

Rancang Bangun *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk Estimasi *State-of-Charge* (SOC) Baterai

Regina Salsabila⁽¹⁾, Novie Ayub Windarko⁽²⁾, Bambang Sumantri⁽³⁾

Politeknik Elektronika Negeri Surabaya, JL. Raya ITS, Keputih, Kec. Sukolilo, Kota Surabaya, Jawa Timur, Indonesia

Email: ¹salsabilargn18@gmail.com, ²ayub.sch@gmail.com, ³bambang@pens.ac.id

Tersedia Online di

<http://www.jurnal.unublitar.ac.id/index.php/briliant>

Sejarah Artikel

Diterima 17 Desember 2024

Direvisi 27 Desember 2024

Disetujui 31 Desember 2024

Dipublikasikan 26 Februari 2025

Keywords:

Adaptive Neuro-Fuzzy Inference System, Battery Management, Lithium-ion Battery, State-of-Charge Estimation.

Kata Kunci:

Adaptive Neuro-Fuzzy Inference System (ANFIS), Baterai Lithium-ion, Estimasi *State-of-Charge* (SOC), Manajemen Baterai

Corresponding Author:

Name:

Regina Salsabila

Email:

salsabilargn18@gmail.com

Abstract: *The growing demand for energy around the world is driving the development of renewable resources, and batteries are the primary choice for energy storage. To carry out effective energy management, State of Charge (SOC) estimation of Lithium-ion batteries is essential. The development of an Adaptive Neuro-Fuzzy Inference System (ANFIS) model for SOC estimation using LG 18650 HG2 battery dataset is the objective of this research. It is tested with two parameters, namely two inputs consisting of voltage and current; and three inputs consisting of voltage, current, and temperature. The shape of the membership function, number of nodes, and epochs are some of the indicators tested to find the best configuration. The results show that the three-input configuration with generalized-bell membership function (Gbell MF), five nodes, and 100 epochs has the smallest Root Mean Square Error (RMSE), which is 0.0317, compared to the best two-input configuration, which has an RMSE of 0.0527. Since the three-input configuration takes longer to train, further improvements are needed for real-time implementations such as in electric vehicle battery management systems.*

Abstrak: Semakin banyaknya permintaan energi di seluruh dunia mendorong pengembangan sumber daya terbarukan, dan baterai adalah pilihan utama untuk penyimpanan energi. Untuk menjalankan pengelolaan energi yang efektif, estimasi *State of Charge* (SOC) baterai Lithium-ion sangat penting. Pengembangan model *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk estimasi SOC menggunakan dataset baterai LG 18650 HG2 adalah tujuan penelitian ini. Diuji dengan dua parameter yaitu dua input yang terdiri dari tegangan dan arus; dan tiga input yang terdiri dari tegangan, arus, dan temperatur. Bentuk *membership function*, jumlah *node*, dan *epoch* adalah beberapa indikator yang diuji untuk menemukan konfigurasi terbaik. Hasil penelitian menunjukkan bahwa konfigurasi tiga input dengan *membership function generalized-bell* (Gbell MF), lima *node*,

dan *epoch* 100 memiliki *Root Mean Square Error* (RMSE) terkecil, yaitu 0,0317, dibandingkan dengan konfigurasi dua input terbaik, yang memiliki RMSE 0,0527. Karena konfigurasi tiga input memerlukan waktu yang lebih lama untuk dilatih, diperlukan peningkatan lebih lanjut untuk implementasi *real-time* seperti dalam sistem manajemen baterai kendaraan listrik.

PENDAHULUAN

Pertumbuhan teknologi dan kebutuhan energi global terus meningkat seiring dengan bertambahnya populasi dunia, yang menyebabkan permintaan energi listrik melonjak. Saat ini, energi listrik sebagian besar masih bersumber dari energi fosil yang tak terbarukan (Aisyah et

al., 2020). Oleh karena itu, muncul upaya mencari sumber energi terbarukan sebagai alternatif utama. Penyimpanan energi, terutama dalam bentuk baterai, sangat penting untuk memastikan ketersediaan suplai yang stabil dan dapat diandalkan secara berkelanjutan (Aisyah et al., 2020).

Baterai sangat diperlukan dalam penyimpanan energi listrik, khususnya untuk energi terbarukan seperti tenaga surya, angin, dan air, yang produksinya sering kali tergantung pada kondisi lingkungan dan tidak selalu optimal setiap saat (Hariyadi et al., 2021). Untuk keperluan ini, baterai sekunder yang bisa diisi ulang (*rechargeable*) dan jenis *deep cycle* yang mampu melepaskan sebagian besar kapasitasnya sangat diperlukan (Prasetyo et al., 2021).

Baterai Lithium-ion menjadi salah satu pilihan utama dalam penyimpanan energi listrik karena stabilitasnya yang tinggi, kapasitas energi yang besar, bobot yang ringan, dan tidak memiliki efek memori (Kumar et al., 2022). Bahkan, dengan bobot yang sama, baterai Lithium-ion dapat menghasilkan energi dua kali lipat dibandingkan jenis baterai lain, sehingga diproyeksikan akan menggantikan baterai jenis lain dalam kendaraan listrik dan *hybrid* (Yin et al., 2022). Biasanya, kondisi pengisian daya baterai yang aman berkisar antara 20% hingga 95% *State of Charge* (SOC), sehingga kemampuan memantau SOC secara akurat sangatlah penting (Suhariningsih et al., 2024).

SOC adalah indikator utama yang menunjukkan sisa kapasitas energi baterai terhadap kapasitas totalnya, dengan rentang antara 0 hingga 100% (Mawatwal et al., 2020). Estimasi SOC tidaklah sederhana karena dipengaruhi banyak faktor seperti tegangan, arus, temperatur, dan durasi pengisian. Dalam penelitian ini, parameter tegangan, arus, temperatur, serta waktu pengisian digunakan untuk mengestimasi SOC. Pemilihan parameter ini dilakukan karena semuanya mencerminkan kondisi baterai yang relevan (Dzaky et al., 2021).

Beberapa metode tersedia untuk mengukur SOC, di antaranya metode pengukuran tegangan, *coulomb counting*, dan *Open Circuit Voltage* (OCV). Pengukuran tegangan merupakan metode termudah namun memiliki keterbatasan dalam akurasi karena hasilnya bisa terpengaruh oleh perubahan temperatur baterai saat operasi (Qays et al., 2022). Temperatur baterai dapat memengaruhi SOC hingga 10-20% pada awal dan akhir pengisian serta berdampak pada tegangan selama proses *discharging*. Temperatur baterai perlu dijaga untuk mempertahankan efisiensi optimal, karena temperatur ekstrem dapat mengurangi kinerja dan umur baterai (Chaoufi et al., 2022).

Metode *coulomb counting* memperkirakan SOC dengan mengintegrasikan arus selama proses pengisian dan pengosongan baterai (Cui et al., 2020). Metode ini cukup handal namun rentan terhadap perubahan temperatur, memerlukan akurasi sensor yang tinggi, serta estimasi SOC awal yang tepat berdasarkan nilai OCV (Dao et al., 2021). Sementara itu, metode OCV membutuhkan waktu sekitar satu jam untuk mendapatkan tegangan stabil ketika baterai berada dalam kondisi *rest*, yang membuatnya kurang cocok untuk pemantauan SOC secara *real-time* (Mawatwal et al., 2020).

Metode *machine learning* seperti *neural network* dan logika fuzzy bisa menjadi solusi karena mampu memodelkan hubungan nonlinier antara input dan output sehingga dapat menghasilkan estimasi SOC yang lebih akurat (Triawan et al., 2024). Mudah beradaptasi dengan kondisi terbaru melalui pembaruan data pelatihan, serta dapat mengelola ketidakpastian dalam sistem baterai (Cui et al., 2020). Kombinasi keduanya, yang dikenal sebagai *Adaptive Neuro-Fuzzy Inference System* (ANFIS).

ANFIS memiliki keunggulan dalam menyesuaikan estimasi SOC secara *real-time* dan membantu optimasi proses pengisian daya. Namun, metode ini bergantung pada data pelatihan yang representatif dan sensitif terhadap perubahan kondisi, seperti temperatur, sehingga data perlu diperbarui secara berkala. Kompleksitas penerapan ANFIS juga menjadi tantangan, karena memerlukan penyesuaian manual pada parameter seperti arus dan tegangan untuk menjaga akurasi dalam aplikasi praktis (Mawatwal et al., 2020).

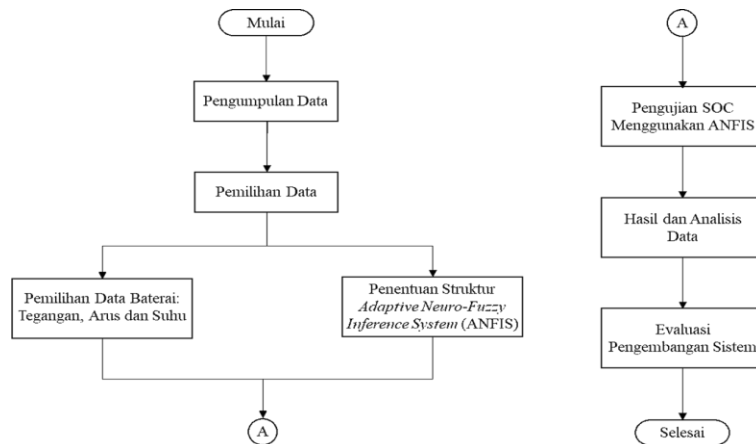
Mengingat berbagai metode estimasi SOC yang memiliki kekurangan, penelitian ini menerapkan metode ANFIS karena memiliki akurasi tinggi dengan perhitungan efisien dan

penerapan yang lebih praktis. ANFIS dapat mengestimasi SOC baik secara offline maupun online setelah melalui proses training, menunjukkan kemampuan adaptif yang tinggi. Selain itu, metode ini tidak bergantung pada model matematis atau rangkaian ekuivalen (Muna et al., 2022), sehingga dapat menyesuaikan hubungan antara variabel input dan output secara dinamis dengan kondisi operasional baterai yang terus berubah.

Penelitian ini memperkenalkan pendekatan baru dalam estimasi SOC baterai Lithium-ion LG 18650 HG2 dengan menggunakan ANFIS. Kebaruan dari penelitian ini terletak pada penggunaan tiga input utama yaitu tegangan, arus, dan temperatur. Dibandingkan penelitian sebelumnya yang cenderung terbatas pada dua input saja. Selain itu, dataset eksperimen dari berbagai kondisi operasi baterai memberikan validitas yang lebih tinggi terhadap hasil model. Dengan demikian, penelitian ini tidak hanya meningkatkan akurasi estimasi SOC, tetapi juga membuka potensi implementasi dalam sistem manajemen baterai (*Battery Management System/BMS*) di dunia nyata.

METODE

Desain sistem dalam penelitian ini mengikuti metodologi yang mencakup langkah – langkah yang diambil dalam penelitian. Mulai dari proses pengumpulan data, analisis data, dan prosedur lain yang relevan dengan penelitian tersebut. Desain sistem dari penelitian ini mengikuti metodologi dalam diagram alir pada Gambar 1.



Gambar 1. Diagram Alir Sistem


Untuk memulai penelitian ini, proses pengumpulan dan pemilihan data digambarkan dalam Gambar 1. Penentuan struktur ANFIS dan pemilihan data baterai adalah dua bagian proses ini. Data yang digunakan dalam penelitian ini berasal dari baterai Lithium-ion yang dikumpulkan selama tahap *load* untuk memastikan representasi data sesuai dengan kondisi operasional sebenarnya. Tahap ini juga bertujuan untuk memastikan bahwa data yang digunakan dalam pelatihan model ANFIS mencakup variasi parameter yang relevan, yang memungkinkan model untuk memberikan estimasi SOC. Baterai LG 18650 HG2 digunakan dalam penelitian ini. Baterai ini memiliki kapasitas nominal 3000 mAh dan dirancang untuk berbagai kondisi pengisian dan pengosongan, seperti *fast charge* dan *fast discharge* (Vidal et al., 2020), seperti yang ditunjukkan dalam Tabel 1 yang merupakan spesifikasi penting yang mendasari analisis lebih lanjut.

Tabel 1. Dataset LG 18650 HG2

Item	Condition	Specification
Capacity	Std. charge / discharge	Nominal 3000 mAh (C_{nom})
Nominal voltage	Average for std. discharge	3.60 V

Standard charge	Constant current	1500 mA
	Constant voltage	4.2 V
	End condition (cut off)	50 mA
Fast charge	Constant current	4000 mA
	Constant voltage	4.2 V
	End condition (cut off)	100 mA
Max. charge voltage	-	4.2 ± 0.05 V
Max. charge current	-	4000 mA
Standard discharge	Constant current	600 mA
	End voltage (cut off)	2.5 V
Fast discharge	Constant current	10000 mA, 20000 mA
	End voltage (cut off)	2.5 V
Max. discharge current	For continuous discharge	20000 mA
Weight	Max	47.0 g
Operating temperature	Charge	0 ~ 50 °C
	Discharge	-20 ~ 75 °C
Storage temperature	1 month	-20 ~ 60 °C
	3 month	-20 ~ 45 °C
	1 year	-20 ~ 20 °C

Dataset ini digunakan untuk penentuan struktur ANFIS yang bertujuan untuk memprediksi SOC berdasarkan parameter seperti tegangan, arus, dan suhu (Kollmeyer et al., 2020). Kemudian menentukan input dan output sebagai langkah dalam merancang arsitektur sistem yang akan diterapkan dalam penelitian ini. Sistem ini memiliki tiga input, yakni tegangan, arus, dan suhu, dengan output yang berupa SOC baterai. Desain sistem tersebut dapat dilihat pada gambar 2.




Gambar 2. Topologi Estimasi SOC Menggunakan ANFIS

Gambar 2 menunjukkan sistem menggunakan tegangan, arus, dan temperatur, yang merupakan input yang menentukan kondisi dan kinerja baterai. SOC adalah output yang berfungsi sebagai indikator utama untuk memantau status baterai. Untuk menangani hubungan non-linear antara input dan output, *membership function* digunakan untuk memproses setiap input.

ANFIS menggabungkan *Artificial Neural Network* (ANN) dan *Fuzzy Inference System* (FIS). Meskipun tidak dapat menyimpan data numerik, logika fuzzy membantu menunjukkan elemen kualitatif dari pengetahuan manusia dan pengambilan keputusan dengan menggunakan basis aturan yang sederhana (Boyle et al., 2020). Sebaliknya, ANN memiliki kemampuan yang terbatas untuk memproses sistem yang diwakili oleh informasi linguistik, tetapi ANN dapat mempelajari dan mengenali pola dan memecahkan masalah dengan akurasi tinggi melalui proses pembelajaran (Kai et al., 2020). Menggabungkan ANN dan FIS memungkinkan metode ANFIS untuk mendapatkan keuntungan dari pengetahuan numerik dan linguistic (Chandrasekhar & Kumar, 2023).

Metode ANFIS merupakan model prediktor yang efisien berdasarkan hasil dengan tingkat kesalahan yang rendah. Selain itu, tingkat akurasi model ANFIS dipengaruhi oleh jumlah dan kualitas sampel data (Chopra et al., 2021). Namun, model ini dapat ditangani dengan data nonlinier dengan tingkat kesalahan



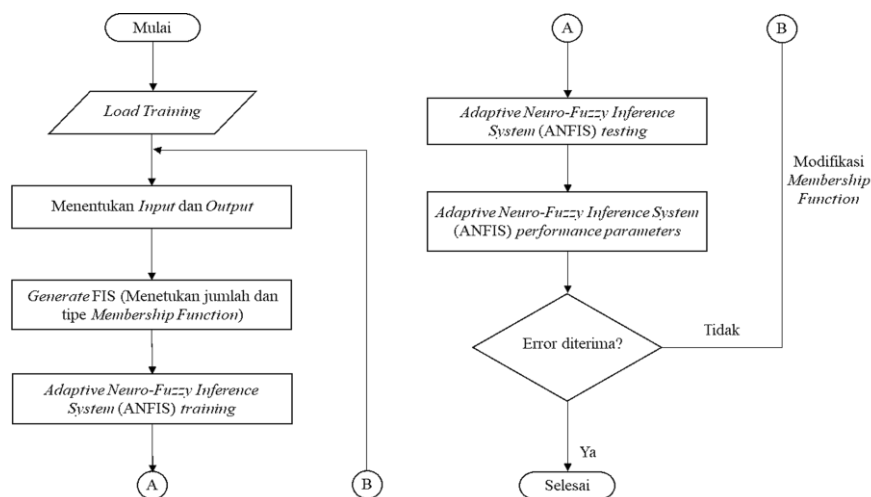
Gambar 3. Arsitektur ANFIS

Struktur ANFIS digambarkan pada gambar 3. Pada gambar 3 terdapat 2 input x, y dan 1 output f . Maka akan ada 4 aturan seperti pada persamaan (1) (Sahoo & Baitalik, 2022).

- Rule 1: *If* x adalah A_1 dan y adalah B_1 , *then* $f_1 = p_1x + q_1y + r_1$
- Rule 2: *If* x adalah A_1 dan y adalah B_2 , *then* $f_2 = p_2x + q_2y + r_2$
- Rule 3: *If* x adalah A_2 dan y adalah B_1 , *then* $f_3 = p_3x + q_3y + r_3$
- Rule 4: *If* x adalah A_2 dan y adalah B_2 , *then* $f_4 = p_4x + q_4y + r_4$ (1)


Di mana x dan y adalah input, dan f adalah output, A_i dan B_i ($i=1,2,3,4$) adalah himpunan fuzzy, p_i, q_i , dan r_i ($i = 1, 2, 3, 4$) adalah parameter desain yang ditentukan selama proses pelatihan. Arsitektur ANFIS mencakup 5 layer yang saling berhubungan, masing-masing layer ini—layer fuzzifikasi, layer membership, layer normalisasi, layer defuzzifikasi, dan layer penjumlahan—melakukan tujuan yang berbeda (Astuti & Mashuri, 2020). Menemukan dan memasukkan sampel data yang berisi variabel input dan output adalah langkah pertama dalam proses ANFIS (Bakar et al., 2022).

Layer 1 adalah lapisan fuzzifikasi yang menyediakan *membership function* (MF) untuk setiap input. Output dari lapisan ini ditentukan oleh derajat keanggotaan yang diberikan oleh input MF. Layer 2 adalah lapisan keanggotaan, yang diwakili oleh π , yang merupakan perkalian dari semua input untuk menghitung *firing strength* untuk setiap rule. Layer 3 adalah lapisan normalisasi, yang menunjukkan bobot *firing strength* input yang telah dinormalisasi oleh neuron yang disimbolkan dengan N diperoleh dengan menghitung rasio *firing strength* dari lapisan sebelumnya dengan jumlah semua *firing strength*. Layer 4 adalah lapisan defuzzifikasi, di mana output setiap node diperoleh dengan mengkalikan output dengan *firing strength* yang dinormalisasi di layer 3. Layer 5 adalah lapisan penjumlahan, dimana semua sinyal yang diterima dijumlahkan sebagai kontribusi total dari setiap aturan (Rachmawardani et al., 2024).




Gambar 4. Diagram Alir ANFIS

Gambar 4 menunjukkan proses ANFIS dimana langkah awal yang perlu dilakukan yaitu memasukkan data *training* pada *tools* ANFIS (Yanaratri et al., 2023) sehingga desain logika fuzzy akan dibentuk seperti yang ditunjukkan pada gambar 5 dan gambar 6, dimana FIS tipe Sugeno digunakan dengan dua parameter yaitu dua input dan tiga input, serta satu output untuk setiap parameter.

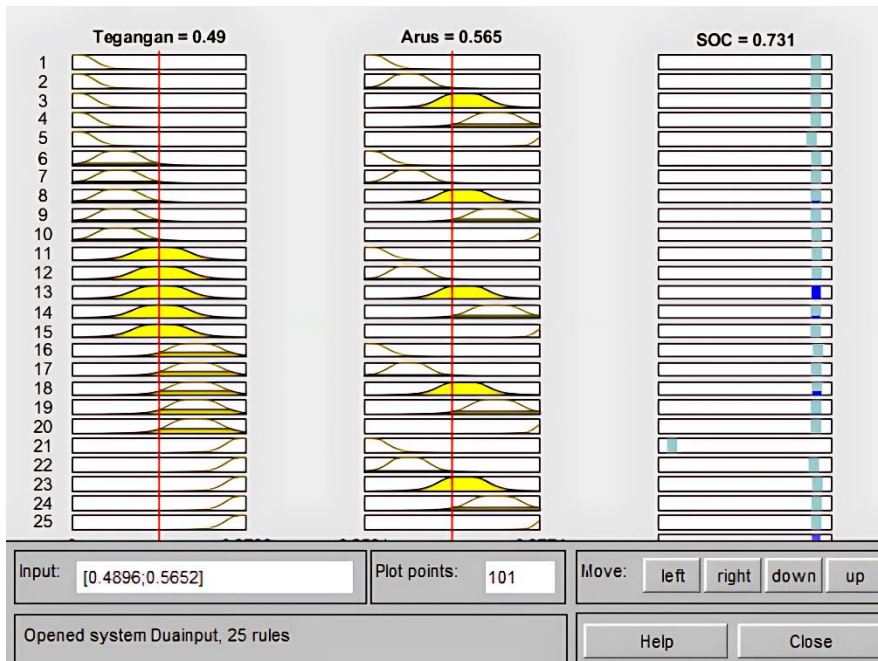


Gambar 5. Desain FIS 2 Input

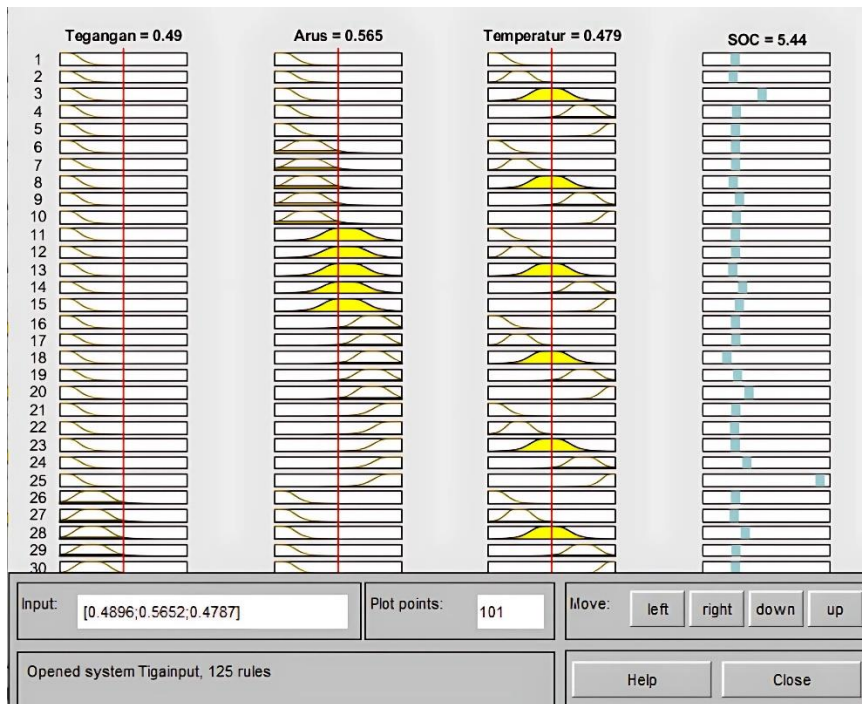


Gambar 6. Desain FIS 3 Input

Pada konfigurasi dua input dan tiga input, *rule view* ditampilkan pada gambar 7, dan gambar 8. 25 *rules* digunakan untuk 2 input dan 125 *rules* digunakan untuk 3 input. Fungsi keanggotaan *generalized-bell* salah satu contoh yang diterapkan pada tegangan, arus, temperatur, dan SOC untuk membentuk logika fuzzy yang akan digunakan dalam proses estimasi.



Gambar 7. Rule View 2 Input



Gambar 8. Rule View 3 Input

HASIL DAN PEMBAHASAN

Pada penelitian ini, pengujian dilakukan dengan parameter yang berbeda. Menggunakan dua input yang terdiri dari tegangan dan arus, kemudian tiga input yang dilakukan dengan menambahkan temperatur. Model ANFIS dirancang untuk estimasi SOC baterai. Desain ini bertujuan untuk mengevaluasi kinerja model dalam memprediksi SOC baterai dengan mempertimbangkan pengaruh parameter temperatur terhadap akurasi estimasi SOC. Dalam perancangan sistem estimasi SOC yang lebih akurat, fluktuasi suhu harus dipertimbangkan karena mempengaruhi kinerja baterai.

Untuk desain model ANFIS menggunakan 756766 data yang diproses menjadi 3 bagian yaitu terdiri dari 669956 data *training*, 47517 data *testing* dan 39293 data validasi. Pembagian ini bertujuan untuk menjaga keseimbangan antara pelatihan dan evaluasi model. Selanjutnya, model ANFIS dibangun menggunakan MATLAB R2023a untuk mengetahui bentuk terbaik berdasarkan jumlah *membership function* dan *epoch* yang digunakan. Dalam penelitian ini, empat macam bentuk *membership function* diuji dengan tiga jumlah *node* yang berbeda untuk menentukan konfigurasi terbaik berdasarkan nilai RMSE terkecil.

1. Pengujian ANFIS dengan 2 Input

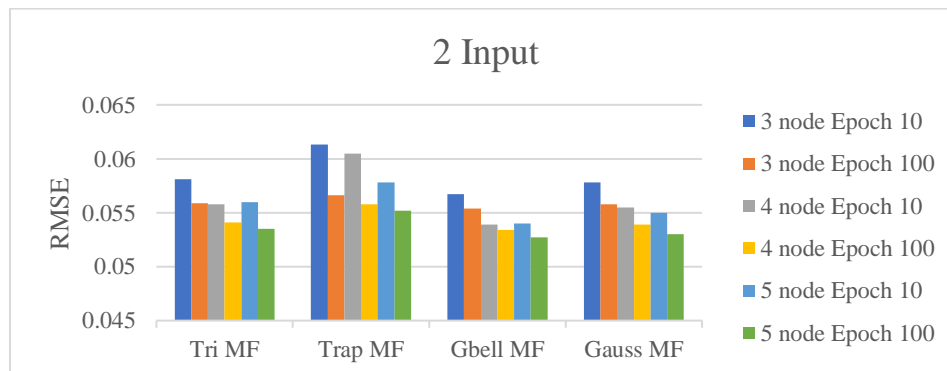
Pada pengujian ini data yang digunakan terdiri dari dua input yaitu tegangan dan arus. Tabel 2 merupakan hasil desain ANFIS dengan konfigurasi ini.

Tabel 2. Hasil Desain ANFIS dengan 2 Input

Node	Epoch	Bentuk Membership Function	RMSE	Time
3	10	Triangle MF	0,0581	50s
		Trapezium MF	0,0613	559s
		Generalized-Bell MF	0,0567	1m 26s
		Gaussian MF	0,0578	50s
	100	Triangle MF	0,0559	8m 38s


		Trapesium MF	0,0566	9m 36s
		Generalized-Bell MF	0,0554	14m 24s
		Gaussian MF	0,0558	9m 14s
4	10	Triangle MF	0,0558	1m 13s
		Trapesium MF	0,0605	1m 21s
		Generalized-Bell MF	0,0539	1m 58s
		Gaussian MF	0,0555	1m 11s
	100	Triangle MF	0,0541	12m 23s
		Trapesium MF	0,0558	14m 17s
		Generalized-Bell MF	0,0534	19m 54s
		Gaussian MF	0,0539	11m 57s
5	10	Triangle MF	0,0560	1m 38s
		Trapesium MF	0,0578	1m 51s
		Generalized-Bell MF	0,0545	2m 37s
		Gaussian MF	0,055	1m 40s
	100	Triangle MF	0,0535	16m 37s
		Trapesium MF	0,0552	18m 32s
		Generalized-Bell MF	0,0527	26m 38s
		Gaussian MF	0,0530	17m 27s

Dari tabel 2 dapat diketahui konfigurasi 5 *node* dengan Gbell MF dan *epoch* 100 memiliki nilai error terkecil yaitu 0,0527. Meskipun konfigurasi ini memiliki tingkat error yang paling kecil, tetapi membutuhkan 26 menit 38 detik untuk melakukan pembelajaran dan pengujian, waktu ini lebih lama dibandingkan dengan konfigurasi lainnya. Gambar 9 dibawah ini menunjukkan hasil *Root Mean Square Error* (RMSE) yang dihasilkan dari setiap kombinasi *membership function*, jumlah *node*, dan *epoch* yang ditampilkan dalam bentuk diagram. Diagram ini menunjukkan perbedaan performa model ANFIS berdasarkan variasi parameter yang diuji.



Gambar 9. Diagram ANFIS dengan 2 Input

Dari gambar 9 dapat dilihat bahwa secara keseluruhan, pengujian ini menunjukkan bahwa Gbell MF memberikan hasil terbaik dibandingkan dengan *membership function* lainnya. Nilai RMSE yang lebih rendah menunjukkan estimasi yang lebih baik untuk memprediksi SOC baterai. Dibandingkan dengan *membership function* lainnya seperti *trapesium* atau *triangle*, Gbell MF ini dapat menangkap pola data yang kompleks dan non-linear. Dengan kinerja yang unggul ini, Gbell MF menjadi pilihan yang lebih baik untuk model ANFIS. Namun, untuk mencapai keseimbangan antara akurasi dan efisiensi waktu komputasi, parameter lain seperti jumlah *node* dan *epoch* harus dioptimalkan. Gambar 10 menunjukkan grafik perbedaan antara dataset dan ANFIS.



Gambar 10. Perbandingan SOC Antara Dataset dan ANFIS

Dari gambar 10 terlihat bahwa secara keseluruhan, kurva prediksi ANFIS mengikuti pola dari dataset dengan cukup baik, meskipun terlihat sedikit perbedaan di beberapa titik. Dengan hanya dua input, model tetap mampu menangkap hubungan non-linear utama dalam dataset. Hal ini menunjukkan bahwa dua input memiliki kontribusi yang cukup signifikan terhadap output.

2. Pengujian ANFIS dengan 3 Input


Pengujian ini untuk mengetahui bentuk *membership function* terbaik yang dapat digunakan untuk mengestimasi SOC pada baterai. Pada tahap ini, peneliti menggunakan dataset dengan tiga input yang terdiri dari tegangan, arus dan temperatur. Tabel 3 merupakan hasil dari desain ANFIS dengan tiga input.

Tabel 3. Hasil Desain ANFIS

<i>Node</i>	<i>Epoch</i>	Bentuk Membership Function	RMSE	Time
3	10	Triangle MF	0,0397	2m 16s
		Trapesium MF	0,0677	2m 27s
		Generalized-Bell MF	0,0381	3m 14s
		Gaussian MF	0,0389	2m 17s
	100	Triangle MF	0,0374	22m 37s
		Trapesium MF	0,0396	26m 40s
		Generalized-Bell MF	0,0345	30m 27s
		Gaussian MF	0,0348	22m 35s
4	10	Triangle MF	0,0363	5m 4s
		Trapesium MF	0,0565	5m 55s
		Generalized-Bell MF	0,0356	6m 33s
		Gaussian MF	0,0359	5m 3s
	100	Triangle MF	0,0341	51m 30s
		Trapesium MF	0,0349	53m 53s
		Generalized-Bell MF	0,0332	1j 5m 30s
		Gaussian MF	0,0333	51m 46s
5	10	Triangle MF	0,0347	12m 3s
		Trapesium MF	0,0449	13m 27s
		Generalized-Bell MF	0,0338	13m 41s
		Gaussian MF	0,0339	12m 20s
	100	Triangle MF	0,0328	2j 24m 7s
		Trapesium MF	0,0347	2j 30m 55s
		Generalized-Bell MF	0,0317	3j 12m 42s
		Gaussian MF	0,0318	2j 47m 43s


Pada tabel 3 menunjukkan tiga hasil proses pembelajaran dan pengujian. Dapat diketahui konfigurasi 5 *node* dengan *membership function generalized-bell* dan *epoch* 100 memiliki nilai error terkecil yaitu 0,0317. Tetapi, proses pelatihan dan pengujian membutuhkan waktu yang

lebih lama dibandingkan dengan konfigurasi lainnya, yaitu 3 jam 12 menit 42 detik. Gambar 11 menunjukkan hasil RMSE yang dihasilkan dari setiap kombinasi *membership function*, jumlah *node*, dan *epoch* yang ditampilkan dalam bentuk diagram.



Gambar 11. Diagram ANFIS dengan 3 Input

Dari gambar 11 dapat dilihat bahwa pengujian dengan tiga input ini menunjukkan Gbell MF memberikan hasil terbaik dibandingkan dengan *membership function* lainnya. Nilai RMSE yang lebih rendah menunjukkan estimasi yang lebih baik untuk memprediksi SOC baterai. Tidak berbeda dengan dua input, pada tiga input ini Gbell MF dapat menangkap pola data yang kompleks dan non-linear. Serta menjadi pilihan yang lebih baik untuk model ANFIS. Namun parameter lainnya harus dioptimalkan, seperti jumlah *node* dan *epoch* untuk mencapai keseimbangan antara akurasi dan efisiensi waktu komputasi. Gambar 12 menunjukkan grafik perbedaan antara dataset dan ANFIS.



Gambar 12. Perbandingan SOC Antara Dataset dan ANFIS

Pada gambar 12 terlihat kurva biru merepresentasikan dataset, sementara kurva merah adalah hasil prediksi dari ANFIS. Prediksi ANFIS pada tiga input terlihat lebih baik dibandingkan dua input. Prediksi ANFIS mengikuti dataset dengan baik disebagian besar area. Hal ini menunjukkan bahwa model ANFIS dengan tiga input mampu mempelajari pola pada dataset. Ada beberapa bagian kecil di mana prediksi terlihat sedikit meleset, meskipun tidak signifikan. Error pada beberapa area tersebut dapat terjadi karena model ANFIS lebih bergantung pada interpolasi dari *membership function* yang telah dibangun.

Hasil pengujian dari dua parameter tersebut menunjukkan bahwa sistem ANFIS yang dikembangkan bekerja dengan baik dalam mengestimasi *State of Charge* (SOC) pada baterai Lithium-ion LG 18650 HG2. Dengan menggunakan tiga input menghasilkan estimasi yang lebih akurat dibandingkan dengan dua input, seperti yang ditunjukkan oleh nilai RMSE yang lebih

rendah. Tabel 4 dibawah ini menunjukkan perbedaan dalam hal error terbaik (RMSE), waktu pelatihan, serta jenis *membership function* yang digunakan.

Tabel 4. Perbedaan Desain ANFIS 2 Input dan 3 Input

Parameter	2 Input	3 Input
Input	Tegangan dan arus	Tegangan, arus dan temperatur
RMSE	0,0527	0,0317
Waktu Pelatihan	26 menit 38 detik	3 jam 12 menit 42 detik
Membership Function Terbaik	Generalized-bell MF	Generalized-bell MF

Dari tabel 4 menunjukkan bagaimana penambahan input, seperti temperatur mempengaruhi waktu pelatihan yang diperlukan dan estimasi SOC yang tepat. Perbandingan ini sangat penting untuk menentukan konfigurasi yang paling sesuai dengan kebutuhan aplikasi untuk akurasi dan waktu pelatihan yang efisien.

Membership function generalized-bell (Gbell MF) konsisten memberikan hasil terbaik dalam berbagai konfigurasi. Di sisi lain, ada beberapa kekurangan yang perlu diperhatikan di balik keunggulan ini, terutama jika digunakan pada aplikasi nyata seperti kendaraan listrik.

Kompleksitas komputasi merupakan masalah utama. Konfigurasi yang paling akurat, yang menggunakan lima *node* dan *epoch* 100, membutuhkan banyak pelatihan, terutama jika jumlah input meningkat. Untuk kendaraan listrik yang membutuhkan respons cepat, hal ini menjadi tantangan untuk menerapkan *real-time*. Selain itu, dataset yang digunakan mungkin tidak mewakili semua kondisi operasi aktual, seperti fluktuasi temperatur ekstrim atau beban dinamis yang sering terjadi pada kendaraan listrik. Kemampuan untuk generalisasi model dalam situasi nyata dapat dipengaruhi oleh faktor-faktor ini.

Untuk menggabungkan model ANFIS ke dalam sistem manajemen baterai (BMS), ada masalah tambahan. Proses ini membutuhkan lebih banyak sumber daya komputasi, yang dapat menjadi tantangan bagi *hardware* yang memiliki kapasitas terbatas. Selain itu, karena keadaan pengukuran di lapangan tidak selalu ideal, perlu dipertimbangkan apakah model rentan terhadap gangguan atau data pengukuran yang tidak akurat.

SIMPULAN

Dalam penelitian ini, penulis mengajukan penggunaan metode ANFIS untuk melakukan estimasi *State of Charge* (SOC) pada baterai Lithium-ion LG 18650 HG2 melalui simulasi di MATLAB. Model ANFIS dengan tiga input cocok untuk estimasi SOC pada baterai Lithium-ion. Meskipun membutuhkan waktu yang lebih lama untuk dilatih, *membership function generalized-bell* (Gbell MF) melakukan yang terbaik, terutama dengan konfigurasi lima *node* dan *epoch* 100. Ketika temperatur ditambahkan sebagai input, prediksi menjadi lebih akurat yang menunjukkan betapa pentingnya mengambil variabel lingkungan dalam estimasi SOC.

Untuk implementasi yang lebih luas, sebaiknya model dioptimalkan agar dapat mengurangi kompleksitas komputasi tanpa mengurangi akurasi. Untuk memastikan bahwa model berfungsi dengan baik dalam berbagai situasi, termasuk kondisi ekstrim, pengujian lapangan dengan data *real-time* juga penting. Selain itu, keandalan model dalam aplikasi dunia nyata dapat ditingkatkan. Dengan melakukan langkah-langkah ini, model ANFIS dapat digunakan secara efektif dalam berbagai aplikasi industri, terutama yang berkaitan dengan kendaraan listrik. Selain itu, langkah-langkah ini akan membantu mengembangkan teknologi yang lebih efisien dan berkelanjutan.

DAFTAR RUJUKAN

Aisyah, Habibi, M. N., Prasetyo, M. I. D., Windarko, N. A., & Yanaratri, D. S. (2020). Estimasi State of Charge (SOC) Pada Baterai Lithium – Ion Menggunakan Feed-Forward Backpropagation Neural Network Dua Tingkat. *JIT (Jurnal Teknologi Terpadu)*, 8(2),

- 82–91.
- Astuti, D. P. P., & Mashuri. (2020). Penerapan Metode Fuzzy Tsukamoto dan Fuzzy Sugeno Dalam Penentuan Harga Jual Sepeda Motor. *UNNES Journal of Mathematics*, 1(2252), 75–84.
- Bakar, M. A. A., Ghani, A. T. A., Abdullah, M. L., Ismail, N., & Aziz, S. A. (2022). Adaptive Neuro-Fuzzy Inference System (ANFIS) Formulation to Predict Students' Neuroscience Mechanistic: A Concept of an Intelligent Model to Enhance Mathematics Learning Ability. *TEM Journal*, 11(4), 1942–1951. <https://doi.org/10.18421/TEM114-63>
- Boyle, J., Littler, T. B., & Foley, A. (2020). Battery energy storage system state-of-charge management to ensure availability of frequency regulating services from wind farms. *Renewable Energy*, 160, 1119–1135. <https://doi.org/10.1016/j.renene.2020.06.025>
- Chandrasekhar, T., & Kumar, C. S. (2023). Improved Facial Identification Using Adaptive Neuro-Fuzzy Logic Inference System. *Indian Journal Of Science And Technology*, 16(13), 1014–1020. <https://doi.org/10.17485/ijst/v16i13.1833>
- Chaoufi, I., Abdelkhalek, O., & Gasbaoui, B. (2022). State of Charge Estimation of Lithium-ion Batteries Using Adaptive Neuro Fuzzy Inference System. *IAES International Journal of Artificial Intelligence*, 11(2), 473–484. <https://doi.org/10.11591/ijai.v11.i2.pp473-484>
- Chopra, S., Dhiman, G., Sharma, A., Shabaz, M., Shukla, P., & Arora, M. (2021). Taxonomy of Adaptive Neuro-Fuzzy Inference System in Modern Engineering Sciences. *Computational Intelligence and Neuroscience*, 2021. <https://doi.org/10.1155/2021/6455592>
- Cui, S., Yong, X., Kim, S., Hong, S., & Joe, I. (2020). An LSTM-Based Encoder-Decoder Model for State-of-Charge Estimation of Lithium-Ion Batteries. In: *Silhavy, R. (Eds) Intelligent Algorithms in Software Engineering. CSOC 2020. Advances in Intelligent Systems and Computing*, 1224. https://doi.org/10.1007/978-3-030-51965-0_15
- Dao, V. Q., Dinh, M.-C., Kim, C. S., Park, M., Doh, C.-H., Bae, J. H., Lee, M.-K., Liu, J., & Bai, Z. (2021). Design of an Effective State of Charge Estimation Method for a Lithium-Ion Battery Pack Using Extended Kalman Filter and Artificial Neural Network. *Dao2021DesignOA, Energies*, 14, 2634. <https://api.semanticscholar.org/CorpusID:236543644>
- Dzaky, M., Logika, I., Dzaky Ashidqi, M., Anwar, M., Hermanu, C., Ramelan, A., & Adriyanto, F. (2021). Implementasi Logika Fuzzy untuk Pengukuran SoC Baterai Mobil Listrik yang Akurat (Fuzzy Logic Implementation for Accurate Electric Car Battery SoC Measurement). *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 10(3), 257–264.
- Hariyadi, A., Nugroho, A., & Suwarno. (2021). The origin of cycle life degradation of a lead-acid battery under constant voltage charging. *International Journal of Power Electronics and Drive Systems*, 12(2), 986–993. <https://doi.org/10.11591/ijpeds.v12.i2.pp986-993>
- Kai, W., Jun, R., Xiao, F., Duan, C., & Liwei, L. (2020). State of Charge (SOC) Estimation of Lithium-ion Battery Based on Adaptive Square Root Unscented Kalman Filter. *International Journal of Electrochemical Science*, 15(9), 9499–9516. <https://doi.org/10.20964/2020.09.84>
- Kollmeyer, P., Vidal, C., Naguib, M., & Skells, M. (2020). LG 18650HG2 Li-ion Battery Data and Example Deep Neural Network xEV SOC Estimator Script. *Mendeley Data*, 3. <https://doi.org/10.17632/cp3473x7xv.3>
- Kumar, A. S., Aher, P. K., & Patil, S. L. (2022). SOC Estimation using Coulomb Counting and Fuzzy Logic in Lithium Battery. *2022 International Conference on Industry 4.0 Technology (I4Tech)*, 1–5. <https://doi.org/10.1109/I4Tech55392.2022.9952949>
- Mawatwal, M., Mohanty, A., & S, A. G. (2020). State of Charge Estimation for Rechargeable Lithium-ion Battery using ANFIS MATLAB. *International Journal of Engineering Research And*, V9(03), 703–708. <https://doi.org/10.17577/ijertv9is030565>

- Muna, M. F. Z., Purwanto, E., & Wahjono, E. (2022). *Rancang Bangun Neural Network untuk Estimasi State of Charge (SoC) Pada Lead Acid Battery*. April, 31–37.
- Prasetyo, R. B., Nurrohim, A., Gusyairi, A., Mukhid, S., & Nurhuda, M. (2021). Evaluasi Kondisi Baterai Sistem Hybrid. *Power Elektronik : Jurnal Orang Elektro*, 10(2), 53–56.
- 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>
- Rachmawardani, A., Wijaya, S. K., Prawito, P., & Sopaheluwakan, A. (2024). Prediksi Banjir menggunakan ANFIS-PCA sebagai Peringatan Dini Bencana Banjir. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 12(2), 335. <https://doi.org/10.26760/elkomika.v12i2.335>
- Sahoo, A., & Baitalik, S. (2022). Fuzzy Logic, Artificial Neural Network, and Adaptive Neuro-Fuzzy Inference Methodology for Soft Computation and Modeling of Ion Sensing Data of a Terpyridyl-Imidazole Based Bifunctional Receptor. *Frontiers in Chemistry*, 10(March), 1–16. <https://doi.org/10.3389/fchem.2022.864363>
- Suhariningsih, S., Yulianda, F., Sunarno, E., & Nugroho, M. A. B. (2024). Battery Management System dengan Fitur Adaptive Current Protection terhadap Suhu. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 12(2), 498. <https://doi.org/10.26760/elkomika.v12i2.498>
- Triawan, M. A., Yolanda, D., & Humam, F. (2024). Estimating SoC and SoH of Li-ion Battery Using Coulomb Counting Method in IoT Node Application. *2024 2nd International Symposium on Information Technology and Digital Innovation (ISITDI)*, 96–101. <https://api.semanticscholar.org/CorpusID:274895464>
- Vidal, C., Kollmeyer, P., Naguib, M., Malysz, P., Gross, O., & Emadi, A. (2020). Robust xEV Battery State-of-Charge Estimator Design Using a Feedforward Deep Neural Network. *SAE International Journal of Advances and Current Practices in Mobility*.
- Yanaratri, D. S., Amanda, S. D., Rakhmawati, R., & others. (2023). Penerapan Adaptive Neuro-Fuzzy Inference System untuk Estimasi State of Charge Baterai Lead Acid. *Prosiding Seminar Nasional Terapan Riset Inovatif (SENTRINOV)*, 9(1), 120–127.
- Yin, J., Lin, H., Shi, J., Lin, Z., Bao, J., Wang, Y., Lin, X., Qin, Y., Qiu, X., & Zhang, W. (2022). Lead-Carbon Batteries toward Future Energy Storage: From Mechanism and Materials to Applications. In *Electrochemical Energy Reviews* (Vol. 5, Issue 3). Springer Nature Singapore. <https://doi.org/10.1007/s41918-022-00134-w>