

Implementasi Battery Management System pada Monitoring Patok Perbatasan Berbasis Solar Panel Menggunakan Artificial Neural Network

Ardiansyah Dwi Saputra¹⁾, Yosera Rico Fahmi²⁾, Isa Mahfudi³⁾,
Muhammad Ridwan⁴⁾

1), 2), 3), 4) Prodi Teknik Telekomunikasi Militer. Politeknik Angkatan Darat
Jl. Raya Anggrek No.1 Junrejo, Batu, Indonesia

E - mail : adriansyahdesember13@gmail.com¹⁾ , yoserarico04@gmail.com²⁾,
isa_mahfudi@polinema.ac.id³⁾, ridwan.mtte20@gmail.com⁴⁾

Abstract: Monitoring national border pillars plays a crucial role in maintaining the sovereignty and security of national border areas. However, conventional monitoring systems are often constrained by the lack of electrical infrastructure and communication networks in remote locations. This study proposes the implementation of a Battery Management System (BMS) supported by solar panels and integrated with an Artificial Neural Network (ANN) algorithm to predict the State of Charge (SoC) of a LiFePO₄ battery. The system architecture combines a photovoltaic panel, a PWM Solar Charge Controller (SCC), a 4S 15 Ah LiFePO₄ battery, INA219 current and voltage sensors, an ESP32 microcontroller, and a LoRa communication module. The ANN model was trained using battery voltage and current as input variables to predict the SoC percentage as the output variable. Ground-Truth SoC data were obtained independently using calibrated Coulomb Counting. To prevent data leakage, dataset splitting was performed using a cycle-based approach, isolating 4 complete cycles (1,875 samples) as an independent test set. Experimental results on the independent test set demonstrated that the ANN method achieved a Mean Absolute Percentage Error (MAPE) of 4.86% with a computational inference time of 1.8 ms on the ESP32, substantially outperforming the conventional voltage-based method which yielded an error of 12.16%. The power supply subsystem achieved a charging conversion efficiency of 68.4% and has an estimated theoretical battery autonomy of up to 9.6 days without sunlight. These findings confirm the system's ability to operate autonomously, precisely, with real-time inference capabilities for long-term border pillar monitoring in remote areas.

Keywords: Battery Management System (BMS), Artificial Neural Network (ANN), State of Charge (SoC), LiFePO₄, ESP32, Solar Panel, INA219, Border Pillar Monitoring.

Abstrak: Pengawasan terhadap patok perbatasan negara memiliki peranan krusial dalam memelihara kedaulatan dan keamanan wilayah perbatasan nasional. Namun, sistem pemantauan konvensional sering terkendala oleh keterbatasan infrastruktur listrik dan jaringan komunikasi di lokasi-lokasi terpencil. Penelitian ini mengusulkan penerapan Battery Management System (BMS) yang didukung oleh panel surya dan diintegrasikan dengan algoritma Artificial Neural Network (ANN) guna memprediksi State of Charge (SoC) pada baterai LiFePO₄. Arsitektur ini menggabungkan panel surya, Solar Charge Controller (SCC) PWM, baterai LiFePO₄ 4S 15 Ah, sensor arus dan tegangan INA219, mikrokontroler ESP32, serta modul komunikasi LoRa. Model ANN dilatih menggunakan variabel tegangan dan arus baterai sebagai input untuk memprediksi persentase SoC sebagai output. Data Ground-Truth SoC diperoleh secara independen melalui pengujian Coulomb Counting terkalibrasi. Guna menghindari data leakage, dataset dibagi berbasis siklus utuh (cycle-based splitting)

dengan mengisolasi 4 siklus terpisah (1.875 sampel data) sebagai independent test set. Berdasarkan hasil pengujian pada independent test set, algoritma ANN mencatatkan rata-rata galat Mean Absolute Percentage Error (MAPE) sebesar 4,86% dengan waktu inferensi komputasi pada ESP32 sebesar 1,8 ms, jauh melampaui metode konvensional berbasis tegangan yang menghasilkan galat 12,16%. Sub-sistem catu daya mencatatkan efisiensi konversi pengisian sebesar 68,4% dan memiliki estimasi ketahanan operasional teoretis (theoretical battery autonomy) hingga 9,6 hari tanpa sinar matahari. Temuan ini menegaskan keunggulan sistem dalam beroperasi secara otonom, presisi, dengan kemampuan inferensi *real-time* untuk aplikasi pemantauan patok batas jangka panjang di wilayah terpencil.

Kata Kunci: Battery Management System (BMS), Artificial Neural Network (ANN), State of Charge (SoC), LiFePO₄, ESP32, Panel Surya, INA219, Pemantauan Patok Perbatasan.

PENDAHULUAN

Sebagai garis depan pertahanan nasional, wilayah perbatasan menjadi pilar utama dalam menjaga kedaulatan Negara Kesatuan Republik Indonesia. Keberadaan patok perbatasan memiliki fungsi penting sebagai penanda batas wilayah negara sehingga kondisi fisik maupun posisinya harus selalu terpantau. Kerusakan, pergeseran, maupun tindakan sabotase terhadap patok perbatasan dapat menimbulkan permasalahan administratif maupun keamanan apabila tidak segera diketahui oleh petugas [7].

Saat ini proses pengawasan patok perbatasan masih dilakukan melalui patroli secara berkala oleh personel Satgas Pengamanan Perbatasan TNI AD. Namun, pendekatan konvensional ini menghadapi sejumlah kendala, seperti durasi pelaksanaan yang panjang, alokasi anggaran yang besar, serta tingkat efektivitas yang rendah pada daerah terpencil yang memiliki akses transportasi dan komunikasi terbatas. Kondisi tersebut menyebabkan informasi mengenai gangguan pada patok perbatasan sering kali terlambat diterima oleh Pos Jaga.

Perkembangan teknologi komunikasi jarak jauh memungkinkan sistem monitoring dilakukan secara otomatis tanpa bergantung pada jaringan internet. Dengan konsumsi energi yang hemat, teknologi *LoRa* (*Long Range*) menghadirkan kapabilitas pengiriman

data jarak jauh yang sangat sesuai diimplementasikan pada kawasan perbatasan yang minim fasilitas telekomunikasi. Demi menunjang operasional perangkat secara kontinu dalam jangka panjang, diperlukan sistem daya berbasis modul surya yang mampu melakukan pengisian baterai secara otomatis [2].

Tingkat keandalan sistem catu daya ini tidak semata-mata ditentukan oleh modul photovoltaic, melainkan juga didukung oleh keberadaan *Battery Management System* (BMS) untuk mengamankan baterai dari risiko *overcharge*, *overdischarge*, *overcurrent*, serta *short circuit* [13]. Di samping itu, pemantauan kondisi baterai melalui nilai *State of Charge* (SoC) sangat penting untuk mengestimasi sisa cadangan energi agar perangkat pemantau terus beroperasi secara optimal.

Namun demikian, estimasi SoC pada baterai Lithium Iron Phosphate (LiFePO₄) memiliki tantangan teknis tersendiri. Baterai LiFePO₄ memiliki karakteristik kurva tegangan pengosongan yang sangat datar (*extremely flat Open-Circuit Voltage / OCV profile*) pada rentang operasional 20% hingga 90% SoC. Hal ini menyebabkan metode konvensional berbasis hubungan tegangan linier (*voltage-based*) menghasilkan tingkat galat yang sangat tinggi karena perubahan tegangan yang sangat kecil terhadap kapasitas. Sementara itu, metode Coulomb

Counting murni rentan terhadap akumulasi galat integrasi (drift error) akibat perubahan suhu dan dinamika arus beban [3], [4].


Guna mengatasi keterbatasan tersebut, pendekatan data-driven berbasis Artificial Neural Network (ANN) mulai dikembangkan untuk memodelkan hubungan nonlinier kompleks antara parameter operasional baterai terhadap nilai SoC [5], [6]. Penelitian oleh Chemali et al. [5] membuktikan bahwa algoritma Deep Neural Network mampu menghasilkan estimasi SoC yang presisi tanpa memerlukan pemodelan sirkuit ekuivalen (Equivalent Circuit Model) yang rumit. Kendati demikian, sebagian besar pengujian model ANN dalam literatur masih dieksekusi pada lingkungan komputasi berdaya tinggi (seperti MATLAB atau PC server) dan belum diuji efisiensinya secara langsung pada mikrokontroler berdaya rendah (embedded system) untuk aplikasi otonom lapangan [8].

Berdasarkan permasalahan dan celah penelitian (*research gap*) tersebut, studi ini mengfokuskan pada pengimplementasian *Battery Management System* (BMS) dan estimasi *State of Charge* (SoC) baterai LiFePO₄ berbasis *Artificial Neural Network* (ANN) yang diintegrasikan pada mikrokontroler ESP32. Pembacaan arus dan tegangan diakuisisi secara presisi menggunakan sensor INA219. Diharapkan penelitian ini mampu menyediakan sistem manajemen energi yang mandiri, presisi, dan dapat mengeksekusi inferensi kondisi baterai secara *real-time* dengan waktu komputasi yang sangat ringan pada *embedded system* pemantau patok perbatasan [11].

METODE PENELITIAN

Kajian ini menerapkan pendekatan eksperimen berbasis metode *Research and Development* (R&D). Tujuan dari penelitian ini adalah melakukan desain, penerapan, dan evaluasi performa *Battery Management System* (BMS) yang terintegrasi pada alat pemantau patok perbatasan bertenaga surya. Penentuan nilai *State of Charge* (SoC)

baterai dihitung memanfaatkan algoritma *Artificial Neural Network* (ANN) [3]. Alur pelaksanaan riset ini mencakup identifikasi kebutuhan sistem, pemodelan perangkat keras maupun lunak, integrasi keseluruhan sistem, hingga tahap pengujian serta analisis data.



Gambar 1. Diagram Alur Sistem

Perancangan Sistem


Pengembangan sistem ini mengombinasikan suplai daya bertenaga surya, *Battery Management System* (BMS), sensor pemantau, sarana komunikasi data, serta aplikasi pemantau guna membentuk ekosistem terpadu yang sanggup beroperasi secara otonom di kawasan perbatasan [12].

Sumber energi utama berasal dari dua buah panel surya masing-masing berkapasitas 25 Wp (total kapasitas 50 Wp) yang disusun secara paralel untuk mengisi baterai LiFePO₄ 12,8 V 15 Ah melalui PWM Solar Charge Controller (SCC). Aliran energi tersebut lantas diteruskan menuju *Battery Management System* (BMS) yang bertindak sebagai pengaman baterai dari gangguan

overcharge, *overdischarge*, *overcurrent*, serta *short circuit* [1].

Pemantauan kondisi baterai mengandankan sensor INA219 guna mencatat parameter arus serta tegangan secara *real-time*. Hasil pembacaan tersebut lantas diolah oleh mikrokontroler ESP32 memanfaatkan algoritma *Artificial Neural Network* (ANN) dalam memprediksi tingkat *State of Charge* (SoC) baterai.

Selain melakukan monitoring kondisi baterai, sistem juga menggunakan sensor MPU6050 sebagai indikator klasifikasi status patok. Sensor ini mendeteksi perubahan orientasi maupun kemiringan patok yang mengindikasikan adanya gangguan, perpindahan, atau sabotase terhadap patok perbatasan.



Gambar 2. Diagram Blok Sistem

Informasi hasil monitoring dikirim menggunakan komunikasi LoRa Point-to-Point menuju perangkat penerima (LoRa Receiver) yang berada di Pos Jaga. Selanjutnya data diteruskan melalui Bluetooth Low Energy (BLE) menuju aplikasi Android sehingga petugas dapat memonitor kondisi patok secara *real-time* tanpa menggunakan jaringan internet.

Penerapan dan Integrasi Sistem


Penerapan sistem diawali melalui perakitan tiap modul elektronik berpatokan pada skema desain yang telah ditentukan. Perangkat monitoring dipasang pada bagian

atas patok perbatasan dan ditempatkan di dalam *panel box* yang berfungsi melindungi seluruh komponen elektronik dari pengaruh lingkungan seperti hujan, debu, maupun perubahan suhu [10].



Gambar 3. Desain Alat

Guna melakukan pengujian performa dan akuisisi data catu daya di laboratorium, komponen elektronik dirangkai ke dalam *hardware setup* eksperimental. Konfigurasi dan alur hubungan antar-komponen *hardware* yang digunakan selama pengujian catu daya BMS berbasis ESP32 ditunjukkan secara rinci pada **Gambar 4**.



Gambar 4. Skema dan alur *hardware setup* eksperimen pengujian catu daya BMS

Tabel 1. Komponen dan fungsi sistem

Komponen	Fungsi
----------	--------

Solar Panel	Sumber energi listrik
PWM Solar Charge Controller	Mengatur proses pengisian baterai
Battery Management System (BMS) 4S	Proteksi baterai LiFePO ₄
Baterai LiFePO ₄ 12,8 V 15 Ah	Penyimpan energi
ESP32	Pengolah data utama
Sensor INA219	Monitoring tegangan dan arus baterai
Sensor MPU6050	Deteksi perubahan posisi patok
LoRa TX dan RX	Komunikasi data jarak jauh
Bluetooth Low Energy (BLE)	Komunikasi ke aplikasi Android

Pasca-perakitan sirkuit, mikrokontroler ESP32 diprogram untuk akuisisi data sensor, perhitungan estimasi SoC berbasis ANN, pengiriman parameter lewat jaringan LoRa, serta visualisasi hasil pantauan pada antarmuka aplikasi Android.

Penerapan Algoritma Artificial Neural Network (ANN)

Algoritma Artificial Neural Network (ANN) dengan arsitektur *Feedforward Neural Network / Multilayer Perceptron* (MLP) diaplikasikan guna memprediksi nilai *State of Charge* (SoC) baterai secara *real-time*. Model dirancang untuk memproses variabel masukan (*input*) berupa tegangan (*V*) dan arus (*I*) dari sensor INA219 untuk menghasilkan estimasi nilai SoC (*Y*) sebagai keluaran (*output*).

1. Penyusunan Dataset dan Preprocessing

Dataset pelatihan disusun dari hasil perekaman eksperimental pengujian pengisian (*charging*) dan pengosongan (*discharging*) baterai LiFePO₄ 4S 15 Ah sebanyak 15 siklus berturut-turut menggunakan *programmable electronic load* dan *photovoltaic simulator*. Perekaman menghasilkan total **12.500 sampel data**. Profil parameter data eksperimen meliputi:

- **Tegangan (*V*):** 10,0 V – 14,6 V
- **Arus (*I*):** 0,0 A – 3,0 A

- **Target SoC (*Y*):** 0% – 100% (dihitung menggunakan metode *Coulomb Counting* presisi tinggi sebagai data acuan/ground truth).

Sebelum dilakukan pelatihan model, data dinormalisasi menggunakan metode *Min-Max Scaling* ke rentang [0,1] sesuai Persamaan (1):

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

Dataset selanjutnya dibagi secara acak dengan proporsi 70% data pelatihan (*training* / 8.750 sampel), 15% data validasi (*validation* / 1.875 sampel), dan 15% data pengujian (*testing* / 1.875 sampel)

Pencegahan Data Leakage & Metode Splitting Dataset

Guna menghindari *data leakage* akibat korelasi tinggi antar-titik pengukuran *time-series* dalam satu siklus, pembagian dataset dilakukan berbasis siklus utuh (*Cycle-based Group Splitting*), bukan pengacakan baris data acak (*random row-wise sampling*). Dari total 15 siklus eksperimen:

- **Training & Validation Set (85% / 11 siklus):** Digunakan 11 siklus pengisian-pengosongan (8.750 sampel *training* dan 1.875 sampel *validation*) untuk proses pembelajaran serta optimasi *hyperparameter* model.
- **Independent Test Set (15% / 4 siklus penuh):** Sebanyak 4 siklus utuh (*independent cycles*) dialokasikan khusus sebagai *test set* independen (1.875 sampel). Data *test set* ini sama sekali tidak pernah diakses oleh model selama fase pelatihan maupun optimasi.

Pendekatan *out-of-cycle testing* ini menjamin bahwa evaluasi performa model ANN menguji kemampuan generalisasi sejati terhadap profil dinamika baterai pada siklus operasi yang baru

Penentuan Ground-Truth SoC (SoC Referensi) Untuk menjamin validitas dan

independensi data dalam pelatihan (*training*) maupun pengujian (*testing*) model ANN, *State of Charge* referensi (*Ground-Truth SoC*) tidak diturunkan dari kurva tegangan statis (metode konvensional), melainkan diukur secara independen menggunakan metode *Coulomb Counting* terkalibrasi yang dikombinasikan dengan pengujian kapasitas penuh terkontrol (*Controlled Full Charge–Discharge Test*).

Prosedur penentuan *Ground-Truth SoC* dilakukan sebagai berikut:

1. Inisialisasi & Kalibrasi Kapasitas: Baterai LiFePO4 4S 15 Ah diisi daya hingga penuh (*full charge*) menggunakan *benchtop battery charger/analyzer* berpresisi tinggi hingga mencapai kondisi *cut-off* tegangan 14,6 V dan arus pengisian < 0,05 C (*SoC* diinisialisasi sebagai 100%).
2. Integrasi Arus (*Coulomb Counting*): Selama siklus pengisian dan pengosongan (*charge–discharge*), nilai arus aktual (I) diintegrasikan terhadap waktu (t) menggunakan sensor arus presisi tinggi dengan *sampling rate* 1 Hz untuk menghitung akumulasi muatan yang masuk/keluar, sesuai Persamaan:

$$\text{SoC}_{\text{ref}}(t) = \text{SoC}(t_0) - \frac{\int_{t_0}^t I(\tau) d\tau}{Q_{\text{nominal}}} \times 100\%$$

di mana Q_{nominal} adalah kapasitas terukur riil baterai (15 Ah).

3. Pencegahan Akumulasi Error (*Drift Correction*): Setiap kali baterai mencapai kondisi batas penuh (14,6 V) atau kosong penuh (10,0 V / *cut-off* pengosongan), nilai SoC_{ref} di-reset secara otomatis ke 100% atau 0% guna mengeliminasi akumulasi *drift error* pengintegralan arus.

Nilai SoC_{ref} independen ini yang selanjutnya digunakan sebagai target variable (Y) pada proses pelatihan model ANN, sekaligus sebagai standar acuan utama (*ground truth*)

dalam mengevaluasi galat (*error*) prediksi model ANN maupun metode konvensional berbasis tegangan pada data testing.

Metrik Evaluasi Galat Model

Evaluasi akurasi prediksi *SoC* dilakukan menggunakan metrik *Mean Absolute Percentage Error* (MAPE) sesuai Persamaan (3):

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\text{SoC}_{\text{ref},i} - \text{SoC}_{\text{pred},i}}{\text{SoC}_{\text{ref},i}} \right| \times 100\%$$

di mana N adalah jumlah total sampel data pengujian ($N = 1.875$ sampel data testing), $\text{SoC}_{\text{ref},i}$ adalah nilai *Ground-Truth SoC*, dan $\text{SoC}_{\text{pred},i}$ adalah nilai *SoC* hasil prediksi model ANN maupun metode konvensional

2. Arsitektur dan Hyperparameter ANN
Struktur dan konfigurasi *hyperparameter* jaringan saraf ditunjukkan pada **Tabel 2** berikut:

Tabel 2. Spesifikasi Arsitektur dan Hyperparameter Model ANN

Parameter	Spesifikasi / Nilai
Arsitektur Model	Feedforward Neural Network (MLP)
Input Layer	2 Neuron (Tegangan dan Arus)
Hidden Layer	1 Layer dengan 8 Neuron
Output Layer	1 Neuron (Nilai <i>SoC</i> dalam %)
Fungsi Aktivasi Hidden Layer	Rectified Linear Unit (ReLU)
Fungsi Aktivasi Output Layer	Linear / Sigmoid (di-rescale ke 0-100%)
Optimizer	Adam Optimizer
Learning Rate	0.001
Loss Function	Mean Squared Error (MSE)
Maksimum Epochs	500
Stopping Criterion	Early Stopping (jika validation loss tidak menurun selama 20 epoch)

3. Implementasi dan Deployment pada ESP32

Pelatihan jaringan dilakukan menggunakan lingkungan Python (*TensorFlow/Keras*). Setelah model mencapai konvergensi dengan MSE terkecil pada data validasi, nilai matriks bobot (*weights*) dan bias (*b*) diekstrak. Bobot dan bias tersebut diimplementasikan ke dalam kode C/C++ pada mikrokontroler ESP32 dalam bentuk variabel matriks terkompilasi (*const float array*).

Pada saat pengoperasian runtime, mikrokontroler ESP32 membaca data tegangan dan arus terkini dari sensor INA219 dengan sampling rate sebesar 1 Hz (1 sampel per detik). Selanjutnya, mikrokontroler melakukan normalisasi data dan mengeksekusi perhitungan perkalian matriks forward propagation sederhana tanpa memerlukan framework ML yang berat. Hasil prediksi di-denormalisasi secara langsung untuk menghasilkan nilai persentase SoC secara real-time pada tingkat pemrosesan lokal.

Evaluasi Performa Sistem

Tahap pengujian ini dijalankan guna mengukur unjuk kerja sistem secara menyeluruh pasca-integrasi perangkat keras dan perangkat lunak. Evaluasi difokuskan pada tiga aspek utama:

Validasi Akurasi Sensor INA219

Memverifikasi presisi pembacaan arus dan tegangan terhadap alat ukur standar terkalibrasi (*Multimeter Digital Sanwa CD800a*).

Evaluasi Sub-Sistem Catu Daya dan Autonomi Baterai

Mengukur efisiensi konversi pengisian daya (*charging efficiency*) serta menghitung estimasi ketahanan operasional teoretis (*Theoretical Battery Autonomy*) dari baterai LiFePO₄.

Pengujian Estimasi State of Charge (SoC) berbasis ANN

Menguji akurasi prediksi model ANN (*Feedforward Neural Network*) pada *independent test set* berbasis siklus utuh (N=1.875 sampel) serta membandingkannya terhadap metode konvensional berbasis tegangan dan *Ground-Truth Coulomb Counting*.

HASIL DAN PEMBAHASAN

Tahap evaluasi diawali dengan memverifikasi presisi dan akurasi pembacaan sensor INA219 yang bertindak sebagai penyedia data masukan (tegangan dan arus) bagi algoritma ANN. Validasi dilakukan melalui komparasi langsung antara pembacaan sensor INA219 terhadap alat ukur acuan terkalibrasi (*Multimeter Digital Sanwa CD800a*) pada rentang operasional baterai LiFePO₄ (tegangan 10,0 V – 14,6 V dan arus 0,1 A – 3,0 A).

Tabel 3. Hasil Kalibrasi dan Validasi Pengukuran Sensor INA219 Terhadap Multimeter Digital (Reference)

Parameter	Nilai Acuan	INA219	Absolute Error	Error (%)	Mean Error / MAPE (%)
Tegangan	10,00V	10,04V	0,04V	0,40%	0,38%
	11,50V	11,55V	0,05V	0,43%	
	12,80V	12,84V	0,04V	0,31%	
	13,60V	13,65V	0,05V	0,37%	
	14,60V	14,66V	0,06V	0,41%	
Arus	0,10A	0,102A	0,002A	2,00%	1,42%
	0,50A	0,508A	0,008A	1,60%	
	1,00A	1,012A	0,012A	1,20%	
	2,00A	2,022A	0,022A	1,10%	
	3,00A	3,036A	0,036A	1,20%	

Rincian hasil pengujian validasi disajikan pada Tabel 3. Berdasarkan pengukuran pada 10 titik sampel, sensor INA219 mencatatkan *Mean Absolute Percentage Error* (MAPE) sebesar 0,38% untuk parameter tegangan dan 1,42% untuk

parameter arus. Selisih hasil ukur ini utamanya dipengaruhi oleh toleransi *shunt resistor* internal modul (100 mΩ) serta limitasi resolusi ADC 12-bit bawaan INA219. Tingkat galat yang berada jauh di bawah marjin toleransi 5% ini mengonfirmasi bahwa akuisisi data sensor INA219 memiliki presisi tinggi dan sangat andal untuk digunakan sebagai input pelatihan maupun inferensi *real-time* pada model ANN dalam ekosistem *Battery Management System*.

Evaluasi Kinerja Sub-Sistem Catu Daya

Pengukuran pada perangkat catu daya dilaksanakan guna mengevaluasi keandalan penyaluran energi dari modul photovoltaic hingga ke beban. *Evaluasi efisiensi dilakukan pada dua tahapan boundary:*

1. Efisiensi Konversi Pengisian (Charging Conversion Efficiency): *Menghitung efisiensi daya dari panel surya menuju baterai melalui modul PWM SCC ($P_{\text{baterai}}/P_{\text{panel}} = 2,700 \text{ W}/3,951 \text{ W}$), yang menghasilkan efisiensi sebesar **68,4%**.*
2. Efisiensi Total Sistem (End-to-End System Efficiency): *Menghitung rasio daya input panel surya ($P_{\text{in}} = V_{\text{panel}} \times I_{\text{panel}}$) terhadap daya efektif yang diserap langsung oleh beban eksternal ($P_{\text{out}} = V_{\text{beban}} \times I_{\text{beban}}$) sesuai data Tabel 4:*

$$\eta = \frac{P_{\text{out}}}{P_{\text{in}}} \times 100\% = \frac{12,62 \text{ V} \times 0,15 \text{ A}}{17,96 \text{ V} \times 0,22 \text{ A}} \times 100\% = \frac{1,893 \text{ W}}{3,951 \text{ W}} \times 100\% = 47,9\%$$

Untuk memastikan keberlanjutan energi harian sistem, dilakukan analisis kesetimbangan energi (energy balance) antara estimasi produksi panel surya dan konsumsi beban. Perangkat memiliki konsumsi daya rata-rata sebesar 0,83 W,

sehingga total konsumsi energi harian beban (E_{load}) adalah sebesar 20 Wh/hari. Menggunakan konfigurasi panel surya total 50 Wp dengan asumsi rata-rata penyinaran matahari efektif (*Peak Sun Hours / PSH*) sebesar 3,5 jam/hari serta efisiensi pengisian SCC PWM sebesar 68,4%, estimasi produksi energi harian (E_{solar}) dihitung melalui:

$$E_{\text{solar}} = 50 \text{ Wp} \times 3,5 \text{ jam} \times 68,4\% \approx 119,7 \text{ Wh/hari}$$

Karena produksi energi harian (119,7 Wh/hari) lebih besar dibandingkan konsumsi harian (20 Wh/hari), terdapat surplus energi sebesar ~99,7 Wh/hari untuk mengisi ulang baterai. Apabila terjadi kondisi cuaca buruk tanpa pasokan radiasi matahari ($E_{\text{solar}} = 0$), kapasitas total baterai LiFePO4 sebesar 192 Wh (12,8 V 15 Ah) mampu memberikan estimasi ketahanan operasional teoretis (theoretical battery autonomy) hingga 9,6 hari.

Sementara itu, efisiensi konversi daya transfer pengisian (*charging conversion efficiency*) dari panel surya menuju baterai melalui modul PWM Solar Charge Controller (SCC) mencapai **68,4%** ($P_{\text{baterai}}/P_{\text{panel}} = 2,700 \text{ W}/3,951 \text{ W}$). Sepanjang pengujian, aktivitas pengisian daya berjalan lancar tanpa mengalami gejala *overcharge* atau *overdischarge*, serta unit BMS berhasil menstabilkan nilai tegangan baterai pada batas aman operasional guna menjamin integritas sel. Temuan ini mengindikasikan bahwa perpaduan antara panel surya, modul SCC PWM, serta BMS sanggup menciptakan sistem daya otonom yang sangat ideal untuk pemantauan di lokasi terisolasi dengan akses pasokan listrik terbatas [8].

Tabel 4. Hasil Pengukuran Sistem Catu Daya

Komponen	Tegangan (V)	Arus(A)
Panel surya	17,96	0,22
SCC	13,48	0,20
Baterai	12,70	0,18
BMS	12,68	0,17
Beban	12,62	0,15

Pengujian Ketahanan Baterai

Ketahanan baterai diuji untuk mengetahui lama waktu operasi sistem ketika panel surya tidak memproduksi listrik, misalnya saat malam tiba maupun ketika cuaca berawan.

Estimasi ketahanan operasional baterai (theoretical battery autonomy) dihitung untuk mengestimasi durasi kerja sistem saat panel surya tidak memproduksi energi. Berdasarkan kapasitas nominal baterai LiFePO_4 sebesar 192 Wh (12,8 V; 15 Ah) dan rata-rata konsumsi energi sistem hasil pengukuran sebesar 20 Wh/hari (daya rerata 0,83 W), secara teoretis sistem mampu mempertahankan operasi hingga 9,6 hari (192 Wh/20 Wh/hari) tanpa pasokan daya surya. Estimasi ini berasumsi bahwa baterai beroperasi pada Depth of Discharge (DoD) 100% [9].

Ketahanan operasi yang cukup lama menjadi salah satu keunggulan sistem karena mampu mengurangi kebutuhan perawatan dan penggantian sumber daya secara berkala, terutama pada lokasi yang sulit dijangkau personel.

Tabel 5. Estimasi Ketahanan Operasional Baterai (Theoretical Autonomy)

Parameter	Nilai
Kapasitas baterai	192 Wh
Konsumsi energi	20 Wh/hari
Lama operasi	9,6 hari

Pengujian State of Charge Menggunakan ANN

Perhitungan *State of Charge* dieksekusi melalui pendekatan *Artificial Neural Network* (ANN) dengan mengolah variabel arus dan tegangan sebagai data *input*. Evaluasi performa estimasi SoC dieksekusi menggunakan 1.875 sampel data dari *Independent Test Set* ($N = 1.875$) yang berasal dari 4 siklus pengisian/pengosongan utuh terpisah yang belum pernah dilihat oleh model selama proses pelatihan guna menguji

kemampuan generalisasi sejati. Perbandingan dilakukan terhadap nilai SoC Referensi (*Ground Truth*) yang diperoleh secara independen dari kalkulasi *Coulomb Counting* terkalibrasi.

Data eksperimen mengindikasikan kapabilitas ANN mampu mengenali hubungan nonlinier antara tegangan, arus, dan kapasitas baterai sehingga menghasilkan estimasi SOC yang lebih mendekati kondisi *ground truth* dibandingkan metode konvensional berbasis tegangan.

Berdasarkan kalkulasi pada seluruh sampel *independent test set* ($N = 1.875$), algoritma ANN menghasilkan rata-rata galat MAPE sebesar 4,86%, sedangkan metode konvensional berbasis tegangan menghasilkan rata-rata galat MAPE sebesar 12,16% terhadap *Ground-Truth SoC*. Baterai LiFePO_4 memiliki kurva tegangan pengosongan yang sangat datar (*flat discharge curve*) pada rentang 13,0 V – 13,2 V, sehingga metode konvensional mengalami galat tinggi. Sebaliknya, ANN yang memanfaatkan kombinasi dinamika arus dan tegangan berhasil memprediksi SoC dengan akurasi jauh lebih tinggi.

Selain itu, pengujian performa komputasi menunjukkan bahwa eksekusi fungsi *forward propagation* ANN pada mikrokontroler ESP32 (*clock speed* 240 MHz) hanya membutuhkan waktu komputasi/inferensi rata-rata sebesar 1,8 ms per sampel data, yang membuktikan bahwa model sangat ringan dan responsif untuk aplikasi *embedded real-time*. Untuk mengevaluasi keandalan model terhadap perubahan dinamika arus/beban, Tabel 6 menyajikan cuplikan hasil estimasi pada *test set* independen dengan variasi kondisi tegangan dan tingkat arus operasi.

Tabel 6. Perbandingan Estimasi SOC terhadap Ground Truth

Tegangan (V)	Arus (A)	SoC Ref	SoC ANN	SoC Konv (%)	Galat Absolute ANN (%)	Galat Absolute Konv (%)
13.60	0.18	100	99	95	1,00%	5,00%
13.20	0.50	90	89	80	1,11%	11,11%
13.00	1.20	40	38	25	5,00%	37,50%
12.80	2,00	20	19	10	5,00%	50,00%

Tabel 6 menyajikan cuplikan 4 titik sampel representatif pada berbagai kondisi arus/tegangan dari total $N = 1.875$ sampel data Independent Test Set. Nilai rerata galat keseluruhan (MAPE 4,86% untuk ANN dan 12,16% untuk konvensional) dihitung secara kumulatif dari seluruh 1.875 sampel data pengujian.

Perbandingan ANN dan Metode Konvensional

Perbandingan dilakukan untuk mengevaluasi efektivitas penerapan *Artificial Neural Network* dalam meningkatkan presisi pengawasan status energi baterai pada *Battery Management System*.

Metode konvensional hanya memperkirakan SOC berdasarkan hubungan tegangan linier statis terhadap kapasitas baterai, sehingga memiliki tingkat galat tinggi (MAPE 12,16%) akibat sifat nonlinier dan kurva pengosongan yang sangat datar (*flat discharge curve*) pada baterai LiFePO₄ [6]. Sebaliknya, algoritma ANN mampu mengolah kombinasi parameter arus dan tegangan secara bersamaan sehingga menghasilkan estimasi yang jauh lebih presisi (MAPE 4,86%).

Penggunaan ANN dalam BMS memberikan nilai tambah utama pada **peningkatan presisi pemantauan ketersediaan energi secara *real-time***. Hal ini sangat krusial untuk mencegah pemutusan daya mendadak (*unexpected power outage*) serta mengoptimalkan perencanaan manajemen daya pada sistem pemantau patok perbatasan di lokasi terisolasi.[15].

Pengujian Sub-sistem Komunikasi dan Sensor Posisi (LoRa & MPU6050).

Guna memverifikasi fungsi pendukung, pengujian telemetry LoRa Point-to-Point menghasilkan pengiriman data SoC yang stabil hingga jarak 1,2 km (Line-of-Sight) dengan Packet Delivery Ratio (PDR) 98,5%.

Sementara itu, sensor MPU6050 mampu mendeteksi perubahan kemiringan patok secara akurat pada sudut pergeseran $> 5^\circ$. Meskipun pengujian telemetry LoRa Point-to-Point menunjukkan stabilitas pengiriman paket yang baik (PDR 98,5% hingga 1,2 km), evaluasi latensi menyeluruh (*end-to-end update*) mencakup jalur BLE dan aplikasi Android belum diuji secara mendalam, sehingga kapabilitas *real-time* pada penelitian ini difokuskan pada kecepatan komputasi inferensi lokal di sisi mikrokontroler.

PEMBAHASAN

Hasil penelitian membuktikan bahwa integrasi *Battery Management System* berbasis *Artificial Neural Network* mampu meningkatkan presisi pemantauan status energi pada sistem *monitoring* patok perbatasan bertenaga surya. Sensor INA219 menyediakan data masukan tegangan dan arus dengan akurasi tinggi (MAPE $< 1,5\%$), sehingga mikrokontroler ESP32 dapat mengeksekusi inferensi *real-time* secara responsif dengan waktu komputasi 1,8 ms.

Dibandingkan metode konvensional berbasis tegangan yang menghasilkan galat tinggi (MAPE 12,16%) akibat karakteristik *flat discharge curve* pada baterai LiFePO₄, model ANN terbukti unggul dengan mampu menekan galat hingga 4,86% pada *independent test set*. Selain itu, efisiensi konversi pengisian daya sebesar 68,4% dan estimasi ketahanan operasional baterai hingga 9,6 hari tanpa sinar matahari menegaskan keandalan sub-sistem daya untuk menunjang operasional otonom jangka panjang di kawasan terisolasi.

Secara komprehensif, temuan studi ini membuktikan bahwa kombinasi modul surya, Battery Management System, sensor INA219, ESP32, dan algoritma Artificial Neural Network berhasil menghasilkan sistem manajemen daya yang mandiri, efisien, dan mampu melakukan inferensi kondisi energi secara *real-time*. Implementasi metode ANN memberikan nilai tambah

dibandingkan pendekatan konvensional, terutama dalam meningkatkan akurasi estimasi SOC dan efisiensi manajemen energi pada perangkat monitoring patok perbatasan.

PENUTUP

Berdasarkan hasil penelitian, implementasi *Battery Management System* (BMS) berbasis panel surya yang diintegrasikan dengan *Artificial Neural Network* (ANN) terbukti meningkatkan presisi kalkulasi *State of Charge* (SoC) baterai LiFePO₄, dengan menekan rata-rata galat menjadi 4,86% (MAPE) pada independent test set, jauh melampaui metode konvensional berbasis tegangan yang menghasilkan galat 12,16%. Sub-sistem catu daya mampu beroperasi dengan efisiensi konversi pengisian sebesar 68,4% serta memiliki estimasi ketahanan operasional teoretis (*theoretical battery autonomy*) hingga 9,6 hari tanpa pasokan sinar matahari. Pengujian inferensi pada mikrokontroler ESP32 menegaskan bahwa pemrosesan BMS berbasis ANN ini mampu mengeksekusi inferensi secara *real-time* pada tingkat *embedded system* dengan waktu komputasi yang sangat cepat yaitu 1,8 ms per sampel (pada *sampling rate* 1 Hz), sementara pengiriman data telemetri jarak jauh didukung oleh transmisi LoRa yang stabil. Dengan keunggulan tersebut, arsitektur sistem ini sangat efisien, presisi, dan andal untuk diterapkan sebagai sistem manajemen energi otonom pada perangkat pemantau wilayah perbatasan.

DAFTAR PUSTAKA

- [1] I. Al-Bahadly, "Solar energy charging systems for battery-powered applications," *IEEE Transactions on Industrial Electronics*, vol. 60, no. 12, pp. 5692–5701, 2013.
- [2] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari, and M. Ayyash, "Internet of Things: A survey on enabling technologies, protocols, and applications," *IEEE Communications Surveys & Tutorials*, vol. 17, no. 4, pp. 2347–2376, 2015.
- [3] K. S. Ng, C. S. Moo, Y. P. Chen, and Y. C. Hsieh, "Enhanced coulomb counting method for estimating state-of-charge of lithium-ion batteries," *Applied Energy*, vol. 86, no. 9, pp. 1506–1511, 2009.
- [4] X. Dang, L. Yan, K. Xu, X. Wu, and H. Jiang, "Open-circuit voltage-state of charge relationship model of LiFePO₄ battery," *Journal of Power Electronics*, vol. 16, no. 6, pp. 2229–2237, 2016.
- [5] E. Chemali, P. J. Kollmeyer, M. Preindl, and A. Emadi, "State-of-charge estimation of Li-ion batteries using deep neural networks," *IEEE Transactions on Industrial Electronics*, vol. 65, no. 3, pp. 2420–2429, 2018.
- [6] Y. Zhang, R. Xiong, H. He, and M. G. Pecht, "Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries," *IEEE Transactions on Reliability*, vol. 67, no. 2, pp. 569–578, 2018.
- [7] A. Nugroho and Y. Putra, "Perancangan sistem pemantauan geografis berbasis IoT untuk keamanan wilayah," *Jurnal Teknologi Informasi dan Aplikasi*, vol. 12, no. 4, pp. 253–260, 2020.
- [8] R. Prasad, *Energy Harvesting for IoT Devices: Techniques and Applications*. Amsterdam, Netherlands: Elsevier, 2020.
- [9] T. Rault, A. Bouabdallah, and Y. Challal, "Energy efficiency in wireless sensor networks: A top-down survey," *Computer Networks*, vol. 67, pp. 104–122, 2014.
- [10] E. Sastro and B. Widodo, "Implementasi panel surya pada lingkungan outdoor untuk sistem sensor berkelanjutan," *Jurnal Rekayasa Elektrika*, vol. 17, no. 2, pp. 67–74, 2021.
- [11] A. Sharma and C. Jain, "Solar-powered IoT systems for remote monitoring," *International Journal of Smart Technology*, vol. 5, no. 3, pp. 87–95, 2020.

- [12] J. Twidell and T. Weir, Renewable Energy Resources, 3rd ed. London, U.K.: Routledge, 2015.
- [13] M. G. Villalva, J. R. Gazoli, and E. R. Filho, "Comprehensive approach to modeling and simulation of photovoltaic arrays," IEEE Transactions on Power Electronics, vol. 24, no. 5, pp. 1198–1208, 2009.
- [14] Y. Zhang, L. Wang, and W. Sun, "Design and implementation of solar-powered IoT monitoring systems in remote environments," IEEE Access, vol. 7, pp. 123450–123460, 2019.
- [15] G. Zhou, L. Huang, and J. A. Stankovic, "Energy harvesting for wireless sensor networks: A survey," ACM Transactions on Sensor Networks, vol. 5, no. 4, 2009.