMAD FIRYAL ADILA

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

Received 13 Juni 2023 | *Revised* 18 Juli 2023 | *Accepted* 28 Juli 2023

ABSTRAK

Penggunaan panel surya sebagai sumber energi terbarukan membutuhkan baterai sebagai tempat penyimpanan energi. Penggunaan baterai secara terus menerus, dapat menyebabkan pengurangan kapasitas dan penurunan performa. Untuk mengatasi permasalahan tersebut, diperlukan sistem estimasi nilai State of Charge (SOC) pada baterai yang berfungsi untuk mengontrol kondisi charge, agar performa baterai tetap optimal. Pada penelitian dikembangkan suatu sistem estimasi SOC pada baterai jenis lead acid, dengan metode algoritma Elman Recurrent Neural Network (ERNN). Keunggulan yang terkait dengan metode ERNN meliputi proses iterasi menjadi lebih cepat, peningkatan kecepatan pembaruan parameter, dan pencapaian konvergensi yang lebih cepat. Hasil dari penelitian estimasi SOC pada baterai lead acid 12V, 12Ah dengan menggunakan algoritma ERNN sebesar 0.101% sedangkan dengan algoritma Feedforward Backpropagation sebesar 0.767%. Sehingga dapat disimpulkan bahwa algoritma ERNN lebih efisien dalam mengestimasi nilai SOC pada baterai lead acid.

Kata kunci: *Baterai, Elman Recurrent Neural Network, Panel Surya, State of Charge; Lead Acid*

ABSTRACT

Using solar panels as a renewable energy source requires batteries as energy storage. Continuous use of batteries can result in reduced capacity and performance degradation. Based on these problems, a State of Charge (SOC) estimation system is needed for the battery to control charge conditions so that battery performance remains optimal. In this research, a SOC estimation system was developed for lead acid battery using the Elman Recurrent Neural Network (ERNN) algorithm. The advantage of the ERNN method is that the iteration process is faster, the parameter update speed is increased, and convergence is faster. The results of the SOC estimation for a 12V, 12Ah lead acid battery using the ERNN algorithm were 0.101%, while the Feedforward Backpropagation algorithm resulted in 0.767%. The ERNN algorithm is more efficient in estimating the SOC value of a lead acid battery.

Keywords: *Battery, Elman Recurrent Neural Network, Solar Panel, State of Charge, Lead Acid*

1. PENDAHULUAN

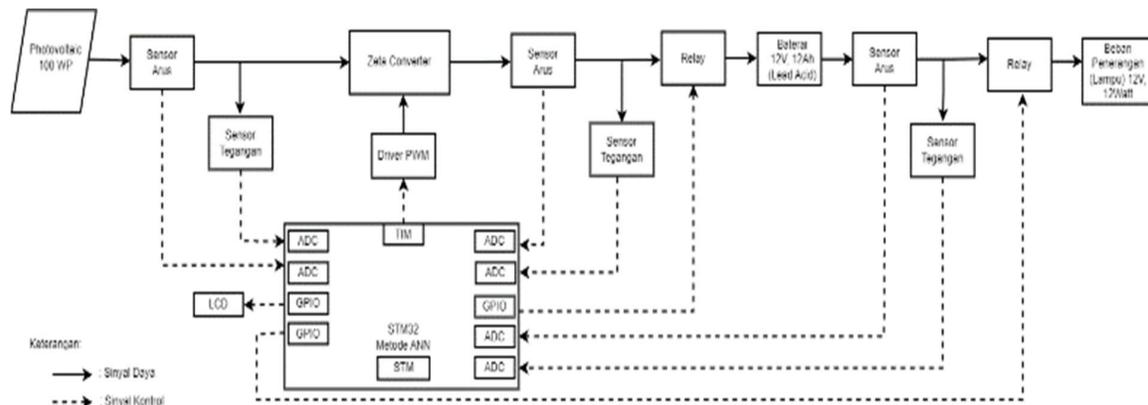
Energi matahari merupakan sumber energi yang tak terbatas dan abadi, yang dapat digunakan sebagai sumber energi alternatif untuk menghasilkan listrik melalui penggunaan panel surya (Ula & Rahmadani, 2023). Dalam pemanfaatan panel surya sebagai sumber energi terbarukan, diperlukan penggunaan baterai sebagai tempat penyimpanan energi untuk sistem terpusat atau *off-grid* (Damiri, dkk, 2023). Penggunaan baterai ini berguna karena baterai memiliki kemampuan untuk menyimpan energi listrik sesuai dengan kapasitasnya. Selama penggunaan baterai, akan terjadi siklus pengisian dan pengosongan energi yang berlangsung secara periodik. Penggunaan baterai secara terus menerus, dapat menyebabkan pengurangan kapasitas dan penurunan performa (Fajrianingrum, dkk, 2022). Baterai yang rusak dapat disebabkan oleh penggunaan yang tidak optimal, dimana kapasitas baterai dapat menjadi kosong atau terlalu penuh, sehingga mengakibatkan baterai menjadi terlalu panas (*overheating*) serta dapat mengurangi umur baterai (Lindgren & Lund, 2016). Oleh karena itu, penting untuk menjaga baterai dari masalah seperti *overcharge*, *undercharge* (Hauck & Kurrat, 2018), *overcurrent*, *short circuit* (Ouyang, dkk, 2018), serta variasi suhu (Łebkowski, 2017), agar baterai dapat bertahan lama. Untuk mengatasi permasalahan tersebut, diperlukan suatu sistem yang mampu memperkirakan nilai *State of Charge* (SOC) pada baterai dengan tujuan menjaga performa baterai tetap optimal, serta melindungi baterai dari kelebihan dan kekurangan muatan yang dapat menyebabkan umur baterai menjadi pendek (Afandi, dkk, 2022). Sistem estimasi SOC dapat mengontrol kondisi pengisian dan pengosongan baterai. SOC diartikan sebagai nilai rasio antara kapasitas baterai yang masih tersisa dan kapasitas nominal yang dimilikinya (sisa daya) (Sutedjo, dkk, 2019).

Didalam implementasinya, nilai SOC tidak bisa secara langsung diukur. Oleh karena itu, telah dilakukan berbagai penelitian yang bertujuan untuk melakukan estimasi SOC dengan menggunakan beberapa metode yang tersedia. Metode *coulomb counting* ini memanfaatkan pembacaan arus pada saat proses pengisian dan pengosongan baterai untuk mengestimasi muatan coulomb melalui integral arus. Namun, metode ini memiliki kelemahan yang perlu diperhatikan, yaitu kemungkinan terjadinya akumulasi *error* atau *galat* dalam hasil estimasi SOC dikarenakan ketergantungan pada hasil pembacaan sensor arus (Ningrum, dkk, 2021). Penelitian lain menerapkan metode *Open Voltage Circuit* (OCV) yang hanya dapat diimplementasikan ketika baterai tidak terhubung dengan sumber daya atau beban. Hal ini menjadi sebuah hambatan, mengingat bahwa proses pengisian dan pengosongan baterai berlangsung secara kontinu (Pillai, dkk, 2022). Penelitian selanjutnya yaitu estimasi nilai SOC menggunakan *Kalman Filter*, dimana algoritma ini sangat kompleks sehingga menyebabkan ketidakstabilan numerik serta pada metode ini sangat bergantung pada pemodelan baterai dan kepresisian sensor-sensor (Afandi, dkk, 2020). Pengembangan metode estimasi SOC selanjutnya yaitu menggunakan *Adaptive Neuro Fuzzy Inference System* (ANFIS). Metode ini memiliki performa yang lebih buruk ketika menghadapi data dengan tingkat kebisingan yang tinggi atau nonlinier. Hal itu dikarenakan ANFIS lebih sensitif terhadap data yang tidak terstruktur dan tidak beraturan (Nurdiansyah, dkk, 2022). Dalam konteks yang berbeda, *Neural Network* sebagai suatu metode *Machine Learning* memiliki kemampuan untuk secara akurat memperkirakan hubungan *nonlinier* antara masukan dan keluaran melalui pembentukan model berdasarkan data pembelajaran (Trinandana, dkk, 2020). Salah satu jenis algoritma *Neural Network* adalah *Feedforward Backpropagation*, yang mana memiliki kelemahan yaitu proses iterasinya lambat dan tidak ada *layer* tambahan yang dapat menghafalkan aktivitas sebelumnya sehingga tidak ada *layer* yang digunakan untuk memperbaiki pembelajaran sebelumnya (Qays, dkk, 2022).

Penelitian ini bertujuan untuk mengembangkan suatu sistem estimasi nilai *State of Charge* (SOC) pada baterai jenis *lead acid* dengan menggunakan algoritma *Elman Recurrent Neural Network*. Sistem estimasi SOC ini memiliki kemampuan untuk menambahkan *layer neuron context* yang dapat memberikan pola unit tersembunyi yang akan diumpungkan kembali ke dirinya sendiri. Hal ini memungkinkan proses iterasi menjadi lebih cepat, peningkatan kecepatan pembaruan parameter, dan pencapaian konvergensi yang lebih cepat, serta memberikan tingkat akurasi yang tinggi dalam memperkirakan nilai SOC (Li, dkk, 2021).

2. METODE

Sistem ini merancang suatu alat estimasi nilai SOC pada baterai jenis *lead acid* dengan algoritma *Elman Recurrent Neural Network*. Perancangan sistem pada penelitian ini dimuat pada diagram blok secara menyeluruh pada Gambar 1.

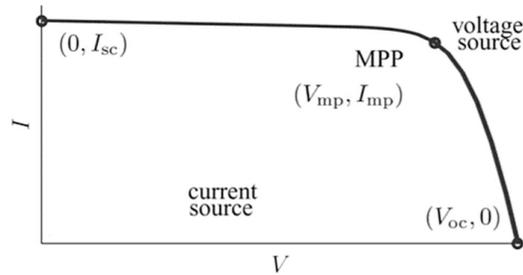


Gambar 1. Blok Diagram Sistem

Hasil data pengukuran nilai arus dan tegangan pada saat kondisi *charging* akan dijadikan input training data dengan tambahan parameter waktu pengisian yang nantinya diproses menggunakan metode algoritma *Elman Recurrent Neural Network* sebagai *monitoring* level kapasitas baterai dan estimasi waktu lama pengisian hingga mencapai tegangan maksimum baterai. Sedangkan untuk proses *discharging*, ketika baterai sudah penuh maka baterai akan menyuplai beban yaitu lampu, maka energi yang tersimpan pada baterai akan berkurang.

2.1 Sistem Solar Panel

Pada umumnya, solar panel berfungsi untuk mengkonversi intensitas sinar matahari menjadi energi listrik. Daya listrik yang dihasilkan oleh solar panel saat menerima cahaya berasal dari kemampuan perangkat solar panel untuk menghasilkan tegangan dan mengalirkan arus melalui beban yang diberikan. Kemampuan ini tersajikan melalui sebuah kurva yang dikenal sebagai kurva arus-tegangan ($I - V$). Kurva karakteristik solar panel $I - V$ menggambarkan beberapa parameter penting, termasuk arus hubung singkat (I_{sc}), tegangan rangkaian terbuka (V_{oc}), dan serta MPP (V_{mp} , I_{mp}), yang memiliki pengaruh signifikan terhadap karakteristik panel tersebut. Gambar 2 merupakan bentuk kurva karakteristik $I - V$ pada panel surya.



Gambar 2. Karakteristik Panel Surya Berdasarkan Kurva I – V

Ketika panel surya beroperasi, dapat dilakukan pengukuran terhadap parameter daya yang diperoleh melalui pergeseran nilai keluaran arus dan tegangan pada kurva I-V. Namun, dalam situasi sebenarnya, terdapat beberapa faktor yang dapat mengakibatkan nilai keluaran panel surya tidak mencapai tingkat maksimumnya, di antaranya adalah perubahan suhu yang fluktuatif dan variasi intensitas sinar matahari. Tabel 1 adalah parameter panel surya yang digunakan.

Tabel 1. Parameter Panel Surya

Parameter	Value
Maximum Power (P_{max})	100 W
Maximum Power Current (I_{mp})	5.62 A
Maximum Power Voltage (V_{mp})	17.8 V
Open Circuit Voltage (V_{oc})	21.8 V
Short Circuit Current (I_{sc})	6.05 A
Standard Test Condition	25°C ,1000 W/m ²

2.2 Estimasi *State of Charge* (SOC)

State of Charge (SOC) merupakan parameter yang menggambarkan perbandingan antara kapasitas sisa baterai dengan kapasitas totalnya ketika baterai telah sepenuhnya diisi pada kondisi standar yang seragam. Secara umum, SOC diwakili dalam bentuk persentase, di mana 100% menunjukkan kapasitas penuh dan 0% menunjukkan kapasitas kosong (**Iskak, dkk, 2019**). Estimasi SOC memiliki peranan yang sangat penting dalam aplikasi baterai karena dapat mencegah gangguan tak terduga pada sistem dan mencegah terjadinya *overcharge* (pengisian berlebih) dan *overdischarge* (pengosongan berlebih) yang dapat merusak baterai secara permanen. Secara matematis, SOC dapat diungkapkan melalui Persamaan (1) (**Suyanto, dkk, 2021**).

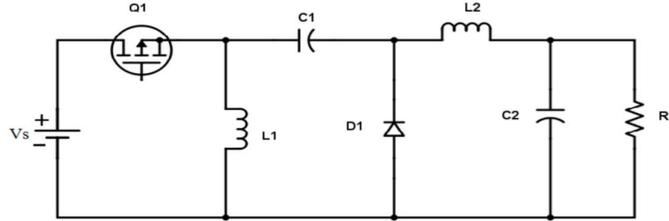
$$SOC \% = \left(\frac{Ah^{(t)}}{Q_n} \right) \times 100 \quad (1)$$

Pada Persamaan (1), nilai $Ah^{(t)}$ merupakan kapasitas baterai pada waktu tertentu, sedangkan Q_n merupakan kapasitas nominal baterai. Nilai $Ah^{(t)}$ dapat diketahui melalui pembacaan sensor arus. Akan tetapi, untuk menentukan nilai SOC pada baterai tidak dapat diukur secara langsung. Oleh karena itu, pada penelitian ini digunakan algoritma ERNN untuk menentukan nilai baterai. Metode ini dipilih karena tidak memerlukan data fisik baterai seperti hambatan internal dan kapasitas.

2.3 Topologi Konverter Zeta

Konverter Zeta adalah jenis konverter DC-DC (*direct current*) yang berfungsi untuk pengatur tegangan yang dapat meningkatkan atau menurunkan nilai tegangan DC keluaran, dengan karakteristik *ripple* tegangan yang rendah karena menggunakan kapasitor keluaran yang

memiliki kapasitas lebih besar (**Sunarno, dkk, 2019**). Dibandingkan dengan konverter Buck-Boost atau Sepic, konverter Zeta memiliki efisiensi konversi yang lebih tinggi karena mampu mengurangi kerugian daya pada dioda penyearah dan kerugian *switching* pada induktor (**Eviningsih, dkk, 2023**). Konverter Zeta bekerja dalam keadaan *continuous conduction mode* (CCM) (**Febian, dkk, 2022**).



Gambar 3. Rangkaian Zeta Converter

Seperti yang ditunjukkan pada Gambar 3 diatas, bahwasannya rangkaian konverter Zeta terdiri atas dua kapasitor dan dua induktor, satu *ultrafast* dioda, dan satu MOSFET P-channel (**Sutedjo, dkk, 2021**). Dalam penelitian ini, sumber tegangan masukan DC yang tidak stabil dari panel surya diubah melalui konverter Zeta menjadi 14.4 V, nilai maksimum yang digunakan dalam proses pengisian baterai *lead acid*. Nilai ini setara dengan 120% dari kapasitas baterai 12V, 12 Ah. Selanjutnya, konverter tersebut mempertahankan tegangan output untuk proses pengosongan baterai dengan Kontrol PI. Metode pengisian baterai yang digunakan adalah *Constant Voltage*, di mana baterai diisi dengan tegangan konstan hingga mencapai kapasitas penuh, sementara arusnya semakin menurun seiring pengisian (**Irianto, dkk, 2022**).

Nilai tegangan masukan (V_{in}), tegangan keluaran (V_{out}) dan *duty cycle* (D) dari konverter ZETA pada kondisi CCM dapat diketahui melalui Persamaan (2).

$$V_{out} = \frac{D}{1-D} V_{in} \quad (2)$$

Untuk menghitung arus *ripple* yang diinginkan, dapat menggunakan Persamaan (3).

$$\Delta I_L = r I_L \times I_{in} \quad (3)$$

Dengan demikian nilai induktor L_1 dan L_2 dapat dihitung menggunakan Persamaan (4).

$$L_1 = L_2 = \frac{D \times V_{in}}{\Delta I_L \times F} \quad (4)$$

Untuk mengatasi *ripple* tegangan diperlukan suatu kapasitor didalam rangkaian. Untuk menentukan nilai kapasitor C_2 , C_1 dan C_{in} dapat diketahui dengan Persamaan (5), (6) dan (7).

$$C_2 = \frac{\Delta I_L}{8 \times \Delta V_{C_2} \times F} \quad (5)$$

$$C_1 = \frac{D \times I_{out}}{\Delta V_{C_1} \times F} \quad (6)$$

$$C_{in} = \frac{D \times I_{out}}{\Delta V_{C_{in}} \times F} \quad (7)$$

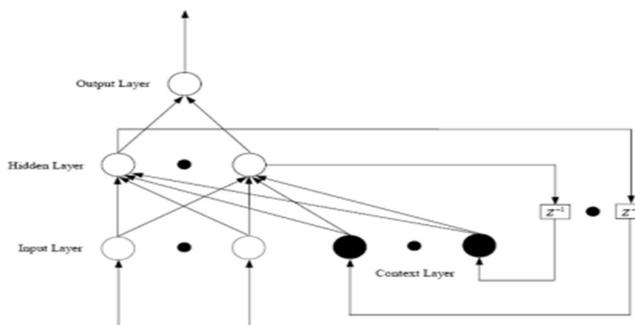
Berdasarkan hasil perhitungan yang telah dilakukan, Tabel 2 merupakan parameter komponen pada rangkaian konverter Zeta.

Tabel 2. Parameter Konverter Zeta

Parameter	Simbol	Nilai	Satuan
Tegangan Masukan	V_{in}	17.8	<i>Volt</i>
Tegangan Keluaran	V_{out}	14.4	<i>Volt</i>
Arus Keluaran	I_{out}	7.9418	<i>A</i>
Frekuensi	F	40k	<i>Hz</i>
Induktor 1	L_1	156.891	μH
Induktor 2	L_2	123.272	μH
Kapasitor 1	C_1	150	μF
Kapasitor 2	C_2	220	μF
Kapacitor Masukan	C_{in}	47	μF

2.4 Algoritma *Elman Recurrent Neural Network* (ERNN)

Elman Recurrent Neural Network (ERNN) adalah jenis jaringan *Feedforward* yang memiliki kinerja prediksi yang lebih baik karena memiliki *context layer* yang tidak dimiliki oleh jaringan saraf lainnya. Jika dibandingkan dengan *Feedforward*, ERNN memiliki tingkat akurasi yang akurat untuk estimasi SOC (Yolcu, dkk, 2021).



Gambar 4. Struktur *Elman Recurrent Neural Network*

Seperti yang ditunjuk pada Gambar 4, metode ini terbagi menjadi *input layer*, *hidden layer*, *context layer*, dan *output layer*. *Context layer* beban dari jaringan dapat mengirimkan informasi keadaan dan memiliki kemampuan memori, yang dapat membantu ERNN untuk mendapatkan prediksi yang lebih baik terutama dalam memecahkan masalah data deret dan deret waktu (Kamanditya & Kusumoputro, 2020). Struktur dari ERNN membentuk koneksi antar unitnya membentuk siklus yang terarah. *Elman Neural Network* merupakan jaringan tiga *layer* dengan tambahan satuan *set context layer*. Terdapat koneksi dari *hidden layer* ke *context layer* untuk perbaikan yang selalu menyimpan salinan nilai sebelumnya dari *hidden layer*. Dengan demikian, jaringan dapat mempertahankan semacam keadaan, memungkinkan melakukan tugas prediksi urutan yang dapat melampaui *perceptron multilayer* standar (Abdulrahman, dkk, 2021). Jaringan ERNN memiliki parameter *Feed Forward* yang tetap, tidak ada pengulangan dalam jalur input dan output.

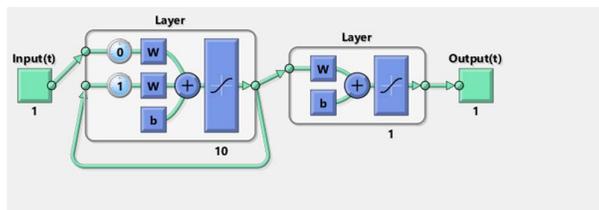
Implementasi metode ERNN dalam estimasi nilai SOC, dibuat dengan cara pencarian data pembelajaran berupa karakteristik arus pengisian pada baterai dan output target ERNN berupa nilai SOC yang nantinya akan menghasilkan nilai estimasi. Untuk menjalankan sistem estimasi SOC pada baterai *lead acid* menggunakan metode ERNN maka diperlukan proses pembelajaran atau *learning* atau *training*. Dimana proses ini dilakukan dengan cara menentukan data yang akan digunakan untuk *learning*. Selanjutnya data tersebut di *learning* menggunakan fitur *Neural Network Tool* (NNTool) pada MATLAB. Sehingga dapat diperoleh nilai dari bias dan

bobot yang akan digunakan pada sistem. Beberapa data pembelajaran yang akan digunakan pada sistem ini ditampilkan pada Tabel 3.

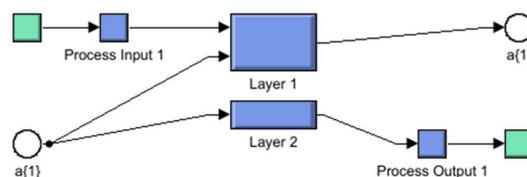
Tabel 3. Data Pembelajaran *Elman Recurrent Neural Network*

Target SOC (%)	Arus Masukan Pengisian (A)	Tegangan Pengisian (V)
40	2.4	14.4
45	2.04	14.4
50	1.738	14.4
55	1.482	14.4
60	1.262	14.4
65	1.071	14.4
70	0.8958	14.4
75	0.7474	14.4
80	0.6089	14.4
85	0.4814	14.4
90	0.3712	14.4

Pada Tabel diatas terdapat 3 parameter yaitu arus, SOC, dan tegangan. Namun yang digunakan untuk pembelajaran hanyalah data arus yang digunakan untuk masukan dan data SOC digunakan untuk target, data tegangan tidak digunakan sebagai pembelajaran dikarenakan nilai tegangan konstan. Data pembelajaran diambil dari SOC 40% dikarenakan batas maksimal nilai pengosongan adalah 40% dan data maksimal pengisian diambil ketika SOC 90%. Hal itu dikarenakan, ketika dilakukan pengambilan data pembelajaran diatas 80% nilai tegangan tidak sesuai dengan *setpoint* yang telah ditentukan (**Murdianto, dkk, 2019**). Pada penelitian ini menggunakan *2 layer* yaitu 1 *hidden layer* dengan jumlah *neuron* 10 menggunakan fungsi aktivasi *tansig*. *Layer* selanjutnya adalah *output layer* dengan jumlah *neuron* 10 menggunakan fungsi aktivasi *tansig*. Gambar 5 merupakan hasil dari desain arsitektur algoritma ERNN yang telah dibuat.



Gambar 5. Arsitektur Algoritma ERNN

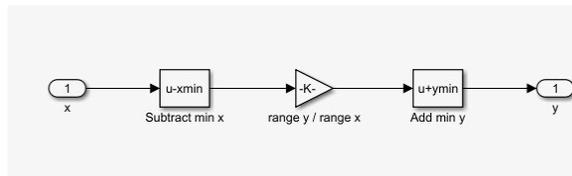


Gambar 6. Diagram Algoritma Jaringan ERNN

Struktur diagram jaringan ERNN ditunjukkan pada Gambar 6 yang terdiri dari beberapa komponen penyusun yaitu, *Process Input 1*; *Layer 1*; *Layer 2* dan *Process Output 1*. Dari empat komponen proses utama dari jaringan ERNN diatas, kemudian dibahas lebih detail untuk mendapatkan persamaan ERNN yang nantinya digunakan sebagai proses perhitungan.

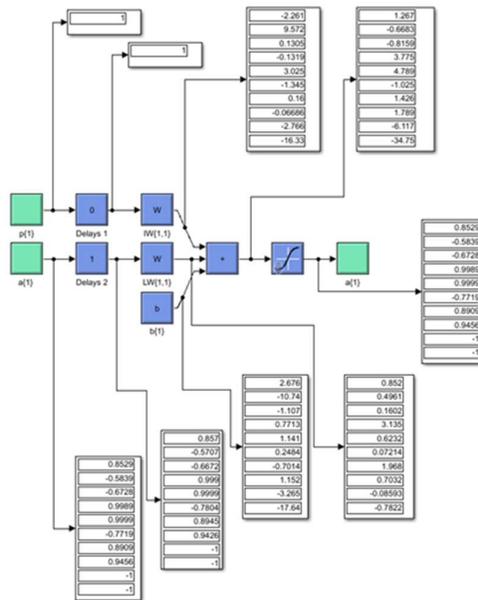
Normalisasi data terdapat didalam proses input pada pembelajaran jaringan syaraf tiruan, bertujuan untuk mendapatkan data yang mewakili data asli dengan nilai data yang lebih kecil, tanpa menghilangkan karakteristiknya mendapatkan data yang mewakili data asli dengan nilai data yang lebih kecil, tanpa menghilangkan karakteristiknya. Proses normalisasi dilakukan melalui blok fungsi *mapminmax*. Dimana ketika blok tersebut dilihat lebih detail terdapat persamaan yang digunakan untuk menghasilkan output tersebut yang dapat dilihat pada Gambar 7. Nilai output normalisasi data pada blok *mapminmax* (x) dapat dilakukan perhitungan Persamaan (8).

$$x = (u - x_{min}) \times \frac{(y_{max} - y_{min})}{(x_{max} - x_{min})} + Y_{min} \quad (8)$$



Gambar 7. Simulink Blok *Mapminmax* Normalisasi

Variabel X_{min} dan X_{max} adalah nilai maksimal dan minimal dari input dari tegangan serta Y_{max} bernilai 1 dan Y_{min} bernilai -1. Blok fungsi *mapminmax* berfungsi untuk menstandartkan nilai input agar dapat diolah oleh jaringan *neural*, selanjutnya hasil dari proses input 1 akan masuk ke *layer* 1 dan selanjutnya menuju pada *layer* 2. Dimana dapat dilihat pada Gambar 8.



Gambar 7. Simulink Diagram *Layer* 1

Berdasarkan Gambar 8 dapat diketahui bahwa pada diagram *layer* 1 terdapat blok fungsi utama yaitu *Weight*, *Bias*, *Netsum* dan *Tansig* (fungsi aktivasi). Sebelum masuk ke *layer* 2, terdapat blok fungsi aktivasi *Tansig*. *Layer* 1 pada ERNN disebut juga dengan "*hidden layer*" atau lapisan tersembunyi. Pada *layer* ini, terdapat beberapa unit yang menerima masukan dari *layer* sebelumnya dan menghasilkan keluaran yang menjadi masukan bagi *layer* selanjutnya (Belov, dkk, 2021). *Layer* 2 pada ERNN adalah *output layer* atau lapisan keluaran. Pada

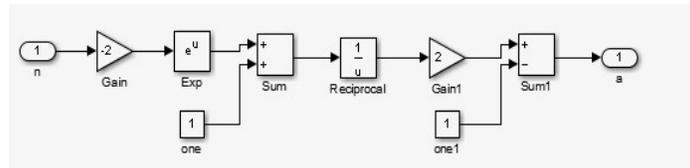
layer ini, setiap unit menerima masukan dari unit-unit pada *hidden layer* dan menghasilkan keluaran yang merupakan prediksi dari model untuk masukan yang diberikan (**Laily, dkk, 2018**). Pada *layer 1* dapat dilakukan perhitungan menggunakan Persamaan (9).

$$net_j(t) = \sum_i^n v_{ij} x_i(t) + \sum_h^m u_{jh} y_h(t-1) + B_j \tag{9}$$

Setiap nilai unit *hidden layer* ($net_j(t)$) akan ditambahkan dengan nilai vektor input pada waktu (t) ($x_i(t)$) yang akan dikalikan dengan matriks bobot yang menghubungkan setiap unit pada *input layer* (v_{ij}) dan ditambahkan dengan nilai *context layer* ($y_h(t-1)$) yang dikalikan matriks bobot yang menghubungkan setiap unit pada *hidden layer* (u_{jh}), yang dijumlahkan dengan vektor bias *hidden layer* (B_j). Fungsi aktivasi *Tansig* (*tangent sigmoid*) $f(net_j)$ sebagai pengaktif *neuron* pada ERNN, dapat dilihat pada Gambar 9 dan dinyatakan Persamaan (10) (11).

$$y_j(t) = f(net_j(t)) \tag{10}$$

$$f(net_j) = \frac{1}{1+e^{-net_j}} \tag{11}$$



Gambar 9. Simulink Blok *Tansig*

Sedangkan untuk persamaan *layer 2* atau *output layer* adalah (12) (13).

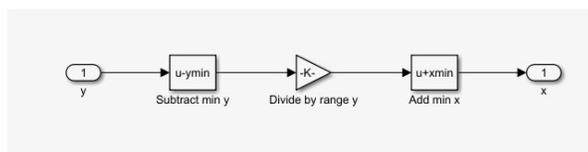
$$net_k(t) = (\sum_j^m y_j(t) w_{kj}) + B_k \tag{12}$$

$$y_k(t) = g(net_k(t)) \tag{13}$$

Setiap keluaran dari unit pada *layer 2* pada waktu (t) pada (y_k) akan ditambahkan output dari setiap unit pada *hidden layer* (y_j) yang dikalikan dengan matriks bobot yang menghubungkan setiap unit pada *hidden layer* (w_{kj}) dan dijumlahkan dengan vektor bias pada *output layer* (B_k). Untuk mendapatkan nilai *output layer*, maka (net_k) akan dilakukan perhitungan dalam fungsi pengaktif menjadi (y_k).

Denormalisasi pada ERNN merupakan proses untuk mengembalikan data yang telah dinormalisasi ke dalam skala awalnya. Hal ini dilakukan untuk memperoleh hasil prediksi yang dapat dipahami dan berguna dalam kehidupan sehari-hari. Nilai keluaran denormalisasi data pada blok *mapminmax* (*out_x*) dapat dilihat pada Gambar 10 dan Persamaan (14) berikut.

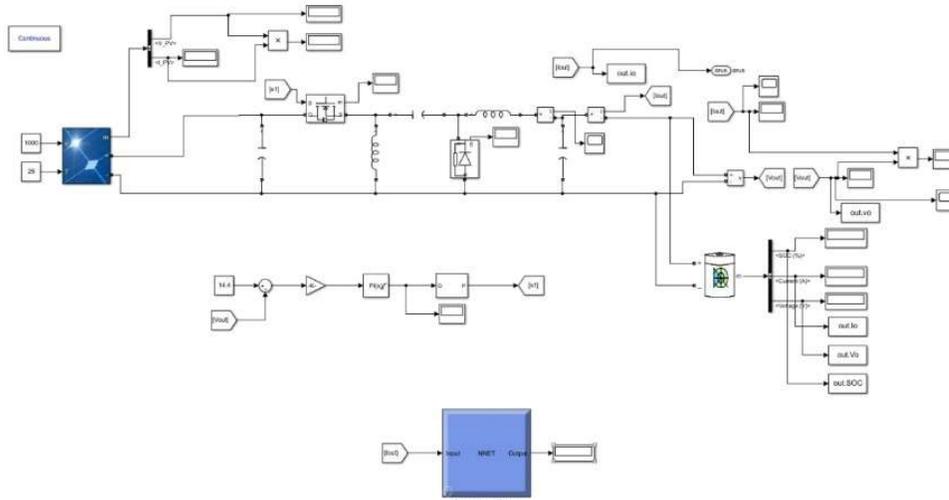
$$out_x = \left((net_1 - Y_m) \times \frac{X_{max}-X_{min}}{Y_{max}-Y_{min}} \right) + X_{min} \tag{14}$$



Gambar 10. Simulink Blok *Mapminmax* Denormalisasi

3. HASIL DAN PEMBAHASAN

Pengujian estimasi SOC menggunakan metode algoritma ERNN untuk mengestimasi level baterai yang disimulasikan menggunakan *software* Simulink-Matlab. Pada simulasi ini terdapat rangkaian konverter Zeta dimana keluarannya berupa nilai tegangan yang diatur konstan yang digunakan untuk pengisian baterai. Berikut pada Gambar 11 merupakan rangkaian simulasi dari estimasi nilai SOC pada baterai *lead acid* menggunakan metode algoritma ERNN.



Gambar 11. Rangkaian Estimasi SOC Menggunakan Metode Algoritma ERNN

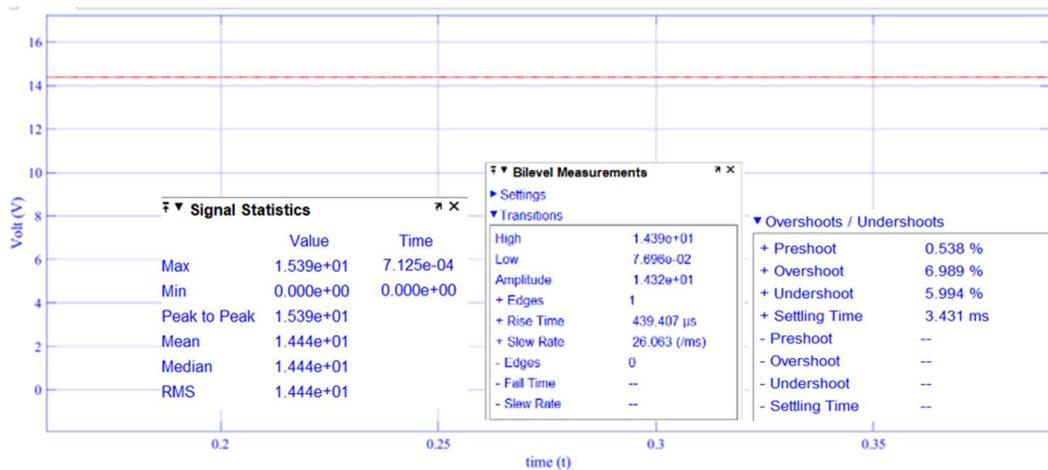
Pada Gambar 11 simulasi dari estimasi nilai SOC pada baterai *lead acid* menggunakan metode algoritma ERNN. Pengujian pertama dilakukan dengan memberikan tegangan konstan pada baterai sebesar 14.4V. Selanjutnya, mengambil data arus pengisian dan nilai SOC yang digunakan untuk pembelajaran data. Pengujian rangkaian konverter Zeta dirancang secara *close loop* menggunakan kontrol PI dengan *setpoint* 14.4 V dan dilakukan pada saat solar panel dalam keadaan *Standard Test Condition* (STC) dengan nilai suhu = 25 °C dan Iradiasi = 1000 W/m². Hasil pengujian konverter ditunjukkan pada Tabel 4

Tabel 4. Data Pengujian Zeta Converter *Close Loop* dengan Beban Baterai

Suhu (°C)	Iradiasi (W/m ²)	SOC (%)	Vout (V)	Iout (A)
25	1000	40	14.4	2.4
		45	14.4	2.04
		50	14.4	1.738
		55	14.4	1.482
		60	14.4	1.262
		65	14.4	1.071
		70	14.4	0.8958
		75	14.4	0.7474
		80	14.4	0.6089
		85	14.4	0.4814
		90	14.4	0.3529

Dari Tabel 4 diatas dapat disimpulkan bahwa konverter dengan input solar panel dapat mencapai tegangan *setpoint* yaitu 14.4V, serta keluaran tegangan yang sudah sesuai dengan perhitungan pada saat perencanaan. Pada saat SOC rendah arus yang masuk pada baterai

tinggi dan semakin tinggi SOC maka arus yang lewat kecil, hal tersebut sudah sesuai dengan teori.



Gambar 12. Gelombang Tegangan Simulasi *Close Loop*

Dari Gambar 12 dapat dilihat bahwa ketika sudah rangkaian *close loop* menggunakan beban baterai maka nilai *rise time* nya lebih cepat dikarenakan sudah terdapat kontrol, maka didapatkan nilai *rise time* sebesar 0.001207 ms dan gelombang tidak berosilasi. Sedangkan untuk nilai *overshoot* didapatkan sebesar 6.989% dan *undershoot* sebesar 5.994%. Selanjutnya dilakukan pengujian estimasi SOC menggunakan metode algoritma ERNN, dengan hasil pengujian yang ditunjukkan pada Tabel 5.

Tabel 5. Data Estimasi SOC Menggunakan Metode Algoritma ERNN

Arus (A)	SOC Baterai (%)	SOC ERNN (%)	Error
2.4	40	40.15543	0.39%
2.04	45	44.98668	0.03%
1.738	50	49.99675	0.01%
1.482	55	55.00408	0.01%
1.262	60	60.00257	0.00%
1.071	65	65.0302	0.05%
0.8958	70	70.16885	0.24%
0.7474	75	74.89693	0.14%
0.6089	80	79.9349	0.08%
0.4814	85	85.03921	0.05%
0.375	90	90.10378	0.12%
Rata-rata %error			0.101 %

Pada pengujian estimasi SOC menggunakan algoritma ERNN terdapat *galat* atau *error* pada proses pembelajaran. Galat pada jaringan syaraf tiruan merujuk pada perbedaan antara keluaran aktual (*current output*) dan keluaran yang diharapkan (*desired output*) dari suatu data input. Semakin kecil tingkat *error*, semakin tinggi tingkat akurasi model. Artinya, semakin mendekati nilai *error* nol, semakin akurat hasil prediksi yang dihasilkan oleh jaringan syaraf tiruan tersebut. Dari hasil data simulasi pada Tabel 5 dihasilkan *error* rata-rata sebesar 0.101 %. Setelah dilakukan simulasi menggunakan algoritma ERNN, maka dilakukan perbandingan dengan algoritma *Feedforward Backpropagation* (FFBP), data hasil pengujian dapat dilihat pada Tabel 6.

Tabel 6. Perbandingan Data Estimasi SOC Menggunakan Metode ERNN dan FFBP

Arus (A)	SOC (%)			Error	
	Baterai	FFBP	ERNN	FFBP	ERNN
2.4	40	41.56229	40.15543	3.91%	0.39%
2.04	45	44.7562	44.98668	0.54%	0.03%
1.738	50	49.63206	49.99675	0.74%	0.01%
1.482	55	55.11225	55.00408	0.20%	0.01%
1.262	60	60.35314	60.00257	0.59%	0.00%
1.071	65	65.12962	65.0302	0.20%	0.05%
0.8958	70	69.90123	70.16885	0.14%	0.24%
0.7474	75	74.66905	74.89693	0.44%	0.14%
0.6089	80	80.07682	79.9349	0.10%	0.08%
0.4814	85	85.45555	85.03921	0.54%	0.05%
0.375	90	89.06607	90.10378	1.04%	0.12%
Rata- rata %error				0.767%	0.101%

Dari hasil perbandingan pengujian simulasi antara algoritma ERNN dengan FFBP, maka dapat diperoleh *galat* atau *error* rata-rata FFBP sebesar 0.101%, sedangkan *error* ERNN 0.19%. Nilai simulasi *error* pada algoritma ERNN lebih kecil dibanding dengan algoritma FFBP. Nilai *error* pada ERNN lebih kecil dikarenakan algoritma ini dapat memperhitungkan informasi dari waktu sebelumnya dan menggunakannya dalam memprediksi nilai SOC pada waktu yang akan datang. Dengan kata lain, algoritma ERNN lebih baik dan akurat dalam memprediksi SOC baterai *lead acid* 12V 12Ah pada situasi yang dinamis dan kompleks.

4. KESIMPULAN

Berdasarkan hasil dari penelitian yang dilakukan terkait estimasi SOC pada baterai *lead acid* menggunakan algoritma ERNN, metode ini terbukti sangat optimal untuk digunakan dalam proses estimasi tersebut. Algoritma ERNN memiliki struktur tambahan berupa lapisan *neuron context* yang memungkinkan adanya pola unit tersembunyi yang dapat diumpan balik ke dirinya sendiri. Keberadaan fitur ini mempercepat proses iterasi, pembaruan parameter, dan konvergensi secara signifikan, serta menghasilkan estimasi dengan tingkat keakuratan yang tinggi. Pembelajaran data pada algoritma ERNN menggunakan nilai arus, dengan nilai pengisian baterai konstan sebesar 14.4 V. Pengujian dilakukan pada kondisi solar panel *Standard Test Condition*, dimana rangkaian konverter Zeta secara *close loop* dengan kontrol PI, dapat menghasilkan nilai *setpoint* 14.4 V. Selanjutnya diperoleh nilai hasil *galat* atau *error* pembelajaran pada pengujian estimasi SOC pada baterai 12V 12Ah menggunakan algoritma ERNN sebesar 0.101%, sedangkan algoritma FFBP sebesar 0.767%. Sehingga dapat disimpulkan bahwa algoritma ERNN lebih baik dalam mengestimasi nilai SOC pada baterai *lead acid*.

DAFTAR RUJUKAN

- Abdulrahman, M. L., Ibrahim, K. M., Gital, A. Y., Zambuk, F. U., Ja'afaru, B., Yakubu, Z. I., & Ibrahim, A. (2021). A Review on Deep Learning with Focus on Deep Recurrent Neural Network for Electricity Forecasting in Residential Building. *Procedia Computer Science*, *193*, 141–154. <https://doi.org/10.1016/j.procs.2021.10.014>
- Afandi, A., Sumantri, B., & Windarko, N. A. (2020). Estimation State of Charge (SOC) of Ultracapacitor Based On Classical Equivalent Circuit Using Extended Kalman Filter. *2020 International Electronics Symposium (IES)*, (pp. 31–36).

- <https://doi.org/10.1109/IES50839.2020.9231736>
- Afandi, A., Windarko, N. A., Sumantri, B., & Fakhrudin, 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), 61. <https://doi.org/10.26760/elkomika.v10i1.61>
- Belov, M. P., Van Lanh, N., & Khoa, T. D. (2021). State Observer based Elman Recurrent Neural Network for Electric Drive of Optical-Mechanical Complexes. *Proceedings of the 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus 2021*, (pp. 802–805). <https://doi.org/10.1109/ElConRus51938.2021.9396310>
- Damiri, D. J., Lamania, R., & Laksana, R. (2023). Design and Simulation of On-Grid Rooftop Solar Power Plant (Rooftop PV) System on Office Buildings with a PLN Grid System. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(1), 231. <https://doi.org/10.26760/elkomika.v11i1.231>
- Eviningsih, R. P., Rahmadani, A., Kinasih, A. R., & Arvioneta, R. (2023). Perancangan SEPIC Converter untuk Pengisian Baterai dengan Metode Kontrol PI. *Jurnal Politeknik Caltex Riau*, 9(1), 75–85. <https://doi.org/https://doi.org/10.35143/elementer.v9i1>
- Fajrianingrum, F. N., Rakhmawati, R., & Prasetyono, E. (2022). Design and Implementation MPPT-CPG for Constant Power Battery Charger. *JAREE (Journal on Advanced Research in Electrical Engineering)*, 6(2). <https://doi.org/10.12962/jaree.v6i2.319>
- 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. <https://doi.org/10.31963/intek.v9i1.3410>
- Hauck, D., & Kurrat, M. (2018). *Overdischarging Lithium-Ion Batteries* (hal. 53–81). https://doi.org/10.1007/978-3-319-70572-9_4
- Irianto, I., Eviningsih, R. P., Murdianto, F. D., & Muhyidin, A. (2022). Optimization Improvement Using Pi Controller to Reach CCCV Method in Lead Acid Battery Load. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*. <https://doi.org/10.22219/kinetik.v7i4.1496>
- Iskak, C. A., Windarko, N. A., & Rakhmawati, R. (2019). Design and Implementation Bidirectional DC-DC Converter for Load Sharing and Charging Battery. *2019 International Seminar on Application for Technology of Information and Communication (iSemantic)*, (pp. 455–459). <https://doi.org/10.1109/ISEMANTIC.2019.8884344>

- Kamanditya, B., & Kusumoputro, B. (2020). Elman Recurrent Neural Networks Based Direct Inverse Control for Quadrotor Attitude and Altitude Control. *2020 International Conference on Intelligent Engineering and Management (ICIEM)*, (pp. 39–43). <https://doi.org/10.1109/ICIEM48762.2020.9160191>
- Łebkowski, A. (2017). Temperature, Overcharge and Short-Circuit Studies of Batteries used in Electric Vehicles. *PRZEGLĄD ELEKTROTECHNICZNY*, *1(5)*, 69–75. <https://doi.org/10.15199/48.2017.05.13>
- Laily, V. O. N, Warsito, B., & Maruddani, D. A. I. (2018). Comparison of ARCH / GARCH model and Elman Recurrent Neural Network on data return of closing price stock. *Journal of Physics: Conference Series*, *1025(1)*. <https://doi.org/10.1088/1742-6596/1025/1/012103>
- Li, S., Ju, C., Li, J., Fang, R., Tao, Z., Li, B., & Zhang, T. (2021). State-of-Charge Estimation of Lithium-Ion Batteries in the Battery Degradation Process Based on Recurrent Neural Network. *Energies*, *14(2)*, 306. <https://doi.org/10.3390/en14020306>
- Lindgren, J., & Lund, P. D. (2016). Effect of extreme temperatures on battery charging and performance of electric vehicles. *Journal of Power Sources*, *328*, 37–45. <https://doi.org/10.1016/j.jpowsour.2016.07.038>
- Murdianto, F. D., Nansur, A. R., Septiarini, N. A., Widarsono, K., & Purwanto, E. (2019). SEPIC converter with coupled inductor using Fuzzy Logic controller to optimized battery charging process. *Journal of Physics: Conference Series*, *1367(1)*, 012074. <https://doi.org/10.1088/1742-6596/1367/1/012074>
- Ningrum, P., Windarko, N. A., & Suhariningsih, S. (2021). Estimation of State of Charge (SoC) Using Modified Coulomb Counting Method With Open Circuit Compensation For Battery Management System (BMS). *JAREE (Journal on Advanced Research in Electrical Engineering)*, *5(1)*. <https://doi.org/10.12962/jaree.v5i1.150>
- Nurdiansyah, R., Windarko, N. A., Rakhmawati, R., & Abdul Haq, M. (2022). State of charge estimation of ultracapacitor based on equivalent circuit model using adaptive neuro-fuzzy inference system. *Journal of Mechatronics, Electrical Power, and Vehicular Technology*, *13(1)*, 60–71. <https://doi.org/10.14203/j.mev.2022.v13.60-71>
- Ouyang, D., Chen, M., Liu, J., Wei, R., Weng, J., & Wang, J. (2018). Investigation of a commercial lithium-ion battery under overcharge/over-discharge failure conditions. *RSC Advances*, *8(58)*, 33414–33424. <https://doi.org/10.1039/C8RA05564E>
- Pillai, P., Sundaresan, S., Kumar, P., Pattipati, K. R., & Balasingam, B. (2022). Open-Circuit Voltage Models for Battery Management Systems: A Review. *Energies*, *15(18)*, 6803.

- <https://doi.org/10.3390/en15186803>
- Qays, M. O., Buswig, Y., Hossain, M. L., & Abu-Siada, A. (2022). Recent progress and future trends on the state of charge estimation methods to improve battery-storage efficiency: A review. *CSEE Journal of Power and Energy Systems*, *8*(1), 105–114. <https://doi.org/10.17775/CSEEJPES.2019.03060>
- Sunarno, E., Sudiharto, I., Nugraha, S. D., Murdianto, F. D., Suryono, & Qudsi, O. A. (2019). Design and implementation bidirectional SEPIC/ZETA converter using Fuzzy Logic Controller in DC microgrid application. *Journal of Physics: Conference Series*, *1367*(1), 012058. <https://doi.org/10.1088/1742-6596/1367/1/012058>
- Sutedjo, S., Ferdiansyah, I., Qudsi, O. A., & Setiawan, F. (2019). Design of Battery Charging System as Supply of Rice Threshers in Tractor. *2019 2nd International Conference on Applied Information Technology and Innovation (ICAITI)*, (pp. 32–36). <https://doi.org/10.1109/ICAITI48442.2019.8982160>
- Sutedjo, S., Rizqi, A., & Wahjono, E. (2021). Hardware Implementation of Maximum Power Point Tracking Using Fuzzy Logic-Based Zeta Converter at PV 100Wp. *CESS (Journal of Computer Engineering, System and Science)*, *7*(1), 67. <https://doi.org/10.24114/cess.v7i1.29477>
- Suyanto, H., Erlina, Diantari, R. A., & Al Rasyid, H. (2021). Study on Optimization of System Management Battery for Lithium Batteries and Lead Acid Batteries at the New and Renewable Energy Research Center IT PLN. *2021 IEEE 5th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, (pp. 213–218). <https://doi.org/10.1109/ICITISEE53823.2021.9655905>
- Trinandana, G. A., Pratama, A. W., Prasetyono, E., & Anggriawan, D. O. (2020). Real Time State of Charge Estimation for Lead Acid Battery Using Artificial Neural Network. *2020 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, (pp. 363–368). <https://doi.org/10.1109/ISITIA49792.2020.9163692>
- Ula, M., & Rahmadani, A. (2023). Rancang Bangun Maximum Power Point Tracking pada Panel Surya dengan Metode Incremental Conductance Menggunakan Zeta Konverter. *Techne: Jurnal Ilmiah Elektroteknika*, *22*(1), 1–20. <https://doi.org/10.31358/techne.v22i1.334>
- Yolcu, O. C, Temel, F. A., & Kuleyin, A. (2021). New hybrid predictive modeling principles for ammonium adsorption: The combination of Response Surface Methodology with feed-forward and Elman-Recurrent Neural Networks. *Journal of Cleaner Production*, *311*, 127688. <https://doi.org/10.1016/j.jclepro.2021.127688>